



POLITECHNIKA POZNAŃSKA

Wydział Inżynierii Środowiska i Energetyki

**INSTYTUT INŻYNIERII ŚRODOWISKA
I INSTALACJI BUDOWLANYCH**

Zakład Ogrzewnictwa, Klimatyzacji i Ochrony Powietrza

mgr inż. Dawid CZAJOR

**Wykorzystanie sztucznych sieci neuronowych
w istniejącym systemie ciepłowniczym.**

ROZPRAWA DOKTORSKA

Promotor:

dr hab. inż. Łukasz Amanowicz, prof. PP

Promotor pomocniczy:

dr inż. Karol Bandurski

Poznań, czerwiec 2025 r.

Składam serdeczne podziękowania
Promotorowi dr. hab. inż. Łukaszowi Amanowiczowi,
profesorowi Politechniki Poznańskiej,
za ukierunkowanie i krytyczne spojrzenie na
problematykę badawczą podczas pisania niniejszej rozprawy.
Równocześnie dziękuję Promotorowi pomocniczemu
dr. inż. Karolowi Bandurskiemu za cenne wskazówki.
Szczególne podziękowania dla mojej kochanej żony i córki,
to był okres intensywnej pracy i wielu wyrzeczeń,
dziękuję za wsparcie.

*Rozprawa doktorska powstała przy współfinansowaniu
w ramach otrzymanego stypendium przyznany przez
Ministerstwo Nauki i Szkolnictwa Wyższego
z programu „Doktorat Wdrożeniowy”
nr umowy DWD/5/0017/2021.*

Streszczenie

W pracy przeanalizowano możliwości wykorzystania sztucznych sieci neuronowych do prognozy parametrów związanych z funkcjonowaniem systemu ciepłowniczego opartego o gazową elektrociepłownię zasilaną przez kotły wodne oraz agregaty kogeneracyjne. Wykorzystując autorskie oprogramowanie poddano ocenie ponad 12 tysięcy wygenerowanych modeli sieci neuronowej o różnych konfiguracjach warstw, liczbie neuronów, funkcjach aktywacji czy współczynnikach uczenia. Opracowano kryterium, które kwalifikuje wybrany model do zastosowania w prognozowaniu: zapotrzebowania na ciepło budynków przyłączonych do sieci ciepłej, wymaganej ilości ciepła generowanej przez elektrociepłownię jak również jej zapotrzebowania na paliwo gazowe, ceny energii elektrycznej oraz paliwa gazowego na giełdzie. Wykazano jaką architekturę sieci neuronowej osiąga najmniejszą niedokładność przy prognozowaniu wyżej wymienionych parametrów. Opracowana aplikacja, w ramach pracy wdrożeniowej, została zaimplementowana w przedsiębiorstwie zajmującym się wytwarzaniem i przesyłaniem ciepła. Umożliwia ona regulację źródeł wytwórczych w oparciu o predykcyjne zapotrzebowanie na ciepło u odbiorców końcowych przy uwzględnieniu kryterium ekonomicznego. Odnosi się ono w szczególności do pracy układu kogeneracyjnego, którego uruchomienie było uzależniane od prognozowanej ceny energii elektrycznej i jej relacji do ceny paliwa gazowego.

Wykorzystując wyniki badań sformułowano wnioski i praktyczne rekomendacje do projektowania systemów kontroli i nadzoru pracy kogeneracyjnych źródeł wytwórczych opartych o sztuczne sieci neuronowe.

Abstract

The study explores the potential application of artificial neural networks for forecasting parameters related to the operation of a district heating system based on a gas-fired combined heat and power (CHP) plant supplied by water boilers and cogeneration units. Using proprietary software, over 12,000 generated neural network models were evaluated, featuring various configurations of layers, numbers of neurons, activation functions, and learning rates. A set of criteria was developed to qualify a given model for use in forecasting the following: heat demand of buildings connected to the district heating network, the required amount of heat generated by the CHP plant, the plant's natural gas demand, and the market prices of electricity and natural gas. The study identified which neural network architecture achieved the lowest forecasting error for the aforementioned parameters. As part of an implementation project, the developed application was deployed in a company specialising in the generation and distribution of heat. The system enables control of generation sources based on predicted heat demand from end users, while also taking into account economic criteria. This refers in particular to the operation of the CHP plant, in which the start-up of engines was dependent on the forecasted price of electricity and its relation to the price of gas fuel.

Based on the research results, conclusions and practical recommendations were formulated for the design of control and monitoring systems for cogeneration generation sources based on artificial neural networks.

Lista skrótów

Część symboli niewystępujących w poniższej liście została opisana bezpośrednio przy wzorach dla uzyskania pełnej czytelności.

API	– Application Programming Interface – interfejs programowania aplikacji określający sposób komunikacji
CSV	– Comma-separated values
FLOPS	– Floating Point Operations Per Second – operacje zmiennoprzecinkowe na sekundę
FTP	– File Transfer Protocol
GNU/Linux	– system operacyjny GNU z jądrem Linux
IMGW	– Instytut Meteorologii i Gospodarki Wodnej
IoT	– Internet of Things – Internet rzeczy
JSON	– JavaScript Object Notation
KOBIZE	– Krajowy Ośrodek Bilansowania i Zarządzania Emisjami
KSE	– Krajowy System Elektroenergetyczny
MATLAB	– program komputerowy będący interaktywnym środowiskiem do wykonywania obliczeń naukowych i inżynierskich
MFLOPS	– megaflops – milion operacji zmiennoprzecinkowych na sekundę
MPC	– Model Predictive Control
RB	– Rynek Bilansujący
SCADA	– Supervisory Control And Data Acquisition – system informatyczny nadzorujący przebieg procesu technologicznego lub produkcyjnego
SQL	– Structured Query Language – strukturalny oraz deklaratywny język zapytań stosowany w bazach danych
SVM	– Support Vector Machine – jeden z algorytmów uczenia maszynowego
TB	– terabajt, jednostka określająca liczbę danych w informatyce równa 10^{12} bajtów
TGE	– Towarowa Giełda Energii
WWW	– World Wide Web

Spis treści

Streszczenie.....	4
Abstract.....	4
Lista skrótów.....	5
1. Wprowadzenie.....	9
1.1. Problematyka wykorzystania sztucznych sieci neuronowych w istniejącym systemie ciepłowniczym.....	9
1.2. Teza i cel pracy.....	11
1.3. Zakres pracy.....	11
2. Przegląd stanu wiedzy.....	17
2.1. Literatura poruszająca zagadnienie wykorzystania uczenia maszynowego w systemach ciepłowniczych i elektroenergetycznych.....	17
2.2. Aktualne osiągnięcia programistyczne w zakresie uczenia maszynowego i sztucznych sieci neuronowych.....	33
2.3. Oryginalność podjętej tematyki w kontekście przeglądu aktualnego stanu wiedzy.....	40
3. Dane na temat analizowanego systemu elektroenergetycznego i ciepłowniczego.....	41
3.1. Opis systemu ciepłowniczego.....	41
3.2. Kontekst prawno–finansowy.....	42
3.3. Praca układu kogeneracyjnego.....	47
3.4. Perspektywy.....	48
4. Algorytmy do zbierania danych na potrzeby zbudowania modelu sztucznej sieci neuronowej.....	49
4.1. Wykorzystywane narzędzia programistyczne.....	49
4.2. Opis danych źródłowych.....	50
4.3. Dane z liczników ciepła.....	51
4.4. Dane z elektrociepłowni.....	52
4.5. Dane meteorologiczne z Instytutu Meteorologii i Gospodarki Wodnej.....	53
4.6. Dane o funkcjonowaniu Krajowego Systemu Elektroenergetycznego.....	54
4.7. Dane o cenach energii elektrycznej na Rynku Bilansującym.....	55
4.8. Dane o cenach paliwa gazowego na Towarowej Giełdzie Energii.....	55

5. Prognozowanie zapotrzebowania na ciepło u odbiorcy końcowego.....	56
5.1. Opis mechanizmu.....	56
5.2. Akceptowalna niedokładność.....	65
5.3. Walidacja.....	66
5.4. Wnioski i analizy.....	75
5.5. Wdrożenie.....	77
6. Prognozowanie zapotrzebowania na ciepło w źródle.....	78
6.1. Opis mechanizmu.....	78
6.2. Akceptowalna niedokładność.....	80
6.3. Walidacja.....	80
6.4. Wnioski i analizy.....	84
6.5. Wdrożenie.....	85
7. Prognozowanie zapotrzebowania na paliwo gazowe dla źródła.....	87
7.1. Opis mechanizmu.....	87
7.2. Akceptowalna niedokładność.....	89
7.3. Walidacja.....	90
7.4. Wnioski i analizy.....	94
7.5. Wdrożenie.....	95
8. Rozszerzona prognozy pogody.....	97
8.1. Opis mechanizmu.....	97
8.2. Akceptowalna niedokładność.....	100
8.3. Walidacja.....	101
8.4. Wyniki i analizy.....	104
8.5. Wdrożenie.....	107
9. Prognoza ceny energii elektrycznej na Rynku Bilansującym.....	108
9.1. Opis mechanizmu.....	108
9.2. Akceptowalna niedokładność.....	112
9.3. Walidacja.....	113
9.4. Wyniki i analizy.....	118

9.5. Wdrożenie.....	118
10. Prognoza ceny paliwa gazowego.....	120
10.1. Opis mechanizmu.....	120
10.2. Akceptowalna niedokładność.....	125
10.3. Walidacja.....	126
10.4. Wyniki i analizy.....	133
10.5. Wdrożenie.....	134
11. Opis wdrożenia algorytmów uczenia maszynowego z wykorzystaniem sieci neuronowych w istniejącym systemie ciepłowniczym.....	135
11.1. Dane o aktualnym systemie informatycznym w przedsiębiorstwie.....	135
11.2. Wymagania sprzętowe.....	136
11.3. Moduły oprogramowania.....	137
11.4. Moduły wykonawcze.....	140
11.5. Uproszczona analiza finansowa.....	142
11.6. Wizualizacja prognozy parametrów.....	145
12. Podsumowanie, wnioski i uwagi końcowe.....	148
12.1. Weryfikacja postawionej tezy.....	148
12.2. Dyskusja wyników pracy.....	150
12.3. Wnioski.....	155
12.4. Propozycje dalszych prac.....	156
13. Bibliografia.....	158

1. Wprowadzenie.

1.1. Problematyka wykorzystania sztucznych sieci neuronowych w istniejącym systemie ciepłowniczym.

Uczenie maszynowe to zagadnienie z obszaru sztucznej inteligencji, które wykorzystuje zbudowane modele na bazie danych źródłowych w celu:

- rozpoznawania obrazów i dźwięków przez komputer,
- sterowania robotami oraz różnymi procesami,
- klasyfikacji użytkowników w celu zwiększenia efektywności kampanii reklamowych,
- budowy systemów wspomaganie decyzji
- czy predykcji parametrów w określonym horyzoncie czasowym.

Na podstawie informacji zawartych w [1] zauważalny jest znaczny wzrost danych cyfrowych wytwarzanych na świecie. Począwszy od 2 miliardów terabajtów w 2010 r. do 123 miliardów TB w 2023 r. Prognozy wskazują, że w 2028 roku aktualna wartość może zostać podwojona. Taka ilość danych publikowanych w internecie czy rejestrowanych przez instalacje przemysłowe napędzana jest dodatkowo przez rozwój nowych technologii. Większa ilość informacji źródłowych daje znaczne możliwości do interpretacji czy optymalizacji danego zjawiska. Jednak samo rozpowszechnienie technologii do rejestracji danych nie byłoby możliwe bez równoległego postępu technologicznego w zakresie mocy obliczeniowej komputerów. W latach 60. XX wieku zdolności obliczeniowe procesora wynosiły około kilku milionów operacji zmiennoprzecinkowych na sekundę (MFLOPS). Dzisiejsze laptopy mają moc rzędu kilkuset tysięcy MFLOPS, natomiast superkomputery umożliwiają przeprowadzenie działań ponad miliard razy szybciej. Dzięki powszechnej dostępności systemów komputerowych oraz ich implementacji z wykorzystaniem systemów typu SCADA zyskują one popularność w sterowaniu systemami ciepłowniczymi i elektroenergetycznymi. Oprogramowanie wykorzystuje różne metody komunikacji z czujnikami oraz regulatorami znajdującymi się w węzłach cieplnych, sieci ciepłej oraz w samym źródle, umożliwiają ich wykorzystanie jako dane wsadowe w procesie uczenia maszynowego. Jest to podejście zgodne z koncepcją odnoszącą się do czwartej rewolucji przemysłowej określanej mianem Przemysłu 4.0, w której automatyzacja, internet rzeczy czy przetwarzanie danych w chmurze jest powszechnie stosowane.

Zgodnie z aktualną strategią energetyczną, opisaną w [2], Polska dąży do osiągnięcia przed 2040 r. neutralności klimatycznej. Osiągnięcie tego celu będzie możliwe przez zwiększenie efektywności energetycznej procesów technologicznych przy rosnącym udziale odnawialnych źródeł energii. Z tego powodu konieczna jest budowa instalacji wytwórczych bazujących na energii słonecznej, wiatrowej czy paliwach gazowych (biogaz, biometan, wodór). Przekłada się to na nowe wymagania po stronie zarządców systemów ciepłowniczych w zakresie:

- większej elastyczności w produkcji ciepła, uwzględniającej chwilową dostępność energii odnawialnej na rynku jak również uwarunkowanie ekonomiczne,
- odbioru ciepła odpadowego z procesów technologicznych od przyłączonych klientów,
- budowaniu magazynów ciepła,
- kalkulacji taryf dla ciepła uwzględniającego różnorodność źródeł oraz większą dynamikę w zakresie zmienności czynników ekonomicznych w trakcie jej stosowania,
- rozszerzenia działalności ciepłowniczej o generację energii elektrycznej.

Ostatni punkt jest konsekwencją prognozowanego zwiększenia zapotrzebowania na energię elektryczną w Polsce o ponad 30 % do roku 2040 (od wartości 173,5 TWh w 2022 r. do 230 TWh). Takie podejście, które umożliwia generowanie dodatkowych środków finansowych ze sprzedaży energii elektrycznej do Krajowego Systemu Elektroenergetycznego, wiąże się również z wieloma wyzwaniami. Funkcjonujący rynek staje się coraz bardziej dynamiczny i strategię działania przedsiębiorstw energetycznych oparte o jeden typ urządzenia do wytwarzania energii są coraz rzadziej spotykane. Z kotłami opalonymi węglem kamiennym mogą współpracować kotły opalane gazem ziemnym czy agregaty kogeneracyjne lub pompy ciepła [3]. Kierując takim układem dostępnych jest więcej możliwości w zakresie wyboru źródła, które będzie najlepiej dopasowane do aktualnych potrzeb. W tym celu konieczna jest ciągła analiza następujących parametrów:

- ceny energii elektrycznej na Rynku Bilansującym,
- kosztu paliwa gazowego,
- wolumenu sprzedawanego ciepła oraz energii elektrycznej,
- wymaganej ilości ciepła jaką należy dostarczyć do systemu ciepłowniczego,
- planowanej generacji energii elektrycznej,
- sprawności poszczególnych urządzeń czy ich dyspozycyjności.

Realizacja tego zadania z należytą starannością, dokładnością i wymaganą częstotliwością przez człowieka, może stwarzać wyzwanie. W tym celu opracowano algorytmy wykorzystujące sztuczne sieci neuronowe do wspomaganie podejmowania decyzji. Oparte są one o zweryfikowane modele predykcji, które muszą spełniać określoną granicę akceptowalności. Zostały one wygenerowane na bazie danych archiwalnych dotyczących funkcjonowania systemu ciepłowniczego zasilanego z elektrociepłowni, dla której źródłem energii są agregaty kogeneracyjne oraz kotły opalane gazem ziemnym. Opracowany system analizuje w sposób ciągły parametry techniczne oraz ekonomiczne związane z cenami paliwa gazowego oraz energii elektrycznej, wprowadzając w istniejący system kontroli pracy źródła zaktualizowaną strategię działania. Jego działanie powinno przynieść wymierne rezultaty

zarówno pod kątem efektywności energetycznej jak i w kwestii ekonomicznej prowadzenia tego typu działalności gospodarczej.

1.2. Teza i cel pracy.

Biorąc pod uwagę tło rozprawy nakreślone w punkcie 1.1, postawiono następującą tezę *„Istnieje możliwość wykorzystania sztucznych sieci neuronowych na cele prognozy: zapotrzebowania na ciepło, ceny energii elektrycznej oraz ceny paliwa gazowego, z akceptowalną dokładnością, dla istniejącego systemu ciepłowniczego zasilanego z kogeneracyjnej elektrociepłowni gazowej.”*

Na tej podstawie postawiono następujące zadania badawcze:

- opracowanie koncepcji rejestracji danych pomiarowych niezbędnych do wytrenowania modeli predykcji opartych o uczenie maszynowe w postaci sztucznych sieci neuronowych,
- wygenerowanie różnych struktur (zwanych dalej również architekturą) sztucznej sieci neuronowej do rozwiązania tego samego problemu na podstawie założonych zakresów jej konfiguracji,
- wykorzystanie zebranych danych pomiarowych na cele wytrenowania modelu predykcji,
- analiza dokładności modeli predykcyjnych.

Realizacja powyższych zadań ma na celu znalezienie odpowiedzi na następujące pytania badawcze:

- czy sieci neuronowe można wykorzystać do uniwersalnego prognozowania parametrów funkcjonowania systemu ciepłowniczego,
- jak struktura sieci neuronowej wpłynie na dokładność prognozowania, a jednocześnie na czas wykonywania obliczeń,
- czy możliwe jest sterowanie źródłem ciepła w oparciu o prognozowane dane wygenerowane przez sztuczne sieci neuronowe.

1.3. Zakres pracy.

Analiza dostępnej literatury, zaprezentowana w punkcie 2.1, potwierdza wykorzystywanie sztucznych sieci neuronowych w celu rozwiązywania problemów, które są zbyt skomplikowane dla metod opartych na regresji liniowej, drzewach decyzyjnych czy metodach k–najbliższych sąsiadów lub k–średnich. Badacze implementują je w wielu zastosowaniach [4] eksperymentując z różną strukturą sieci neuronowej. Wyniki ich prac oraz uzyskiwana dokładność odnosi się wyłącznie do kilku losowo zdefiniowanych parametrów

sieci. Brakuje publikacji, w których zaprezentowany został przekrój wygenerowanych modeli na szeroką skalę wraz z oceną dokładności oraz kryterium ich kwalifikacji do zastosowania w funkcjonującym systemie. Z tego powodu zaproponowano autorską metodę ich wyboru w zależności od zastosowania. Motywacją do podjęcia tej tematyki były zmiany w aktach prawnych z zakresu szeroko pojętej energetyki, które wymagają od systemów ciepłowniczych i elektroenergetycznych większej elastyczności w działaniu. Wymaga to opracowania nowych metod w zakresie sterowania pracy źródłami wytwórczymi, które na bieżąco analizują warunki techniczne i ekonomiczne pracy całego systemu i na tej podstawie podejmują decyzję.

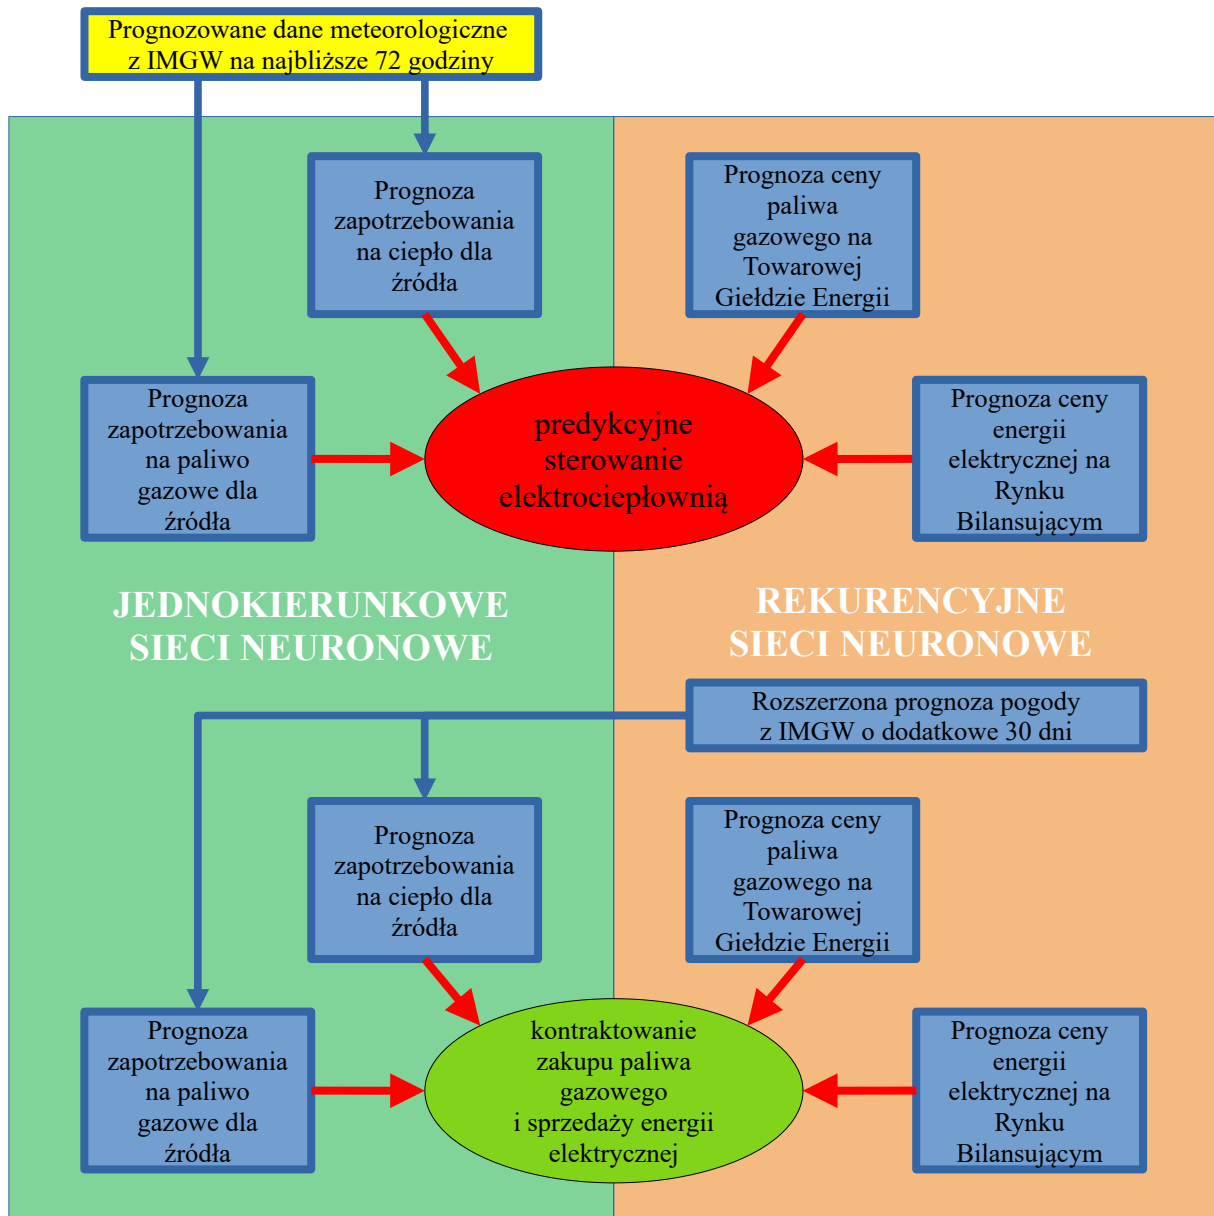
Uwzględniając powyższe, zakres pracy obejmuje opracowanie algorytmów pozwalających na zgromadzenie odpowiednich danych źródłowych do wytrenowania sztucznej sieci neuronowej w celu prognozy:

- godzinowego zapotrzebowania na moc cieplną na cele centralnego ogrzewania oraz ciepłej wody użytkowej dla każdego budynku przyłączonego do sieci ciepłowniczej,
- dobowego zapotrzebowania na moc cieplną i paliwo gazowe dla źródła,
- parametrów meteorologicznych oraz ceny energii elektrycznej na Rynku Bilansującym w ujęciu godzinowym,
- ceny paliwa gazowego na Towarowej Giełdzie Energii z kilkudniowym horyzontem.

Dla każdego opisanego powyżej zagadnienia generowane zostaną modele o różnej architekturze sieci neuronowej. Struktura oraz dokładność każdego z nich, będzie uzależniona od zmiany parametrów wewnętrznych takich jak:

- liczby warstw sieci neuronowej w zakresie od 1 do 4,
- liczby neuronów w każdej warstwie w zakresie od 32 do 320,
- wyboru funkcji aktywacji neuronu z zakresu:
 - ReLU,
 - Leaky ReLU.
 - ReLU6,
 - GELU,
 - ELU,
- częstotliwości aktualizacji wag sieci w trakcie procesu uczenia w zakresie od 32 do 256,
- zadanej szybkości uczenia w zakresie od 0,005 do 0,1.

Każdy wygenerowany model w kolejnym etapie przechodzi proces walidacyjny. Polega on na ocenie dokładności predykcji w oparciu o opracowaną metodologię zawierającą tzw. kryterium akceptowalności. Określa ona graniczną jakość predykcji, która kwalifikuje daną architekturę do wykorzystania w rozwiązaniu konkretnego problemu. Z racji na wdrożeniowy charakter pracy, zakres został rozszerzony o opis układu ciepłowniczego jak i sposób implementacji wyników rozprawy w funkcjonującym systemie informatycznym przedsiębiorstwa, zajmującego się wytwarzaniem oraz przesyłaniem ciepła.



Rys. 1.1. Schemat opracowanego końcowego systemu do sterowania predykcyjnego elektrociepłownią oraz kontraktowaniem zakupu paliwa gazowego i sprzedażą energii elektrycznej w podziale na zastosowane typy sieci neuronowych.

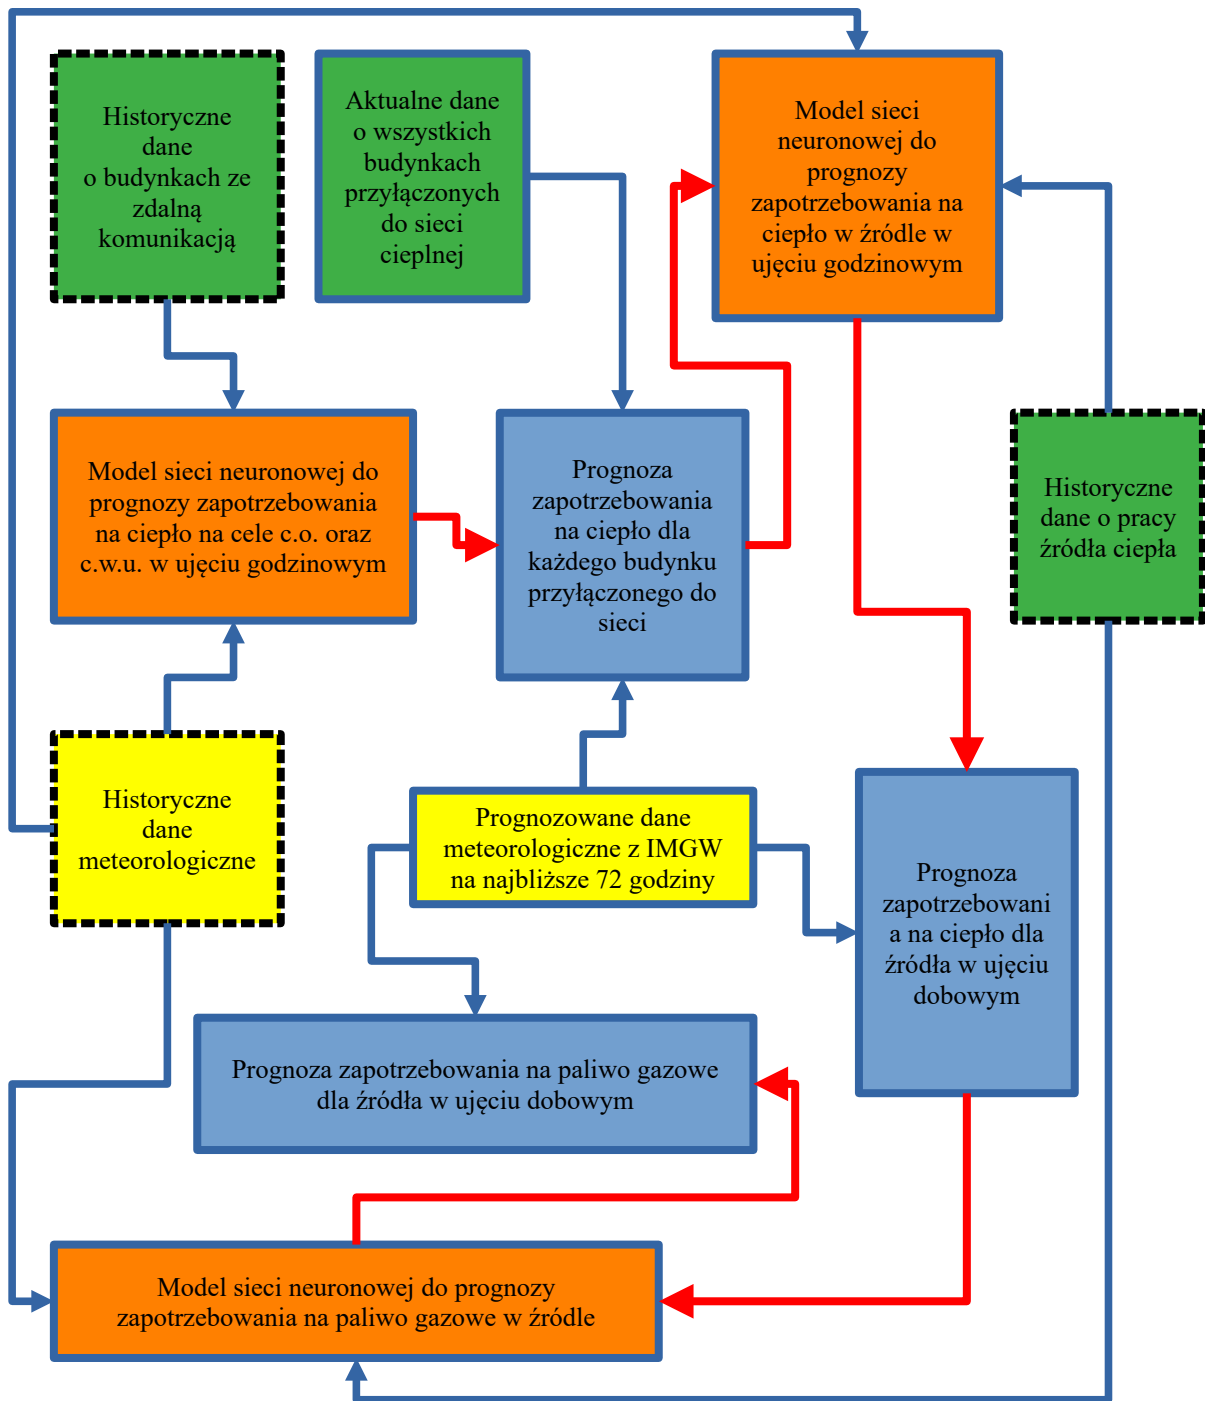
Opracowany mechanizm umożliwia dynamiczną i elastyczną pracę całego systemu ciepłowniczego w zależności od aktualnego zapotrzebowania na ciepło, cen paliw gazowych i energii elektrycznej na giełdzie. Sposób funkcjonowania algorytmu został zaprezentowany na schematach w podziale na typ wykorzystywanych sieci neuronowych. W końcowym etapie wszystkie wygenerowane prognozy uwzględniane są w jednym końcowym algorytmie, który odpowiada za:

- predykcyjne sterowanie obiektem,
- kontraktowanie zakupu paliwa gazowego i sprzedaży energii elektrycznej.

