

RECENZJA

pracy doktorskiej mgra inż. Jakuba Białka
pt. „Wyjaśnienie predykcji i szacowanie wpływu dryfu danych na jakość modeli Uczenia Maszynowego prognozujących zapotrzebowania na energię na przykładzie modelu prognozującego zapotrzebowanie na ciepło w Warszawskiej Sieci Ciepłowniczej”

1. Informacje ogólne

Praca wykonana została w Instytucie Techniki Ciepłej na Wydziale Mechanicznym Energetyki i Lotnictwa, Politechniki Warszawskiej pod kierunkiem promotora dra hab. inż. Wojciecha Bujalskiego, prof. uczelni oraz promotora pomocniczego dra inż. Konrada Wojdana.

Recenzję opracowano w oparciu o pismo Przewodniczącego Rady Naukowej Dyscypliny Inżynieria Środowiska, Górnictwo i Energetyka Politechniki Warszawskiej, prof. dr. hab. inż. Tomasza Wiśniewskiego z dnia 24 października 2023 w sprawie powołania na recenzenta.

Pracę doktorską przedstawiono na 103 stronach, zawiera ona pięć rozdziałów, które poprzedza Streszczenie w języku polskim i angielskim, Spis treści, kończy natomiast Dodatek A: Wkład osób trzecich oraz Bibliografia. Dysertacja zawiera 52 pozycje rysunków, 2 pozycje tabel oraz wykaz literatury - 46 pozycji.

2. Omówienie treści pracy

W rozdziale 1 zatytułowanym *Wprowadzenie* (6 stron) Doktorant omawia znaczenie prognozowania zapotrzebowania na energię oraz rosnącą popularność systemów prognostycznych opartych na algorytmach Uczenia Maszynowego (UM) w dziedzinie energetyki. Podkreśla, że dokładne prognozy są kluczowe dla podejmowania optymalnych decyzji przez operatorów sieci energetycznych, elektrownie, uczestników rynku energii, aż po ostatecznych odbiorców. Systemy oparte na UM są wykorzystywane

do prognozowania zapotrzebowania na różne rodzaje energii oraz do utrzymania predykcyjnego maszyn i urządzeń energetycznych, a także do optymalizacji reakcji strony popytowej. Jednakże rosnąca złożoność algorytmów UM powoduje trudności w interpretacji ich predykcji. Zwiększa się także zainteresowanie interpretowalnością modeli UM, czyli ich zdolnością do wyjaśniania przyczyn podjętych decyzji. Wyższa interpretowalność ułatwia zrozumienie, dlaczego model dokonał konkretnej predykcji w danych warunkach.

W dalszej części rozdziału Doktorant opisuje problem zrozumienia decyzji podejmowanych przez modele uczenia maszynowego, zwłaszcza tzw. "czarnych skrzynek". Jak stwierdza, w przypadku takich modeli trudno jest ocenić, czy wyuczona przez nie zależność pomiędzy zmiennymi wejściowymi a docelowymi odpowiada rzeczywistym fizycznym zależnościom. Ekstremalnym przykładem danych, które mogą doprowadzić do wyuczenia niewłaściwych zależności jest pokazana na rysunku 1 korelacja pomiędzy liczbą utonięć w basenach a energią wygenerowaną przez elektrownie jądrowe w Stanach Zjednoczonych w latach 2000-2009.

Autor pokazuje w dalszej części dysertacji, że nawet drobne błędy w danych treningowych mogą prowadzić do błędnych predykcji na nowych danych. Doktorant podkreśla potrzebę otwierania tych "czarnych skrzynek", czyli wyjaśniania decyzji podejmowanych przez modele oraz monitorowania ich w warunkach produkcyjnych. Stwierdza także, że brakuje narzędzi do efektywnego monitorowania modeli, co może prowadzić do utrzymania modeli, które stopniowo tracą na jakości. Autor proponuje zbadanie tych problemów na przykładzie istniejącego modelu prognozującego zapotrzebowanie na ciepło.

W rozdziale 1.1 pt. *Teza pracy* sprecyzowano bardzo szczegółowo cel i zakres dysertacji. W podrozdziale 1.3 pt. *Aktualny stan wiedzy i wkład autora* podjęta została dyskusja na temat analizowanych modeli i udziału Doktoranta w rozwijaniu tych modeli.

W pierwszej części rozdziału skupiono się na *Analizie narzędzi XAI dla modeli prognozujących zapotrzebowanie na energię*. Autor opisuje zastosowanie różnych metod wyjaśnialnej sztucznej inteligencji (XAI) do analizy modeli prognozujących zapotrzebowanie na energię, w tym na przykładzie modelu prognozującego zapotrzebowanie na ciepło w Warszawskiej Sieci Ciepłowniczej (WSC). Metody takie jak Permutation Importance (PI), Local Interpretable Model-Agnostic Explanations (LIME), Partial Dependence (PD) i Shapley Additive Explanations (SHAP) są wykorzystywane do zrozumienia istotności zmiennych oraz mechanizmu decyzyjnego

modelu. Autor podkreśla, że choć te metody są już stosunkowo rozwinięte teoretycznie, w praktyce nadal prowadzi się badania nad ich skutecznością i przydatnością. Sugeruje potrzebę dalszych badań w obszarze inteligentnych sieci i odnawialnych źródeł energii oraz weryfikacji tych metod na rzeczywistych danych i modelach. Badania nad zastosowaniem XAI w prognozowaniu zapotrzebowania na energię są istotne dla poprawy jakości predykcji oraz zrozumienia mechanizmu działania modeli w tej dziedzinie.

Dalej opisana jest *Weryfikacja modelu SSN prognozującego zapotrzebowanie w WSC i stworzenie zestawu wskazówek dotyczących analizowania modeli prognozujących zapotrzebowanie na energię*. Jak relacjonuje Doktorant, autorzy artykułu [31] opisują implementację Sztucznej Sieci Neuronowej (SSN) do prognozowania zapotrzebowania na energię elektryczną w norweskiej sieci elektroenergetycznej. W swoim badaniu używają metody SHAP do zbadania wpływu nowej zmiennej informującej, czy dany dzień jest świętem, na wartość predykcji oraz na jakość modelu. Według Doktoranta autorzy podkreślają brak analizy algorytmów sztucznej inteligencji przy użyciu metod XAI w obszarze prognozowania zapotrzebowania na energię, pomimo licznych badań i implementacji tych algorytmów. Główny autor artykułu, opublikował również inną pracę [32], w której użył metody SHAP w bardziej zaawansowany sposób do określenia istotności cech wejściowych, ich selekcji oraz do wyjaśnienia wybranych predykcji. Doktorant podsumowuje wkład autora w rozwój wiedzy związany z celem nr 2 następująco:

- *przedstawienie zaawansowanego sposobu manipulowania wynikami jednej z metod XAI dla pokazywania uśrednionego wpływu poszczególnych zmiennych surowych (np. temperatura zewnętrzna) i grup zmiennych (pogoda) na predykcję w wybranych okresach (tj. zima, lato, okres przejściowy).*
- *analiza wpływu interakcji pomiędzy zmiennymi wejściowymi na interpretację wyjaśnień generowanych przez metodę SHAP dla tych zmiennych.*
- *stworzenie spójnego procesu analizowania modeli zapotrzebowania na energię o strukturze podobnej do modelu [1] – od badań ogólnych, do szczegółowych, wraz z konfrontacją wyników otrzymanych za pomocą wybranej metody XAI z oczekiwaniami wynikającymi z praw fizyki.*

Ciąg dalszy dotyczy *Badania dryfu danych na modelu prognostycznym WSC. Teoretycznej i praktycznej analizy sposobów wykrywania dryfu, określania jego rodzaju, szacowania wielkości dryfu oraz wpływu dryfu na dokładność predykcji modelu.*

Jak opisuje Doktorant, *dryf danych to zmiana w rozkładach prawdopodobieństwa zmiennych wejściowych* w modelach uczenia maszynowego. Testy dla dwóch prób pozwalają na ocenę podobieństwa rozkładów dwóch zmiennych losowych, co jest kluczowe do wykrywania dryfu. Istnieje wiele metod oceny zmiany rozkładów, takich jak testy statystyczne, dywergencje i dystanse statystyczne, jednak każda z nich ma swoje ograniczenia. Wyzwaniem jest określenie wpływu dryfu na jakość predykcji modelu, ponieważ zmiana w rozkładzie zmiennej wejściowej nie zawsze prowadzi do pogorszenia jakości predykcji. Istnieją prace proponujące sposoby korekty predykcji modelu w przypadku dryfu danych, ale brakuje teoretycznego określenia wpływu dryfu na jakość predykcji.

Wkład autora w progres wiedzy w związku z celem nr 3. został podsumowany następująco:

- *teoretyczne określenie absolutnej miary dryfu jednej zmiennej,*
- *wyznaczenie teoretycznego wpływu dryfu danych na rozkład zmiennej celu oraz na jakość predykcji modelu,*
- *zapropozowanie praktycznej metody szacowania wpływu dryfu zmiennych na jakość predykcji modelu (szacowanie błędu) i weryfikacja na modelu [1].*

Rozdział 2 pt. *Opis badanego modelu* przedstawiono na 4 stronach dysertacji. W podrozdziale 2.1 pt. *Powstanie modelu* Doktorant analizuje model, który został opracowany i dedykowany Warszawskiej Sieci Ciepłowniczej (WSC) w ramach Systemu Wspomagania Decyzji (SWD). Projekt SWD był częścią większego przedsięwzięcia realizowanego przez Veolia Energia Warszawa pod nazwą Inteligentna Sieć Ciepłownicza, mającego na celu minimalizację strat ciepła i ubytku wody sieciowej. Dzięki modernizacji aparatury kontrolno-pomiarowej oraz wdrożeniu inteligentnych systemów informatycznych, w tym SWD, osiągnięto zamierzone cele. SWD składa się głównie z modelu prognostycznego i optymalizatora.

Następnie w podrozdziale 2.2 pt. *Architektura modelu* Doktorant przywołuje pracę [1], w której zaprezentowano i zastosowano różnorodne algorytmy do prognozowania, w tym regresję liniową, regresję grzbietową oraz Sztuczne Sieci Neuronowe (SSN) o różnych architekturach. Modele obejmowały także sezonowe warianty, takie jak modele letnie i zimowe oraz modele rozmyte, wykorzystywane w sezonie przejściowym. W przypadku krótkiego horyzontu predykcji (24h) najlepsze wyniki uzyskano dzięki modelowi autoregresyjnemu SSN, natomiast dla dłuższych horyzontów (>24h) lepsze efekty przyniósł model SSN z warstwą skierowaną (feedforward). W niniejszej pracy skupiono

się na analizie tego drugiego modelu SSN, który jest perceptronem wielowarstwowym (MLP) o warstwach wejściowej, ukrytych i wyjściowej. Warstwy ukryte, w pełni połączone, zawierały odpowiednio 400, 450 i 400 neuronów z funkcją aktywacji ReLU, warstwa wyjściowa miała 1 neuron z liniową funkcją aktywacji. Całkowita liczba trenowanych parametrów wynosiła 423 451.

Podrozdział 2.3 pt. *Dane i zmienne wejściowe* opisuje zastosowany model zbudowany na bazie historycznych danych dotyczących konsumpcji ciepła oraz danych meteorologicznych, które są dostępne od czerwca 2015 roku. Dane te zostały wykorzystane do ponownego treningu modelu o określonej architekturze na zaktualizowanych danych, obejmujących okres do marca 2021 roku. Zapotrzebowanie na ciepło dla roku 2019 zostało przedstawione na rysunku 2 w procentach maksymalnego zapotrzebowania zarejestrowanego w badanym okresie, uwzględniając wpływ temperatury zewnętrznej. Model wykorzystuje szereg danych meteorologicznych, w tym temperaturę, prędkość i kierunek wiatru, wilgotność, nasłonecznienie i zachmurzenie, uśrednione dla obszaru całej sieci ciepłowniczej (rysunek 3). Podczas trenowania i ewaluacji modelu wykorzystano rzeczywiste pomiary meteorologiczne tak, aby zminimalizować dodatkowe źródło niepewności. Na podstawie danych meteorologicznych oraz kalendarzowych utworzono 152 cechy wejściowe poprzez różne transformacje, takie jak opóźniona temperatura zewnętrzna czy temperatura odczuwalna (rysunek 4).

Kolejny obszerny rozdział 3 pt. *Wyjaśnianie predykcji modelu prognostycznego* został przedstawiony na 36 stronach. Dokonano tu analizy przydatności narzędzi XAI (Explainable Artificial Intelligence) dla modeli prognozujących zapotrzebowanie na ciepło. Przeprowadzono również weryfikację modelu SSN (Sztuczna Sieć Neuronowa) odpowiedzialnego za prognozowanie tego zapotrzebowania w Warszawskiej Sieci Ciepłowniczej (WSC) za pomocą wybranych narzędzi XAI.