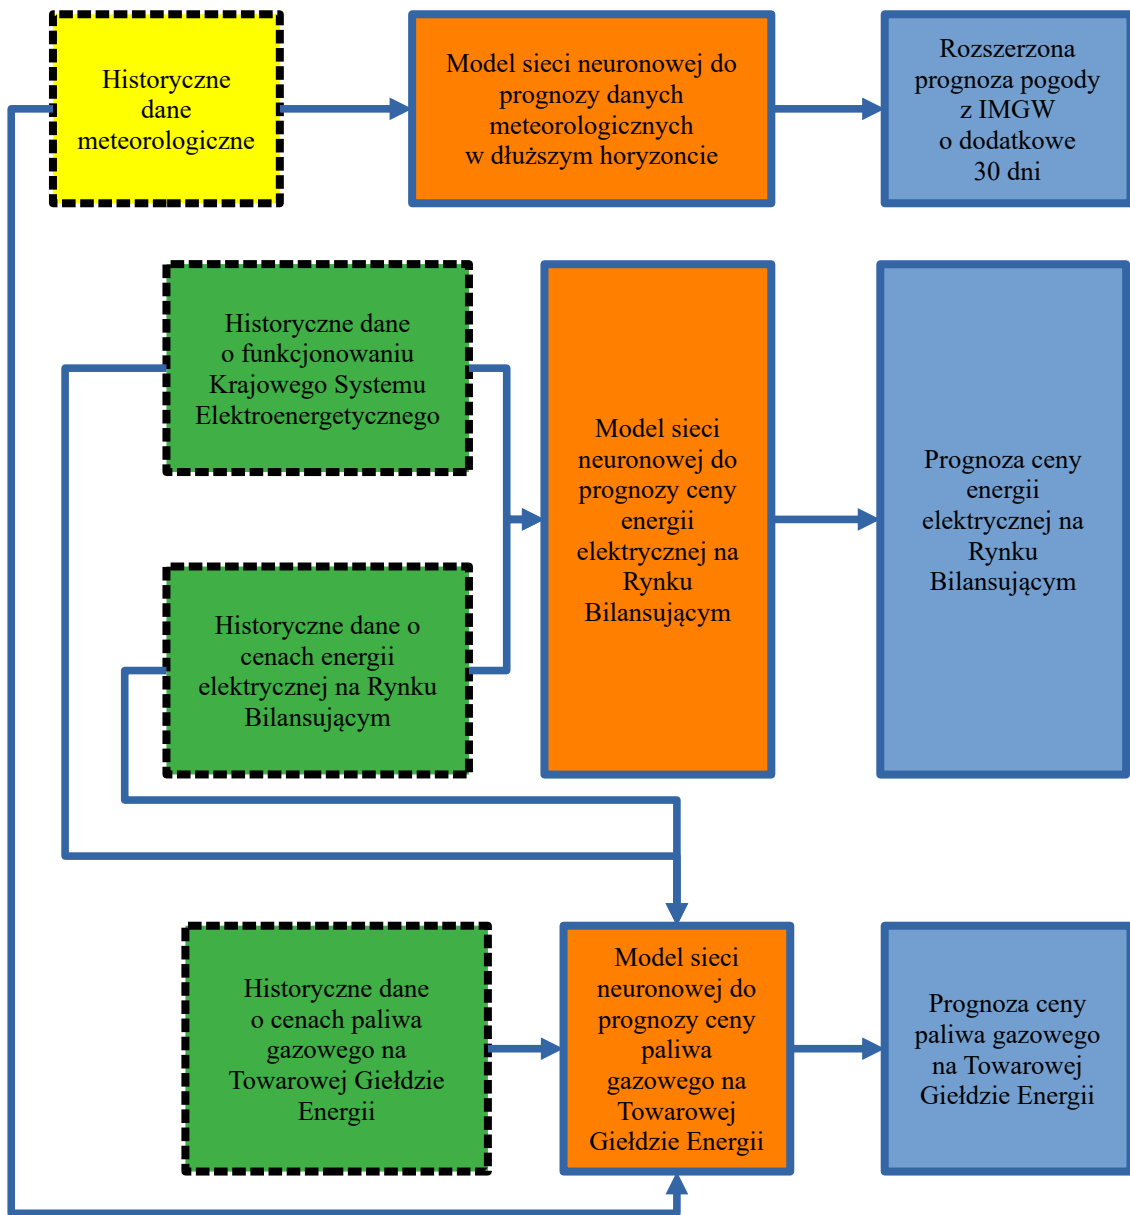
Jego schemat został przedstawiony na Rys. 1.1. W pierwszym zastosowaniu wykorzystana została prognoza pogody udostępniana z Instytutu Meteorologii i Gospodarki Wodnej na najbliższe 72 godziny. Założono, że taki horyzont prognozy wystarczy do zaplanowania pracy urządzeń w elektrociepłowni. W drugim zastosowaniu podjęto próbę jego wydłużenia o dodatkowe 30 dni. Może on być wykorzystany do wyznaczenia produkcji ciepła w źródle i w konsekwencji zużycia paliwa gazowego w całym miesiącu, w celu zakontraktowania odpowiedniego wolumenu na rynku.

Na Rys. 1.2 przedstawiono algorytm wykorzystujący jednokierunkowe sieci neuronowe do prognozowania zapotrzebowania na ciepło u odbiorców końcowych jak i w samym źródle oraz dobowe zapotrzebowanie na paliwo gazowe. Wykorzystuje on prognozy generowane z jednego modułu jako źródło danych wejściowych do kolejnego. Strzałki koloru czerwonego przedstawiają kierunek przesyłania informacji pomiędzy głównymi elementami. Kolorem żółtym zaznaczono dane pochodzące z IMGW, kolorem zielonym dane zbierane we własnym zakresie, kolorem pomarańczowym opracowane modele sztucznej sieci neuronowej, a kolorem niebieskim generowane prognozy określonych parametrów. Czarną linią przerywaną po obwodzie zaznaczono dane historyczne, natomiast linią ciągłą dane aktualne.

Na Rys. 1.3 zaprezentowano zasadę działania opracowanego systemu w zakresie prognozy ceny energii elektrycznej na Rynku Bilansującym, ceny paliwa gazowego na Towarowej Giełdzie Energii oraz rozszerzonej prognozy pogody. W tych zastosowaniach wykorzystywane są rekurencyjne sieci neuronowe. Każdy z modułów jest powiązany jedynie niektórymi wspólnymi danymi źródłowymi, natomiast nie ma w nich szeregowych zależności tak jak w poprzednim schemacie.



Rys. 1.2. Schemat opracowanego systemu do prognozy parametrów w systemie ciepłowniczym z wykorzystaniem jednokierunkowych sieci neuronowych służących do prognozowania: zapotrzebowania na ciepło przez odbiorców końcowych, zapotrzebowania na ciepło oraz paliwo gazowe dla źródła.



Rys. 1.3. Schemat opracowanego systemu do prognozy parametrów wspierających system ciepłowniczy z wykorzystaniem rekurencyjnych sieci neuronowych służących do prognozowania: ceny energii elektrycznej na Rynku Bilansującym oraz ceny paliwa gazowego na Towarowej Giełdzie Energii jak również parametrów meteorologicznych w dłuższym horyzoncie.

2. Przegląd stanu wiedzy.

2.1. Literatura poruszająca zagadnienie wykorzystania uczenia maszynowego w systemach ciepłowniczych i elektroenergetycznych.

W 2014 r. K. Wojdyga [5] opublikował artykuł dot. predykcji zapotrzebowania na ciepło w systemie ciepłowniczym. Badania zostały przeprowadzone na podstawie danych z kampusu Politechniki Warszawskiej, dla którego ciepło dostarczane było siecią ciepłowniczą. Informacje jakie zostały wykorzystane do uczenia maszynowego pochodzą z 16 węzłów cieplnych regulowanych w funkcji temperatury zewnętrznej oraz układu do pomiaru wykorzystania ciepła. Dane były rejestrowane z interwałem 1–10 min, a następnie uśrednione z interwałem godzinowym. Do prognozy wykorzystano parametry z głównego ciepłomierza na potrzeby całego kompleksu. Tak opracowane dane z okresu od 1995 do 2009 zostały przygotowane na potrzeby algorytmu, dla którego sygnałem wejściowym była temperatura zewnętrzna a sygnałem wyjściowym zapotrzebowanie na moc cieplną. Autor dodatkowo jako sygnał wejściowy dodaje historyczne zapotrzebowania na moc cieplną oraz wartość temperatury zewnętrznej z następujących przedziałów czasowych:

- godzinę, dwie i trzy wcześniej tego samego dnia,
- godzinę, dwie i trzy dnia wcześniejszego oraz
- godzinę, dwie i trzy dwa dni wstecz.

W swoim tekście wykorzystuje 48 godzinne okno czasowe do prognozowania zapotrzebowania na ciepło w oparciu o prognozę pogody. Dokładność predykcji uzależniona była od wielu czynników tj. warunków atmosferycznych, cyklicznych zmian związanych z sezonowością dostaw ciepła, wpływu ludzkiego zachowania oraz akumulacji ciepła. Autor wskazuje również na zjawisko bezwładności cieplnej układu, która powinna zostać uwzględniona w takich analizach. Wg Wojdygi równania analityczne nie są wskazane do wykorzystania przy budowaniu złożonych modeli dla całych sieci ciepłowniczych. Mogą okazać się one zbyt skomplikowane, biorąc pod uwagę ilość współczynników związanych z różnymi charakterystykami obiektów. Autor zaznacza, że predykcje związane z zapotrzebowaniem na moc elektryczną w porównaniu do predykcji mocy cieplnej wykazują wyższą dokładność, ponieważ nie zależą bezpośrednio od warunków atmosferycznych. Po wykonanych analizach stwierdzono, że najlepsze efekty daje wykorzystanie 25 neuronów w warstwie ukrytej. Autor nie testował innych rozwiązań powielających liczbę warstw ukrytych, jak również nie analizował zastosowania algorytmów wstecznej propagacji. Prognozowano zapotrzebowanie na moc cieplną dla obiektu z 1, 2 i 3 godzinnym wyprzedzeniem dla którego błąd MAPE wyniósł od 2,9 % do 4,7 %. Wojdyga podsumowuje, że wraz ze wzrostem horyzontu predykcji proporcjonalnie wzrasta błąd prognozy. Biorąc pod uwagę globalne założenia klimatyczne tj. redukcja emisji zanieczyszczeń do atmosfery, ograniczenie emisji dwutlenku węgla sugeruje, że rozwiązania oparte na kogeneracji będą wiodące w osiągnięciu tego celu. Dodatkowo wykorzystując akumulatory ciepła powinno się

tak regulować układem aby produkować energię elektryczną w czasie w którym jej cena jest najwyższa. W roku publikacji artykułu autor wskazuje, że ceny energii w Polsce są na stabilnym poziomie i prognozuje, że w przyszłości będą one coraz bardziej zmienne.

Zastosowanie algorytmów może być również wykorzystane do prognozowania czasu dotarcia „fali” ciepła z nowo uruchomionego kotła lub agregatu kogeneracyjnego. W publikacji [6] autorzy wykorzystując metody numeryczne analizują zachowanie sieci ciepłej oraz jej reakcję na zwiększoną lub zmniejszoną temperaturę zasilania sieci ciepłej i w rezultacie zwiększenie lub zmniejszenie przepływu w danym węźle. Inni natomiast wykorzystują podobną metodę do symulacji hydraulicznej sieci ciepłowniczej i skupiają się na jej optymalizacji w artykule [7]. Dzięki modelowaniu przepływów w sieci oraz węzłach ciepłych można przeprowadzić analizy zmiany ciśnienia dyspozycyjnego. Autorzy uzyskują błąd nieprzekraczający 10 % prognozowanego przepływu wody w węźle ciepłym w stosunku do wartości rzeczywistej.

Inną możliwość zastosowania algorytmów uczenia maszynowego prezentuje [8]. W opublikowanym artykule podejmuje on próbę optymalizacji pracy kotłów grzewczych. Autor podkreśla, że wykorzystanie sztucznych sieci neuronowych w porównaniu z klasycznymi metodami modelowania nieliniowych zależności daje lepsze rezultaty. Dodatkowo podkreśla, że monitorowanie procesów z wykorzystaniem algorytmów opartych na sieciach neuronowych jest potężniejszym narzędziem niż monitoring na podstawie klasycznych równań matematycznych. Do analizy zostały wykorzystane dane z 65 kotłów grzewczych z ponad 50 miast, które odzwierciedlają szerokie spektrum zastosowań (od przemysłu przez budownictwa jedno- i wielomieszkaniowe po komercyjne zastosowania) zarówno przy produkcji pary wodnej jak i gorącej wody. Do analizy posłużono się komercyjnym programem MATLAB. Jako sygnał wyjściowy z algorytmu została wybrana sprawność kotła, a na wejściu wybrane zostały:

- typ paliwa,
- typ kotła,
- okres eksploatacji,
- nominalna moc cieplna,
- obciążenie cieplne oraz
- zawartość tlenu w spalinach.

Po testach przyjęto 10 neuronów w jednej warstwie ukrytej oraz zdecydowano się na sigmoidalną funkcję aktywacji. Przy trenowaniu ustawiona liczba epok na 100 i uzyskano średni bezwzględny błąd procentowy na poziomie 3,18 %. Po wytrenowaniu sieci autor dokonał symulacji modelu przy zmianie każdego z parametrów wejściowych pozostawiając pozostałe bez zmian w zakresie od -30 % do +30 %. Analiza wskazała, że największy wpływ

na sprawność kotła mają zawartość tlenu w spalinach, nominalna moc cieplna oraz rzeczywiste obciążenie cieplne. Z podsumowania wynika, że model dobrze prognozuje zwiększenie sprawności kotła przy zmniejszeniu zawartości tlenu w spalinach lub zwiększeniu obciążenia cieplnego przy niezmienniej zawartości tlenu. Autor podsumowuje, że dzięki algorytmom można uzyskać wyższą sprawności kotłów opalanych:

- gazem ziemnym:
 - parowych o 0,5 % – 1,0 %,
 - wodnych 2,0 % – 3,5 %,
- olejem opałowym:
 - parowych o 0,5 % – 1,5 %
 - oraz 1,5 % – 3,5 % dla kotłów wodnych.

Podobne zagadnienie dot. analizy efektywności energetycznej kotła parowego przedstawił [9]. W analizowanych dwóch modelach sztucznej sieci neuronowej, zaprogramował jako sygnały wejściowe:

- obciążenie cieplne kotła,
- zawartość tlenu w spalinach,
- wartość opałowa paliwa,
- temperaturę wody zasilającej
- oraz zawartość części palnych w popiele.

Na tej podstawie skonstruowane zostały modele, które oprócz obowiązkowej warstwy wejściowej i wyjściowej dodatkowo zawierają dwie warstwy ukryte w swojej architekturze. Pierwsza składająca się z siedmiu lub dziewięciu neuronów natomiast druga z wyłącznie z dziewięciu. Współczynnik uczenia ustawiono na 0,05 natomiast jako sygnał wyjściowy przypisano procentową stratę kominową. Najwyższą dokładność modelu otrzymano dopiero przy 783 iteracji a parametrem, który miał największy wpływ na minimalizowanie straty był:

- nadmiar powietrza do spalania
- oraz temperatura spalin.

Model wskazał, że zwiększenie zawartości tlenu w spalinach z 4 % na 6 % powoduje zwiększenie straty kominowej o 0,8 %. Równocześnie zwiększenie zawartości części palnych w popiele w zakresie 0,8 % do 1,6 % zwiększa stratę kominową o ok. 1 %.

Kolejnym zastosowaniem algorytmów sztucznej sieci neuronowej jest ich implementacja w analizie sprawności skraplacza turbiny parowej. Autor w swojej pracy [10]

miał na celu określenie momentu w którym skraplacz kotła będzie wymagał czyszczenia. Predykcja zbudowana została na podstawie danych z elektrowni z okresu niepełnych 12 miesięcy. Algorytm zaprojektowany został w oprogramowaniu MATLAB. Na podstawie zgromadzonych danych autor na wejściu do algorytmu zaprogramował 44 parametry, które związane były ze:

- strumieniami wymienianego ciepła,
- natężeniem przepływu wody cyrkulującej,
- poziomowi wody w zbiorniku,
- zapotrzebowaniu na moc elektryczną,
- temperaturami oraz ciśnieniami panującymi w wymienniku.

Autor proponuje trzy typy modeli dla danych parametrów wejściowych. Pierwszy z nich prognozuje strumień wymienianego ciepła, drugi współczynnik przewodzenia ciepła a ostatni tzw. współczynnik czystości (cleanliness factor). Otrzymane prognozy dla przewidywanego strumienia ciepła nie odbiegają od rzeczywistych wartości o więcej niż o 2 %, natomiast prognozy dla współczynnika wymiany ciepła oscylują w granicach 15 – 20 % a dla współczynnika czystości 6 – 12 %.

W opracowaniu [11] autorzy wykorzystują sztuczne sieci neuronowe do predykcji wykorzystania ciepła dla budynku pasywnego. Niestety w analizie nie wykorzystywane są dane rzeczywiste do nauki algorytmu uczenia maszynowego, a zostają one wygenerowane z symulatora danych (jest to autorskie rozwiązanie o nazwie ZID). Zawierają one dane dla budynku przy różnych temperaturach zewnętrznych oraz o różnych konstrukcjach przegród. Badacze wykorzystali sieć neuronową do predykcji wykorzystania ciepła przez budynek w każdej godzinie. Testowane były różne architektury sieci neuronowej zawierające 3, 4 lub 5 warstw ukrytych jak również z różną liczbą neuronów. Autorzy zaproponowali równanie, które ma wyznaczać liczbę neuronów w warstwie ukrytej. Odpowiada ono połowie sumy neuronów w warstwie wejściowej i wyjściowej oraz pierwiastka z ilości danych do nauki algorytmu.

Źródłem danych do trenowania było 401 rekordów wygenerowanych za pomocą symulacyjnego oprogramowania z których 55 losowo wybranych próbek zostało wziętych do testowania dokładności algorytmu. Uczenie trwało około 6 minut i wymagało 690 epok. Po przeprowadzonym procesie uczenia zrealizowano predykcję zapotrzebowania na energię dla budynku. Model został zwalidowany w oparciu o inne komercyjne oprogramowanie i wykazywał wysoką dokładność (współczynnik determinacji wyniósł 0,9991). Autorzy zauważają, że koszt takich komercyjnych oprogramowań opartych na opisywaniu fizycznych zależności pomiędzy temperaturą zewnętrzną, nasłonecznieniem, konstrukcją przegród budowlanych jest wysoki.

W swojej pracy T. Cholewa [12] przedstawił metodę prognozowania zapotrzebowania na potrzeby ogrzewania dla istniejących jak i projektowanych budynków. Autorska metoda pozwala uwzględnić zmieniające się warunki atmosferyczne jak i preferencje użytkowników w zakresie komfortu cieplnego, przy jednoczesnym obniżeniu wykorzystania ciepła. Zaimplementowane algorytmy w opracowanym regulatorze sterowania węzła cieplnego wykorzystują zarówno wartość temperatury powietrza zewnętrznego, prędkości wiatru, nasłonecznienia lub zachmurzenia. Osiągnięta dokładność prognozy przekraczała 85 %.

Kolejnym przykładem zastosowania algorytmów sztucznej inteligencji proponują autorzy [13], którzy analizują zapotrzebowania na moc elektryczną w sezonie letnim w Tajlandii. Według danych z artykułu 60 % całkowitego zapotrzebowania na moc elektryczną w kraju wykorzystywane jest przez urządzenia do klimatyzacji. W celu uzyskania danych potrzebnych do analizy, opomiarowany został jeden z pokoi wydziału inżynierii uniwersytetu Chiang Mail w tym kraju. Zlokalizowany jest on na ósmym piętrze po stronie zachodniej przedmiotowego budynku. Całkowita powierzchnia pomieszczenia wynosiła 65,7 m². Autorzy zgromadzili dane z czujników, dla których pomiary były realizowane w kilku wariantach:

- całkowicie wyłączona klimatyzacja,
- włączona klimatyzacja z zadaną temperaturą powietrza w pomieszczeniu ustawioną na:
 - 25 °C,
 - 26 °C
 - oraz 27 °C.

Dane rejestrowano z minutowym interwałem dla każdego wariantu przez cztery tygodnie. W trakcie pomiarów nie było żadnej aktywności ludzkiej lub innej powodującej wpływ ciepła utajonego na wartość pomiarów. Kalkulacja obciążenia cieplnego odbyła się metodą tradycyjną biorąc pod uwagę strumienie wymienianego ciepła z każdym z sąsiadujących pomieszczeń oraz otoczeniem. Autorzy wykorzystując program MATLAB, zaprojektowali sztuczną sieć neuronową zawierającą:

- jedną warstwę wejściową,
- jedną warstwę ukrytą
- oraz jedną warstwę wyjściową.

Na podstawie własnej analizy wywnioskowali, że najbardziej czułymi parametrami powiązаныmi z obciążeniem cieplnym pomieszczenia są:

- temperatura powietrza zewnętrznego,

- temperatura powietrza w pomieszczeniu
- oraz natężenie promieniowania słonecznego.

To właśnie te 3 parametry stanowiły warstwę wejściową dla modelu, a w warstwie wyjściowej ustawiona została wartość obciążenia cieplnego. Autorzy eksperymentowali z różnymi architekturami sieci wprowadzając dodatkową warstwę ukrytą lub zwiększając liczbę neuronów np. do 20 w warstwie ukrytej oraz różne funkcje aktywacji. Do nauki modelu wykorzystano 11 520 rekordów a do weryfikacji 5 760. Dla tej analizy autorzy otrzymali wartość średnio-kwadratową błędu poniżej 0,1.

Inne podejście z wykorzystaniem algorytmów zaproponowali [14]. W swojej pracy szukają rozwiązań mających na celu zwiększenie efektywności energetycznej procesów związanych z wytwarzaniem prądu elektrycznego oraz ciepła. Na podstawie danych z dwóch agregatów kogeneracyjnych eksploatowanego obiektu w północnej części Włoch, autorzy próbują dopasować inne rozwiązanie oparte na kogeneracji tj. mikro turbina gazowa wraz z akumulatorem ciepła. Na podstawie zgromadzonych danych uruchomiono symulację pracy alternatywnego źródła prądu i ciepła. W zależności od wariantu pracy źródła (priorytet pracy w funkcji zapotrzebowania na prąd lub ciepło) autorzy uzyskują od 2 % do 6 % oszczędności energii pierwotnej.

Witold Chmielnicki w swoim artykule [15] wykorzystał algorytm uczenia maszynowego do regulacji pracy siłownika. Jest on sprzężony z zaworem regulacyjnym odpowiadającym za kontrolę przepływu czynnika grzewczego na potrzeby podgrzewania ciepłej wody użytkowej obiektu. W zaproponowanym modelu w warstwie wejściowej zdefiniowane są:

- temperatura czynnika grzewczego na zasilaniu oraz powrocie,
- temperatura ogrzewanego medium na wejściu i wyjściu z wymiennika ciepła,
- maksymalna temperatura ogrzewanego medium,
- pozycja zaworu regulacyjnego (jako sygnał zwrotny z siłownika).

Natomiast na wyjściu wymagana pozycja pracy zaworu regulacyjnego. Po wytrenowaniu modelu autor uzyskuje lepszą jakość regulacji temperatury ciepłej wody użytkowej w porównaniu z regulatorem PID. Podsumowuje, że regulatory oparte na sieciach neuronowych mają szersze zastosowanie niż ich klasyczne odpowiedniki i potrafią lepiej kontrolować układ aby nie dopuścić do jego niestabilnej pracy.

Kolejną analizę dotyczącą predykcji zapotrzebowania na energię elektryczną przeprowadzili [16]. Do badania autorzy wykorzystali dane zgromadzone w czasie od czerwca do grudnia 2018 r. z jednego z budynków komercyjnych w Malezji. Dane rejestrowane były z minutowym interwałem, a do modelowania zostało wykorzystane oprogramowanie Microsoft Azure Machine Learning Studio, wykorzystujące język

programowania R. Na potrzeby wytrenowania, a potem walidacji, podzielono zestaw dostępnych rekordów w proporcji 70/30. Trenowanie modelu w zależności od konfiguracji sieci neuronowej trwało od niecałych pięciu do ponad sześciu i pół godziny. Autorzy uzyskują bardzo dużą rozpiętość średniej kwadratowej błęd (RMSE) przy predykcji zapotrzebowania na energię elektryczną, która oscyluje od 1 % do nawet 43 %.

W swojej pracy [17] autorzy próbują zaimplementować algorytm sztucznej inteligencji do predykcji zapotrzebowania na ciepło dla budynków zasilanych z sieci ciepłowniczej. Do analizy posłużyły dane z pięciu budynków wielorodzinnych oraz pięciu budynków komercyjnych zlokalizowanych w Szwecji. Dane zostały zgromadzone w okresie od połowy lutego do początku kwietnia 2014 r. Do warstwy wejściowej algorytmu wprowadzono:

- temperaturę zewnętrzną,
- historyczną wartość obciążenia cieplnego,
- zmienną odpowiadającą aktualnej dacie
- oraz parametry dotyczące węzła cieplnego.

Dane dotyczące obciążenia cieplnego na potrzeby centralnego ogrzewania oraz ciepłej wody użytkowej był rejestrowane przez jeden ciepłomierz dla każdego budynku. W większości przypadków zaobserwowano szczytowe obciążenie cieplne w godzinach porannych pomiędzy 6 a 11. Natomiast w przypadku budynków wielorodzinnych zaobserwowano drugi szczyt obciążenia przypadający na godziny 18 – 22. Dla budynków komercyjnych ten drugi wierzchołek zapotrzebowania na moc nie występuje lub jest bardzo łagodny. Cały proces związany z uczeniem modelu został przeprowadzony w oprogramowaniu MATLAB. Autorzy prognozują zapotrzebowania na następne 24 godziny i w zależności od budynku uzyskują bardzo dobre wartości predykcji. Dla otrzymanych prognoz błąd NRMSE zawiera się w przedziale od 0,06 do 0,32. Parametr NRMSE definiowany jest jako błąd RMSE podzielony przez średnie obciążenie cieplne dla budynku (zgodnie z definicją autorów tekstu).