W pierwszej kolejności w podrozdziale 3.1 pt. *Weryfikacja wybranych modeli XAI*, przedstawiono cel analizy modeli Ucznia Maszynowego przy użyciu narzędzi XAI. Narzędzia XAI mają za zadanie przedstawienie relacji między wejściami a predykcją modelu w sposób uproszczony i zrozumiały dla użytkownika. Spośród metod działających niezależnie od analizowanego algorytmu wybrano cztery, które potwierdziły swoją użyteczność w przypadku wielu klas modeli UM: Permutation Importance (PI), Local Interpretable Model-Agnostic Explanations (LIME), Partial Dependence (PD) oraz Shapley Additive exPlanations (SHAP).

Doktorant w rozdziale 3.1.1 pt. *Opis badanych metod* w pierwszej kolejności poddał analizie *Metodę PI* (rozdział 3.1.1.1), czyli metoda Permutation Importance (PI). Służy ona do pomiaru wpływu pojedynczej cechy na błąd predykcji modeli. Polega na predykcji zmodyfikowanego zbioru i porównaniu wydajności modelu z wydajnością na oryginalnych danych. Metoda ta ma zaletę łatwości implementacji, ale jej wadą jest to, że mierzy wpływ zmiennej na błąd modelu, a nie na jego predykcję, co utrudnia interpretację. Dodatkowo nie pozwala na jednoznaczne wyjaśnienie pojedynczych predykcji ani na przeprowadzenie tasowania dla pojedynczych obserwacji. Pomimo swojej klasycznej natury, ze względu na wady, takie jak przedstawianie wpływu zmiennej na błąd modelu zamiast na jego predykcję oraz brak możliwości wyjaśnienia pojedynczych obserwacji, metoda PI nie będzie dalej brana w dysertacji pod uwagę.

Kolejna metoda opisana w podrozdziale 3.1.1.2. *Metoda LIME*, według Autora ma na celu wyjaśnienie pojedynczych obserwacji poprzez następujące kroki: (1) tworzenie sztucznych punktów w przestrzeni cech wejściowych w otoczeniu analizowanej obserwacji, (2) przeprowadzanie predykcji na tych sztucznych obserwacjach za pomocą modelu black-box, (3) przypisanie wagi predykcjom na podstawie odległości zmiennych wejściowych od analizowanej obserwacji, przy czym im bliżej, tym większa waga, (4) trenowanie nowego modelu interpretowalnego, który lokalnie naśladuje model black-box na podstawie sztucznych obserwacji, uwzględniając wagi obliczone w poprzednim kroku. Kolejna metoda to *Metoda PD* (podrozdział 3.1.1.3). Profile PD są obliczane jako średnia z profili Ceteris Paribus. Profil CP służy do wyjaśnienia wpływu pojedynczej zmiennej wejściowej na predykcję modelu poprzez pokazanie zmiany predykcji w zależności od wartości tej zmiennej przy założeniu stałości pozostałych zmiennych. Profil CP dla danej zmiennej będzie różny w zależności od wartości pozostałych, niezmiennych zmiennych wejściowych. Profile PD uśredniają profile CP dla wszystkich obserwacji, co pozwala na ogólny obraz modelu, tj. średni wpływ zmiennej na predykcję uwzględniając wszystkie obserwacje.

Metoda SHAP (podrozdział 3.1.1.4), czyli SHapley Additive exPlanations, generuje wyjaśnienia na podstawie lokalnie dokładnego, uproszczonego modelu, który jest kombinacją liniową zmiennych binarnych. Opis tego modelu jest przedstawiony równaniem 1. Metoda SHAP wykorzystuje koncepcję teorii gier kooperatywnych, gdzie wartości Shapleya są używane do określenia udziału gracza w wyniku danej rozgrywki.

W dalszej części w podrozdziale 3.1.2 (*Wyniki*) Autor skupił się na wyjaśnieniu predykcji modelu prognozującego zapotrzebowanie na ciepło w WSC otrzymane za pomocą metod LIME, PD i SHAP.

Rozdział 3.1.2.1 dotyczy *Metody LIME*, na początku Autor wykorzystując rysunek 5 przedstawia wyjaśnienie uzyskane za pomocą metody LIME dla konkretnej predykcji zapotrzebowania na ciepło na daną godzinę. Wyjaśnienie to zostało wygenerowane przy użyciu biblioteki LIME. Wyniki predykcji modelu są przedstawione w procentach maksymalnego zapotrzebowania na ciepło, wynoszące w tym przypadku 17,36%. Lokalnie dokładny, interpretowalny model stworzony za pomocą metody LIME wskazuje osiem najbardziej istotnych wejść dla tej predykcji, które są związane ze zmiennymi kalendarzowymi - dzień roku, miesiąc i godzina. Jak podkreśla Autor, niestety, metoda LIME może generować wyniki trudne do zinterpretowania, zwłaszcza gdy modele są złożone i posiadają dużą liczbę skorelowanych zmiennych wejściowych. Ponadto dobór odpowiednich wag przypisywanych predykcjom na sztucznych obserwacjach oraz wybór metryki odległości stanowi wyzwanie, co może prowadzić do różnych wyników. Pomimo możliwości wpływu na złożoność wyników, metoda LIME może być kosztowna obliczeniowo, zwłaszcza dla modeli z dużą liczbą zmiennych wejściowych. Ze względu na te ograniczenia, LIME nie powinien być używany do analizy modeli o wysokiej złożoności, takich jak model prognozujący zapotrzebowanie w WSC.

Dalsza analiza przedstawiona w podrozdziale 3.1.2.2 *Metoda PD*, została wyjaśniona na rysunku 6, gdzie zastosowano badaną metodę w celu analizy danych z całego roku 2019. Wykorzystano bibliotekę scikit-learn [38] do uzyskania wyników. Większość profili CP jest stała, co oznacza, że profil PD również nie wykazuje żadnej wyraźnej tendencji. Sugeruje to m.in., że temperatura zewnętrzna nie ma istotnego wpływu na predykcje modelu. Jest to spowodowane tym, że model zawiera wiele innych zmiennych skorelowanych z temperaturą zewnętrzną, takich jak temperatura zewnętrzna w godzinie predykcji, temperatura z poprzednich godzin czy temperatura odczuwalna. Analizując profile CP, zmienia się tylko jedno wejście, w tym przypadku temperatura zewnętrzna w godzinie predykcji. Reakcja modelu jest niewielka, ponieważ nie uwzględniono, że wiele powiązanych parametrów również ulega zmianie. Główną wadę profili CP i profilu PD stanowi zatem pominięcie interakcji pomiędzy zmiennymi, co znacząco utrudnia analizę modelu. Jak podkreśla Doktorant, metoda ALE (Accumulated Local Effects) częściowo rozwiązuje problem korelacji pomiędzy zmiennymi poprzez badanie wpływu zmiany wartości danego wejścia w podzbiorach obserwacji, w których wartości zmiennych

skorelowanych są bardziej realistyczne. Jednakże problem braku reakcji modelu na zmianę tylko jednej z wielu skorelowanych zmiennych pozostaje.