W zakresie predykcji zapotrzebowania ciepła w sieci ciepłowniczej podobną pracę opublikowali [18]. Autorzy na podstawie danych z systemu ciepłowniczego Karlshamn w Szwecji zgromadzili dane o zapotrzebowaniu na moc cieplną oraz temperaturze zewnętrznej z jednego pełnego sezonu grzewczego. Testowali dwa podejścia:

- pierwsze to stworzenie modelu indywidualnego dla każdego z budynków,
- a drugie to zunifikowany model na podstawie agregowanych danych o wszystkich budynkach.

Do nauki algorytmu wykorzystywano również prognozy pogody, które były aktualizowane z godzinowym interwałem. Autorzy prognozowali zapotrzebowanie na moc cieplną w oparciu o prognozę pogody na najbliższe 24 godziny. Testy wykazały minimalną przewagę na korzyść

globalnego modelu, który charakteryzował się średnim bezwzględnym błędem procentowym MAPE na poziomie 4,8 % w stosunku do indywidualnego podejścia z błędem 5,1 %.

Podobną analizę zaprezentowali [19], która dotyczy predykcji zapotrzebowania na prąd elektryczny. Zgromadzono dane trzypiętrowego budynku w Tajwanie o powierzchni całkowitej 350 m². Rekordy, które pierwotnie były zapisywane z interwałem 1 minutowym zostały uśrednione w celu uzyskania wartości 15-minutowych. Na wejściu modelu zostały wprowadzone trzy parametry:

- wartość temperatury zewnętrznej,
- dzień tygodnia
- oraz godzina.

Cały algorytm zaprojektowany został w programie MATLAB. Uzyskana prognoza wykorzystania energii dla budynku sprawdziła się bardzo dobrze dla algorytmów sztucznej inteligencji. Autorzy jednak proponują zastosowanie rozwiązań hybrydowych, które łączą zarówno sieci neuronowe jak i inne metody (np. SVR, CART, LR, SARIMA). Zaproponowany przez nich model nazwany SARIMA–MetaFA–LSSVR, który w zależności od zastosowania, miał wyższą skuteczność od 3 % do nawet 72 % w porównaniu dla modelu pojedynczego wykorzystującego wyłącznie sztuczne sieci neuronowe.

Zastosowanie sztucznej inteligencji zaproponowali oraz wdrożyli autorzy [20] w swojej pracy. Na podstawie zgromadzonych danych dla systemu ciepłowniczego zlokalizowanego w Ljubljanie w Słowenii opracowali model do prognozy zapotrzebowania na moc cieplną. Perspektywa analizy dla całego systemu grzewczego obejmowała horyzont od 1 do 48 godzin. Pracujący system ciepłowniczy miał nominalne parametry pracy 118/80 st. C i zasiliał ok. 65 tysięcy odbiorców za pośrednictwem sieci rurociągów o długości 270 km. Zgromadzone dane z prawie pięciu lat posłużyły jako wsad do wytrenowania modelu. Zawierały one m.in.:

- godzinowe zapotrzebowanie na moc cieplną na wyjściu z ciepłowni,
- zmierzoną temperaturę powietrza zewnętrznego
- oraz archiwalną prognozę pogody, która zawierała również:
 - nasłonecznienie,
 - wilgotność względną powietrza zewnętrznego
 - oraz prędkość wiatru

Architektura modelu zawierała:

- jedną warstwę wejściową,

- jedną warstwę ukrytą z sigmoidalną funkcją aktywacji
- oraz jedną warstwę wyjściową.

Warstwa wyjściowa zawierała 48 wartości zapotrzebowania na moc ciepłą, która odpowiada horyzontowi predykcji ustawionym na najbliższe 48 godzin. Model został zaprojektowany w kilku wersjach różniących się między sobą liczbą neuronów w warstwie ukrytej (w zakresie od 2 do 4). Skonstruowany algorytm w oprogramowaniu MATLAB został wyuczony w 200 epokach w czasie nieprzekraczającym jednej minuty. Prognozy zapotrzebowania na moc ciepłą bazujące wyłącznie na danych historycznych miały błąd ok. 5 %. Ich uzupełnienie o dane meteorologiczne umożliwiły zwiększenie dokładności o kolejne 2 %. Autorzy wysunęli również wniosek, że wprowadzenie do sieci neuronowej informacji o nasłonecznieniu ma marginalny wpływ na prognozę zapotrzebowania na moc ciepłą.

Bazując na danych z systemu ciepłowniczego w mieście Uppsala w Szwecji autorzy [21] zbudowali model, który miał na celu predykcję zapotrzebowania na moc ciepłą oraz temperaturę powrotu z sieci ciepłowniczej. Ideą było zwiększenie produkcji ciepła z turbiny parowej przez maksymalne obniżenie temperatury powrotu z sieci. Na wejściu model miał zdefiniowane:

- obciążenie cieplne dla 24, 48 i 72 godzin historycznych oraz 7 dni wstecz,
- średnią moc ciepłą z ostatnich 24 godzin,
- prognozę temperatury powietrza zewnętrznego
- oraz dzień tygodnia reprezentowany w formie binarnej.

W warstwie ukrytej zastosowano 10 neuronów. Autorzy mieli do dyspozycji dane zarówno po stronie odbiorcy ciepła (pomiar z węzła cieplnego) jak i po stronie źródła (dane z elektrociepłowni). Analizując predykcje zapotrzebowania na ciepło doszli do wniosku, że model zbudowany na podstawie danych z węzłów cieplnych daje lepsze rezultaty. Ostateczny rezultat po przeprowadzonych symulacjach z wykorzystaniem modeli sztucznych sieci neuronowych umożliwił obniżenie temperatury zasilania sieci ciepłowniczej w zakresie od 1,1 do 2,8 st. C. Przełożyłoby się to na obniżenie kosztów produkcji o ok. 1,2 % – 1,5 %. Autorzy przy predykcji zapotrzebowania na ciepło osiągnęli błąd rzędu 11 % argumentując, że wyższa dokładność predykcji byłaby do osiągnięcia przy większej ilości danych do trenowania modelu.

Podobny temat poruszył w swoim artykule K. Łukaszewski [22], który wykorzystując sztuczne sieci neuronowe opisuje model do prognozowania zapotrzebowania na ciepło dla horyzontu 1 do 4 godzin dla zespołu budynków Politechniki Warszawskiej. Autor przedstawia różne analizy jak powinien zostać opracowany model predykcji zapotrzebowania na ciepło, który uwzględnia warunki atmosferyczne czy straty ciepła na dystrybucji od źródła do

odbiorcy końcowego. Niestety nie dowiadujemy się jak wyglądał docelowy model sieci neuronowej ani jaką miał dokładność.

W pracy [23] autor szczegółowo opisuje zaprojektowany model, którego celem była predykcja zapotrzebowania na ciepło dla pomieszczeń w budynku. Źródłem było 250 obiektów zlokalizowanych na Cyprze, które były opomiarowane pod kątem zapotrzebowania na moc cieplną. Dane źródłowe zawierały również dobrze opisane parametry charakterystyczne budynków tj.:

- powierzchnia i liczba pomieszczeń wraz z ich temperaturą wewnętrzną,
- powierzchnia oraz budowa ścian i okien,
- podpiwniczenie lub jego brak.

Na wejściu do modelu zaproponowane zostały następujące parametry:

- powierzchnia okien,
- powierzchnia ścian zewnętrznych,
- powierzchnia przegród wewnętrznych,
- powierzchnia podłogi,
- podpiwniczenie (wyrażone jako sygnał binarny 0 lub 1),
- typ okien,
- konstrukcja ściany
- oraz projektowana temperatura wewnętrzna.

W przypadku konstrukcji ścian i okien A. Kalogirou przypisuje w zależności od wartości współczynnika przewodzenia ciepła odpowiednią kategorię dla elementu, która ma wartość w zakresie od 0 do 4 (gdzie 4 oznacza najniższy współczynnik przewodzenia ciepła). Autor przetestował kilka różnych struktur modelu i ostatecznie proponuje zastosowanie 3 warstw ukrytych z różnymi funkcjami aktywacji (gaussian, tanh oraz gaussian complement). W każdej warstwie ukrytej znajduje się 10 neuronów, a na wyjściu otrzymujemy jeden neuron odpowiadający za wartość obciążenia cieplnego wyrażoną w kcal/hr. Dane źródłowe podzielone zostały na dwie grupy:

- pierwsza zawierająca pomieszczenia o powierzchni do 7 m²,
- a druga od 7 do 100 m².

Dzięki takiemu podziałowi otrzymano dokładność modelu na poziomie 10 % dla pierwszej grupy i 9 % dla drugiej.

Tematykę planowania pracy kogeneracyjnej elektrociepłowni współpracującej z akumulatorem ciepła podjęli również P. Żymelka oraz M. Szega w swoim artykule [24]. Analizowany obiekt składa się z dwóch turbin gazowych o mocy elektrycznej 42,1 MW_e (przy sprawności 40,6 %). Całkowita ich moc cieplna wraz z dodatkowymi układami kotłów gazowo–olejowych wynosi 311,8 MW_t. Układ współpracuje z akumulatorem ciepła o pojemności 12 000 m³ o nominalnej pojemności cieplnej 575 MWh. Autorzy w pierwszej części podjęli próbę prognozowania cen energii elektrycznej na Rynku Dnia Następnego. Porównują przy tym metody oparte na statystyce oraz uczeniu maszynowym. Na potrzeby wytrenowania modelu zgromadzono dane w dwóch wariantach 7 i 14 dni wstecz. Błąd w zakresie predykcji na podstawie danych z 7 ostatnich dni wynosił w zakresie od 8,32 % do 12,20 % a dla 14 dni od 7,00 % do 9,42 %. Najlepszą skuteczność osiągnęły modele oparte o gęste sieci neuronowe oraz metodę statystyczną do prognozowania szeregów czasowych AUTO ARIMA. Dalsze symulacje związane z określeniem wymaganych parametrów pracy elektrociepłowni potrzebne do zaplanowania produkcji zostały opracowane z wykorzystaniem oprogramowania EBSILON PROFESSIONAL. Zbudowany model ma za zadanie optymalnie planować produkcję biorąc pod uwagę produkcję energii elektrycznej i cieplnej jak również zużycie paliwa. Zapotrzebowanie na moc cieplną w analizowanym systemie ciepłowniczym waha się od 30 MW_t (dla temperatury zasilania 70 st. C i powrotu 50 st. C) w sezonie letnim do 200 MW (dla temperatury zasilania 115 st. C i powrotu 60 st. C) w sezonie zimowym. Na potrzeby predykcji zapotrzebowania na moc cieplną wykorzystano sztuczną sieć neuronową oprogramowaną w języku R. Podział danych na potrzeby wytrenowania modelu podzielono w proporcjach 70/15/15 (trenowanie, sprawdzenie, testy), na które składały się:

- temperatura powietrza zewnętrznego,
- prędkość wiatru,
- wilgotność względną powietrza
- i zapotrzebowanie na moc cieplną z ostatnich 24 godzin dla obiektu.

Zastosowano sieć złożoną z pięciu warstw ukrytych w celu predykcji zapotrzebowania na moc cieplną. Uzyskana dokładność modelu sieci neuronowej wyniosła 3,65 %.

Kolejny model matematyczny wykorzystany do planowania pracy urządzeń w elektrociepłowni wykorzystuje parametry zewnętrzne funkcjonowania obiektu tj.:

- dyspozycyjność jednostek wytwórczych,
- aktualną pojemność cieplną akumulatora,
- wymaganą moc cieplną na zasilaniu sieci ciepłowniczej
- oraz parametry sieci cieplnej.

Następnie autorzy opracowali równanie, które ma optymalizować proces produkcji elektrociepłowni z wykorzystaniem akumulatora ciepła. Równanie, którego wynikiem jest maksymalizacja przychodu z elektrociepłowni, ma w swoich zmiennych w horyzoncie najbliższych 24 godzin:

- przychód ze sprzedaży energii elektrycznej oraz ciepłej,
- premię kogeneracyjną,
- koszty:
 - paliwa,
 - ochrony środowiska,
 - potrzeb własnych
 - oraz wynikający z uruchomienia i zatrzymania turbin.

W pierwszym etapie analizowana jest dopuszczalna zdolność produkcji energii ciepłej i elektrycznej na najbliższe 24 godziny. Następnie analizowany jest scenariusz pracy turbiny oraz całej elektrociepłowni biorąc pod uwagę:

- poziom gorącej wody w akumulatorze,
- maksymalną liczbę ładowań i rozładowań akumulatora,
- wymaganą moc ciepłą dostarczaną do sieci ciepłowniczej,
- maksymalną moc turbiny i kotłów
- oraz maksymalną ilość zużytego paliwa gazowego.

Poszukiwanie optymalnego rozwiązania odbywało się poprzez zmianę odpowiedniego parametru podczas pracy układu w każdej godzinie dnia. Model zyskał dużą dokładność, która dla predykcji:

- ceny energii elektrycznej wyniosła 2,07 %,
- 2,17 % dla produkcji energii ciepłej
- oraz 2,83 % dla zużycia gazu w turbinach.

Ciekawego przeglądu metod uczenia maszynowego dokonali autorzy w swojej pracy [25] podkreślając, że w 2018 r. wykorzystanie energii na potrzeby budownictwa generowało ok. 40 % globalnej emisji dwutlenku węgla. Tendencja ta ma się wg nich w kolejnych latach nasilać. Możliwość prognozowania zapotrzebowania na energię umożliwi lepsze jej zarządzanie i optymalizację produkcji. Na podstawie przeprowadzonych analiz, autorzy zauważyli, że najczęściej wykorzystywanym horyzontem dla predykcji jest okres jednej godziny lub krótszy (90 % analiz). Pozostałe okresy dotyczą dłuższych okresów z taką uwagą,

że okres miesięczny był bardzo rzadko wykorzystywany (raz na sto przypadków). W artykule poruszane jest zagadnienie prognozowania zużycia paliwa gazowego na następny dzień. Autorzy zastosowali metodę klastrowania do określenia, który z modeli wykorzystujących sieć opartą na LSTM najlepiej sprawdzi się w predykcji. Podejście to zostało zweryfikowane i potwierdzono wzrost dokładności przy prognozowaniu z wykorzystaniem takiej metody. Jak podkreślono w dalszej części artykułu, konieczne są dalsze prace badawcze.

Inne zastosowanie klastrowania z wykorzystaniem metody k-średnich oraz metody hierarchicznej, wykorzystał w swojej rozprawie K. Bandurski [26]. W celu pogrupowania gospodarstw domowych wg sposobu użytkowania instalacji w budynku dokonał porównania obu metod. Udowodnił, że obie uzyskują podobne wyniki jak również wskazał podział na 4 grupy gospodarstw jako najbardziej racjonalny.

W artykule [27] autorzy również zajmują się prognozowaniem zapotrzebowania na ciepło dla 52 budynków przyłączonych do sieci ciepłowniczej zasilanych z wykorzystaniem STTS (Short-term Thermal Storage) oraz BTES (Borehole Thermal Energy Storage). Zakumulowana w ten sposób energia może zostać wykorzystywana, w zależności od typu, w różnym okresie czasu. Celem analizy jest prognozowanie zapotrzebowania na ciepło w horyzoncie kilku najbliższych godzin. Autorzy zauważają, że na zapotrzebowania na moc cieplną największy wpływ mają:

- warunki atmosferyczne tj.:
 - temperatura zewnętrzna,
 - nasłonecznienie
 - oraz wilgotność względna powietrza zewnętrznego.

Na potrzeby analizy zostały wykorzystane różnego typu algorytmy jak SVM, DT, LR oraz ANN zawierającą jedną warstwę ukrytą złożoną z 10 neuronów (jako funkcja aktywacji został wybrany tangens sigmoidalny). Wnioski z analiz podkreślają, że wykorzystanie sztucznych sieci neuronowych do prognozowania zapotrzebowania na ciepło dla zespołu budynków ma większą dokładność niż inne metody uczenia maszynowego. Nie zauważono jednak znacznej poprawy w prognozowaniu przy uwzględnieniu natężenia promieniowania słonecznego oraz czasu przebywania mieszkańców w lokalach (założono, że w dniach od poniedziałku do piątku w godzinach od 8 do 18 mieszkańcy przebywają w pracy). Autorzy zauważają, że niski wpływ na jakość predykcji tych czynników może być spowodowany indywidualnymi zachowaniami mieszkańców oraz nieuwzględnieniem rzeczywistego ukierunkowania przegród szklanych w stosunku do źródła promieniowania.

W kolejnym artykule [28] autorzy poszukują metody automatyzującej zarządzanie energią w sieci elektroenergetycznej. Zastosowane zostały urządzenia wykorzystujące internet rzeczy oraz sztuczne sieci neuronowe. Analiza została zrealizowana na podstawie danych z szesnastu ośmiopiętrowych budynków mieszczących 216 lokali. Zasilane są one w 70 %

z odnawialnych źródeł energii (pompy ciepła sprzężone ze źródłem geotermalnym). Autorzy prognozują, że w niedalekiej przyszłości sterowanie systemami energetycznymi w mieście będzie odbywało się wyłącznie z wykorzystaniem sztucznej inteligencji co spowoduje wzrost efektywności energetycznej oraz jakości życia w miastach. Na potrzeby analiz różnych scenariuszy została opracowana cyfrowa kopia całego osiedla wykorzystując oprogramowanie z rodziny AUTODESK. Dzięki takiemu podejściu możliwe jest opracowanie wielu symulacji pracy całego systemu energetycznego i jego reakcji na różne zdarzenia losowe. W budynkach zainstalowano szereg czujników wykorzystujących IoT, które w czasie rzeczywistym przesyłają dane do systemu na temat chwilowego wykorzystania energii elektrycznej na potrzeby oświetlenia, ogrzewania, wentylacji i klimatyzacji oraz urządzeń AGD. Model wymaga również wprowadzenia do systemu informacji na temat konstrukcji przegród budowlanych (grubości, współczynnika przewodzenia ciepła). Różne metody w algorytmie przeanalizowały zachowania mieszkańców wybierając wariant zachowań skutkujący najmniejszym wykorzystaniem energii. Został on następnie skopiowany na inne lokale o podobnym charakterze i wykorzystaniu energii. Dzięki takiemu podejściu obniżono roczne zapotrzebowanie na energię dla całego budynku z 26,8 kWh/m² do 16,1 kWh/m². Wg autorów, tego typu algorytmy będą miały w przyszłości zdolność do podejmowania autonomicznych decyzji i kontrolę nad załączaniem i regulacją odbiorników w budynkach.

Podobne podejście do prognozowania zapotrzebowania na energię elektryczną na najbliższe 24 godziny proponują [29]. Autorzy analizują różne konfiguracje sieci neuronowej opartej o LSTM [30], GRU oraz K-clustering. Na podstawie zgromadzonych danych z liczników energii elektrycznej dokonano ich pogrupowania (z wykorzystaniem K-najbliższych sąsiadów) tworząc profile zużycia podzielone na trzy grupy:

- minimalne,
- średnie
- oraz maksymalne zużycie.

Do uczenia modelu wykorzystano dane testowe zawierające 1, 3 lub 6 miesięcy archiwalnych pomiarów z całego 2010 roku. Zastosowano różne konfiguracje struktury sieci neuronowej:

- od 16 do 128 neuronów w warstwach ukrytych,
- współczynniki uczenia od 0,001 do 0,01
- oraz liczbą epok od 50 do 200.

Opracowany model wykorzystuje w pierwszym etapie wybór odpowiedniego profilu dla odbiorcy aby w kolejnym uruchomić predykcję z wykorzystaniem sztucznej sieci neuronowej. Autorzy dokonali podsumowania, z którego wynika, że wykorzystanie modelu opartego o:

- rekurencyjne sieci neuronowe ma błąd ok. 8 %,
- sieci neuronowe wykorzystującą bramkę:
 - LSTM ma błąd ok. 6 %,
 - GRU ma błąd ok. 5 %.

W przypadku metod statystycznych wykorzystanych do prognozowania zapotrzebowania błąd predykcji wynosił ok. 18 %.

Bardzo podobnym zagadnieniem zajęli się autorzy [31] przy próbie prognozowania na moc chłodniczą. Opracowane we własnym zakresie modele sztucznej sieci neuronowej, zaprogramowane w programie MATLAB, zostały zaimplementowane do analizy 12 budynków o całkowitej kubaturze 771 m³. Testowane były różne konfiguracje sieci od 1 do 10 warstw ukrytych natomiast jako funkcję aktywacji wykorzystano tangens sigmoidalny. Autorzy uzyskali najmniejszy błąd procentowy dla modelu SFS (Stochastic Fractal Search) wynoszący od 6 % do 15 % w porównaniu do pozostałych modeli tj. Grasshopper Optimization Algorithm (GOA) oraz Firefly Algorithm (FA), które osiągnęły wynik od 8 % do 25 %.

Inne zastosowanie prezentują autorzy w [32], którzy próbują zaimplementować algorytmy uczenia maszynowego do wyznaczania zawartości wilgoci w przegrodach budowlanych. Zgodnie z ich opinią, najlepszym urządzeniem do przeprowadzenia tego typu pomiarów jest zastosowanie EIT (Electrical Impedance Tomography). Narzędzie to wymaga jednak zastosowania odpowiedniego algorytmu odpowiedzialnego za konwersję pomierzonych wartości na obraz wyjściowy. W przykładowej analizie autorzy opracowali metodę do przekształcenia 448 pomiarów w trójwymiarowe zdjęcie zawierające 7 765 pikseli. Do analizy wykorzystano metody oparte na regresji liniowej, modelu Gaussa–Newtona z regularyzacją Tikhonova oraz sztuczną sieć neuronową. W przypadku sieci neuronowej skonstruowano model, który w pierwszej warstwie zawierał 448 wejść, w kolejnej jedną warstwę ukrytą z 12 neuronami i na końcu warstwę wyjściową z jednym parametrem. Funkcją aktywacji był tangens hiperboliczny. Uczenie zostało zrealizowane na podstawie 44 000 przykładów podzielonych w proporcji 70/15/15. Wyniki otrzymane za pomocą sztucznej sieci neuronowej mają dwukrotnie mniejszy błąd tj. ok. 15 % w stosunku do innych metod.

Podobną tematyką zajmują się autorzy [33]. Widzą oni dużą możliwość w zmniejszeniu emisji dwutlenku węgla oraz zwiększeniu sprawności sieci ciepłych wykorzystując do optymalizacji sztuczne sieci neuronowe. Do analizy wykorzystane zostało oprogramowanie ENERGYPLUS oraz TRANSYS. Autorzy wykorzystują dane z dwóch

projektów *Sharing Cities* oraz *Remourban* skierowanych do domów mieszkalnych. Dane z pierwszego projektu zawierają informacje o:

- dacie,
- temperaturze powietrza zewnętrznego,
- oraz zapotrzebowaniu na moc cieplną.

Dotyczą one 95 domów w Londynie z 3 ostatnich lat z 15–sto minutową rejestracją powyższych parametrów. Drugim systemem źródłowym jest *Remourban*, który gromadzi dane z 30 budynków z ostatniego roku z częstotliwością 1 min. Wszystkie dane zostały skonwertowane do interwału 15. minutowego i zsumowane na potrzeby prognozy całkowitego zapotrzebowania na ciepło. Zbudowany model charakteryzuje się zadowalającą dokładnością wynoszącą 73 % w przypadku danych z projektu *Remourban*. Natomiast w przypadku projektu *Sharing Cities* spada ona bardzo nisko do ok. 21 %. Taką małą dokładność autorzy argumentują bardzo małą liczbą dostępnych parametrów do wykorzystania w procesie uczenia w porównaniu z danymi z projektu *Remourban*. Dysponował on informacjami o wilgotności względnej powietrza zewnętrznego jego ciśnieniu, prędkości wiatru jak również godziny wschodu i zachodu słońca.

W publikacji [34] autorzy wykorzystują algorytm SVM do analizy parametrów transformatorów wysokiego napięcia i oceny ich prawidłowego funkcjonowania. Opracowana metoda została wdrożona na podstawie danych źródłowych o funkcjonowaniu 448 urządzeń w systemie elektroenergetycznym. Podobne zastosowanie sieci neuronowych w zabezpieczeniu mikro sieci elektroenergetycznej przez awariami zaproponowali [35]. Analizując parametry sieci możliwe jest wcześniejsze odłączenie lokalnego systemu elektroenergetycznego i przejście do pracy na tzw. wyspę energetyczną w celu zapewnienia stabilności zasilania klientów.

Wykorzystanie uczenia maszynowego może też być zastosowane w analizie ekonomicznej funkcjonowania systemu elektroenergetycznego [36], [37]. Autorzy podkreślają, że inteligentna sieć dystrybucji energii elektrycznej to obiecująca technologia, która przekształci tradycyjny przemysł energetyczny. Wzrost rozproszonych źródeł, takich jak odnawialne źródła energii, magazyny energii i pojazdy elektryczne, znacząco wpływa na sieci energetyczne. Ponadto konsumenci są coraz bardziej świadomi korzyści środowiskowych i ekonomicznych wykorzystywania odnawialnych źródeł energii, które w połączeniu z magazynowaniem sprawiają, że ich zapotrzebowanie na energię jest bardziej elastyczne, do czego muszą dostosowywać się producenci.

2.2. Aktualne osiągnięcia programistyczne w zakresie uczenia maszynowego i sztucznych sieci neuronowych.

Pojęcie uczenia maszynowego jest bardzo szerokie i obejmuje wiele metod, które można pogrupować wg różnych parametrów [38]. Pierwsza grupa związana jest z jawnym reprezentowaniem metody działania algorytmu, którego postać powinna być czytelna i zrozumiała dla człowieka. Zaliczamy do niej m.in. algorytmy indukcji drzew decyzyjnych czy indukcyjne programowanie logiczne [39]. Druga grupa to tzw. metody „nieprzezroczyste”, które nie tworzą jawnej reprezentacji wiedzy (tak zwane metody czarnej skrzynki). Te rozwiązania posiadają wewnętrzne zapisy, które nie są łatwe (lub nawet niemożliwe) do zinterpretowania przez człowieka i zaliczają się do niej m.in. sztuczne sieci neuronowe [40]. Inną formą podziału może być sposób trenowania danego modelu. Może to być uczenie nadzorowane, w którym tzw. programista–nauczyciel wskazuje jakie dane stanowią źródło wiedzy a jakie będą informacje wyjściowe. W przeciwieństwie do uczenia nienadzorowanego, w którym dostarczane są wyłącznie dane wejściowe i oczekuje się od algorytmu znalezienia powiązań pomiędzy nimi.

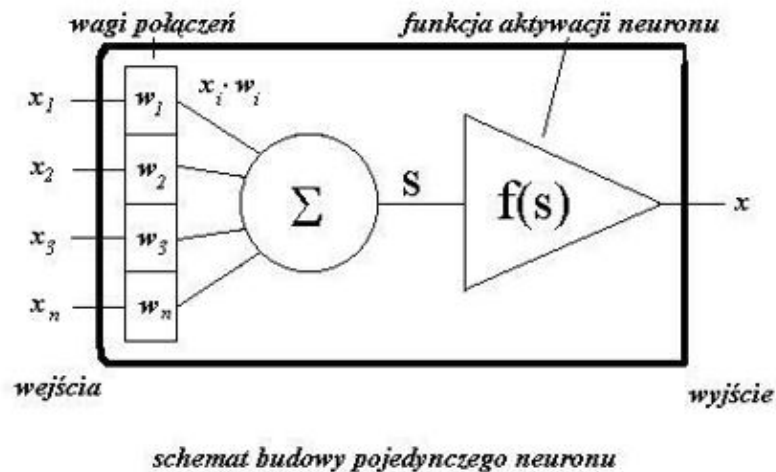
Mnogość metod uczenia maszynowego, które należy stosować w zależności od postawionego problemu powoduje często problem z jej odpowiednim wyborem, w przeciwieństwie do sztucznych sieci neuronowych [41]. Ich uniwersalne zastosowanie sprawia, że bardzo dobrze będą sobie radziły z prostym jak i skomplikowanym problemem w zależności od zaprogramowanej architektury. Metoda ta jest wzorowana na ludzkich komórkach nerwowych, które charakteryzują się wysokim stopniem powiązania (rzędu 10^{14} [42]). Symulacja takiej liczby neuronów jest w aktualnych systemach komputerowych nie do osiągnięcia, w przeciwieństwie do kilkunastu tysięcy neuronów, które będą mogły rozwiązywać prostsze problemy.

Architektura sztucznej sieci neuronowej składa się z kilku elementów, które pracują równolegle i się ze sobą komunikują. Ich siła leży w liczbie neuronów, liczbie połączeń między nimi, zdefiniowaną odpowiednią strukturą oraz dobranymi wagami w trakcie procesu uczenia [43].

Do jej podstawowych elementów zaliczamy:

- warstwę wejściową, w której następuje wprowadzenie sygnałów zewnętrznych (danych zarówno na etapie uczenia a później na etapie predykcji),
- wagi, które odpowiadają za aktywację poszczególnych neuronów w sieci,
- funkcję aktywacji odpowiedzialną za obliczanie pobudzenia danego neuronu na podstawie wag i sygnałów wejściowych,
- warstwę wyjściową z której sygnały są wyprowadzane z sieci i mogą być wykorzystywane do dalszej analizy.


Każde stworzone połączenie pomiędzy wyjściem jednego neuronu jest powiązane z wejściem do kolejnego z wagą przypisaną w trakcie uczenia. Skonstruowany w ten sposób neuron jest prezentowany najczęściej w sposób przedstawiony na Rys. 2.1.



Rys. 2.1. Schemat budowy pojedynczego sztucznego neuronu wykorzystywanego do budowy sieci neuronowej. Źródło: [44]

Ich połączenie w całą sieć przedstawione jest w sposób schematyczny na Rys. 2.2. Aktualnie możemy wyróżnić dwa podstawowe sposoby łączenia poszczególnych neuronów uzależnione od sposobu przepływu sygnału przez taką sieć:

- jednokierunkowe sieci neuronowe [45], w których przepływ sygnału realizowany jest w jednym kierunku tj. od warstwy wejściowej do wyjściowej za pośrednictwem warstw ukrytych oraz
- rekurencyjne sieci neuronowe, w których przepływ sygnału może być realizowany w dwóch kierunkach od warstwy wejściowej przez warstwy ukryte do warstwy wyjściowej. Są one rozszerzeniem jednokierunkowej sieci neuronowej i wymagają większej mocy obliczeniowej. Występujące w nich sprzężenie zwrotne znacznie lepiej radzi sobie z analizą sekwencyjnych danych i umożliwia im „zapamiętywanie” poprzednich informacji w celu ich wykorzystania do predykcji przyszłych wartości. Doskonale radzą sobie z analizą danych, które z biegiem czasu ewoluują i w których informacja z kolejnego kroku może wpłynąć na wartość z kroku poprzedniego o czym pisali m.in. [46], [47], [48].



Rys. 2.2. Schemat połączeń neuronów pomiędzy warstwami sieci neuronowej. Źródło: [49]

Do podstawowej jednostki sieci neuronowej należą warstwy, które mogą mieć określone właściwości i sprawdzać się najlepiej w konkretnym zastosowaniu (rozpoznawanie obrazów [50], analiza danych [51], rozpoznawanie komórek [52] lub kolorów [53] itp.). Większość z nich może być dowolnie łączona tak aby zwiększyć (lub zmniejszyć) dokładność prognozy i posiadać dowolną liczbę neuronów [54].

Tabela 2.1. Typy warstw sztucznej sieci neuronowej dostępne w bibliotece TensorFlow / Keras.


Typy warstw sztucznej sieci neuronowej dostępne w bibliotece TensorFlow / Keras		
Dense	MaxPooling1D	LSTM
EinsumDense	MaxPooling2D	LSTM cell
Activation	MaxPooling3D	GRU
Embedding	AveragePooling1D	GRU Cell
Masking	AveragePooling2D	SimpleRNN
Lambda	AveragePooling3D	TimeDistributed
Identity	GlobalMaxPooling1D	ConvLSTM1D
Conv1D	GlobalMaxPooling2D	ConvLSTM2D
Conv2D	GlobalMaxPooling3D	ConvLSTM3D

Typy warstw sztucznej sieci neuronowej dostępne w bibliotece TensorFlow / Keras		
Conv3D	GlobalAveragePooling1D	Conv1DTranspose
SeparableConv1D	GlobalAveragePooling2D	Conv2DTranspose
SeparableConv2D	GlobalAveragePooling3D	Conv3DTranspose
DepthwiseConv1D	Base RNN	Stacked RNN cell
DepthwiseConv2D	Simple RNN cell	Bidirectional

Dodatkowo możemy wyróżnić różne funkcje aktywacji, których przykładowe przebiegi zostały przedstawione na Rys. 2.3. Natomiast w Tabeli 2.2 zaprezentowano możliwości ich wyboru posługując się biblioteką TENSORFLOW / KERAS.

Tabela 2.2. Typy funkcji aktywacji sztucznej sieci neuronowej dostępne w bibliotece TensorFlow / Keras.

Typy funkcji aktywacji sztucznej sieci neuronowej dostępne w bibliotece TensorFlow / Keras		
relu	silu	exponential
sigmoid	hard_silu	leaky_relu
softmax	gelu	relu6
softplus	hard_sigmoid	mish
softsign	linear	log
tanh	selu	elu



Rys. 2.3. Zestawienie popularnych funkcji aktywacji wraz z ich graficznym odwzorowaniem.
 Źródło: [55]

Najbardziej popularną funkcją aktywacji w różnego typu zastosowaniach jest ReLU [56] (Rectified Linear Unit). Przyjmuje ona postać liniową dla wartości dodatnich a dla ujemnych jest równa zero. Jej popularność w głównej mierze polega na nieznaczących wymaganiach pod kątem mocy obliczeniowej komputera w przeciwieństwie do funkcji sigmoidalnej lub tanh, w której konieczne jest przeprowadzenie obliczeń wykładniczych [57].

Zbudowanie struktury sieci neuronowej wymaga również zdefiniowania funkcji optymalizacji czyli mechanizmu jaki będzie odpowiedzialny za aktualizację wag sieci po każdej epoce. Ich wybór jest uzależniony od konkretnej aplikacji a zakres możliwości został zaprezentowany w Tabeli 2.3. Dla wybranej funkcji optymalizacji należy określić tzw. szybkość uczenia. Bardzo mała wartość skutkuje długim procesem, który może utknąć w lokalnym minimum funkcji. Zbyt duży parametr przyspieszy proces uczenia ale jednocześnie może obniżyć jego dokładność. W takiej sytuacji algorytm może nie być w stanie uzyskać najmniejszej wartości funkcji straty przy wyszukiwaniu rozwiązania.

Tabela 2.3. Typy funkcji optymalizacji sztucznej sieci neuronowej dostępne w bibliotece TensorFlow / Keras.

Typy funkcji optymalizacji sztucznej sieci neuronowej dostępne w bibliotece TensorFlow / Keras		
SGD	Adadelata	Nadam
RMSprop	Adagrad	Ftrl
Adam	Adamax	Lion
AdamW	Adafactor	Loss Scale Optimizer

Określenie wartości funkcji straty wymaga wyliczenia błędu tj. różnicy pomiędzy wartością prognozowaną a rzeczywistą. Można zdefiniować sposób jej wyliczenia wybierając do tego odpowiedni mechanizm. W przypadku problemów regresji liniowej możemy najczęściej spotkać się z:

- średnim błędem kwadratowym,
- średnim błędem bezwzględnym,
- średnim procentowym błędem bezwzględnym,
- metodą HUBER
- i innymi opisanymi szczegółowo w bibliotece TENSORFLOW/KERAS.

Dysponując komputerem o ogromnej liczbie zasobów, możliwe jest zbudowanie architektury o bardzo dużej liczbie warstw i neuronów. Takie podejście mogłoby sugerować utworzenie modelu sieci, która z najlepszą możliwą dokładnością rozwiąże każdy postawiony przed nią problem. Jednak jak udowodniono w wielu publikacjach może ono doprowadzić do efektu tzw. przeuczenia. Głównymi jego przyczynami są wg [58] zbyt rozbudowana architektura sieci lub zbyt długi proces uczenia. Jest to zjawisko, które powoduje, że sieć zbyt dobrze dopasowuje się do danych prezentowanych w trakcie procesu uczenia i bardzo słabo sobie radzi z danymi do których nigdy nie miała dostępu. Natomiast pojęciem odwrotnym jest niedouczenie, w którym sieć nie potrafi rozwiązać przedstawionego problemu i jest konsekwencją zbyt małej liczby neuronów lub parametrów zaplanowanych w takiej architekturze.

Sam proces uczenia (trenowania) polega w dużym skrócie na:

- wylosowaniu wag dla każdego połączenia pomiędzy neuronami podczas inicjowania struktury sieci,
- korekcji tych wag w każdych kolejnych iteracjach na podstawie porównywania rezultatu z warstwy wyjściowej w stosunku do danych rzeczywistych (przedstawianych w trakcie procesu uczenia).

Jest to etap najdłuższy przy pracy ze skomplikowanymi układami sieci neuronowych i wymaga najwięcej mocy obliczeniowej, o czym piszą [59]. W trakcie tego procesu oprogramowanie będzie dążyło do minimalizacji funkcji straty. Różnica ta może mieć określoną granicę przy której proces ten się zakończy i nie będą losowane kolejne wagi. Dzięki temu można znacznie skrócić proces trenowania jednak bez gwarancji, że wyuczona sieć będzie w globalnym ujęciu tą najlepszą (o najmniejszej wartości funkcji straty). Taki parametr określany jest mianem epoki, który odpowiada przeanalizowaniu wszystkich dostępnych danych wprowadzonych do modelu. Wartość epoki ustawiona na 100 oznacza zatem, że algorytm będzie 100 razy analizował te same dane i próbował tak dopasować wagi przy wszystkich połączeniach neuronowych aby zminimalizować funkcję straty. Możliwe jest

też wykorzystanie specjalnych funkcji zaimplementowanych w bibliotece TENSORFLOW, która analizując po każdej epoce dokładność modelu potrafi sama zdecydować o kontynuowaniu lub zakończeniu trenowania. Jedną z takich funkcji jest `EarlyStopping`, która odpowiednio skonfigurowana zapisze model o najmniejszej wartości funkcji straty przed osiągnięciem maksymalnej liczby epok.

Należy również pamiętać o odpowiednim przygotowaniu danych źródłowych przed wprowadzeniem ich do modelu. W wielu publikacjach [58], [60], [61] podkreślana jest rola normalizacji danych wejściowych czyli ich odpowiedniego przeskalowania. Jak wskazują przywołani wcześniej autorzy, „normalizacja jest [...] konieczna”, ponieważ „w problemach maszynowego uczenia [...] atrybuty [...] charakteryzują się zazwyczaj różną dynamiką”. „Obecność atrybutów o zróżnicowanym zakresie wartości utrudnia zbieżność procesu uczenia, ponieważ sieć bardziej dostosowuje się wówczas do zmian atrybutów o dużej dynamice, choć przecież nie zawsze niosą one ze sobą najwięcej informacji”. Bez zastosowania tej techniki modelowi grozi przeuczenie sieci, która będzie niezdolna do uogólniania wyników dla nowych danych. Dodatkowo należy mieć na uwadze aby w żaden sposób nie sugerować algorytmowi porządku danych. W szczególności jeżeli wykorzystujemy tę metodę do rozwiązywania problemów związanych z klasyfikacją. Obiekt o przykładowym indeksie numer 3 będzie traktowany przez sieć jako bardziej istotny w przypadku innego obiektu o indeksie numer 1. W takich sytuacjach należy zastosować różne techniki, które temu przeciwdziałają np. metoda gorąco–jedynkowa lub metoda „1 z n” (z ang. one-hot encoding) opisana szczegółowo w 5.1.

Powyżej przedstawiono spektrum możliwości konfiguracji architektury sieci neuronowej jak i metod związanych z przygotowaniem danych źródłowych. Zakres ten został opracowany na podstawie aktualnej wiedzy dotyczącej szeroko pojętego uczenia maszynowego. Jednak postępujący wzrost zainteresowania tą tematyką przekłada się na budowę nowych algorytmów. Każda kolejna wersja jest bogatsza o funkcjonalności, które z reguły wprowadzają więcej możliwości jak również usprawniają proces obliczeniowy. Z tego powodu konieczna jest ich ciągła analiza i wdrażanie w projektowanych lub istniejących aplikacjach.

2.3. Oryginalność podjętej tematyki w kontekście przeglądu aktualnego stanu wiedzy.

Zrealizowany przegląd literatury potwierdza szerokie zainteresowanie tematyką sieci neuronowych w systemach energetycznych. Jednak w żadnej z przeanalizowanych publikacji nie można się doszukać kompleksowej metody wykorzystującej sztuczne sieci neuronowe do prognozowania:

- zapotrzebowania na ciepło dla budynków przyłączonych do sieci,
- strat ciepła na przesył od źródła do odbiorców końcowych,
- zapotrzebowania na ciepło i paliwo gazowe dla źródła,
- ceny energii elektrycznej oraz paliwa gazowego.


Równocześnie zauważono, że wielu badaczy publikuje wyniki predykcji modeli w analizowanych zastosowaniach ale bardzo rzadko opisują jaką konkretną strukturą została wykorzystana. Analiza literatury wskazuje, że w chwili obecnej nie ma jednej najlepszej metodologii do zaplanowania architektury sieci neuronowej. W skrypcie [58] autorzy napisali, że „brak jest jednak jednoznacznych reguł sugerujących optymalne wartości parametrów, stąd konieczny jest indywidualny dobór tych wielkości do rozwiązanego problemu uczenia.” W dalszej części poświęconej ustaleniu odpowiednich parametrów przy konfiguracji sieci możemy przeczytać: „niestety, brak jest uniwersalnych wytycznych nieumożliwiających dobór wielkości [...] optymalnej dla danego problemu. Zazwyczaj stosuje się wartości z przedziału [...]” czy np. „metoda prób i błędów polegająca na wielokrotnym uruchamianiu procesu uczenia i obserwowania końcowych wartości [...] może być dobrym środkiem do określenia, czy architektura wykorzystanej sieci jest stosowna do rozmiaru złożoności” zadanego problemu jak również „architekturę sieci neuronowej uzyskano metodą prób i błędów” [62]. Zatem dobór odpowiednich parametrów konfiguracyjnych architektury sieci neuronowej może być kluczowy w celu uzyskania jej akceptowalnej dokładności.

Biorąc pod uwagę powyższe, interesującym problemem badawczym jest przeanalizowanie różnych architektur sztucznej sieci neuronowej i opracowanie metody ich oceny w analizowanym zastosowaniu związanym z funkcjonowaniem systemu ciepłowniczego.

3. Dane na temat analizowanego systemu elektroenergetycznego i ciepłowniczego.

3.1. Opis systemu ciepłowniczego.

Analizowany system ciepłowniczy, w którym realizowane będzie wdrożenie składa się z gazowej elektrociepłowni o łącznej mocy cieplnej prawie 15 MW_t oraz elektrycznej 3,6 MW_e. Źródło zasila sieć ciepłowniczą, która w całości wykonana jest z rur preizolowanych o łącznej długości ponad 17 km. Znaczna jej część stanowi układ pierścieniowy, co zostało przedstawione na Rys. 3.1. Pierwotnie układ stanowił odrębne lokalne gazowe kotłownie oznaczone symbolami K1–K7, które zasilały pobliskie osiedla. Na przestrzeni kilku lat system został zmodernizowany w celu ich likwidacji i połączenia w jeden wspólny system, który jest zasilany przez nową elektrociepłownię.



Rys. 3.1. Uproszczony schemat sieci ciepłowniczej łączącej nowe źródło energii (CHP gazowa – oznaczona kolorem zielonym) z istniejącymi lokalnymi systemami ciepłowniczymi zasilanych wcześniej przez indywidualne kotłownie gazowe. Źródło grafiki: [63]

Wspomniana modernizacja obejmowała również węzły cieplne, które zostały odpowiednio zmodyfikowane lub wymienione w celu utrzymania normatywnych parametrów pracy instalacji w budynkach. Zmiana była podyktowana korektą temperatur pracy systemu ciepłowniczego jak również ciśnienia dyspozycyjnego w danym miejscu przyłączenia budynku do sieci. Łączna liczba węzłów przekracza 100 instalacji w tym jedno- jak i dwufunkcyjnych.


Poza zrealizowaną modernizacją w zakresie hydraulicznym, zmiany dotyczyły również warstwy informatycznej. Zarówno źródło ciepła jak i wszystkie, nowe i modernizowane, węzły mają możliwość zdalnej komunikacji z regulatorami odpowiadającymi za procesy sterowania jak i urządzeniami do pomiaru zużytej energii cieplnej. Rozwiązanie to

umożliwiło opracowanie algorytmów wykorzystujących tę infrastrukturę w celu zgromadzenia odpowiednich danych na potrzeby uczenia maszynowego.

Wg danych opublikowanych przez dostawcę ciepła [64] w 2024 roku, źródło dostarczyło do systemu ciepłowniczego ponad 100 tys. GJ przy udziale ciepła z wysokosprawnej kogeneracji przekraczającym 81 %. Produkcja energii elektrycznej wiązała się z emisją dwutlenku węgla na poziomie 292 kg/MWh co jest wartością o 441 kg/MWh mniejszą od średniej emisji w Polsce w roku 2023 (na podstawie raportu KOBIZE [65]).

3.2. Kontekst prawno-finansowy.

W ciągu ostatnich kilku lat odnotowano znaczny wzrost zainstalowanej mocy elektrycznej z odnawialnych źródeł energii. Na szczególną uwagę zasługuje moc szczytowa zainstalowana w panelach PV, która w 2019 roku oscylowała w granicach 1 GW i wzrosła w 2024 roku do prawie 20 GW (Rys. 3.2). Podobny trend dotyczy mocy turbin wiatrowych jednak już nie w tak imponującym tempie.



Rys. 3.2. Struktura mocy zainstalowanej w OZE w Polsce. Źródło: [66].

Powyższe działania są skutkiem przyjętych przepisów związanych z szeroko pojętą dekarbonizacją przemysłu i planem przejścia od 2050 r. wyłącznie na odnawialne źródła energii. Wg [67] zwiększona generacja energii przez OZE odbija się pozytywnie, z punktu widzenia odbiorcy, poprzez spadek ceny energii elektrycznej na rynku. Jednak ma to swoje konsekwencje w rentowności nowych instalacji wykorzystujących panele PV czy turbiny wiatrowe. Dla źródeł kogeneracyjnych wzrost generacji z niesterowalnych odnawialnych źródeł stanowi również wyzwanie, które muszą uwzględniać zwiększając elastyczność pracy przy utrzymywaniu stabilnej częstotliwości systemu elektroenergetycznego.


Handel energią elektryczną jest realizowany na tzw. Rynku Bilansującym. Jest to wirtualne miejsce bilansowania, w którym udział biorą zarówno:

- wytwórcy energii,
- operatorzy systemów dystrybucyjnych,
- przedsiębiorstwa posiadające koncesję na obrót energią elektryczną,
- uczestnicy giełdy energii.

Każdy podmiot zobowiązany jest udokumentować, że w danym okresie czasu (najczęściej 15–to minutowym):

- zakupił z rynku tyle energii ile odsprzedał klientom lub
- oddał na rynek tyle energii ile sam wyprodukował.

Ceny energii elektrycznej są uzależnione w największym stopniu od jej dostępnego wolumenu w handlu w określonym przedziale czasowym. O tym ile faktycznie energii zostało wyprodukowanej i odebranej z systemu dowiadujemy się dopiero po zakończeniu danego okresu. Oznacza to, że podejmując decyzję o uruchomieniu generatora i produkcji energii na Rynek Bilansujący nie mamy dokładnej wiedzy po jakiej cenie tak naprawdę ją sprzedamy.




Rys. 3.3. Ceny energii elektrycznej w okresie od 2015 do połowy 2025 r. Źródło: opracowanie własne.

Na Rys. 3.3. zaprezentowano godzinowe wartości ceny energii elektrycznej w latach od 2015 do 2024. Zaobserwować można znaczny jej wzrost od drugiej połowy 2021 r. co było skutkiem zmiany sytuacji geopolitycznej w Europie. Agresja Rosji na Ukrainę, która oficjalnie została rozpoczęta 24 lutego 2022 r., a następnie całkowite wstrzymanie dostaw


gazu ziemnego rurociągiem jamalskim do Polski, przełożyło się na nigdy wcześniej nierejestrowane ceny paliwa gazowego oraz energii elektrycznej. Pomimo wprowadzania różnych pakietów osłonowych dla wytwórców energii jak i odbiorców przez rząd polski, poziom cen nie wrócił do tego sprzed wojny.

Wg danych z Towarowej Giełdy Energii na koniec grudnia 2024 r. cena energii elektrycznej jaką można by zakontraktować na cały 2025 r wynosiła 422,50 zł netto / MWh natomiast gazu ziemnego 203 zł netto / MWh. Taka relacja cen nie pokryje kosztów pracy agregatu kogeneracyjnego co zostało przedstawione szczegółowo w [68], w którym autorzy wyznaczyli minimalny stosunek ceny energii elektrycznej do paliwa gazowego równy 2,5. W samym 2024 roku ceny energii elektrycznej przewyższające 500 zł netto / MWh stanowiły 75 % i zdarzały się sytuacje w których przekraczała ona 2 700 zł netto / MWh. Średnia cena dla całego roku wynosiła 413 zł netto / MWh a jej przebieg w 2024 r. został przedstawiony na Rys. 3.4.




Rys. 3.4. Ceny energii elektrycznej za MWh w 2024 r. na Rynku Bilansującym.

W przypadku gazu ziemnego średnia cena w tym samym roku wynosiła 167 zł netto / MWh przy czym ponad 75 % stanowiły wartości większe od 186 zł netto / MWh. Zdarzały się chwilowe maksymalne ceny wynoszące 236 zł netto / MWh, co zostało zaprezentowane na Rys. 3.5.




Rys. 3.5. Wykres prezentujący cenę paliwa gazowego na TGE w 2024 r.

Kolejny wykres prezentuje relację ceny energii elektrycznej w stosunku do ceny paliwa gazowego w 2024 roku. Wskaźnik o wartości 2,5 i więcej został zarejestrowany przez 3 776 godzin, natomiast w 2023 roku było takich godzin 4 734.



Rys. 3.6. Wykres prezentujący relację ceny energii elektrycznej w stosunku do paliwa gazowego w 2024 r. Linia czerwona zaznaczono minimalną wartość wskaźnika określoną na 2,5. Źródło: opracowanie własne.

Pomimo opisanych trudności i wahań związanych z cenami energii elektrycznej, rozbudowa elektrowni opartych o panele fotowoltaiczne czy turbiny wiatrowe była kontynuowana. Jak zaprezentowano na wykresie (Rys. 3.7) ich udział w rynku systematycznie wzrastał. Utrzymując ten trend można prognozować, że w najbliższych latach coraz więcej energii będzie pochodziło z tego źródła. Skutkiem może być nadpodaż energii w Krajowym Systemie Elektroenergetycznym w słonecznych i wietrznych okresach, co przełoży się na bardzo niską jej cenę w tym czasie. Natomiast w odwrotnym scenariuszu, w którym w ciągu dnia pracującego mamy duże zapotrzebowanie na energię, a nie ma odpowiednich warunków dla pracy turbin wiatrowych czy paneli fotowoltaicznych, energia będzie charakteryzowała się bardzo wysoką ceną. Taki scenariusz, którego załówek widzimy już w aktualnym systemie elektroenergetycznym, będzie wymuszał bardzo dużą elastyczność w funkcjonowaniu systemów ciepłowniczych połączonych z kogeneracyjnym układem prądotwórczym w celu utrzymania założonych współczynników rentowności.



Rys. 3.7. Wykres rzeczywistej ilości wygenerowanej energii elektrycznej z PV w okresie od grudnia 2021 do lipca 2024 r. Źródło: opracowanie własne.

W odróżnieniu od rynku elektroenergetycznego, funkcjonowanie systemu ciepłowniczego nie podlega aż takim wahaniom. Przeważnie ich operatorzy działają lokalnie w granicach jednej miejscowości, a nie na terenie całego kraju. Dodatkowo jest to rynek, który jest regulowany przez Urząd Regulacji Energetyki. Podmioty, które posiadają moc zainstalowaną lub moc zamówioną u swoich odbiorców powyżej 5 MW_t zobowiązani są do składania taryfy dla ciepła, która podlega zatwierdzeniu. Mniejsi wytwórcy ciepła muszą opracowywać taryfy zgodnie z Rozporządzeniem w sprawie szczegółowych zasad kształtowania i kalkulacji taryf (tak jak każdy inny przedsiębiorca działający na rynku ciepła) jednak nie są zobowiązani do

ich akceptacji przez urząd. Daje to pewien komfort w sytuacjach bardzo zmiennych kosztów prowadzenia działalności, gdyż umożliwia przekalkulowanie taryfy bez zbędnej zwłoki i wprowadzenie jej do stosowania. Taki mechanizm nie jest dostępny dla dużych podmiotów, o których wspomniano wcześniej. Skutkuje to tym, że w przypadku znacznych zmian kosztów prowadzenia działalności związanej z wytwarzaniem energii, przedsiębiorstwo nie jest w stanie w krótkim czasie wprowadzić do stosowania skorygowanych cen. Wpływa to w sposób znaczny na stabilność finansową, ponieważ wytwórca jest zobowiązany do dostarczania ciepła po stawkach, które nie są w stanie pokryć kosztów jego wytworzenia.

W artykule [69] autorzy sugerują podjęcie zmian legislacyjnych mających na celu większą elastyczność w kreowaniu cen i stawek za ciepło. Nawiązują w ten sposób do przepisów, w których regulator kontroluje stawki już po ich wprowadzeniu porównując je z innymi taryfami przedsiębiorstw działających na danym rynku. O problemie rentowności ciepłowni oraz procesie taryfowania w Polsce pisali również [68]. Podkreślając, że wyzwania jakie stoją przed podmiotami działającymi na rynku ciepłowniczym będą wymagały zwiększenia ceny ciepła w celu sfinansowania procesu transformacji energetycznej.

3.3. Praca układu kogeneracyjnego.

Rynek energii elektrycznej wymaga coraz większej elastyczności od jego uczestników, w szczególności w kwestii generacji energii jak i odpowiedzialności za stabilność całego systemu elektroenergetycznego. Praca układu kogeneracyjnego w oparciu o kryterium ekonomiczne wymaga śledzenia cen energii elektrycznej oraz paliwa gazowego i dopasowywania harmonogramu pracy tych urządzeń w celu maksymalizacji efektywności energetycznej i zysku [70]. W takim modelu funkcjonowania rynku, urządzenia wytwórcze oparte o gazowe agregaty kogeneracyjne wydają się być bardzo dobrym wyborem. Wynika to z faktu, że silnik może być bardzo szybko włączony do ruchu w zależności od zapotrzebowania. W momencie podjęcia decyzji o generacji, uruchamiane są odpowiednie układy pomocnicze systemu tj. wentylacja, chłodzenie, wstępne smarowanie i następuje rozruch maszyny. Cała procedura nie przekracza łącznie okresu kilku minut, a jeszcze krócej trwa jej odstawienie od pracy.

Rozwiązania oparte o kogenerację gazową napędzaną przez gazowy silnik tłokowy z zapłonem iskrowym charakteryzują się również wysoką sprawnością elektryczną oraz cieplną co zostało przedstawione w Tabeli 3.1. W dostępnych katalogach producentów urządzeń możemy znaleźć sprawności elektryczne w zakresie 40 – 41 % oraz cieplne na tym samym lub minimalnie wyższym poziomie. Daje to całkowitą sprawność agregatu ok. 85 %, przy założeniu wykorzystania całej dostępnej energii cieplnej z chłodzenia urządzenia. Dostępne są również rozwiązania wykorzystujące wymiennik spalin–woda umożliwiające kondensację spalin. Dzięki takiemu rozwiązaniu możemy uzyskać dodatkowy wzrost sprawności cieplnej oscylujący w granicach 10 %. Wymaga to jednak współpracy z instalacją o odpowiedniej temperaturze wody powrotnej [71].

Tabela 3.1. Zestawienie sprawności agregatów kogeneracyjnych kilku popularnych producentów.

Typ silnika	Sprawność elektryczna [%]	Sprawność cieplna [%]
Jenbacher typ 4 (zakres mocy elektrycznej od 0,749 do 1,562 MW)	do 44,0	do 50,5
Jenbacher typ 9 (moc elektryczna 10,606 MW)	do 48,7	do 47,0
MTU (zakres mocy elektrycznej od 0,776 do 2,547 MW)	do 44,0	do 43,9
CAT (zakres mocy od 0,1 do 4,5 MW)	do 45,0	do 45,0
2G (zakres mocy od 0,02 do 4,5 MW)	do 45,5	do 45,9

Dla typowego rozwiązania opartego o silnik gazowy praca układu oparta jest o temperatury wynoszące ok. 90 st. C na zasilaniu oraz 70 st. C na powrocie, a generowana całkowita moc cieplna jest uzależniona od zadanego obciążenia elektrycznego generatora.

3.4. Perspektywy.

W najnowszym raporcie URE [72] przedstawione zostały wyniki badań ankietowych, z których w perspektywie najbliższych 10 – 15 lat planowane jest wycofanie z eksploatacji źródeł wytwórczych opartych na węglu kamiennym i zastąpienie ich źródłami gazowymi oraz energią z wiatru i słońca. Współpraca tych trzech technologii umożliwi stabilne funkcjonowanie systemu elektroenergetycznego. Uruchamianie silników kogeneracyjnych na żądanie operatora odpowiedzialnego za nadzór nad Krajowym Systemem Elektroenergetycznym i generacja odpowiedniej ilości energii w celu utrzymania częstotliwości pracy sieci to zadanie, które idealnie wpisuje się w możliwości agregatu kogeneracyjnego. Lokalizacja takich urządzeń w miejscu istniejących lub nowo projektowanych ciepłowni do kompleksowego zasilania w energię cieplną oraz elektryczną części lub całego miasta stanowi bardzo dobre rozwiązanie. W szczególności wpłynie ono pozytywnie na ograniczenie strat przy przesyłaniu energii elektrycznej oraz umożliwi lokalne zagospodarowanie ciepła z tego procesu przy współpracy z siecią ciepłowniczą.