Metoda SHAP (Shapley Additive Explanations) została opisana w rozdziale 3.1.2.3. Na rysunku 7 przedstawiono wyniki uzyskane przy użyciu tej metody dla konkretnej obserwacji z roku 2019 (3 stycznia 2019, godzina 5:00). Dane zostały przetworzone za pomocą biblioteki SHAP, która przypisuje atrybucje zmiennym wejściowym na podstawie równania 2.

Mimo podobieństwa do wyników metody LIME, metoda SHAP wykazuje inne właściwości, które ułatwiają interpretację. Suma atrybucji cech składa się na wartość predykcji, co pozwala na zrozumienie wpływu poszczególnych grup zmiennych na predykcję modelu.

Jak pisze Autor, główną wadą metody SHAP jest złożoność obliczeniowa. Dla dużych modeli i zbiorów danych konieczność wielokrotnego wywoływania modelu dla różnych obserwacji referencyjnych może być praktycznie niemożliwa. Jednak istnieją odmiany metody SHAP dostosowane do różnych algorytmów uczenia maszynowego. Na przykład dla sieci neuronowych istnieje metoda Deep SHAP, która wykorzystuje algorytm Deep LIFT i propagację wsteczną do przypisywania atrybutów zmiennym wejściowym.

W rozdziale 3.1.3 *Wnioski*, Autor przeprowadził weryfikację wybranych narzędzi XAI (Explainable Artificial Intelligence) do analizy modeli prognozujących zapotrzebowanie na energię, podobnych do modelu [1]. Podstawowym wnioskiem jest, że chociaż każda z analizowanych metod teoretycznie nadaje się do analizy dowolnego modelu, w praktyce może to oznaczać, że dla każdego modelu zwróci *jakiś* wyniki.

Dalej w podrozdziale Autor przedstawił zalety i wady analizowanych metod w stosunku do modeli podobnych do modelu zaimplementowanego w WCS.

W rozdziale 3.2 *Analiza modelu za pomocą metody SHAP* Autor omawia znaczenie predykcji modelu, co umożliwia zrozumienie przyczyn generowania danej wartości predykcji przez model przy określonym zestawie wejść. Wskazuje, że analiza kilku pojedynczych predykcji za pomocą pojedynczego wykresu czy zestawu liczb nie wystarcza, podobnie jak analiza wszystkich predykcji, co byłoby zadaniem nieefektywnym ze względu na złożoność modelu.

Dalej Doktorant omawia dwa podejścia do analizy modelu: wstępujące (analiza pojedynczych predykcji) i zstępujące (analiza zbiorów obserwacji obejmujących pełny cykl pracy modelu, a następnie wybrane predykcje). Zdaniem Autora podejście zstępujące jest bardziej efektywne, ponieważ pozwala na zbudowanie ogólnego obrazu

modelu na podstawie reprezentatywnych zbiorów obserwacji, co ułatwia analizę pojedynczych predykcji.

Analiza modeli stosująca podejście zstępujące pozwala Doktorantowi na uporządkowane tworzenie w pewnym sensie *intuicji* co do sposobu działania modelu i weryfikowanie poprawności nauczonych wzorców, co może przyczynić się do lepszego zrozumienia działania modelu. Analiza pojedynczych predykcji staje się łatwiejsza, gdy można odnieść się do ogólnego obrazu modelu, zbudowanego na wcześniejszych etapach analizy.

W rozdziale 3.2.1 Autor proponuje przeprowadzenie analizy modelu za pomocą metody SHAP, stosując podejście zstępujące. Do analizy wykorzystano dane produkcyjne z całego roku 2019, a następnie obliczono wartości atrybucji za pomocą metody Deep SHAP dla każdej obserwacji i każdej zmiennej wejściowej modelu. W wynikach analizy zstępującej XAI za pomocą metody SHAP Autor prezentuje istotne zmienne wejściowe oraz ich wpływ na predykcję modelu.

Analizę rozpoczyna Doktorant od pytania, *które cechy wejściowe są najbardziej istotne dla predykcji modelu*, a następnie analizuje wpływ poszczególnych zmiennych na predykcję zapotrzebowania. Wykresy (rysunki 9 i 10) prezentujące wpływ poszczególnych zmiennych na predykcję modelu wskazują, że temperatura zewnętrzna dominuje wraz z funkcjami związanymi z czasem, takimi jak miesiąc czy dzień roku kalendarzowego. Jak konkluduje, analiza istotności poszczególnych cech może jednak sprawiać trudności w interpretacji ze względu na skorelowanie wielu zmiennych wejściowych oraz sezonowe wahania.

Następnie Autor analizuje kierunek wpływu poszczególnych zmiennych na predykcję modelu (rysunek 11) i ostrzega przed jednoznacznymi interpretacjami, ponieważ wpływ temperatury zewnętrznej może być zniekształcony przez inne zmienne oraz sezonowe czynniki.

W kolejnych rozdziałach Autor skupia się na analizie wpływu temperatury zewnętrznej na wahania predykcji oraz relacji pomiędzy temperaturą zewnętrzną a predykcją. Analiza modelu za pomocą metody SHAP przy użyciu podejścia zstępującego pozwala na zrozumienie istotnych zmiennych wpływających na predykcję modelu oraz kierunku ich wpływu, co stanowi ważny krok w interpretacji działania modelu prognostycznego.

Rozdział 3.2.2.2 pt. *Temperatura zewnętrzna* poświęcony jest analizie wpływu temperatury zewnętrznej (rysunek 12) na predykcję zapotrzebowania na ciepło, wskazując, że istnieje silna, odwrotnie proporcjonalna zależność między nimi.

Dodatkowo opóźnione zmienne temperatury zewnętrznej (rysunki 13, 14 i 15) mają istotny wpływ na predykcje, szczególnie w przypadku systemów o dużej bezwładności. W podrozdziale 3.2.2.3 *Dzień i miesiąc roku* Autor omawia zmienne kalendarzowe, zwłaszcza transformację cosinusa dnia roku, wykazując znaczący wpływ na predykcję. Interakcje między miesiącem a dniem roku sugerują, że miesiąc roku przejął rolę, którą normalnie spełniałaby funkcja sinusowa dla dnia roku. Analiza atrybucji SHAP dla tych zmiennych ujawnia istotne związki, choć w niektórych przypadkach odwrotne niż oczekiwano (rysunki od 16 do 23).

W dalszej części w podrozdziale 3.2.2.4 *Godzina dnia* Doktorant skupia się na profilach zapotrzebowania na energię w ciągu doby, które mają istotny wpływ na predykcję. Pomimo braku tych zmiennych w pierwszej dziesiątce najistotniejszych cech, analiza atrybucji SHAP potwierdza, że model dobrze odwzorowuje te profile (rysunki 24 i 25). Podrozdział 3.2.2.5 pt. *Pozostałe zmienne* dotyczy analiz atrybucji SHAP dla prędkości wiatru i jej interakcji z temperaturą zewnętrzną sugerując zgodność z oczekiwaniami fizycznymi (rysunek 26).

W podrozdziale 3.2.2.6 *Analiza wybranych obserwacji* znajdują się analizy pojedynczych obserwacji, zwłaszcza tych ze skrajnymi błędami predykcji, potwierdzając zgodność atrybucji SHAP z oczekiwaniami. Przykład anomalii związanej z awarią systemu ciepłowniczego podkreśla wartość tej analizy w identyfikowaniu nietypowych zdarzeń (rysunek 27 i 28).

Na zakończenie rozdziału 3.2.3 pt. *Wnioski* Autor stwierdza, że analiza atrybucji SHAP potwierdza, że model dobrze odwzorowuje zależności zawarte w danych oraz poprawnie identyfikuje kluczowe czynniki wpływające na predykcję zapotrzebowania na ciepło. Spójność wyników z oczekiwaniami wynikającymi z praw fizyki sugeruje wysoką jakość modelu oraz przydatność metody SHAP w jego interpretacji.

W rozdziale 4 pt. *Monitorowanie modelu prognostycznego*, zajmującym 36 stron dysertacji, Autor skupia się na monitorowaniu modeli przewidujących zapotrzebowanie na energię po ich wdrożeniu. Analiza XAI w rozdziale 3 pozwoliła na zrozumienie sposobu generowania predykcji, wykazując, że model działa poprawnie. Z uwzględnieniem, iż pełne zaufanie do predykcji można mieć tylko wtedy, gdy spełnione jest założenie, że przyszłość jest podobna do przeszłości.

Gdy dostępne są pomiary zapotrzebowania, można porównać je z predykcjami i obliczyć błąd modelu. W związku z tym konieczne jest monitorowanie danych wejściowych i predykcji modelu na bieżąco. Klasyczne podejście polega na porównaniu rozkładów

zmiennych wejściowych z okresów referencyjnych, jednak może to być trudne w interpretacji. Ważniejsze jest oszacowanie wpływu zmian w tych rozkładach na jakość predykcji modelu, co można wyrazić np. w jednostce błędu modelu (rysunek 29).

W rozdziale 4.1 pt. *Wprowadzenie teoretyczne*, zdefiniowano podstawowe pojęcia związane z dryfem danych oraz przedstawiono teoretyczne wielkości dryfu danych i ich wpływ na rozkład prognozowanej zmiennej oraz na jakość modelu.

W podrozdziale 4.1.1 pt. *Rodzaje dryfu danych* został opisany podział dryfu danych dokonany według dwóch głównych kryteriów. Pierwsze kryterium dotyczy sposobu ukazania się dryfu w czasie, który może być nagły, stopniowy lub cykliczny. Drugie kryterium odnosi się do zmiany relacji pomiędzy zmiennymi wejściowymi a zmienną celu i wyodrębnia cztery rodzaje dryfu: dryf cech, dryf koncepcji, dryf etykiet oraz dryf reprezentacji.

W dalszej części w podrozdziale 4.1.2 *Podstawowe definicje związane z probabilistycznym Učeniem Maszynowym* Autor wprowadza pojęcia związane z probabilistycznym podejściem do uczenia maszynowego na przykładzie uproszczonego modelu danych, który przedstawia zależności i rozkłady prawdopodobieństwa. Modelem tym jest relacja pomiędzy temperaturą zewnętrzną a zapotrzebowaniem na ciepło. Autor wyjaśnia pojęcia takie jak rozkład brzegowy, rozkład prawdopodobieństwa warunkowego oraz reguła mnożenia prawdopodobieństw, zilustrowane na wykresach 30 oraz 31.

W rozdziale 4.1.3 pt. *Dryf cech* zostało omówione zagadnienie dryfu cech w kontekście zmian w rozkładzie prawdopodobieństwa zmiennych wejściowych i zmiennej celu, przy zachowaniu stałego prawdopodobieństwa warunkowego zmiennej celu pod warunkiem wejść.

Kolejny podrozdział 4.1.3.1 pt. *Definicja* określa dryf cech jako zmianę rozkładu prawdopodobieństwa zmiennych wejściowych i zmiennej celu przy założeniu stałego prawdopodobieństwa warunkowego zmiennej celu. Dryf cech może być zauważalny na przykład w zmianach klimatu, gdzie zmienia się rozkład temperatury zewnętrznej, ale zależność między temperaturą a zapotrzebowaniem na ciepło pozostaje stała. Dryf cech może być jednowymiarowy lub wielowymiarowy w zależności od tego, czy zmienia się rozkład jednej zmiennej czy kilku zmiennych, przy zachowaniu relacji między nimi (rysunek 32).

W dalszej części pracy w podrozdziale 4.1.3.2 pt. *Wielkość dryfu* Autor stwierdza, że wielkość dryfu może być mierzona za pomocą testów statystycznych lub dystansów

statystycznych, które rosną wraz ze wzrostem dryfu. Proponuje także absolutną miarę dryfu jednej zmiennej, która bierze pod uwagę zmiany w funkcji gęstości prawdopodobieństwa (rysunek 33, 34, 35).

Podrozdział 4.1.3.3 *Wpływ na rozkład zmiennej celu* analizuje wpływ dryfu cech na rozkład zmiennej celu, które można obliczyć poprzez uwzględnienie zmian w funkcji gęstości prawdopodobieństwa oraz funkcji warunkowej zmiennej celu. Wartość ta może być dodatnia lub ujemna, w zależności od obszaru, w którym występuje dryf (rysunek 36, 37 oraz 38).

W podrozdziale 4.1.3.4 pt. *Wpływ na jakość predykcji modelu* stwierdzono, że dryf cech może mieć istotny wpływ na jakość predykcji modelu, szczególnie w obszarach o dużej niepewności. Im więcej danych pochodzi z obszaru o dużej niepewności, tym gorsza może być jakość predykcji modelu. Dryf cech może jednak również poprawić jakość predykcji, szczególnie w obszarach o dużej pewności (rysunek 39).

Rozdział 4.1.4 pt. *Dryf koncepcji* omawia definicję dryfu koncepcji, sposoby pomiaru, wpływ na modele uczenia maszynowego. Dryf koncepcji (podrozdział 4.1.4.1 *Definicja*) może być zdefiniowany za pomocą sieci bayesowskiej, co oznacza zmianę rozkładów zmiennych nieobserwowanych wpływających na zmienną celu (rysunek 40).