4. Algorytmy do zbierania danych na potrzeby zbudowania modelu sztucznej sieci neuronowej.

4.1. Wykorzystywane narzędzia programistyczne.

System do predykcji zapotrzebowania na ciepło napisany został w języku programowania Python z udziałem różnych bibliotek. Jest to język programowania wysokiego poziomu, co oznacza wykorzystanie słów używanych w języku naturalnym w celu zapisania zasad działania algorytmu [73]. W przeciwieństwie do języka niskiego poziomu, użytkownik nie musi zajmować się operacjami na rejestrach procesora czy komórkach pamięci komputera, a wykorzystuje abstrakcje programistyczne takie jak pętle czy skomplikowane struktury danych. Został on stworzony na początku lat 90. przez Guido van Rossum i jest rozwijany na licencji otwartego oprogramowania [74]. Uzyskał popularność dzięki czytelności i klarowności kodu źródłowego, jak również charakteryzuje się przejrzystością oraz zwięzłością. Dzięki temu doczekał się implementacji na wiele systemów operacyjnych i rozwoju bibliotek oraz modułów ułatwiających programowanie w różnych dziedzinach. Dostępnych jest wiele programów, które wspierają pisanie kodu źródłowego. W niniejszej rozprawie korzystano z Jupyter [75] oraz PyCharm [76].

Do pobierania danych ze stron internetowych i ich konwersji do struktury wymaganej przez opracowaną aplikację, wykorzystano zestaw bibliotek REQUEST oraz BEAUTIFULSOUP. Pierwsza z nich umożliwia automatyczne odpytanie domeny o jej zawartość przez komputer bez użycia przeglądarki internetowej [77]. Na wyjściu uzyskujemy kompletny kod HTML, który może być analizowany przez kolejną bibliotekę tj. BEAUTIFULSOUP [78]. Napisana w języku Python, umożliwia przeszukiwanie kodu źródłowego z wykorzystaniem znaczników w celu automatycznego zapisywania pożądaných informacji publikowanych na stronie internetowej.

Jedną z najbardziej popularnych bibliotek do analizy i przetwarzania danych jest PANDAS. Aktualnie rozwijana jest na zasadzie otwartego oprogramowania od ponad 17 lat. Napisana w języku programowania Python jest w szczególności ukierunkowana na działania manipulacyjne związane z danymi numerycznymi oraz szeregami czasowymi [79]. Nazwa pochodzi od wyrażenia „panel danych” popularnego w ekonometrii.

W celu zapisania danych do zewnętrznej lub lokalnej bazy wykorzystać można popularną bibliotekę SQLITE. To kompleksowe narzędzie do zarządzania i tworzenia pliku z danymi o maksymalnej wielkości do 281 TB [80]. Jej zaletą jest bardzo wysoka wydajność w porównaniu z rozwiązaniami opartymi na MySQL czy podobnymi. Zawdzięcza to bezpośredniemu dostępowi do dysku, bez udziału dodatkowych mechanizmów pomiędzy użytkownikiem a serwerem [81].

Zaawansowane obliczenia na znacznej ilości danych z udziałem wielowymiarowych tabel i macierzy możliwe są dzięki bibliotece NUMPY [82]. Nazwa pochodzi od „Numerical Python” i jest rozwijana od 2005 r. na zasadzie otwartego oprogramowania. Charakteryzuje

się bardzo wysoką wydajnością przewyższającą w niektórych przypadkach takie programy jak MATLAB czy R [83].

Biblioteką najczęściej wykorzystywaną w niniejszej pracy jest TENSORFLOW, która została stworzona przez Google Brain Team w listopadzie 2015 r. na bazie biblioteki KERAS. Jest to otwarte oprogramowanie, które opracowano z myślą o budowie sztucznych sieci neuronowych oraz ich wykorzystaniu na cele predykcji [84]. Jej sercem jest moduł wykonawczy napisany w języku programowania C++, co gwarantuje uzyskiwanie wysokich wydajności. Do komunikacji z użytkownikiem wykorzystuje ona zaawansowane API napisane w języku Python, które umożliwia tworzenie i konfigurację sieci neuronowych [85].

Skrypty, które mają służyć integracji z systemem SCADA aktualnego wytwórcy ciepła i energii elektrycznej w kogeneracji, napisano przy użyciu języka Python, jak również PHP oraz HTML. Pierwszy z nich służy do programowania stron internetowych oraz budowania aplikacji przeznaczonych do publikowania w internecie. Pojawiła się na rynku już w 1995 roku i pochodzi od słów „Personal Home Page” [86]. Obecnie jest dominującym językiem programowania stron internetowych i obejmuje około 75% wszystkich zarejestrowanych domen [87]. Drugi odpowiada za odpowiednie sformatowanie tekstu tak aby wyświetlał się na stronie internetowej zgodnie z oczekiwaniami twórcy. Wykorzystując odpowiednie znaczniki takie jak `
`, `<td></td>`, `<p></p>`, `<a>` itd., przeglądarka odpowiednio je interpretuje wyświetlając pożądaną strukturę danych. Stąd też pochodzi sama nazwa, która oznacza „HyperText Markup Language” czyli hipertekstowy język znaczników. Jej pierwsza wersja ogólnodostępna została opublikowana w 1991 r. i jest niezbędna do prawidłowego działania stron internetowych [88].

Efektom działania systemu jest uruchomiana strona internetowa na prywatnym serwerze WWW z wykorzystaniem systemu GNU Linux. Dostęp jest ograniczony dla zalogowanych użytkowników pod adresem <https://dawid.czajor.com.pl/phd>.

4.2. Opis danych źródłowych.

Wykorzystanie algorytmów uczenia maszynowego musi być oparte na odpowiedniej ilości danych źródłowych. Będą one służyły do trenowania modelu sieci neuronowej, które zostało szczegółowo opisane w punkcie 2.2 na stronie 38. Jest to proces, w którym algorytm tak dobiera wagi przy każdym połączeniu wewnątrz sieci neuronowej, aby osiągnąć jak najmniejszą różnicę pomiędzy predykcją a wartością rzeczywistą. Z tego powodu zostały opracowane algorytmy, które umożliwiły zapis danych źródłowych w lokalnej bazie danych. Zaliczają się do nich:

- dane z liczników ciepła zainstalowanych w węzłach ciepłych rejestrowane z interwałem 5–cio minutowym od grudnia 2020 r.,
- dane z elektrociepłowni rejestrowane z interwałem 15–to minutowym od marca 2022 r.,

- dane meteorologiczne dla Białogardu rejestrowane z interwałem godzinowym od listopada 2019 r. ,
- informacje o zapotrzebowaniu i generacji energii elektrycznej w Polsce z interwałem 15–to minutowym od grudnia 2021 r.,
- ceny energii elektrycznej na Rynku Bilansującym z interwałem godzinowym od stycznia 2015 r.,
- ceny paliwa gazowego na Towarowej Giełdzie Energii rejestrowane od czerwca 2019 r. z interwałem dobowym.

4.3. Dane z liczników ciepła.

Według stanu na grudzień 2024 r. w bazie danych znajduje się ponad 14 300 000 rekordów. Do ich zapisywania wykorzystane jest połączenie SQL gdzie trafiają wszystkie informacje z każdego licznika podłączonego do systemu odczytowego dostawcy ciepła. Z racji na dużą liczbę rekordów, zaprogramowany algorytm odpytuje bazę danych po unikalnych adresach punktów dostawy ciepła, a następnie zapisuje je w postaci plików CSV. Przyspiesza to znacznie dostęp do informacji z liczników, co jest kluczowe z punktu ich wykorzystania na potrzeby algorytmów trenowania sieci neuronowej.

Rejestrowane przez algorytm dane zawierają:

- numer licznika,
- temperaturę zasilania i powrotu po stronie sieci ciepłej,
- przepływ wody sieciowej,
- chwilową moc cieplną,
- stan licznika odzwierciedlający jego status (sprawny/uszkodzony),
- temperaturę powietrza zewnętrznego mierzoną przez czujnik regulatora pogodowego węzła,
- temperaturę zasilania i powrotu po stronie wtórnej tj. instalacji wewnętrznej budynku,
- temperaturę zasilania instalacji ciepłej wody użytkowej (w przypadku gdy zainstalowany węzeł cieplny jest dwufunkcyjny),
- krzywą grzewczą regulatora pogodowego,
- zadaną temperaturą w pomieszczeniach w funkcji komfortu oraz w trybie zredukowanym,
- maksymalny godzinowy pobór mocy cieplnej zarejestrowany przez licznik,

- tryb pracy węzła ciepłego (tryb komfortu lub oszczędzania),
- data i godzina odczytu,
- lokalizacja węzła ciepłego (adres).

Do pobrania danych licznikowych służą funkcje opisane w głównym pliku `functions.ipynb`. Odpowiadają one w pierwszej kolejności za zebranie wszystkich unikalnych adresów budynków przyłączonych do sieci ciepłej. Jeżeli na dysku lokalnym znajduje się plik CSV o nazwie odpowiadającej lokalizacji danego budynku to system przechodzi do sprawdzenia kolejnego adresu. Jeżeli taki plik nie istnieje to uruchamiane zostaje zapytanie do bazy SQL mające na celu pobranie wszystkich informacji dla danego obiektu i wygenerowanie odpowiednio sformatowanego pliku. Dodatkowo, aby można było wymusić pobranie nowych danych pomimo istniejącego pliku CSV, wprowadzono zmienną odpowiadającą za określenie wersji systemu. Jest ona zaimplementowana w wielu opracowanych w funkcjach, dzięki czemu zmiana jednego parametru spowoduje aktualizację wszystkich danych źródłowych.

4.4. Dane z elektrociepłowni.

Ten mechanizm ewoluował na przestrzeni kilku miesięcy i wynikał z konieczności dostosowania się do zmian technologicznych jakie realizowane były w systemie informatycznym wytwórcy ciepła. W pierwotnym schemacie udostępniono możliwość odczytu parametrów bezpośrednio z bazy danych, do której zapisywane były wszystkie parametry z liczników, czujników i innych urządzeń zlokalizowanych w elektrociepłowni. Odpowiedni algorytm pobierał te informacje i zapisywał do lokalnej bazy SQLITE.

Po zmianie systemu przez wytwórcę, nie było możliwości utrzymania wcześniej opracowanego algorytmu, a pozyskiwanie danych mogło się odbywać wyłącznie za pomocą pośredniego systemu z wykorzystaniem serwera WWW. W związku z powyższym opracowano nowe algorytmy, które umożliwiły funkcjonowanie mechanizmu pomimo poczynionych zmian.

Wszelkie instrukcje odpowiadające za funkcjonowanie mechanizmu zostały zapisane w pliku `pro2000.py` i są uruchamiane automatycznie z określonym interwałem przez oprogramowanie CRON systemu GNU Linux. Wg stanu na koniec marca 2025 r. w bazie znajdowało się ponad 200 tys. rekordów o parametrach elektrociepłowni.

Zapisywane dane dotyczą:

- zadanej i aktualnej temperatury zasilania sieci ciepłej,
- temperatury powietrza zewnętrznego,
- chwilowej mocy ciepłej silników kogeneracyjnych
- chwilowej mocy elektrycznej czynnej oraz biernej silników kogeneracyjnych,

- chwilowej mocy cieplnej kotłów gazowych,
- zużycia gazu przez zainstalowane urządzenia,
- temperatury gazu oraz ciśnienia absolutnego w miejscu pomiaru przez gazomierze,
- przepływu wody przez generatory oraz kotły,
- temperatury zasilania oraz powrotu wszystkich urządzeń wytwórczych,
- mocy cieplnej rejestrowanej przez główny ciepłomierz na wyjściu z obiektu wraz z temperaturami i przepływem wody,
- generacji mocy czynnej oraz biernej w punkcie połączenia sieci dystrybucyjnej wytwórcy z operatorem elektroenergetycznym wraz z natężeniem prądu w każdej z faz,
- temperatury spalin za wymiennikiem ciepła dla silników kogeneracyjnych.

Opracowany skrypt wykorzystuje biblioteki języka Python tj. BEAUTIFULSOUP, REQUESTS oraz JSON, które wspierają wysyłanie oraz odbieranie zapytań w formacie HTML. Wg określonego harmonogramu, system automatycznie odpytuje kilka stron internetowych udostępnionych przez serwer wytwórcy. Algorytm wyszukuje odpowiednich zmiennych w przesłanym pliku JSON, które odpowiadają zdefiniowanym parametrom pracy urządzeń. W efekcie końcowym uzyskiwana jest tablica danych w układzie *zmienna:wartość*, która jest zapisywana do lokalnej bazy danych SQLITE.

4.5. Dane meteorologiczne z Instytutu Meteorologii i Gospodarki Wodnej.

Dzięki współpracy z Instytutem Meteorologii i Gospodarki Wodnej oraz przedsiębiorstwem, w którym nastąpiło wdrożenie pracy doktorskiej udostępniony został serwer FTP przez IMGW, na który automatycznie zostają wgrywane prognozy pogody dla Białogardu. Aktualizacja odbywa się z interwałem 12-to godzinnym tj. o 6:00 i 18:00. Udostępniony plik jest w postaci dokumentu CSV, który zawiera prognozę na najbliższe 72 godziny od daty generacji. Na koniec kwietnia 2025 r. w bazie było ponad 47 tys. rekordów.

Zapisywane dane zawierają:

- temperaturę powietrza zewnętrznego mierzoną 2 m nad poziomem gruntu,
- prędkość wiatru mierzona 10 m nad poziomem gruntu,
- kierunek wiatru mierzony 10 m nad poziomem gruntu,
- ciśnienie atmosferyczne,
- wilgotność względną powietrza,
- wielkość opadu atmosferycznego,

- typ opadu,
- datę i godzinę.

Skrypt co 15 minut łączy się automatycznie z serwerem FTP należącym do IMGW i przeszukuje listę dostępnych dokumentów z prognozą pogody. Najnowszy plik zostaje pobrany z serwera i przekonwertowany tak aby mógł zostać zapisany do lokalnej bazy SQLITE. Następnie sformatowana zostaje odpowiednio data oraz nadane zostają nagłówki spójne z opracowaną strukturą zbudowanego systemu. Wszystkie instrukcje zapisane są w pliku `imgw.py`.

4.6. Dane o funkcjonowaniu Krajowego Systemu Elektroenergetycznego.

Polskie Sieci Elektroenergetyczne udostępniają na swoich stronach internetowych dane techniczne funkcjonowania infrastruktury przesyłowej na terenie całego kraju pod adresem <https://www.pse.pl>. Mechanizm przechodził kilka aktualizacji z racji na zmiany legislacyjne po stronie operatora wynikające m.in. z decyzji [89]. Publikowane dane dostępne są w czasie rzeczywistym jak również umożliwiają pobranie 15-to minutowych parametrów archiwalnych. Na koniec marca 2025 r. w bazie zarejestrowano ponad 1,3 miliona wpisów.

Zapisywane dane zawierają:

- zapotrzebowanie na moc w Krajowym Systemie Elektroenergetycznym,
- generację mocy elektrycznej dla:
 - elektrowni ciepłych,
 - elektrowni wodnych,
 - elektrowni wiatrowych,
 - elektrowni fotowoltaicznych,
 - elektrowni innych odnawialnych,
- datę i godzinę,
- planowany i rzeczywisty przepływ energii na połączeniach międzynarodowych ze:
 - Szwecją,
 - Niemcami,
 - Czechami,
 - Słowacją,
 - Ukrainą,

- Litwą,
- częstotliwość pracy sieci.

Algorytm co określony czas pobiera ze strony PSE plik w formacie JSON zawierający wszystkie wyżej opisane dane. Następnie konwertuje zmienne pliku i formatuje je tak aby mogły zostać zapisane w lokalnej bazie SQLITE. Za cały proces odpowiadają funkcje `read_generation()` oraz `save_generation()`.

4.7. Dane o cenach energii elektrycznej na Rynku Bilansującym.

Ceny energii elektrycznej są odzwierciedleniem bilansu pomiędzy jej generacją a zapotrzebowaniem. Analogicznie jak w poprzednim punkcie dane te publikowane są na stronie <https://raporty.pse.pl>. Na dzień 25.04.2025 r. zgromadzono prawie 90 tys. rekordów.

Zakres rejestrowanych danych:

- cena rozliczeniowa na Rynku Bilansującym,
- wartość energii niezbilansowanej,
- data i godzina.

W aktualnej wersji strony PSE możliwe jest wykorzystanie ogólnodostępnego API, w celu pobrania wyżej opisanych danych. W pierwotnej wersji takiej możliwości nie było i algorytmy musiały korzystać z rozwiązań pośrednich. Niezależnie od sposobu pozyskania informacji w kolejnym etapie następuje formatowanie nagłówków pliku JSON tak, aby spełnić wymagania struktury bazy danych SQLITE. Instrukcje pierwotnie zapisane były w funkcji `get_prices_pse()`, a po zmianach wprowadzonych przez PSE w funkcji pod nazwą `get_prices_api_pse()`.

4.8. Dane o cenach paliwa gazowego na Towarowej Giełdzie Energii.

Na stronie Towarowej Giełdy Energii publikowane są informacje na temat aktualnej oraz archiwalnej ceny paliwa gazowego. Nie jest to ogólnodostępne API, dlatego opracowano metodę pobrania pliku CSV, który zawiera wyżej opisane parametry. W bazie dostępne jest ponad 2 tys. rekordów, wg stanu na koniec marca 2025 r.

Zapisywane dane zawierają:

- rzeczywistą cenę rozliczeniową gazu,
- datę.

Algorytm odpytuje stronę TGE.pl wg określonego interwału, a następnie zapisuje otrzymany plik w formacie JSON. W kolejnym etapie informacje są konwertowane do odpowiedniego formatu i zapisywane do lokalnej bazy SQLITE. Instrukcje zdefiniowane są w funkcjach `get_gas_prices()` oraz `save_gas_prices()` w pliku `gas.py`.

5. Prognozowanie zapotrzebowania na ciepło u odbiorcy końcowego.

5.1. Opis mechanizmu.

Analizowany system ciepłowniczy składa się ze 107-u budynków podłączonych do sieci ciepłej, która działa na potrzeby centralnego ogrzewania oraz ciepłej wody użytkowej. Wyłącznie 46 z nich posiada zdalną komunikację w cel przesyłania parametrów pracy węzła ciepłego do centralnego komputera rejestrującego. Pomimo niepełnych danych opracowano metodę, która wykorzystując dostępne informacje może prognozować zapotrzebowanie na moc cieplną indywidualnie dla każdego budynku. Umożliwia to symulowanie godzinowych obciążeń cieplnych, na cele centralnego ogrzewania oraz ciepłej wody użytkowej, po stronie odbiorców w zadanym horyzoncie prognozy. Przekłada się to następnie na źródło informacji dla kolejnego modelu prognozującego produkcję ciepła w źródle, zasilającym sieć ciepłowniczą na potrzeby powyższych odbiorców, jak również zużycie paliwa gazowego przez urządzenia wytwórcze.

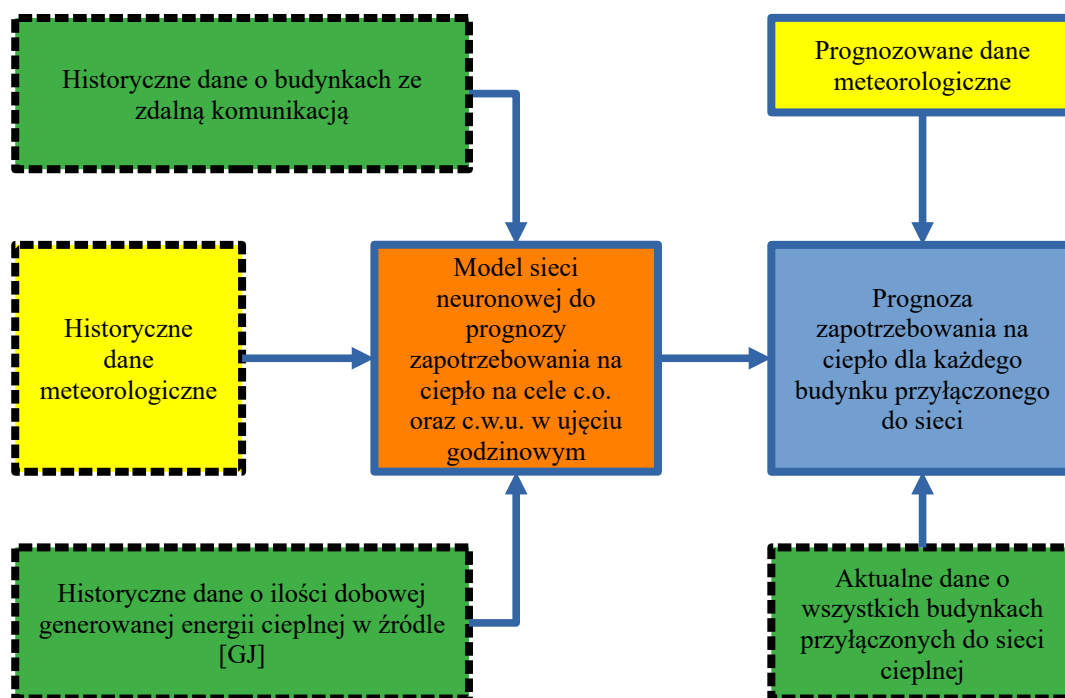
Mechanizm wymaga zdefiniowania wszystkich obiektów przyłączonych do sieci wprowadzając następujące parametry:

- adres (stanowi wyłącznie etykietę na potrzeby rejestracji danych w bazie, a nie źródło informacji do trenowania sieci neuronowej),
- długość i szerokość budynku,
- liczba pięter,
- typ budynku:
 - 0 – wielorodzinny,
 - 1 – usługowy,
 - 2 – publiczny,
 - 3 – szpitalny,
 - 4 – jednorodzinny,
- roczne wykorzystanie ciepła na potrzeby c.o.,
- roczne wykorzystanie ciepła na potrzeby c.w.u.

Powyższe informacje zostały tak dobrane aby ich pozyskanie od podmiotu zarządzającego obiektem nie sprawiało większych trudności. W szczególności mowa tutaj o rocznym zapotrzebowaniu na ciepło, które z zasady jest rejestrowane przez administrację budynku w celu rozliczenia mieszkańców. Określenie lokalizacji oraz jego typu nie stanowi zazwyczaj komplikacji, w przeciwieństwie do wymiarów budynków. Z racji na różne lata budowy uzyskanie tych informacji z projektów, które w wielu przypadkach są

zarchiwizowane, nie było możliwe. Jedną z alternatyw mogła być ponowna weryfikacja parametrów w terenie. Wymagałaby ona jednak wykorzystania specjalistycznego sprzętu oraz pochłonęłaby dużo czasu. Dodatkowo w znaczny sposób utrudniłaby implementację opracowanej metody w systemach ciepłowniczych zlokalizowanych w innych miastach. Z tych powodów zdecydowano się na wykorzystanie ogólnodostępnych internetowych map w celu pozyskania wymaganych informacji. Stanowiły one źródło danych o długości i szerokości budynku, natomiast dzięki jej trójwymiarowemu widokowi możliwe było określenie liczby pięter.

Na Rys. 5.1 przedstawiono schemat funkcjonowania i zależności pomiędzy poszczególnymi algorytmami. Odpowiadają one za zebranie danych i wytrenowanie modelu, który w kolejnym etapie posłuży do wygenerowania prognozy zapotrzebowania na moc ciepłą na cele c.o. i c.w.u. dla każdego budynku.



Rys. 5.1. Schemat opracowanego algorytmu do prognozy zapotrzebowania na moc ciepłą na cele centralnego ogrzewania oraz ciepłej wody użytkowej dla wszystkich budynków podłączonych do sieci ciepłej.


Rozpoczęcie trenowania sztucznej sieci neuronowej musi zostać poprzedzone przygotowaniem danych. Odpowiada za to opracowana funkcja `preprocess_data()` w pliku `tensorflow_functions.ipynb`. W pierwszej kolejności algorytm pobiera godzinowe informacje o pogodzie, za co odpowiedzialna jest funkcja `get_weather_forecast()`. Źródłem danych historycznych jest Instytut Meteorologii i Gospodarki Wodnej. W zależności od wymagań, opracowana funkcja może przyjmować różne argumenty zdefiniowane jako:

- `full_weather=True` – co oznacza całą dostępną historię danych,
- `520d` – co oznacza 520 dni wstecz od daty wywołania funkcji,
- `year` – co oznacza cały rok wstecz od daty wywołania funkcji lub
- `last_48h` – co oznacza ostatnie 48 godzin od momentu wywołania funkcji.

Zakres danych jest wyznacznikiem liczby rekordów jakie będą brane pod uwagę przy trenowaniu modelu sieci neuronowej. W analizowanym systemie ciepłowniczym wykorzystywane są dane z ostatniego roku. Wynikało to z faktu, że niektóre budynki na przestrzeni 2022 i 2023 roku przeszły znaczną korektę parametrów regulatora odpowiadającego za sterowanie centralnym ogrzewaniem oraz ciepłą wodą użytkową. Zmiany te w sposób znaczny wpłynęły na temperatury pracy węzła i sposób regulacji, a ich pozostawienie wprowadziłoby dodatkowy błąd w trakcie procesu trenowania.


Dane jakie są rejestrowane przez IMGW zawierają informacje m.in. o kierunku i prędkości wiatru oraz dacie i godzinie. Zapisane w ten sposób informacje, które są czytelne dla człowieka, nie będą poprawnie interpretowane przez algorytm sieci neuronowej. W przypadku daty i godziny, wraz z jej upływem, do trenowania wprowadzane byłyby coraz większe wartości. Interpretowane byłoby to jako wzrost istotności tego parametru wraz z jego biegiem. Podobna sytuacja dotyczy drugiego zestawu parametrów. Wpływ wartości prędkości wiatru na zapotrzebowanie na energię dla budynku jest zbliżony, jeśli nie taki sam, przy kierunku 10 stopni i 350 stopni. Dlatego też w tych przypadkach zastosowano konwersję parametrów wykorzystując:

- funkcje trygonometryczne do reprezentacji daty i godziny (Rys. 5.2) – jako sinus i cosinus kąta określonego przez:
 - datę wyrażoną w formacie unix-timestamp (tj. liczba sekund od 1. stycznia 1970 r.),
 - wartości liczby pi,
 - liczbę sekund w ciągu jednego dnia oraz całego roku,



Rys. 5.2. Sposób reprezentacji tej samej daty i godziny za pomocą czterech funkcji trygonometrycznych.

- wektory do reprezentacji prędkości i kierunku wiatru (Rys. 5.3), które będą stanowiły iloczyn prędkości oraz wartości sinusa i cosinusa kąta jego kierunku wyrażonego w radianach.



Rys. 5.3. Reprezentacja siły i kierunku wiatru przed (po lewej) i po konwersji (po prawej).

Po lewej stronie na Rys. 5.3 przedstawiono histogram zawierający siłę i kierunek wiatru wyrażoną odpowiednio w metrach na sekundę oraz stopniach. Są to wartości nieznormalizowane, których bezpośrednie wprowadzenie do algorytmu trenowania sieci neuronowej może spowodować uzyskanie niższej dokładności. Konwersja parametrów wejściowych na wektory, co zaprezentowano po prawej stronie na Rys. 5.3, umożliwi:

- pominięcie lub znaczne zmniejszenie wpływu kierunku wiatru, dla którego prędkość jest bardzo mała (z racji na iloczyn pomiędzy prędkością a kierunkiem),
- uzyskanie tożsamego wpływu parametru o podobnej prędkości wiatru na straty ciepła przy różnych jego kierunkach,
- możliwość wyznaczenia odległości pomiędzy wektorami w celu oceny ich podobieństwa (zbliżonej prędkości i kierunku wiatru), co jest stosowane przy metodyce budowy modeli językowych [90].

Po odpowiednim przekonwertowaniu danych pogodowych algorytm pobiera informacje o budynkach jakie zostały wcześniej zdefiniowane. Funkcja `validate_building()` odpowiada za ich weryfikację jak również rozdzielaniu obiektów, które będą uczestniczyły w trenowaniu sieci w zakresie centralnego ogrzewania lub ciepłej wody użytkowej. Algorytm domyślnie przyjmuje, że każdy obiekt dodany do bazy danych będzie działał w funkcji zapotrzebowania na centralne ogrzewanie. Po pierwszej weryfikacji, funkcja pobiera dane historyczne dla danego budynku i jednocześnie konwertuje je do średnich danych godzinowych. Na tym etapie odrzucane są wszelkie odczyty, dla których wykryto nieprawidłowe wartości.

Do tak przygotowanych danych algorytm agreguje kolejne informacje, które będą wykorzystane w procesie uczenia. W pierwszej kolejności dodawana jest zmienna powiązana

z rocznym wykorzystaniem ciepła przez budynek na cele centralnego ogrzewania oraz ciepłej wody użytkowej. Dane te mogą zostać uzupełnione na dwa sposoby:

- wykorzystanie ręcznie wprowadzonych danych z bazy o budynkach – jest to jedyne rozwiązanie dla budynków, które nie mają zarejestrowanych żadnych informacji historycznych,
- wykorzystanie rzeczywistych danych otrzymywanych za pomocą zdalnej komunikacji z liczników ciepła – rozwiązanie sugerowane przy budynkach, które są w nie wyposażone.

Na potrzeby niniejszej pracy założono, że wartość rocznego wykorzystania ciepła będzie świadczyła o konstrukcji danego budynku i jego izolacyjności. Parametr ten jest dostępny u zarządcy danego budynku oraz spójny dla każdego z nich, ponieważ opiera się na danych z licznika zainstalowanego w węźle cieplnym. Dla nowo wybudowanego obiektu można się w pierwszym momencie posłużyć danymi z charakterystyki energetycznej budynku, a następnie wykorzystywać rzeczywiste dane po uruchomieniu licznika ciepła.

W kolejnym kroku dodawana jest informacja o przeznaczeniu budynku zgodnie z wcześniej opisaną numeracją. Jest ona konwertowana tak, aby nie sugerować algorytmowi, że budynek o typie „4”, z racji na większą wartość parametru, jest bardziej istotny od budynku o typie „0”. Z tego powodu funkcja `buildng_type()` ma zaimplementowaną metodę tzw. gorąco-jedynkową (z ang. one-hot encoding) lub metodą „1 z n”, która jest powszechnie stosowana w tego typu aplikacjach o czym świadczą publikacje [91] lub [92]. Zamiast jej reprezentacji w postaci liczbowej jest on przekonwertowany do określeń słownych. Gdy budynek odpowiada danemu przeznaczeniu to otrzymuje parametr równy 1, a w pozostałych kategoriach zero, co zostało zaprezentowane na Rys. 5.4.

<code>multi_family</code>	<code>store</code>	<code>public</code>	<code>hospital</code>	<code>single_family</code>
0	1	0	0	0

Rys. 5.4. Przykładowy sposób reprezentacji budynku wielorodzinnego (typ „0”) w danych źródłowych algorytmu trenującego sieć neuronową.

W następnym etapie dodawane są informacje o rzeczywistym godzinowym zapotrzebowaniu na moc cieplną dla całego budynku w podziale na wartość na cele c.o. i c.w.u (jeżeli budynek posiada węzeł dwufunkcyjny). Stanowią one kolejną kolumnę w tabeli danych źródłowych do trenowania.

Wykorzystując opisane mechanizmy i dane z każdego z 46 budynków, wygenerowane zostały pliki źródłowe na cele:

- prognozy zapotrzebowania na moc na cele ciepłej wody użytkowej, które zawierały 230 731 rekordów (na koniec 2024 r.),

- prognozy zapotrzebowania na moc cieplną na cele centralnego ogrzewania, gdzie zgromadzonych zostało 314 397 rekordów, w tym samym przedziale czasowym.

Tak przygotowane pliki zostają następnie scalone w jeden dokument zawierający wszystkie dostępne informacje o budynkach. Zastaje on wczytany przez kolejny algorytm, który konwertuje go do formatu odpowiedniego dla biblioteki TENSORFLOW. Odpowiedzialna jest za to funkcja `prepare_data_for_tensorflow()`, która ma za zadanie:

- podzielenie danych źródłowych na dane do trenowania i walidacji, w proporcji odpowiednio 80 do 20,
- określenie jakie cechy będą wprowadzone do wytrenowania sieci jako źródło informacji. W opracowanej aplikacji wykorzystano następujące parametry:
 - długość budynku [m],
 - szerokość budynku [m],
 - liczba pięter [-],
 - roczne wykorzystanie ciepła na potrzeby podgrzania ciepłej wody użytkowej [GJ],
 - roczne wykorzystanie ciepła na potrzeby centralnego ogrzewania [GJ],
 - temperatura powietrza zewnętrznego [st. C],
 - ciśnienie atmosferyczne [hPa],
 - wilgotność względna [%],
 - całkowita ilość opadów [mm],
 - wektor prędkości i kierunku wiatru [m/s],
 - data i godzina wyrażona w postaci 4 funkcji trygonometrycznych,
- określenie jakie parametry będą w warstwie wyjściowej, która odpowiada za efekt predykcji:
 - chwilowa moc cieplna na potrzeby centralnego ogrzewania [kW]
 - lub chwilowa moc cieplna na potrzeby ciepłej wody użytkowej [kW],
- zaimplementowanie do struktury warstw sieci neuronowej funkcji normalizującej dane.

Kolejna funkcja jest odpowiedzialna za zdefiniowanie struktury sieci neuronowej. Pierwsza warstwa jest warstwą wejściową, której wielkość odpowiada liczbie wprowadzanych parametrów. W przypadku trenowania sieci na potrzeby ciepłej wody użytkowej czy centralnego ogrzewania jest ich 14. W kolejnym etapie łączą się one

z warstwami ukrytymi, które zdefiniowane są jako gęste. Liczba neuronów w ostatniej warstwie jest uzależniona od tego ile parametrów ma być prognozowanych przez algorytm. W przypadku predykcji zapotrzebowanie na moc na cele c.o. lub c.w.u. ostatnia warstwa będzie zbudowana z pojedynczego neuronu.

Na podstawie dostępnej literatury poruszającej tematykę sieci neuronowych [93], [94], [95], [96], przyjęto poniższe zakresy parametrów w oparciu o które generowane były modele:

- liczba warstw gęstych od 1 do 4,
- liczba neuronów w każdej warstwie, która była wielokrotnością liczby 32 w zakresie od 32 do 320,
- funkcja aktywacji dla wszystkich warstw jednakowa z zakresu:
 - ReLU (rectified linear unit – skorygowana jednostka liniowa, powszechnie stosowana i opisywana przez wielu badaczy np. [97])
 $f(x) = \max(0, x)$
 - Leaky ReLU (leaky rectified linear unit – niedyskretna skorygowana jednostka liniowa, opisana przez A. Dubay, S. Singh, B. Chadhuri w swoim artykule [98])
 $f(x) = \max(ax, x)$
 - ReLU6 (rectified linear unit – skorygowana jednostka liniowa z ograniczeniem wyjścia z neuronu do wartości 6, który jest wykorzystywany np. przez autorów [99])
 $f(x) = \min(\max(0, x), 6)$
 - GELU (gaussian error linear unit – jednostka liniowa błędu gaussowskiego)
 $f(x) = xP(X \leq x) = x\Phi(x)$ [100]
 - ELU (exponential linear unit – wykładnicza jednostka liniowa) [101]

$$f(x) = \begin{cases} x & \text{if } x > 0 \\ \alpha(\exp(x) - 1) & \text{if } x \leq 0 \end{cases}$$

gdzie:

α – parametr szczegółowo opisany w [101] domyślnie przyjmowany jako 1,0,

- parametr `batch_size` (wielkość partii, czyli liczba przeanalizowanych próbek danych zanim zaktualizowane zostaną wszystkie wagi w sieci neuronowej, analizowany m.in. przez [102]) przyjmujący wartości 32, 64, 128, 256,
- zmienna szybkości uczenia (`learning_rate`), poruszana w wielu publikacjach [103], [104] oraz książkach [105], [106], przyjmująca wartości 0,1, 0,01, 0,001, 0,005,

- funkcja optymalizacyjna Adam, która na podstawie [107] jest metodą niewymagającą dużej mocy obliczeniowej i dobrze nadającą się do rozwiązywania problemów złożonych z dużej ilości danych.

Maksymalna liczba epok została ustawiona domyślnie na wartość 1 000 przy równoczesnej implementacji warunku wcześniejszego zatrzymania trenowania sieci neuronowej w przypadku braku postępów. Mechanizm kończy proces w przypadku, gdy przez 10 kolejnych epok wartość funkcji straty nie zmniejszy się o co najmniej 0,01. Po jego spełnieniu, uczenie zatrzymuje się i zapisywane są wagi dla epoki, w której uzyskana została najmniejsza strata wyliczona na podstawie danych walidacyjnych. Do tych obliczeń wykorzystywane mogą być:

1. średni błąd kwadratowy (Mean Squared Error),

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{rz} - y_{pred})^2$$

gdzie:

n – liczba próbek w każdej epoce,

y_{rz} – wartość rzeczywista,

y_{pred} – wartość prognozowana.

2. lub średni błąd bezwzględny (Mean Absolute Error).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{rz} - y_{pred}|$$

gdzie:

n – liczba próbek w każdej epoce,

y_{rz} – wartość rzeczywista,

y_{pred} – wartość prognozowana.

Pierwszy mierzy średnią kwadratową różnicę pomiędzy przewidywanymi wartościami a rzeczywistymi danymi. Jego charakterystyka wykładnicza wzmacnia dodatkowo duże błędy, co skutkuje tym, że wskaźnik jest bardzo wrażliwy na nietypowe dane. Drugi natomiast wylicza różnicę bezwzględną pomiędzy prognozą a danymi rzeczywistymi. Z tego powodu jest mniej wrażliwy na wszelkiego rodzaju pomiary, które znacząco różnią się od reszty danych w zbiorze.

Ponieważ od algorytmu będzie wymagana pełna automatyzacja w zakresie pobierania nowych danych z baz, trenowanie modeli sieci neuronowej oraz generowanie predykcji, dlatego

zdecydowano się na wykorzystanie innej funkcji straty tj. metody Huber (nazwa pochodzi od szwajcarskiego statystyka Petera Hubera i została szczegółowo opisana w publikacji [108]). Jest to kombinacja dwóch powyższych funkcji, która jest mniej wrażliwa niż MSE, ale i mniej oscylacyjna niż MAE.

$$HUBER = \begin{cases} \frac{1}{2}(y_{rz} - y_{pred})^2 & \text{dla } |y_{rz} - y_{pred}| \leq \delta \\ \delta|y_{rz} - y_{pred}| - \frac{1}{2}\delta^2 & \text{dla pozostałych} \end{cases}$$

gdzie:

δ – wartość dla której funkcja straty Hubera zmienia się z kwadratowej na liniową (domyślnie przyjmowana jako 1,0),

n – liczba próbek w każdej epoce,

y_{rz} – wartość rzeczywista,

y_{pred} – wartość prognozowana.

Przy definiowaniu opcji generowanego modelu sieci możliwe jest wprowadzenie jeszcze jednego parametru, który będzie równolegle przeliczał jego dokładność na podstawie danych walidacyjnych. Jego wprowadzenie może być pomocne przy bieżącej kontroli postępu procesu trenowania sieci neuronowej. Różni się on od funkcji straty następującymi aspektami:

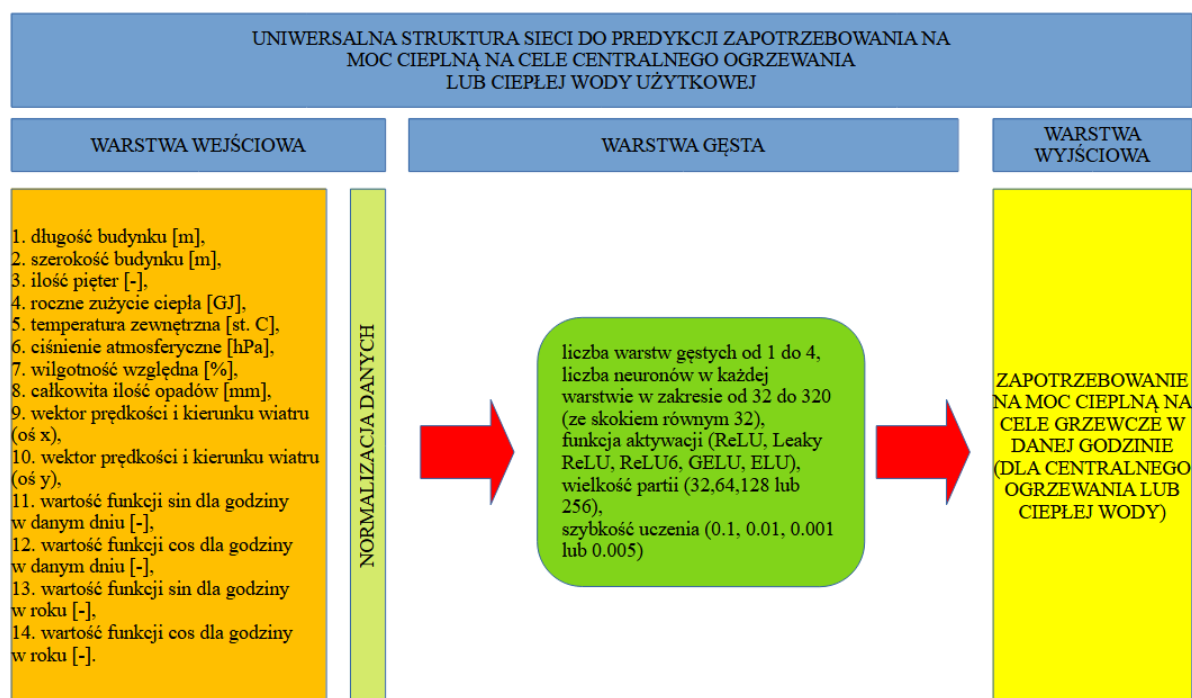
- nie bierze udziału w aktualizacji wag sieci,
- wyliczany jest na bazie wszystkich próbek z epoki w przeciwieństwie do funkcji straty, która jest przeliczana po określonej liczbie próbek (wyznaczonej przez parametr `batch_size`).

W punkcie 2.2 opisane zostały tendencje zbytnio rozbudowanych sieci neuronowych do lepszego „zapamiętywania” danych treningowych, które w konsekwencji skutkują niską jakością predykcji w przypadku nowych danych. Aby tego uniknąć, przy zachowaniu akceptowalnego poziomu dokładności, warto wybrać wygenerowany model o jak najmniejszej liczbie parametrów (warstw i neuronów). Takie podejście będzie zgodne z *zasadą najmniejszego działania* zaczerpniętego z fizyki klasycznej i opracowane przez Hamiltona w 1834 r. [109]. Jej definicję „można sformułować [...] w sposób następujący: natura w swoich działaniach zachowuje się w sposób najprostszy” [110].

W oparciu o wyżej opisany zakres dostępnych parametrów jak i przy wykorzystaniu opracowanych metod oceny dokładności predykcji, wygenerowanych zostało:

- 1 600 modeli dla centralnego ogrzewania,
- 1 600 modeli dla ciepłej wody użytkowej.

Na Rys. 5.5 przedstawiono uniwersalną strukturę sieci neuronowej, która w zależności od wewnętrznych współczynników, była wykorzystywana do zapisania modeli. W kolejnym rozdziale przedstawiono metodę ich oceny i wyboru architektury sieci neuronowej, która najlepiej sprawdziła się przy predykcji zapotrzebowania na moc cieplną na cele centralnego ogrzewania lub ciepłej wody użytkowej.



Rys. 5.5. Uniwersalna struktura sieci neuronowej wykorzystana do generowania modeli do prognozy zapotrzebowania na moc cieplną na cele centralnego ogrzewania oraz ciepłej wody użytkowej dla budynku.

5.2. Akceptowalna niedokładność.

W niniejszej rozprawie przyjęto następującą tezę: *Istnieje możliwość wykorzystania sztucznych sieci neuronowych na cele prognozy: zapotrzebowania na ciepło, ceny energii elektrycznej oraz ceny paliwa gazowego, z akceptowalną dokładnością, dla istniejącego systemu ciepłowniczego zasilanego z kogeneracyjnej elektrociepłowni gazowej.*

Dla tak sformułowanej tezy istotną kwestią jest określenie granicy, której przekroczenie odrzuci wygenerowany model. Z racji na wdrożeniowy charakter pracy, który wymaga implementacji jej wyników w funkcjonującym przedsiębiorstwie, zdecydowano się nawiązać do przepisów prawnych regulujący rynek ciepłowniczy. W przypadku prognozy zapotrzebowania na ciepło, kryterium akceptowalnej dokładności będzie odnosiło się do rozporządzenia w sprawie szczegółowych zasad kształtowania i kalkulacji taryf oraz rozliczeń z tytułu zaopatrzenia w ciepło [111]. W paragrafie 42 opisane jest maksymalne ograniczenia mocy cieplnej dostarczanej do węzła cieplnego, które jest dopuszczalne. W przypadku, gdy

nośnikiem ciepła jest gorąca woda wynosi ono 10 %. Oznacza to, że obniżenie mocy cieplnej dostarczanej do odbiorcy końcowego większe niż powyższa wartość będzie skutkowało naliczeniem bonifikaty, która stanowi dodatkowy koszt funkcjonowania przedsiębiorstwa. Z tego tytułu zaproponowano, aby w przypadku prognozy zapotrzebowania na ciepło, maksymalna wartość niedokładności nie przekraczała 10 %, co będzie stanowiło wyznacznik akceptowalnej dokładności.

5.3. Walidacja.

Algorytmy wykorzystywane przy trenowaniu sieci, a następnie ocenianiu ich postępów w dokładności predykcji danych, mają swoje wewnętrzne mechanizmy do oceny. Jak zostało opisane wcześniej, program na podstawie wartości funkcji straty HUBER tak dobierał wagi w każdej iteracji aby minimalizować błąd wyliczany w oparciu o dane walidacyjne. Realizował to na podstawie 20 % danych treningowych [112], porównując rzeczywiste zapotrzebowania na moc ciepłą w danej godzinie w stosunku do prognozy tej mocy.

Takie postępowanie sprawdza się przy dobieraniu wag neuronów w konkretnej strukturze sieci. Jednak do kompleksowej oceny architektury sieci neuronowej w stosunku do problemu z jakim ma sobie ona poradzić, zdecydowano się na opracowanie własnej metody walidacji. Polega ona na wygenerowaniu rocznego godzinowego zapotrzebowania na moc ciepłą na cele centralnego ogrzewania oraz ciepłej wody użytkowej dla każdego budynku. Następnie zsumowania wszystkich godzinowych wartości i porównania z rocznym rzeczywistym wykorzystaniem ciepła dla danego budynku w tym samym okresie (wyznaczonym na podstawie licznika ciepła w węźle).

Algorytm ten można zapisać w następujący sposób:

1. w zależności od zapotrzebowania na c.o. lub c.w.u. wczytaj wcześniej wygenerowany model sieci neuronowej (tj. nr „x” z 1 600),
2. pobierz dane charakterystyczne o budynkach przyłączonych do sieci,
3. wczytaj prognozę pogody dla całego roku,
4. wygeneruj godzinowe zapotrzebowanie na moc dla całego roku dla wszystkich budynków, a następnie je zsumuj i przelicz na GJ,
5. zsumuj rzeczywiste wykorzystanie ciepła dla wszystkich budynków,
6. wyznacz średni błąd procentowy (Mean Percentage Error) dla wszystkich wartości określony równaniem:

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_{prog} - y_{rz}|}{y_{rz}} \cdot 100 \%$$

gdzie:

n – liczba budynków,

y_{rz} – roczne rzeczywiste wykorzystanie ciepła dla danego budynku ,

y_{pred} – roczne prognozowane wykorzystanie ciepła dla danego budynku.

Model sieci, dla której niedokładność predykcji będzie najmniejsza w stosunku do sumy rzeczywistego wykorzystania ciepła dla wszystkich budynków, określony zostanie jako najlepszy przy rozwiązaniu danego problemu. Analizę wykonano w oparciu o dane pogodowe dla roku, dla którego wprowadzone zostały ręcznie dane o wykorzystaniu ciepła.

W Tabeli 5.1 przedstawiono pierwszych pięć modeli, które charakteryzowały się najmniejszą niedokładnością przy prognozie zapotrzebowania na moc cieplną na cele centralnego ogrzewania oraz ciepłej wody użytkowej. Nazwy modeli zaprezentowano w drugiej kolumnie i składają się one z:

- dwóch początkowych cyfr, z których pierwsza odpowiada za liczbę warstw, a druga za współczynnik odpowiadający liczbie neuronów w każdej warstwie,
- nazwy funkcji aktywacji,
- parametru opisującego wielkości próbek `batch_size`,
- zastosowanego współczynnika uczenia.

Opisane powyżej pierwsze dwie cyfry są efektem zastosowanych mechanizmów przy programowaniu struktury sieci neuronowej. W celu ich lepszego zobrazowania, zostały one opisane w inny sposób w kolumnie nr 3. Zawiera ona informację o liczbie warstw oddzielonych myślnikiem wraz z liczbą neuronów w każdej z nich. Przykładowo wartość 320–160 będzie oznaczała, że model jest zbudowany z dwóch warstw. W pierwszej będzie posiadał 320 neuronów a w drugiej 160. Im bardziej rozbudowana architektura tym liczba wag sieci wzrasta, a ich liczba która odpowiada liczbie połączeń pomiędzy neuronami, została zaprezentowana w kolumnie nr 4. Jest to istotna informacja, która umożliwi zastosowanie *zasady najmniejszego działania* do wyboru architektury. Ostatnia kolumna to wartość niedokładności modelu po wygenerowaniu godzinowych danych dla wszystkich budynków przyłączonych do sieci dla danego roku.

Tabela 5.1. Zestawienie pierwszych pięciu wygenerowanych modeli do prognozy zapotrzebowania na moc ciepłą na potrzeby centralnego ogrzewania dla budynku.

L. p.	Nazwa modelu do prognozy mocy ciepłej na cele c.o.	Struktura sieci neuronowej [-]	Liczba wag sieci [-]	Niedokładność modelu [%]
[1]	[2]	[3]	[4]	[5]
1	3 5 gelu 256 0.1	320-160	56 321,00	7,47
2	5 1 elu 128 0.1	64-32-16-8	3 713,00	7,96
3	2 5 elu 32 0.01	320	5 121,00	8,03
4	5 1 elu 256 0.01	64-32-16-8	3 713,00	8,31
5	3 5 elu 128 0.01	320-160	56 321,00	8,32

Tabela 5.2. Zestawienie pierwszych pięciu wygenerowanych modeli do prognozy zapotrzebowania na moc ciepłą na cele podgrzania ciepłej wody użytkowej dla budynku.

L. p.	Nazwa modelu do prognozy mocy ciepłej na cele c.w.u.	Struktura sieci neuronowej [-]	liczba wag sieci [-]	Niedokładność modelu [%]
[1]	[2]	[3]	[4]	[5]
1	5 5 leaky relu 32 0.1	320-160-80-40	72 321,00	5,09
2	5 2 leaky relu 64 0.1	128-64-32-16	12 801,00	5,34
3	4 5 leaky relu 128 0.1	320-160-80	69 121,00	5,98
4	5 1 leaky relu 32 0.005	64-32-16-8	3 713,00	6,86
5	4 2 leaky relu 128 0.1	128-64-32	12 289,00	7,02

Struktura modelu na pierwszej pozycji do prognozy zapotrzebowania na moc ciepłą na cele centralnego ogrzewania w stosunku do numeru 2. jest ponad 15-to krotnie bardziej rozbudowana przy różnicy niedokładności wynoszącej zaledwie 0,49 p.p. W tym przypadku wybranie modelu nr 2, który będzie charakteryzował się lepszą generalizacją oraz większą szybkością działania, będzie lepszym wyborem. Podobna sytuacja ma miejsce w przypadku modeli do prognozowania zapotrzebowania na moc ciepłą na cele ciepłej wody użytkowej (Tabela 5.2). Model numer 2 ma ponad pięciokrotnie mniej neuronów przy niedokładności

gorszej zaledwie o 0,25 p.p. W tym przypadku również model numer 2 będzie charakteryzował lepszą zdolnością do generalizacji przy niewielkim spadku dokładności.

Biorąc pod uwagę zdefiniowany próg akceptowalnej dokładności, do prognozy zapotrzebowania na moc na cele centralnego ogrzewania wybrano model 5 1 elu 128 0.1, którego niedokładność wyniosła 7,98 %. Model ten skonstruowano w oparciu o następujące parametry:

- 64 neurony w pierwszej warstwie gęstej z funkcją aktywacji ELU,
- 32 neurony w drugiej warstwie gęstej z funkcją aktywacji ELU,
- 16 neuronów w trzeciej warstwie gęstej z funkcją aktywacji ELU,
- 8 neuronów w czwartej warstwie gęstej z funkcją aktywacji ELU,
- wielkość próbek (batch_size) ustawiona na 128,
- szybkość uczenia wynosiła 0,1.

W przypadku ciepłej wody użytkowej wybrano do dalszej analizy model 5 2 leaky relu 64 0.1, który charakteryzował się niedokładnością 5,34 % i zbudowany jest z następujących parametrów:

- 128 neuronów w pierwszej warstwie gęstej z funkcją aktywacji Leaky ReLU,
- 64 neurony w pierwszej warstwie gęstej z funkcją aktywacji Leaky ReLU,
- 32 neurony w drugiej warstwie gęstej z funkcją aktywacji Leaky ReLU,
- 16 neuronów w trzeciej warstwie gęstej z funkcją aktywacji Leaky ReLU,
- 8 neuronów w czwartej warstwie gęstej z funkcją aktywacji Leaky ReLU,
- wielkość próbek (batch_size) ustawiona na 64,
- szybkość uczenia wynosiła 0,1.

Zaproponowana metoda oceny odnosi się do danych źródłowych o wszystkich budynkach. Jednak jak przedstawiono poniżej, ten sam model może sprawdzać się lepiej lub gorzej wobec konkretnego budynku, pomimo średniej wypadającej poniżej granicy akceptowalnej niedokładności. W Tabeli 5.3 oraz Tabeli 5.4 przedstawiono zestawienie trzech budynków, w stosunku do których wybrane modele tj. 5 1 elu 128 0.1 oraz 5 2 leaky relu 64 0.1 wykazywały najlepszą i najgorszą dokładność predykcji.

Tabela 5.3. Zestawienie jakości prognozy zapotrzebowania na moc ciepłą na cele centralnego ogrzewania, wygenerowane na podstawie modelu 5 1 elu 128 0.1, dla trzech najlepszych i najgorszych budynków przyłączonych do sieci ciepłej w roku 2023.

L. p.	Adres	wykorzystanie ciepła na potrzeby c.o. w roku 2023 [GJ]	Prognoza wykorzystania ciepła na cele c.o. w roku 2023 [GJ]	Niedokładność modelu [%]
1	Lelewela 1	382,0	382,0	0,00
2	Ciszewskiego 3	232,0	232,0	0,00
3	Plac Wolności 6-10	583,1	583,0	0,02
105	Czeska 1	58,3	76,0	30,36
106	Mickiewicza 3	1107,7	1592,0	43,72
107	Apteka Olimpijska 1A	46,3	71,0	53,40

Tabela 5.4. Zestawienie jakości prognozy zapotrzebowania na moc ciepłą na cele ciepłej wody użytkowej, wygenerowane dla modelu 5 2 leaky relu 64 0.1, dla trzech najlepszych i najgorszych budynków przyłączonych do sieci ciepłej w roku 2023.

L. p.	Adres	wykorzystanie ciepła na potrzeby c.w.u. w roku 2023 [GJ]	Prognoza wykorzystania ciepła na cele c.w.u. w roku 2023 [GJ]	Niedokładność modelu [%]
1	Wojska Polskiego 62–65	300,0	300,0	0,00
2	Malinowskiego 1	364,1	364,0	0,04
3	Polna 7	344,8	345,0	0,07
43	Kołobrzeska 33	251,6	213,0	15,33
44	Kołobrzeska 43	152,5	95,0	37,71
45	Dworzec PKP	102,0	48,0	52,94

Przyczyną znacznej niedokładności modelu przy prognozie na cele c.o. dla budynków przy ul. Czeskiej 1, ul. Mickiewicza 3 oraz ul. Olimpijskiej 1A, może być ich błędna klasyfikacja. Domyślnie wszystkie mają przypisywany typ budynku wielorodzinnego jednak w tym przypadku:

- pierwszy z nich to budynek jednorodzinny,
- drugi to budynek użyteczności publicznej,
- a trzeci typu usługowego.

Niestety z racji na przeważającą liczbę budynków wielorodzinnych przyłączonych do sieci, z których można było pobrać dane na potrzeby wytrenowania modelu sieci neuronowej, niemożliwe było wykorzystanie danych z innych typów budynków jako rzetelne źródło informacji.

Podobna sytuacja ma miejsce w przypadku prognozy zapotrzebowania na ciepłą wodę użytkową. Ostatnie dwie pozycje, których niedokładność przekracza 35 % to budynki użyteczności publicznej. Również i w tym przypadku nie ulega wątpliwości, że sposób korzystania z ciepłej wody użytkowej w tego typu obiektach znacznie różni się od budownictwa wielorodzinnego.