Następnie w podrozdziale 4.1.4.2 *Wielkość dryfu* Doktorant wprowadza koncepcję czystego dryfu na przykładzie modelu danych dotyczących zapotrzebowania na ciepło. Wartość tej wielkości można obliczyć na podstawie różnicy w rozkładzie zmiennej celu między dwiema chwilami czasowymi (rysunek 41).

W podrozdziale 4.1.4.3 *Wpływ na rozkład zmiennej celu* zostało udowodnione, że dryf koncepcji może mieć zarówno pozytywny, jak i negatywny wpływ na prawdopodobieństwo wystąpienia zdarzenia celowego, zależnie od obszaru przestrzeni cech oraz zmian w rozkładach zmiennych obserwowanych (rysunek 42). Dalej w podrozdziale 4.1.4.4 pt. *Wpływ na jakość predykcji modelu* pokazano, że dryf koncepcji wpływa na jakość modelu uczącego się, często pogarszając jego wyniki, szczególnie w przypadku miar uwzględniających predykcje probabilistyczne (rysunek 43).

W podrozdziale 4.1.5 pt. *Interakcja dryfu cech z dryfem koncepcji* omawiany jest problem możliwej interakcji pomiędzy dryfem cech a dryfem koncepcji, który dodatkowo komplikuje ocenę wpływu dryfu na modele uczenia maszynowego (rysunek 44).

W rozdziale 4.1.6 pt. *Dyskusja* Doktorant zauważa, że analiza dryfu koncepcji w rzeczywistych modelach jest trudna ze względu na ograniczoną liczbę obserwacji i dużą

liczbę zmiennych wejściowych. Jednak wartość tego dryfu może być istotna dla jakości predykcji modelu, szczególnie jeśli dotyczy on zmian nieuwzględnionych w modelu. Monitorowanie wpływu dryfu koncepcji na model jest zatem niezbędne, zwłaszcza w kluczowych okresach wykorzystania modelu. Można wysnuć konkluzję, że dryf koncepcji stanowi istotne wyzwanie dla modeli uczenia maszynowego, wymagając stałego monitorowania i zastosowania odpowiednich strategii zaradczych w celu utrzymania jakości predykcji.

W kolejnym podrozdziale 4.2 pt. *Wpływ dryfu cech na jakość predykcji modelu zapotrzebowania na ciepło*, dokładnie w 4.2.1 pt. *Cele*, Autor opisuje wpływ dryfu cech na jakość predykcji modelu zapotrzebowania na ciepło. Doktorant postawił sobie za cel teoretyczne uzasadnienie i eksperymentalną walidację metod szacowania wpływu dryfu cech na jakość predykcji modelu, przy braku dostępu do rzeczywistych wartości zmiennej celu, czyli szacowania błędu modelu. W praktyce oznacza to szacowanie wybranej metryki jakości, co pozwala ocenić ryzyko związane z decyzjami opartymi na predykcji modelu.

Następnie w 4.2.2 pt. *Rozwiązanie teoretyczne* Autor wnioskuje, że w przypadku rozwiązania teoretycznego przed przystąpieniem do projektowania praktycznych metod, należy określić idealne rozwiązanie przy założeniu pełnego dostępu do danych modelu. Rozkład błędu w takim przypadku może być obliczony na podstawie rozkładu prawdopodobieństwa zmiennej celu oraz predykcji modelu, co pozwala na oszacowanie błędu pojedynczej predykcji (rysunek 47).

Propozycje rozwiązań praktycznych, podrozdział 4.2.3, obejmują wykorzystanie modeli bayesowskich, regresji kwantylowej oraz bezpośredniej predykcji błędu absolutnego. *Modele bayesowskie* (podrozdział 4.2.3.1) mogą zwracać predykcje w postaci rozkładów prawdopodobieństwa, jednak ich skuteczność bywa ograniczona przez konieczność założenia charakteru rozkładu a priori. *Regresja kwantylowa* (podrozdział 4.2.3.2) pozwala prognozować odpowiednie kwantyle, co może być użyteczne w określaniu interwałów predykcji (rysunek 48, 49). Natomiast *Bezpośrednia predykcja błędu absolutnego* (podrozdział 4.2.3.3) umożliwia prognozowanie błędu na podstawie prostszych danych (rysunek 50, 51).

W podrozdziale 4.2.4 *Ocena rozwiązań* Doktorant ocenia rozwiązania przeprowadzone na różnych zbiorach danych, w tym treningowym, referencyjnym i produkcyjnym. Jego wyniki wskazują, że metoda bezpośredniego szacowania błędu absolutnego osiągnęła najlepsze rezultaty przewyższając benchmark w każdym przypadku.

W dyskusji nad metodami (4.2.5 *Wyniki*) Autor wykazał, że modele oparte na regresji kwantylowej mogą być alternatywą, choć wymagają doboru hiperparametrów (Tabela 2). Metody bezpośredniego szacowania błędu są prostsze, jednak potrzebują dodatkowego zbioru danych do nauki (rysunek 52).

Rozdział podsumowuje *Dyskusja* (4.2.6), gdzie zostały omówione zalety i wady różnych metod szacowania błędu modelu, podkreślając znaczenie odpowiedniego doboru danych oraz hiperparametrów dla skuteczności tych metod. Ostatecznie przedstawione metody mają zastosowanie w ocenie ryzyka decyzji opartych na predykcji modelu oraz w ewentualnej aktualizacji modelu w przypadku zaobserwowanego dryfu danych lub koncepcji.

W ostatnim rozdziale 5 pt. *Podsumowanie* (2 strony) Autor konkluduje, że w pierwszej części skoncentrował się na weryfikacji użyteczności różnych metod XAI do analizy modeli prognozujących zapotrzebowanie na energię. W drugiej części zaproponował teoretyczne określenie absolutnej miary różnych rodzajów dryfu danych i zbadane zostały wpływy dryfu cech oraz koncepcji na jakość predykcji modelu.

Podsumowując, analiza przeprowadzona w pracy pozwoliła zweryfikować poprawność działania modelu i zrozumieć sposób, w jaki generuje on predykcje. Metody zaproponowane przez Autora umożliwiły oszacowanie błędu predykcji modelu z uwzględnieniem dryfu cech. Praca pokazała, jak zweryfikować poprawność działania modelu prognozującego typu black-box oraz jak stworzyć wiedzę i narzędzia do świadomego wykorzystania modelu predykcyjnego w celu minimalizacji ryzyka podejmowania błędnych decyzji na podstawie jego predykcji.