Opracowana metoda ma również możliwość oceny modelu w kolejnym etapie. Posługując się rzeczywistymi danymi o rocznej sprzedaży ciepła przez przedsiębiorstwo ciepłownicze, można je porównać z danymi wygenerowanymi przez model dla danego roku dla wszystkich budynków. W tym przypadku należy zsumować wartości jakie będą wynikały z wykorzystania ciepła na cele centralnego ogrzewania oraz ciepłej wody użytkowej. Dodatkowo uzyskane wyniki zostały porównane z prognozą wykorzystującą metodę naiwną zakładającą takie same wykorzystanie ciepła w danym roku co w roku poprzednim [113]. Metoda ta ma pewne wady tj. brak możliwości jej wykorzystania przed zgromadzeniem jakichkolwiek danych historycznych o systemie oraz zakłada statyczność układu ciepłowniczego (brak nowych klientów w całym okresie analizy). Jest jednak szeroko stosowana z racji na swoją prostotę, szybkość i niskie koszty implementacji o czym piszą [114], [115], [116]. Na tej podstawie opracowano następujący algorytm:

- oblicz błąd MPE dla danego roku w oparciu o sprzedaż ciepła wygenerowaną przez sieć neuronową w stosunku do danych rzeczywistych,
- oblicz błąd MPE dla danego roku przyjmując, że dane prognozowane zostały wygenerowane z wykorzystaniem metody naiwnej zakładającej, iż sprzedaż ciepła będzie na poziomie z poprzedniego roku.

Tabela 5.5. Zestawienie dokładności predykcji dla modelu 5 1 elu 128 0.1 dla c.o., 5 2 leaky relu 64 0.1 dla c.w.u. oraz metody naiwnej w okresie od stycznia 2021 r. do grudnia 2024 r.

Rok	Miesiąc	Rzeczywiste wykorzystanie ciepła przez wszystkie budynki na cele c.o. oraz c.w.u. [GJ]	Prognozowane wykorzystanie ciepła przez wszystkie budynki na cele c.o. oraz c.w.u. [GJ]	Niedokładność modelu sieci neuronowej [%]	Niedokładność przy naiwnym założeniu takiego samego wykorzystania ciepła jak w roku poprzednim[%]
2021	1	13 214	14 795	11,96	-12,07
	2	12 712	12 851	1,09	-19,32
	3	11 135	9 818	-11,83	-7,48
	4	8 496	7 265	-14,49	-11,61
	5	3 527	2 178	-38,25	14,89
	6	1 279	1 161	-9,23	0,94
	7	1 161	1 219	5,0	10,42
	8	1 231	1 304	5,93	2,68
	9	2 435	1 332	-45,3	-49,49
	10	6 122	5 244	-14,34	21,01
	11	9 260	9 579	3,44	-10,31
	12	13 661	14 567	6,63	-7,5
	1-12	84 233	81 313	-3,47	-8,4
2022	1	12 728	13 552	6,47	3,82
	2	9 701	10 348	6,67	31,04
	3	10 595	10 103	-4,64	5,1
	4	8 070	6 638	-17,74	5,28
	5	2 622	1 369	-47,79	34,52

Rok	Miesiąc	Rzeczywiste wykorzystanie ciepła przez wszystkie budynki na cele c.o. oraz c.w.u. [GJ]	Prognozowane wykorzystanie ciepła przez wszystkie budynki na cele c.o. oraz c.w.u. [GJ]	Niedokładność modelu sieci neuronowej [%]	Niedokładność przy naiwnym założeniu takiego samego wykorzystania ciepła jak w roku poprzednim[%]
	6	1 272	1 190	-6,45	0,55
	7	1 305	1 231	-5,67	-11,03
	8	1 220	1 293	5,98	0,9
	9	1 501	1 355	-9,73	62,23
	10	6 453	3 901	-39,55	-5,13
	11	8 396	10 611	26,38	10,29
	12	12 338	14 356	16,36	10,72
	1-12	76 201	75 947	-0,33	10,54
2023	1	11 192	12 667	13,18	13,72
	2	10 828	11 004	1,63	-10,41
	3	9 797	9 813	0,16	8,15
	4	6 556	6 620	0,98	23,09
	5	3 834	1 429	-62,73	-31,61
	6	1 332	1 191	-10,59	-4,5
	7	1 519	1 202	-20,87	-14,09
	8	1 404	1 308	-6,84	-13,11
	9	1 411	1 297	-8,08	6,38
	10	6 352	5 098	-19,74	1,59
	11	9 436	10 393	10,14	-11,02
	12	12 883	13 144	2,03	-4,23

Rok	Miesiąc	Rzeczywiste wykorzystanie ciepła przez wszystkie budynki na cele c.o. oraz c.w.u. [GJ]	Prognozowane wykorzystanie ciepła przez wszystkie budynki na cele c.o. oraz c.w.u. [GJ]	Niedokładność modelu sieci neuronowej [%]	Niedokładność przy naiwnym założeniu takiego samego wykorzystania ciepła jak w roku poprzednim[%]
	1–12	76 544	75 166	-1,8	-0,45
2024	1	12 971	12 236	-5,67	-13,72
	2	9 817	9 972	1,58	10,3
	3	8 435	8 616	2,15	16,15
	4	6 299	5 665	-10,07	4,08
	5	1 559	1 303	-16,42	145,93
	6	1 387	1 251	-9,81	-3,97
	7	1 354	1 303	-3,77	12,19
	8	1 324	1 333	0,68	6,04
	9	1 413	1 341	-5,1	-0,14
	10	6 549	5 204	-20,54	-3,01
	11	10 065	10 077	0,12	-6,25
	12	10 998	12 200	10,93	17,14
		1–12	72 171	70 501	-2,31

Na podstawie danych z Tabela 5.5 można zauważyć, że średnia niedokładność modelu dla całego roku (wiersz oznaczony jako 1–12) dla prognozy opartej na sieciach neuronowych, za wyjątkiem roku 2023, jest mniejsza niż w przypadku prognozy opartej na modelu naiwnym (metoda naiwna została szczegółowo opisana na stronie 71). W 2023 roku różnica była bardzo niewielka wynosząca 1,35 p.p. Metoda naiwna lepiej się sprawdziła w tym przypadku, ponieważ różnica pomiędzy sprzedażą ciepła w 2022 a 2023 roku wynosiła zaledwie 343 GJ. W pozostałych przypadkach metoda oparta na sieciach neuronowych w latach 2021, 2022 oraz 2024 sprawdzała się bardzo dobrze osiągając dokładność predykcji lepszą od metody

naiwnej o odpowiednio 4,93 p.p., 10,21 p.p. i 3,75 p.p. Jest to obserwacja zbieżna z publikacją [117].

Analizując poszczególne miesiące widać też pewną zależność pomiędzy znacznym spadkiem dokładności prognozy, a rozpoczęciem i zakończeniem sezonu grzewczego. Mają one miejsca najczęściej w maju oraz na przełomie września i października. Zmianę trybu pracy systemu ciepłowniczego z zimowego na letni, model sieci neuronowej prognozuje biorąc pod uwagę wyłącznie:

- parametry powietrza zewnętrznego,
- datę i czas,
- wymiary charakterystyczne budynku.

W obecnym stanie prawnym funkcjonowania systemów ciepłowniczych to właściciel danego budynku, który jest przyłączony do sieci, decyduje o momencie uruchomienia lub zakończenia ogrzewania. Jest on po części uzależniony od panujących warunków atmosferycznych i ich prognoz, jednak uwzględnia również aspekt społeczno – ekonomiczny. Opracowany algorytm nie uwzględnia ostatniej kwestii z racji na trudności w zdefiniowaniu odpowiednich parametrów oraz pozyskania danych wejściowych. Przełożyło się to bezpośrednio na spadek dokładności w tych miesiącach.

5.4. Wnioski i analizy.

Wykorzystując sieci neuronowe do prognozy zapotrzebowania na ciepło na cele centralnego ogrzewania oraz ciepłej wody użytkowej możliwe jest ich prognozowanie ze średnią niedokładnością poniżej 6,7 %. Opracowana metoda umożliwi realizację tego celu pomimo ograniczeń wynikających z:

1. dokładności wymiarów analizowanych budynków, które opierały się na pomiarach wykonanych z map internetowych,
2. braku danych o konstrukcji przegród zewnętrznych budynku,
3. braku danych o dokładnej wysokości budynku, do modelu wprowadzana była wyłącznie informacja o liczbie pięter,
4. braku danych o ewentualnym podpiwniczeniu budynku,
5. braku możliwości wprowadzenia do budynku informacji o tym czy jest on wolnostojący czy w zabudowie szeregowej,
6. braku danych o innym typie budynku niż wielorodzinny, które mogłyby posłużyć do wytrenowania modelu,

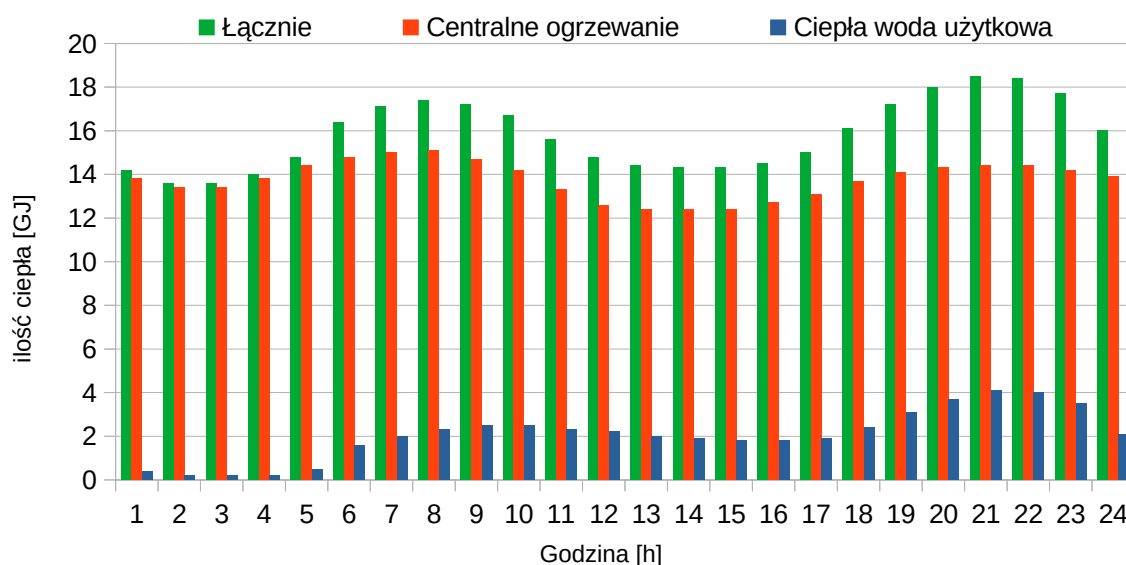
7. braku informacji na temat rozpoczęcia i zakończenia sezonu grzewczego, który aktualnie jest skutkiem decyzji administracyjnej, a nie wprost uzależniony od warunków pogodowych,
8. wprowadzenia do modelu wyłącznie danych z ostatniego roku, co wynikało ze zmiany sposobu regulacji węzłów cieplnych we wcześniejszym okresie.

Opracowana metoda wykorzystuje do prognozowania jednokierunkowe sieci neuronowe, a nie rozwiązanie oparte o prognozowanie szeregów czasowych [118]. Oznacza to, że podając informacje o budynku oraz warunki pogodowe w danej godzinie w roku, możliwe jest uzyskanie wartości obciążenia cieplnego przez budynek na cele c.o. oraz c.w.u. Jest to metoda o tyle lepsza od szeregów czasowych, że nie wymaga wprowadzania historycznych danych o budynku w celu wykonania predykcji. Ma to swoje dalsze konsekwencje w postaci możliwości:

- natychmiastowego dodania nowego obiektu do systemu ciepłowniczego bez wcześniejszego zgromadzenia danych pomiarowych i przeprowadzenie analizy jego wpływu na pracę sieci cieplnej,
- analizy godzinowego obciążenia cieplnego dla danego budynku (oraz zamówionej mocy cieplnej w systemie ciepłowniczym), mając do dyspozycji jedynie informację o rocznym wykorzystaniu ciepła.

5.5. Wdrożenie.

Wytrenowany model służy do predykcji godzinowego zapotrzebowania na moc ciepłą na cele podgrzania ciepłej wody użytkowej jak i centralnego ogrzewania dla każdego budynku zdefiniowanego w bazie danych. Taka informacja w połączeniu z aktualnie stosowaną przez przedsiębiorstwo taryfą dla ciepła, może posłużyć do analizy finansowej przychodów ze sprzedaży ciepła w czasie rzeczywistym.



Rys. 5.6. Godzinowa prognozowana sprzedaż ciepła w systemie ciepłowniczym 10. lutego 2025 r. w podziale na ciepłą wodę użytkową, centralne ogrzewanie oraz wartość łączną, wygenerowana za pomocą sztucznej sieci neuronowej.

Prognozowane wartości sprzedanej energii cieplnej dla przykładowego dnia zostały przedstawione na Rys. 5.6. Wartości te publikowane są na stronie internetowej aplikacji pod adresem <https://dawid.czajor.com.pl/phd> jak również mogą być udostępniane w dowolnej formie na wybrany adres e-mail osoby odpowiedzialnej za sprawy ekonomiczno-finansowe przedsiębiorstwa.

6. Prognozowanie zapotrzebowania na ciepło w źródle.

6.1. Opis mechanizmu.

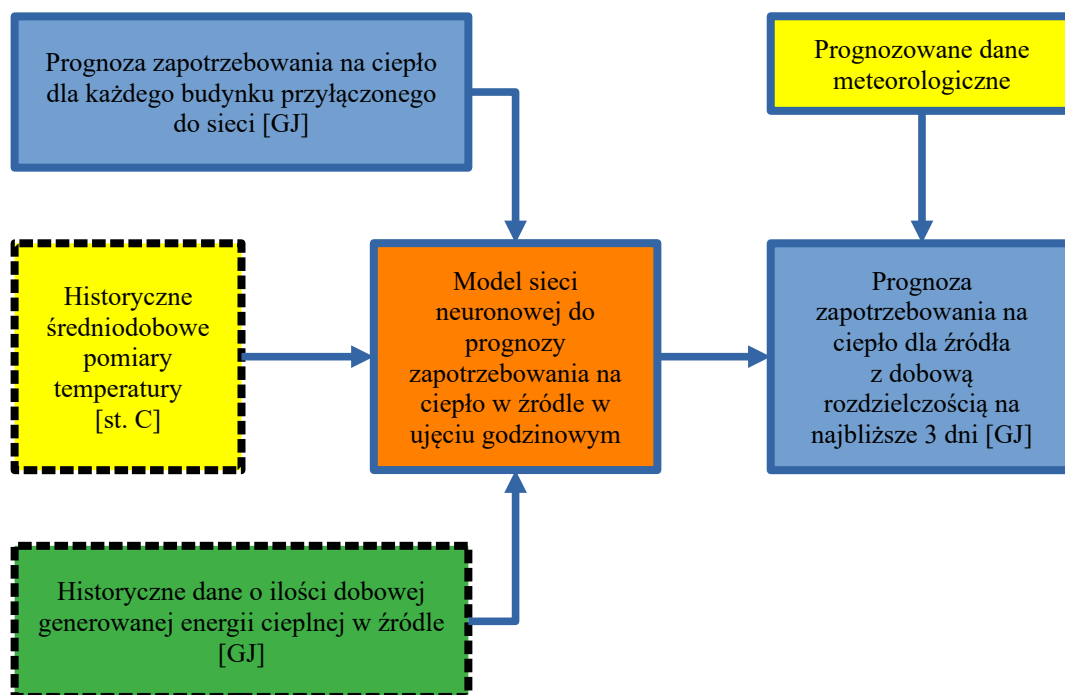
Wykorzystując dane o zapotrzebowaniu na moc cieplną dla wszystkich budynków przyłączonych do sieci ciepłej, konieczne jest zbudowanie narzędzia do prognozy zapotrzebowania na ciepło w źródle. Informacja ta jest kluczowa do sterowania jego pracą oraz w celu opracowania kolejnego mechanizmu do prognozy zużycia paliwa gazowego przez urządzenia wytwórcze. Niniejszy algorytm jest przykładem funkcji, w której dane do wytrenowania sieci neuronowej są wygenerowane przez inny model sieci opisany w punkcie nr 5. W tym zastosowaniu prognozowane zapotrzebowanie na moc cieplną u odbiorców końcowych w połączeniu z rzeczywistymi danymi z elektrociepłowni będą źródłem danych do wytrenowania modelu sieci neuronowej.

Dane z elektrociepłowni są zapisywane z interwałem piętnastominutowym i rejestrowane od 31 grudnia 2022 r. Zawierają one wiele informacji o pracy elektrociepłowni (szczegółowo opisanych w punkcie 4.4) z których wykorzystano wyłącznie:

- moc cieplną rejestrowaną przez główny ciepłomierz na wyjściu ze źródła,
- wartość temperatury powietrza zewnętrznego.

W przypadku temperatury zewnętrznej zostały one uśrednione, a dla mocy cieplnej po stronie źródła i odbiorców, przeliczone na jednostki ciepła i zsumowane do wartości dobowych. Taki zabieg miał na celu uproszczenie modelu, który w przypadku analizy godzinowej musiałby brać pod uwagę bezwładność sieci ciepłej.

W analizowanym systemie ciepłowniczym zwiększenie mocy cieplnej źródła jest konsekwencją zwiększenia jego zapotrzebowania przez odbiorców (jest to przykład regulacji nadeżnej). Może się zatem zdarzyć sytuacja, w której odbiorcy poprzez zwiększenie przepływu czynnika grzewczego przez węzeł cieplny pobierają w danej jednostce czasu więcej ciepła (zakumulowanej w sieci ciepłej) niż wynika to z chwilowej generacji w źródle. Taka sytuacja jest konsekwencją sposobu regulacji urządzeń wytwórczych, który charakteryzuje się bardzo dużymi stałymi czasowymi odpowiadającymi za zwiększenie lub zmniejszenie parametrów technologicznych elektrociepłowni. Sposób działania opracowanego mechanizmu do prognozy zapotrzebowania na moc cieplną dla źródła został przedstawiony na Rys. 6.1.

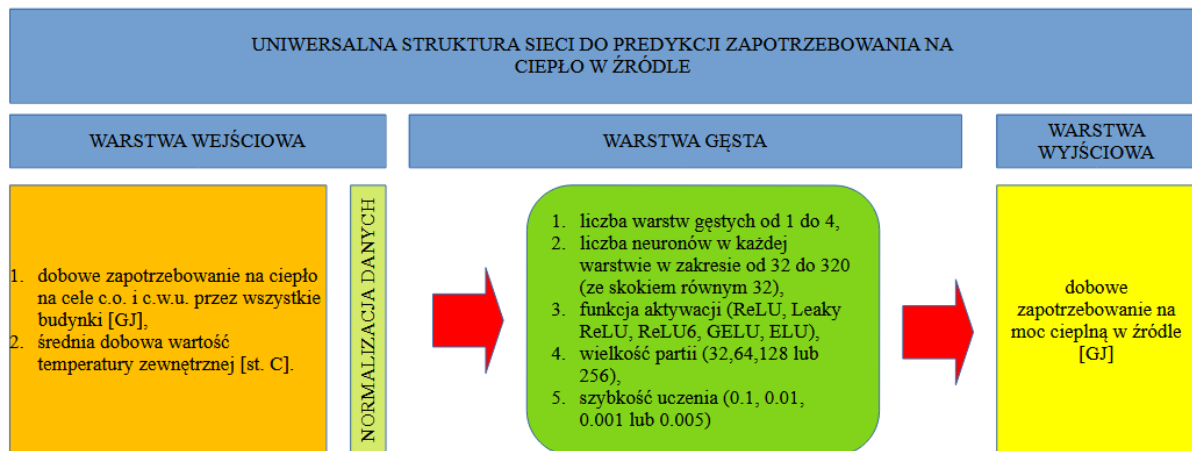


Rys. 6.1. Schemat opracowanego algorytmu do prognozy zapotrzebowania na ciepło w źródle.

Zgromadzone dane przechodzą weryfikację pod kątem wykrycia potencjalnych błędów i zostają skierowane do funkcji odpowiadającej za zbudowanie modelu sieci neuronowej. Tak jak w poprzednim rozdziale przyjęto identyczny zakres parametrów do konfiguracji różnych jej struktur tj.:

- liczba warstw,
- liczba neuronów,
- typ funkcji aktywacji,
- liczba próbek,
- współczynnik uczenia.

Do oceny modelu w trakcie procesu uczenia została wykorzystana funkcja straty HUBER (analogicznie jak w przypadku modeli do prognozy zapotrzebowania na moc cieplną u odbiorcy końcowego). Na Rys. 6.2 przedstawiono graf opisujący uniwersalną strukturę sieci, na podstawie której generowane były modele. Całkowita ich liczba wyniosła 1 600 wersji.



Rys. 6.2. Uniwersalna struktura sieci neuronowej wykorzystana do generowania modeli do prognozy zapotrzebowania na ciepło w źródle.

6.2. Akceptowalna niedokładność.

Akceptowalna niedokładność dla tego rozwiązania będzie odnosiła się do dwóch warunków:

- pierwszy związany z wyprodukowaniem odpowiedniej ilości energii cieplnej dostarczonej do systemu ciepłowniczego i sprzedanej odbiorcy końcowemu, dla którego kryterium niedokładności opisane w poprzednim punkcie nie może przekroczyć 10 %,
- drugi będzie związany z ilością zużytego gazu co wynika bezpośrednio z wymaganej (prognozowanej) ilości ciepła produkowanego w źródle. Mechanizm ten dokładnie będzie opisany w kolejnym rozdziale dotyczącym prognozowania zapotrzebowania na paliwo gazowe, jednak na potrzeby walidacji niniejszego modelu przyjęto a priori granicę niedokładności wynoszącą 10 %.

6.3. Walidacja.

Zgodnie z metodologią opisaną w punkcie 5.3, opracowano mechanizm walidacji wygenerowanych modeli w oparciu o następujące reguły:

1. wczytaj pierwszy wygenerowany model sieci neuronowej (tj. nr „x” z 1600),
2. pobierz dane o temperaturze zewnętrznej z IMGW i przekonwertuj je na wartości średniodobowe,
3. pobierz dane z wszystkich budynków przyłączonych do sieci w zakresie zapotrzebowania na moc ciepłą, a następnie wygeneruj prognozę produkcji ciepła w źródle,
4. pobierz rzeczywiste dane o produkcji ciepła w źródle i porównaj je z wartością prognozowaną wykorzystując średni błąd procentowy określony równaniem:

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_{prog} - y_{rz}|}{y_{rz}} \cdot 100\%$$

gdzie:

- n – liczba dni z których dostępne są pomiary w bazie danych,
 y_{rz} – dobowa rzeczywista produkcja ciepła w źródle,
 y_{pred} – dobowa prognozowana produkcja ciepła w źródle.

Analizowany problem jest z kategorii mało skomplikowanych, ponieważ na wejściu do sieci neuronowej mamy dwie zmienne a na wyjściu jedną. Ma to swoje odzwierciedlenie w dokładności prognozy zapotrzebowania na ciepło w źródle, która dla większości modeli niezależnie od jej struktury, osiągała bardzo podobne wartości. Model, który sklasyfikowany został na pierwszym miejscu charakteryzuje się niedokładnością o wartości 6,23 % tak jak kolejne 1 275 pozycji, których niedokładność nie przekracza 7,00 %. W Tabeli 6.1 przedstawiono pierwszych 10 architektur, które miały najmniejszą niedokładność. Uwzględniając opisaną wcześniej *zasadę najmniejszego działania* [110] zaprezentowano dodatkowo model, który zbliżony jest dokładnością do pierwszych dziesięciu miejsc ale charakteryzuje się najprostszą strukturą sieci neuronowej.

Tabela 6.1. Zestawienie pierwszych dziesięciu modeli do prognozowania zapotrzebowania na moc cieplną w źródle wraz z modelem o najmniejszej liczbie wag sieci.

L. p.	Nazwa modelu	Liczba wag sieci [-]	Niedokładność modelu [%]
1	5 5 elu 32 0.005	68 481	6,23
2	4 4 gelu 32 0.005	41 985	6,24
3	5 2 gelu 64 0.005	11 265	6,24
4	5 2 gelu 32 0.01	11 265	6,24
5	5 2 elu 64 0.01	11 265	6,24
6	3 2 gelu 64 0.001	8 705	6,25
7	5 3 gelu 32 0.01	24 961	6,25
8	5 4 gelu 64 0.005	44 033	6,26
9	4 4 gelu 64 0.005	41 985	6,26

L. p.	Nazwa modelu	Liczba wag sieci [-]	Niedokładność modelu [%]
10	4 5 elu 32 0.001	65 281	6,26
75	2 1 elu 128 0.1	257	6,31

Dodatkowy model 2 1 elu 128 0.1 charakteryzuje się niedokładnością o 0,08 p.p. mniejszą od modelu na pierwszym miejscu tj. 5 5 elu 32 0.005, pomimo 266 razy mniejszej liczbie neuronów. W tym przypadku model nr 75 będzie charakteryzował się lepszą zdolnością do generalizacji przy pomijalnym spadku dokładności predykcji.

Model sklasyfikowany na pierwszym miejscu o dokładności 6,23 % charakteryzował się:

- pierwszą warstwę gęstą zawierającą 320 neuronów z funkcją aktywacji ELU,
- drugą warstwę gęstą zawierającą 160 neuronów z funkcją aktywacji ELU,
- trzecią warstwę gęstą zawierającą 80 neuronów z funkcją aktywacji ELU,
- czwartą warstwę gęstą zawierającą 40 neuronów z funkcją aktywacji ELU,
- wielkością próbek (batch_size) ustawioną na 32,
- szybkością uczenia równą 0,005,
- liczbą wag wynoszącą 68 481.

Wybrany do dalszego wykorzystania model 2 1 elu 128 0.1 o niedokładności równej 6,31 % skonstruowany jest w następujący sposób:

- posiada jedną warstwę gęstą z 64 neuronami z funkcją aktywacji ELU,
- wielkość próbek (batch_size) ustawiona na 128,
- szybkość uczenia wynosiła 0,1,
- liczba wag sieci do przeliczenia wynosiła 257.

Wybrany model posłużył do wygenerowania zapotrzebowania na ciepło dla źródła w kilku dniach lutego 2025 r. Zostało to przedstawione w Tabeli 6.2, w której dokonano porównania z rzeczywistą ilością wyprodukowanego ciepła w źródle. Niedokładność została wyznaczona jako średni błąd procentowy odniesiony do wartości rzeczywistej.

Tabela 6.2. Prognoza zapotrzebowania na ciepło dla źródła z wykorzystaniem modelu 2 1 e lu 128 0.1 dla kilku dni lutego 2025 r.

Data	Prognoza produkcji ciepła w źródle [GJ]	Rzeczywista produkcja ciepła w źródle [GJ]	Niedokładność [%]
2025-02-01	472	467	1,07
2025-02-02	487	473	2,96
2025-02-03	503	479	5,01
2025-02-04	506	503	0,60
2025-02-05	481	502	-4,18
2025-02-06	439	471	-6,79
2025-02-07	467	477	-2,10
2025-02-08	499	529	-5,67
2025-02-09	532	535	-0,56
2025-02-10	585	576	1,56
2025-02-11	612	588	4,08
2025-02-12	569	609	-6,57
2025-02-13	527	577	-8,67
2025-02-14	557	562	-0,89

Dodatkowo opracowano mechanizm porównujący niedokładność modelu wykorzystującego sieci neuronowe w stosunku do metody naiwnej. Zakłada ona zapotrzebowanie na ciepło w źródle równe rzeczywistemu wykorzystaniu ciepła w poprzedniej dobie. Wyniki dla przykładowego okresu od 01.02.2025 r. do 14.02.2025 r. zaprezentowano w Tabela 6.3.

Tabela 6.3. Porównanie prognozy zapotrzebowania na ciepło w źródle dla modelu 2 1 e lu 128 0.1 z metodą naiwną dla kilku dni lutego 2025 r.

Data	Prognoza produkcji ciepła w źródle [GJ]	Naiwna prognoza zapotrzebowania na ciepło w źródle [GJ]	Rzeczywista produkcja ciepła w źródle [GJ]	Niedokładność modelu [%]	Niedokładność naiwnej prognozy [%]
2025-02-01	472	393	467	1,07	-15,85
2025-02-02	487	467	473	2,96	-1,27
2025-02-03	503	473	479	5,01	-1,25
2025-02-04	506	479	503	0,60	-4,77
2025-02-05	481	503	502	-4,18	0,20
2025-02-06	439	502	471	-6,79	6,58
2025-02-07	467	471	477	-2,10	-1,26
2025-02-08	499	477	529	-5,67	-9,83
2025-02-09	532	529	535	-0,56	-1,12
2025-02-10	585	535	576	1,56	-7,12
2025-02-11	612	576	588	4,08	-2,04
2025-02-12	569	588	609	-6,57	-3,45
2025-02-13	527	609	577	-8,67	5,55
2025-02-14	557	577	562	-0,89	2,67

6.4. Wnioski i analizy.

Wykorzystując sieci neuronowe można prognozować zapotrzebowanie na ciepło w elektrociepłowni, w której źródłem ciepła są kotły gazowej oraz agregaty kogeneracyjne ze średnią dokładnością powyżej 93,0 %. Opracowana metoda umożliwia realizację tego celu pomimo następujących ograniczeń:

- źródłem danych o wykorzystaniu ciepła przez odbiorów końcowych są wartości wygenerowane przez sieć neuronową,

- z racji na realizowaną prognozę w ujęciu dobowym uśredniana jest wartość temperatury zewnętrznej,
- nie ma wprowadzanych do modelu żadnych informacji o parametrach technicznych i eksploatacyjnych sieci ciepłowniczej.