Autor wskazał również na dalsze kierunki badań, które obejmują potrzebę kolejnych przykładów analiz XAI modeli oraz badania nad detekcją dryfu cech do wcześniej niewidzianych obszarów. Należy również rozważyć bardziej zaawansowane metody szacowania metryki jakości modelu regresji bez dostępu do rzeczywistych wartości zmiennej celu, aby radzić sobie z obszarami przestrzeni cech, w których żadna z zaproponowanych metod nie działa poprawnie.

W Dodatku A: Wkład osób trzecich, Autor wymienia udział osób trzecich w pracach związanych z przedstawioną do analizy dysertacją.

Pracę zamyka wykaz literatury oraz spis ilustracji. Prawie wszystkie pozycje literaturowe (oprócz nru 43 i 44) są anglojęzyczne. Większość stanowią publikacje wydane zaledwie kilka lat temu.

3. Ocena pracy

3.1. Wybór tematu rozprawy

Obecne systemy ciepłownicze są z reguły niskoemisyjnym i efektywnym ekonomicznie sposobem na dostarczenie ciepła w stosunkowo gęsto zaludnionych obszarach miejskich. Ich „konstrukcja” oraz warunki użytkowania powodują, że charakteryzują się dużym potencjałem do optymalizacji, głównie w celu zmniejszenia kosztów produkcji i dystrybucji ciepła, co za tym idzie zredukowania emisji gazów cieplarnianych. W dużym uproszczeniu optymalizacja pracy systemu ciepłowniczego polega na zapewnieniu możliwie takich parametrów pracy źródeł (temperatury zasilania i ciśnienia), które mogłyby pokryć w minimalnym stopniu zapotrzebowanie na ciepło u odbiorców. Najbardziej efektywne rezultaty przynoszą działania dla systemów ciepłowniczych charakteryzujących się dużymi mocami wytwórczymi oraz rozwiniętą infrastrukturą dystrybucyjną. Dla takich układów redukcja temperatury zasilania źródła nawet o 1K daje znaczące korzyści zarówno finansowe, jak i ekologiczne. Optymalizacja polega na rozwiązaniu problemu dotyczącego takiego wyznaczenia parametrów pracy systemu, aby zminimalizować funkcję celu (np. odzwierciedlającą koszt prowadzenia systemu lub/i straty ciepła) przy jednoczesnym spełnieniu ograniczeń technicznych oraz zapewnieniu dostarczenia ciepła o odpowiednich parametrach do wszystkich odbiorców. Kluczowym elementem tego procesu wydaje się prognozowanie zapotrzebowania na ciepło.

Prognozowanie zapotrzebowania na energię jest zagadnieniem podejmowanym w energetyce od co najmniej trzech dekad. W przypadku dużych systemów ciepłowniczych jest to zadanie bardzo skomplikowane. Niewątpliwie takim przykładem jest Warszawska Sieć Ciepłownicza, która składa się z około 1800 km ciepłociągów, które dostarczają ciepło do 19 tys. obiektów, tym samym pokrywając około 80% zapotrzebowania na ciepło w stolicy. Ciepło wytwarzane jest przez 4 źródła: Elektrociepłownię Siekierki, Elektrociepłownię Żerań, Ciepłownię Kawęczyn i Ciepłownię Wola (dwa ostatnie to źródła szczytowe). System jest na tyle rozległy, że na jego krańcach mogą występować znacząco różne warunki atmosferyczne, które w głównej mierze określają zapotrzebowanie na ciepło u odbiorców. Jednocześnie w ostatnich latach upowszechniło się opomiarowanie telemetryczne systemów przemysłowych, w tym systemów ciepłowniczych, które

dostarcza bardzo dokładnych danych pomiarowych w trybie online, z możliwością ich przetwarzania i analizy w trybie rzeczywistym. Wszystko to skłania do wykorzystania do prognozowania zapotrzebowania na ciepło złożonych algorytmów, które osiągają coraz wyższą dokładność prognoz. Algorytmy te posiadają dziesiątki lub setki tysięcy parametrów, których wartości dobierane są automatycznie w procesie uczenia na danych historycznych. Co sprawia, że właściwie niemożliwe jest odczytanie i zinterpretowanie wyuczonych przez model relacji pomiędzy zmiennymi wejściowymi a wartością predykcji poprzez analizę tych parametrów.

W efekcie nie wiadomo, czy relacje te są spójne z podstawowymi zasadami fizyki. Jeśli nie są, z dużym prawdopodobieństwem model zwróci błędne predykcje, gdy rozkład danych wejściowych zmieni się, np. podczas anomalii pogodowych. Co więcej, w takim przypadku użytkownik modelu nie będzie miał świadomości potencjalnego problemu – jedyną informacją, jaką otrzyma, to punktowa wartość predykcji zapotrzebowania. W związku z tym potrzebne jest zweryfikowanych narzędzi i procesów pozwalających na ekstrakcję i interpretację relacji zaszytych w modelu celem określenia ich poprawności. Dodatkowo niezbędne są narzędzia do monitorowania modelu już w okresie produkcyjnym, które pozwolą ocenić, czy rozkłady wartości wejść do modelu odpowiadają dobrze znanym danym historycznym, a jeśli nie, to jaki jest wpływ na dokładność predykcji modelu i czy dalej powinno się tę predykcję wykorzystywać w procesie optymalizacji.

Właśnie tymi zagadnieniami zajmował się Doktorant w przedstawionej dysertacji. W rozdziale 1.1 jednoznacznie i bardzo precyzyjnie zostały zdefiniowane cele i zakres pracy doktorskiej.

Ogólne cele badawcze niniejszej pracy są następujące:

- *Analiza użyteczności narzędzi wyjaśniających modele predykcyjne XAI dla modeli prognozujących zapotrzebowanie na energię na przykładzie modelu prognozującego zapotrzebowanie na ciepło w WSC.*
- *Przeprowadzenie weryfikacji modelu Sztucznej Sieci Neuronowej prognozującego zapotrzebowanie w WSC za pomocą wybranych narzędzi XAI i na tym przykładzie stworzenie spójnych wytycznych do przeprowadzania tego typu analiz na modelach prognozujących zapotrzebowanie na energię.*

- *Badanie dryfu danych na modelu prognostycznym WSC. Teoretyczna i praktyczna analiza sposobów wykrywania dryfu, określania jego rodzaju, szacowania wielkości dryfu oraz wpływu dryfu na dokładność predykcji modelu.*

Do realizacji celów i zakresu rozprawy doktorskiej, Autor w rozdziale 1.2 pt. *Tezy pracy*, opracował dwie tezy:

Teza 1. Możliwe jest wykorzystanie metod XAI do stworzenia interpretowalnych wyjaśnień predykcji dla złożonych modeli typu black-box opartych o algorytmy Sztucznych Sieci Neuronowych prognozujących zapotrzebowanie na energię i stworzenie procesu weryfikacji wzorców wyuczonych przez model poprzez konfrontację wyjaśnień predykcji z oczekiwaniami wynikającymi z praw fizyki i wiedzy technicznej.

Teza 2. Możliwe jest stworzenie algorytmów, których zadaniem jest weryfikacja czy założenia postawione w procesie tworzenia modeli SSN prognozujących zapotrzebowanie na energię są spełniane w produkcyjnym okresie korzystania modelu, w szczególności czy występuje dryf danych i jaki jest jego wpływ na jakość predykcji modelu.

Ilość przeprowadzonych wnikliwych analiz stanowi olbrzymi atut tej rozprawy. Uważam również, że wybór tematu pracy doktorskiej jest trafny i ważny z naukowego, technicznego, a przede wszystkim praktycznego punktu widzenia.

3.2. Metodologia prowadzonych badań

Warsztat Doktoranta związany był głównie z analizami dużych zbiorów danych, opracowaniem algorytmów ich przetwarzania i interpretacji. Zakres przeprowadzonych badań, sposób ich prezentacji, wnikliwość oraz interpretacja uzyskanych wyników wskazuje na duże zaangażowanie Doktoranta w tematykę dysertacji.

3.3. Ocena wyników badań i uwagi krytyczne

Uważam, że praca stanowi kompendium wiedzy dotyczącej zastosowania uczenia maszynowego do przewidywania zapotrzebowania na ciepło dla tak rozległej sieci ciepłowniczej jak WSC.

Przedstawiona w pierwszej części rozprawy weryfikacja narzędzi Wyjaśnialnego Uczenia Maszynowego (ang. XAI) oraz analiza modelu prognozującego zapotrzebowanie na ciepło za pomocą wybranego narzędzia stanowi wartościową propozycję rozwiązania ważnego problemu badawczego. Zalety i wady istniejących narzędzi XAI w kontekście analizowanego modelu zostały, w mojej opinii, przedstawione w sposób klarowny. Za pomocą wybranej metody (SHAP) przeanalizowano model prognozujący zapotrzebowanie na ciepło w Warszawskiej Sieci Ciepłowniczej. Zaproponowano przy tym konkretną strukturę analizy – rozpoczynając od zależności globalnych i najistotniejszych cech wejściowych oraz grup cech wejściowych, kończąc na analizie pojedynczych predykcji. Wykorzystując właściwości matematyczne wybranego narzędzia przedstawiono wyuczone przez model zależności w sposób łatwy w interpretacji i pozwalający na weryfikację poprawności tych zależności, tj. zgodności z prawami fizyki czy wiedzy technicznej. Doktorant jednocześnie wskazuje potencjalnie słabe punkty modelu oraz proponuje metody usprawnienia poprzez dodanie zmiennych wejściowych dostarczających dodatkowych informacji dla modelu. Niestety, weryfikacja tych propozycji nie znalazła się w zakresie badań prowadzonych w ramach doktoratu.

W drugiej części pracy przeprowadzono analizę wpływu dryfu danych na jakość predykcji modelu i zaproponowano autorskie rozwiązania w tym zakresie, których efekt zweryfikowano na badanym modelu. Całość poprzedzono analizą na uproszczonym modelu danych pozwalającym na wyprowadzenie analitycznych rozwiązań. Stanowi to dużą wartość pracy. Po pierwsze w przejrzysty sposób definiuje zaawansowane statystyczne pojęcia dotyczące zmian w rozkładach zmiennych wejściowych oraz ich wpływu na jakość predykcji modelu. Po drugie, stanowi solidne teoretyczne uzasadnienie dla proponowanego algorytmu szacującego wpływ dryfu danych na jakość predykcji badanego modelu. Zaproponowana metoda daje lepsze wyniki od zwykle stosowanego podejścia tj. założenia, że jakość modelu nie zmienia się. Zagadnieniem otwartym pozostaje pytanie, czy wyniki te są na tyle dobre, żeby można je było wykorzystać w praktyce. Za pomocą zaproponowanej metody szacowano błąd prognozy na horyzoncie 24 i 120 godzin. W praktyce operator korzystający z prognoz może być zainteresowany błędem w krótszym odcinku czasu lub nawet błędem pojedynczej predykcji. Takiej analizy jednak nie przeprowadzono.

Podsumowując, należy podkreślić dużą znajomość zagadnień zarówno z obszaru energetyki, jak i statystycznego uczenia maszynowego. Pozwoliło to Doktorantowi na zaawansowaną interpretację wyników otrzymanych za pomocą narzędzi XAI w części

pierwszej rozprawy oraz na głębokie zrozumienie problemu i zaproponowanie teoretycznie uzasadnionych rozwiązań w części drugiej. Opisane metody i wnioski są adekwatne do całej klasy modeli prognozujących zapotrzebowanie na energię z wykorzystaniem algorytmu Sztucznej Sieci Neuronowej i w związku z tym mogą być wykorzystane przez innych badaczy i praktyków.

3.4. Uwagi redakcyjne

Praca jest bardzo dobrze zredagowana. Staranność edytorska oraz wykonane rysunki mogą być stawiane za wzór dla innych prac doktorskich.

4. Podsumowanie

Reasumując przedstawione wyżej opinie dotyczące wyboru tematu rozprawy, sposobu analizowania, zastosowanych metod badawczych i osiągniętych efektów, stwierdzam, że Pan mgr inż. Jakub Białek wykazał, że potrafi formułować i rozwiązywać problemy badawcze oraz wyciągać wnioski z otrzymanych wyników. Stwierdzam także, że posiadana wiedza, doświadczenie oraz umiejętności pozwalają mu na prowadzenie badań w dyscyplinie inżynieria środowiska, górnictwo i energetyka, dlatego też spełnia warunki do ubiegania się o stopień doktora nauk technicznych.

Wnoszę, zgodnie z Ustawą o stopniach naukowych i tytule naukowym oraz o stopniach naukowych i tytule w zakresie sztuki z dnia 2 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce oraz warunki określone w art. 13 Ustawy z dn. 14 marca 2003 r., o dopuszczenie Pana mgra inż. Jakuba Białka do obrony pracy i nadanie stopnia doktora nauk technicznych.

Po wnikliwej analizie dysertacji, przestudiowaniu zakresu zrealizowanych badań i poziomie przedstawionej rozprawy uważam, że dysertacja Pana mgra inż. Jakuba Białka zasługuje na **WYRÓŻNIENIE**.



Dr hab. inż. Sławomir PIETROWICZ, prof. uczelni