Pomimo powyższych limitów i bardzo uproszczonego modelu sieci neuronowej, osiągnięta dokładność jest satysfakcjonująca. Brak danych o parametrach technicznych sieci może być jednym z powodów, dla których model powinien być ponownie wytrenowany po jej modernizacji lub wybudowaniu nowego przyłącza.

Opracowane rozwiązanie oparte jest o gęste jednokierunkowe sieci neuronowe, a nie prognozowanie szeregów czasowych. Dzięki takiemu podejściu, znając wymaganą ilość ciepła jakie należy dostarczyć do odbiorców oraz wartość średniej dobowej temperatury zewnętrznej, możliwe jest wyznaczenie obciążenia cieplnego źródła. Nie ma konieczności wprowadzania historycznych danych o jego pracy. Metoda wykorzystująca podejście naiwne, również daje satysfakcjonujące wyniki. Warunkiem ich osiągnięcia jest założenie, że codzienna praca układu nie różni się w sposób znaczący od poprzedniej doby. Przy niewielkich wahaniami temperatury można osiągnąć dokładność predykcji powyżej 90 %. Natomiast mogą zdarzyć się dni, w których rejestrowana jest gwałtowna zmiana parametrów powietrza zewnętrznego lub zmiana zachowań użytkowników wynikających z konkretnego dnia tygodnia. Przekłada się to na zwiększenie niedokładności prognozy i przekroczenie akceptowalnego 10 % progu.

6.5. Wdrożenie.

Opracowany model sieci neuronowej służy do prognozowania zapotrzebowania na moc cieplną w źródle, która jest kluczowa od strony sterowania elektrociepłownią. Wykorzystuje do tego dane o ilości ciepła jaką pobiorą odbiorcy przyłączeni do sieci cieplnej oraz wartości temperatury zewnętrznej. Obliczone przez algorytm wartości prezentowane są na stronie internetowej <https://dawid.czajor.com.pl/phd> i dotyczą każdego dnia w założonym horyzoncie czasowym. Zostały one wykorzystane do napisania algorytmu, który w oparciu o ilość ciepła jaką należy wyprodukować planuje czas pracy agregatów kogeneracyjnych. Mechanizm ten zakłada scenariusz działania silników w priorytecie produkcji energii cieplnej i jest codziennie aktualizowany. Harmonogram pracy wysyłany jest w sposób automatyczny na podany adres e-mail operatora zajmującego się nadzorem nad obiektem. Przykładowa treść została zaprezentowana na Rys. 6.3. Równocześnie informacja ta może być wprowadzona do istniejącego systemu informatycznego przedsiębiorstwa z wykorzystaniem serwera bazy danych SQL. Taka implementacja umożliwi automatyczne uruchamianie oraz wyłączanie jednostek kogeneracyjnych w zależności od warunków techniczno-ekonomicznych.

Subject: Harmonogram pracy silników z 12-04-2024 na następne 2 dni.


Harmonogram pracy silników kogeneracyjnych.

Data	Zadana moc silników	Czas pracy 1. silnika	Czas pracy 2. silnika	Czas pracy 3. silnika
2024-04-13	1100 kW	24 h 0 min	24 h 0 min	9 h 50 min
2024-04-14	1100 kW	24 h 0 min	24 h 0 min	13 h 50 min

Wiadomość wysłana automatycznie. Prosimy na nią nie odpowiadać.

Rys. 6.3. Fragment wiadomości e-mail wysłanej na adres operatora przez algorytm sterujący z podaniem wartości mocy generatora oraz czasu pracy poszczególnych jednostek.

Powyższe dane mogą być też podstawą do zastosowania sterowania predykcyjnego źródłem ciepła. Zakłada ono zmianę nastaw urządzeń wytwórczych zanim jeszcze temperatura na wyjściu ze źródła spadnie poniżej założonego minimum. Takie podejście umożliwiłoby wypłaszczenie szczytowego poboru uzależnionego od zapotrzebowania na ciepło na podgrzanie wody użytkowej. Wykorzystując naturalny akumulator jakim może być sieć ciepłownicza możliwe byłoby wcześniejsze stopniowe zwiększenie generowanej mocy. Idea ta w sposób uproszczony została przedstawiona na Rys. 6.4. Miałoby to pozytywny wpływ zarówno na sprawność cieplną urządzeń grzewczych jak i ograniczenie maksymalnego godzinowego poboru paliwa gazowego.



Rys. 6.4. Godzinowe obciążenie cieplne źródła w dniu 14.02.2025 r. Źródło: opracowanie własne.

7. Prognozowanie zapotrzebowania na paliwo gazowe dla źródła.

7.1. Opis mechanizmu.

Praca elektrociepłowni wymaga odpowiedniego planowania wytwarzania energii cieplnej dostarczanej do systemu ciepłowniczego oraz energii elektrycznej wprowadzanej do sieci elektroenergetycznej. Oba te czynniki mają bezpośredni wpływ na zużycie paliwa gazowego. W przypadku dostawy ciepła jest on przede wszystkim związany z temperaturą zewnętrzną, natomiast w przypadku produkcji energii elektrycznej jest powiązany ze strategią pracy układu kogeneracyjnego (poruszaną m.in. w artykule [119]), która może zależeć od:

- aktualnej ceny energii elektrycznej na Rynku Bilansującym,
- podpisanego kontraktu na określoną wielkość produkcji z podmiotem kupującym energię elektryczną,
- dostawy energii do własnej sieci dystrybucyjnej lokalnym odbiorcom w zależności od ich zapotrzebowania.

Ręczna analiza zużycia gazu musi uwzględniać szereg czynników, która kalkulowałaby prognozowaną wartość w zależności od wyżej przyjętego scenariusza pracy układu kogeneracyjnego. W przypadku większych systemów ciepłowniczych byłaby ona trudna do zrealizowania. Dodatkowo obowiązujące regulacje rynku gazu mogą wymuszać zastosowanie oprogramowania do prognozy zapotrzebowania na paliwo w zależności od przyjętego wariantu pracy systemu. Pierwszy zakłada podpisanie umowy na stałą cenę dostawy gazu w danym roku, natomiast drugi umożliwia kontraktowanie zakupu na giełdzie z dnia na dzień.

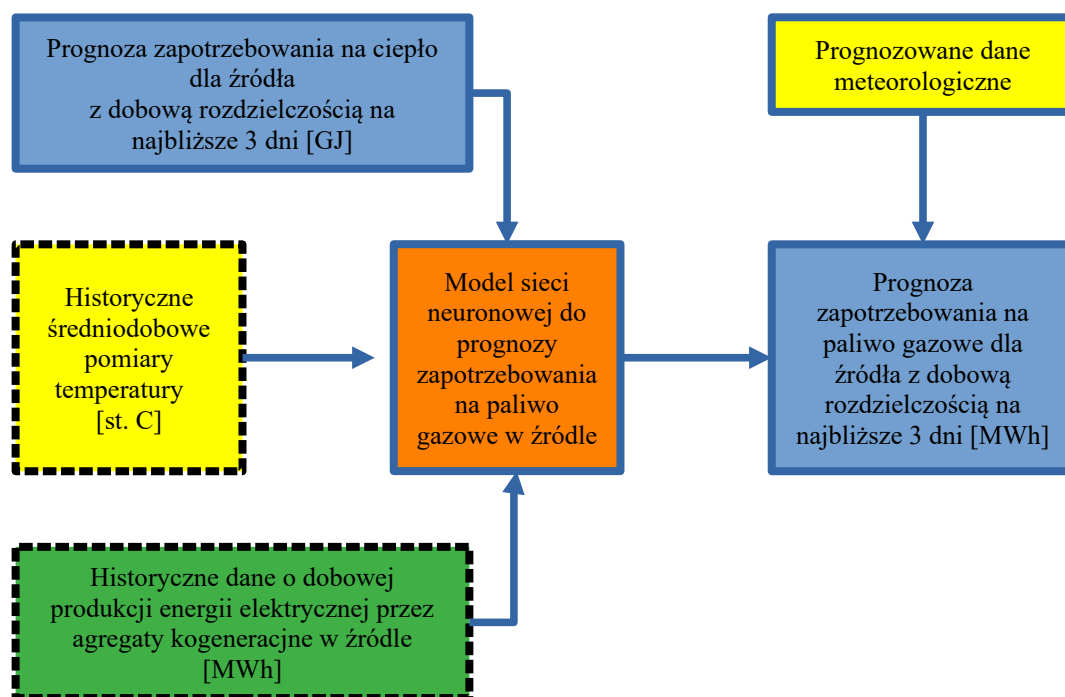
Wariant pierwszy jest bezpieczniejszy, ponieważ nie jest narażony na wahania cen w trakcie roku. Jest on zalecany przy pracy obiektów zajmujących się wyłącznie wytwarzaniem ciepła, które podlegają pod taryfowanie przez Urząd Regulacji Energetyki (art. 45 Prawa Energetycznego [120]). W tego typu postępowaniach konieczne jest zaplanowanie wszystkich kosztów na cały najbliższy rok i na tej podstawie skalkulowanie stawek za ciepło.

Drugi mechanizm daje większą elastyczność ale przy podwyższonym ryzyku prowadzenia działalności gospodarczej. Możliwe jest wygenerowanie większego przychodu z tytułu sprzedaży energii elektrycznej do Krajowego Systemu Elektroenergetycznego. Może to być realizowane poprzez analizę stosunku ceny prądu do gazu i wybiórcze uruchamianie agregatów kogeneracyjnych w określonych godzinach dnia. Minusem tej strategii jest wrażliwość na ceny paliwa gazowego, która w przypadku konieczności produkowania energii cieplnej z gazu, może wpłynąć negatywnie na wynik finansowy przedsiębiorstwa [68].

Interesującym rozwiązaniem w przypadku elektrociepłowni może być stosowanie modelu hybrydowego. Zakłada on zakupienie odpowiedniej ilości gazu na potrzeby wytwarzania ciepła i kontraktowanie dodatkowe gazu na potrzeby produkcji energii elektrycznej ad hoc na następny dzień. Wariant ten zagwarantuje stabilność produkcji ciepła przy obowiązku jego

taryfowania przez URE, w którym konieczne jest zaplanowanie wszystkich kosztów. Natomiast w przypadku produkcji energii elektrycznej umożliwi elastyczne podejście do generacji, które będzie powiązane z aktualnymi warunkami ekonomicznymi.

Niezależnie od wybranej strategii nie ulega wątpliwości, że wyznaczanie zużycia gazu zarówno w perspektywie długo- jak i krótkoterminowej jest kluczowe z punktu działalności energetycznej, o czym pisali m.in. [121], [122]. Z tego powodu opracowano mechanizm, który wykorzystując sztuczne sieci neuronowe, jest w stanie wyznaczyć te wartości, a sposób jego działania został przedstawiony na Rys. 7.1.



Rys. 7.1. Schemat opracowanego algorytmu do prognozy zapotrzebowania na ciepło w źródle.

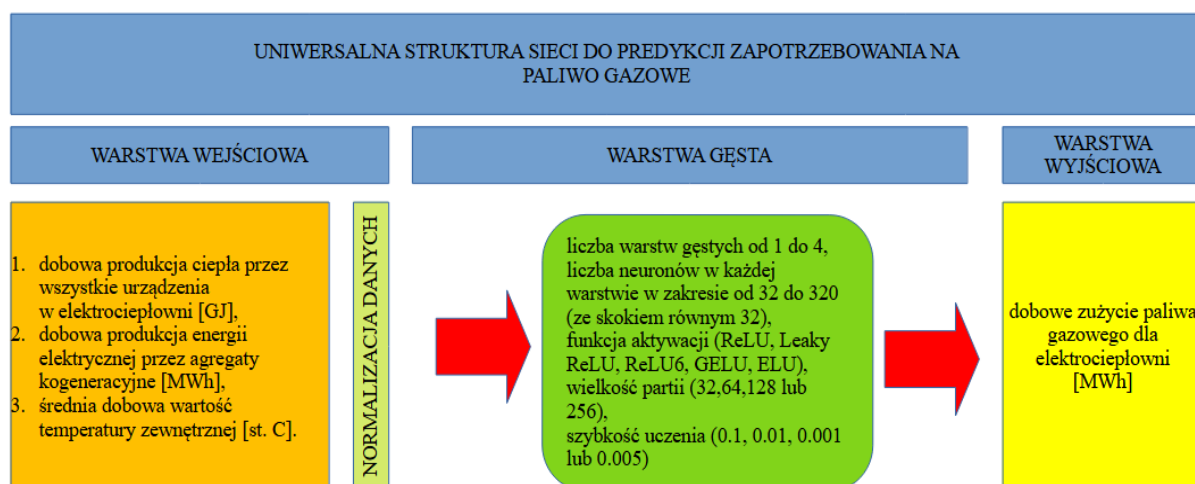
Źródłem danych do wytrenowania modelu są zgromadzone w bazie informacje o pracy istniejącej elektrociepłowni (szczegółowo opisane w punkcie 4.4, zawierające ponad 18 tys. rekordów wg stanu na 22.01.2025 r.). Prognoza zużycia gazu raportowana jest do sprzedawcy paliwa w ujęciu dobowym. W związku z powyższym dane wejściowe jak i wyjściowe muszą być w identyczny sposób sformatowane.

Algorytm w pierwszej kolejności pobiera dane zapisane w bazie SQLITE i konwertuje je do odpowiedniego formatu. Następnie filtruje dane pod kątem poprawności wartości i przekazuje do funkcji odpowiedzialnej za zbudowanie modelu sieci neuronowej. Analogicznie jak w poprzednich punktach, dotyczących prognozy danych wykorzystujących jednokierunkowe sieci neuronowe, przyjęto te same parametry do konfiguracji sieci tj.:

- liczba warstw,

- liczba neuronów,
- typ funkcji aktywacji,
- liczba próbek,
- współczynnik uczenia,
- mechanizm HUBER jako funkcja do oceny doboru wag sieci w trakcie procesu uczenia.

Do wytrenowania modelu wykorzystywana jest informacja o dobowej produkcji ciepła oraz energii elektrycznej przez elektrociepłownię oraz wartość temperatury powietrza zewnętrznego (zgodnie z Rys. 7.2).



Rys. 7.2. Uniwersalna struktura sieci neuronowej wykorzystana do generowania modeli do prognozy zapotrzebowania na paliwo gazowe w źródle.

Łączna liczba modeli jaka została wygenerowana wynosi 1 600 wersji.

7.2. Akceptowalna niedokładność.

Akceptowalna niedokładność tego rozwiązania będzie związana z regulacjami prawnymi dotyczącymi nominacji dobowych realizowanych przez operatora dostarczającego paliwo gazowe w tzw.:

- Instrukcjach Ruchu i Eksploatacji Sieci Przesyłowej (IRIESP Gaz–System S.A.) [123],
- Instrukcjach Ruchu i Eksploatacji Sieci Dystrybucyjnej (IRIESD PSG Sp. z o. o.) [124].

Określają one maksymalną różnicę pomiędzy wartością prognozowaną zużycia gazu a rzeczywistym zużyciem na poziomie 10 %. Przekroczenie tej wartości wiąże się

z naliczeniem dodatkowej opłaty stanowiącej 1 % z iloczynu prognozowanego zużycia gazu powyżej granicznego limitu oraz jego średniej ceny obowiązującej w miesiącu poprzedzającym zarejestrowane przekroczenie. Opłata zostaje naliczana dla każdego dnia w którym prognozowana ilość zużytego gazu odbiegła od wartości rzeczywistej o więcej niż 10 %.

7.3. Walidacja.

Zgodnie z przyjętą wcześniej metodą walidacyjną dla prognoz opartych na jednokierunkowych sieciach neuronowych, niniejsza została zrealizowana na podobnych zasadach tj.:

1. wczytaj pierwszy wygenerowany model sieci neuronowej (tj. nr „x” z 1 600),
2. pobierz dane o temperaturze zewnętrznej z IMGW i przekonwertuj je na wartości średniodobowe,
3. pobierz dobowe dane o produkcji ciepła w elektrociepłowni [GJ],
4. pobierz dobowe dane o generacji energii elektrycznej w elektrociepłowni [MWh],
5. pobierz rzeczywiste dane o zużyciu paliwa gazowego w źródle i porównaj je z wartością prognozowaną wykorzystując średni błąd procentowy określony równaniem:

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_{prog} - y_{rz}|}{y_{rz}} \cdot 100 \%$$

gdzie:

n – liczba dni z których dostępne są pomiary w bazie danych,

y_{rz} – dobowe rzeczywiste zużycie paliwa gazowego w źródle,

y_{pred} – dobowe prognozowane zużycie paliwa gazowego w źródle.

Analizowane zastosowanie jest, pod względem skomplikowania, bardzo zbliżone do problemu prognozy zapotrzebowania na ciepło w źródle. Z tego powodu ponad 1 200 wygenerowanych modeli ma niedokładność na poziomie nieprzekraczającym 5 %. W Tabeli 7.1 zaprezentowano pierwszych 10 architektur, które charakteryzowały się najmniejszą niedokładnością.

Tabela 7.1. Zestawienie pierwszych dziesięciu modeli do prognozowania zapotrzebowania na paliwo gazowe w źródle wraz z modelem o najmniejszej liczbie wag sieci.

L. p.	Nazwa modelu [-]	Struktura sieci neuronowej [-]	Liczba wag sieci [-]	Niedokładność modelu [%]
1	5 5 relu 256 0.001	320-160-80-40	68 801	1,47
2	5 5 relu 128 0.001	320-160-80-40	68 801	1,61
3	3 4 leaky relu 256 0.01	256-128	34 049	1,76
4	5 5 relu 32 0.001	320-160-80-40	68 801	1,82
5	5 4 relu 64 0.001	256-128-64-32	44 289	1,83
6	4 5 relu 64 0.005	320-160-80	65 601	1,87
7	4 1 relu 32 0.01	64-32-16	2 881	1,97
8	5 3 leaky relu 256 0.001	192-96-48-24	25 153	1,97
9	4 3 relu 128 0.001	192-96-48	24 001	1,99
10	5 2 relu 32 0.01	128-64-32-16	11 393	2,00
52	2 1 gelu 64 0.1	64	321	2,24

Analogicznie jak w poprzednich przypadkach wykorzystaną *zasadę najmniejszego działania* i wybrano do dalszej implementacji model sklasyfikowany na miejscu 52. Jego dokładność jest o 0,77 p.p. gorsza od pierwszego modelu w zestawieniu, jednak równocześnie wymaga ponad 200–krotnie mniejszej liczby połączeń pomiędzy neuronami. Charakteryzuje się on następującą budową:

- jedna warstwa gęsta zawierająca 64 neurony z funkcją aktywacji GELU,
- wielkość próbek ustawiona na 64,
- szybkość uczenia wynosiła 0,1,
- liczba wag sieci do przeliczenia wynosiła 321.

Wybrany model posłużył do wygenerowania zapotrzebowania na paliwo gazowe dla źródła w dwóch pierwszych tygodniach lutego 2025 r. Ilość ciepła jaka musiała zostać wyprodukowana przez elektrociepłownię została wyznaczona na podstawie poprzedniego modelu sieci neuronowej. Natomiast ilość energii elektrycznej jaka planowana była do wyprodukowania, została wyznaczona jako średnia z dwóch poprzedzających dni. Wyniki zostały przedstawione w Tabeli 7.2, w której dokonano porównania z rzeczywistą ilością zużytego gazu w źródle. Niedokładność została wyznaczona jako średni błąd procentowy odniesiony do wartości rzeczywistej.

Tabela 7.2. Prognoza zapotrzebowania na paliwo gazowe dla źródła z wykorzystaniem modelu 2 1 ge lu 64 0.1 dla kilku przykładowych dni w lutym 2025 r.

Data	Prognozowane zużycie gazu [MWh]	Rzeczywiste zużycie gazu [MWh]	Niedokładność [%]
2025-02-01	194	197,6	-1,82
2025-02-02	207	198	4,55
2025-02-03	222	210,4	5,51
2025-02-04	224	220	1,82
2025-02-05	198	219,6	-9,84
2025-02-06	205	213	-3,76
2025-02-07	207	199,3	3,86
2025-02-08	218	218,1	-0,05
2025-02-09	217	220,1	-1,41
2025-02-10	232	238,7	-2,81
2025-02-11	261	265,6	-1,73
2025-02-12	245	260,3	-5,88
2025-02-13	254	260,6	-2,53
2025-02-14	232	229,8	0,96

W Tabeli 7.3 przedstawiono porównanie niedokładności wybranego modelu 2 1 ge lu 64 0.1 w oparciu o naiwną metodę prognozy zapotrzebowania na paliwo gazowe w okresie od 01.02.2025 r. do 21.02.2025 r. Zakłada ona, iż zużycie gazu w aktualnej dobie będzie identyczne jak w dniu poprzednim.

Tabela 7.3. Porównanie prognozy zapotrzebowania na paliwo gazowe w źródle dla modelu 2 1 ge lu 64 0.1 z metodą naiwną dla kilku dni lutego 2025 r.

Data	Prognozowane zużycie gazu [MWh]	Naiwna prognoza zużycia gazu [MWh]	Rzeczywiste zużycie gazu [MWh]	Niedokładność modelu [%]	Niedokładność naiwnej prognozy [%]
2025-02-01	194	190,2	197,6	-1,82	-3,74
2025-02-02	207	197,6	198	4,55	-0,20
2025-02-03	222	198	210,4	5,51	-5,89
2025-02-04	224	210,4	220	1,82	-4,36
2025-02-05	213	220	219,6	-3,01	0,18
2025-02-06	205	219,6	213	-3,76	3,10
2025-02-07	207	213	199,3	3,86	6,87
2025-02-08	218	199,3	218,1	-0,05	-8,62
2025-02-09	217	218,1	220,1	-1,41	-0,91
2025-02-10	232	220,1	238,7	-2,81	-7,79
2025-02-11	261	238,7	265,6	-1,73	-10,13
2025-02-12	245	265,6	260,3	-5,88	2,04
2025-02-13	254	260,3	260,6	-2,53	-0,12
2025-02-14	232	260,6	229,8	0,96	13,40
2025-02-15	232	229,8	227,4	2,02	1,06
2025-02-16	254	227,4	245,1	3,63	-7,22
2025-02-17	247	245,1	243,3	1,52	0,74

Data	Prognozowane zużycie gazu [MWh]	Naiwna prognoza zużycia gazu [MWh]	Rzeczywiste zużycie gazu [MWh]	Niedokładność modelu [%]	Niedokładność naiwnej prognozy [%]
2025-02-18	223	243,3	224,8	-0,80	8,23
2025-02-19	236	224,8	231,8	1,81	-3,02
2025-02-20	228	231,8	234,8	-2,90	-1,28
2025-02-21	193	234,8	201,6	-4,27	16,47

7.4. Wnioski i analizy.

Wykorzystując sieci neuronowe można prognozować zapotrzebowanie na paliwo gazowej w elektrociepłowni, w której źródłem ciepła są kotły gazowe oraz agregaty kogeneracyjne ze średnią niedokładnością poniżej 3,0 %. Opracowana metoda daje taką możliwość pomimo następujących ograniczeń:

1. prognozowane zapotrzebowanie na ciepło w elektrociepłowni jest wygenerowane z wykorzystaniem sztucznej sieci neuronowej, której średnia niedokładność wynosi ok. 7,0 %,
2. prognozowana ilość energii elektrycznej wyprodukowanej przez agregaty kogeneracyjne określona została jako średnia z dwóch poprzedzających dni,
3. brak danych o rzeczywistej sprawności urządzeń w dniu wyznaczania prognozy.

Pomimo powyższych, nawet nieskomplikowana struktura sieci neuronowej zawierająca jedną warstwę z 64 neuronami może wykazywać średnią niedokładność na podstawie wszystkich dostępnych danych na poziomie 2,24 %, co klasyfikuje ten model do dalszego stosowania w oparciu o kryterium akceptowalnej dokładności.

Opracowany mechanizm wykorzystuje jednokierunkowe sieci neuronowe, dzięki czemu możliwe jest wygenerowanie zapotrzebowania na paliwo gazowe podając dane o:

- zapotrzebowaniu na ciepło wraz z ilością planowanej energii elektrycznej do wyprodukowania,
- temperaturze powietrza zewnętrznego.

Na poprawę dokładności mogłyby mieć wpływ rzeczywiste wartości planowanej energii elektrycznej do wygenerowania niż posługiwanie się średnią wartością na podstawie dwóch poprzedzających dni. Taka funkcjonalność jest wdrożona i może zostać wykorzystana przez

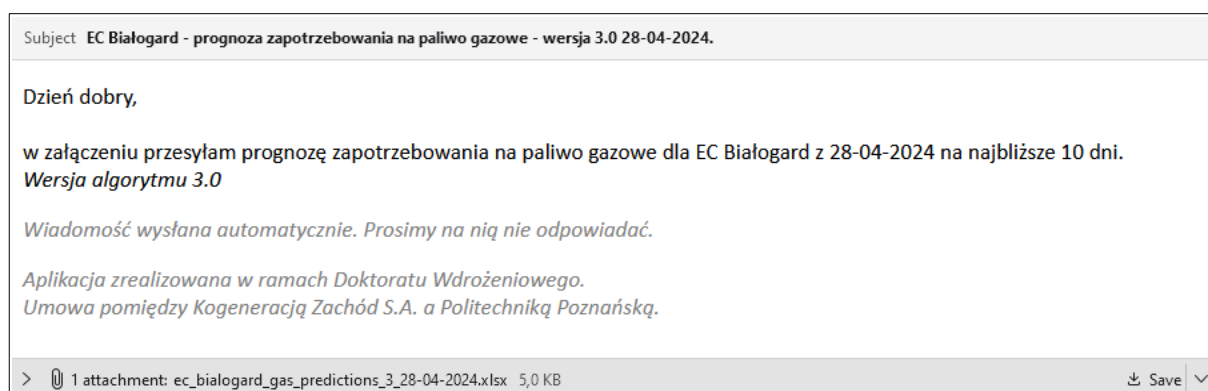
eksploatującego system energetyczny. Wprowadzenie do modelu informacji o aktualnym stanie technicznym urządzeń również mogłoby się przyczynić do zwiększenia dokładności.

Opracowane porównanie prognozy w oparciu o metodę naiwną daje w pewnych zakresach satysfakcjonujące wyniki. Jednak zmiana sposobu pracy źródła np. poprzez zmianę ilości planowanej energii elektrycznej w stosunku do dnia poprzedniego, skutkuje znacznym błędem, który wykracza poza akceptowalną 10-cio procentową niedokładność (np. 16,47 % w dniu 21-02-2025 r.). Z tego powodu wykorzystanie sieci neuronowych, które generują dokładniejsze prognozy jest mechanizmem zalecanym przy tego typu zastosowaniu.

7.5. Wdrożenie.

Opracowany model sieci neuronowej służy do prognozowania zapotrzebowania na paliwo gazowe dla źródła opartego na kotłach gazowych oraz silnikach kogeneracyjnych. Wykorzystując informację o ilości ciepła jaką należy wytworzyć w źródle, w powiązaniu z planowaną generacją energii elektrycznej oraz prognozowaną temperaturą powietrza zewnętrznego, można wyznaczyć jego zapotrzebowanie. W opracowanym rozwiązaniu informacja ta trafia w sposób automatyczny do podmiotu odpowiedzialnego za nominacje wolumenu gazu u dostawcy paliwa.

Dostępna prognoza pogody z IMGW, na której oparte są algorytmy, umożliwia wyłącznie analizę danych meteorologicznych na najbliższe 72 h. Z tego powodu opracowano model, który ma na celu rozszerzyć okno prognozy pogody na dodatkowe 744 godziny. Model ten zostanie opisany szczegółowo w punkcie nr 8. Wykorzystując już w tym miejscu generowane dane o prognozie pogody o dodatkowe dni, możliwe jest prognozowanie zużycia gazu na dłuższy okres niż najbliższe 72 godziny. Na Rys. 7.3 zaprezentowano zrzut ekranu z przykładowej wiadomości elektronicznej wysyłanej automatycznie, zawierającej arkusz kalkulacyjny z prognozą zapotrzebowania na gaz na najbliższe 10 dni (Rys. 7.4).



Rys. 7.3. Treść wiadomości e-mail wysyłana na adres podmiotu dostarczającego paliwo gazowe przez opracowany algorytm.

	Prognozowane zużycie gazu [MWh]
2024-04-28	170
2024-04-29	162
2024-04-30	159
2024-05-01	168
2024-05-02	172
2024-05-03	166
2024-05-04	163
2024-05-05	159
2024-05-06	154
2024-05-07	151
2024-05-08	147

Rys. 7.4. Załącznik do wysyłanej wiadomości e-mail zawierający prognozowane zużycie gazu dla źródła na najbliższe 10 dni od daty generacji.

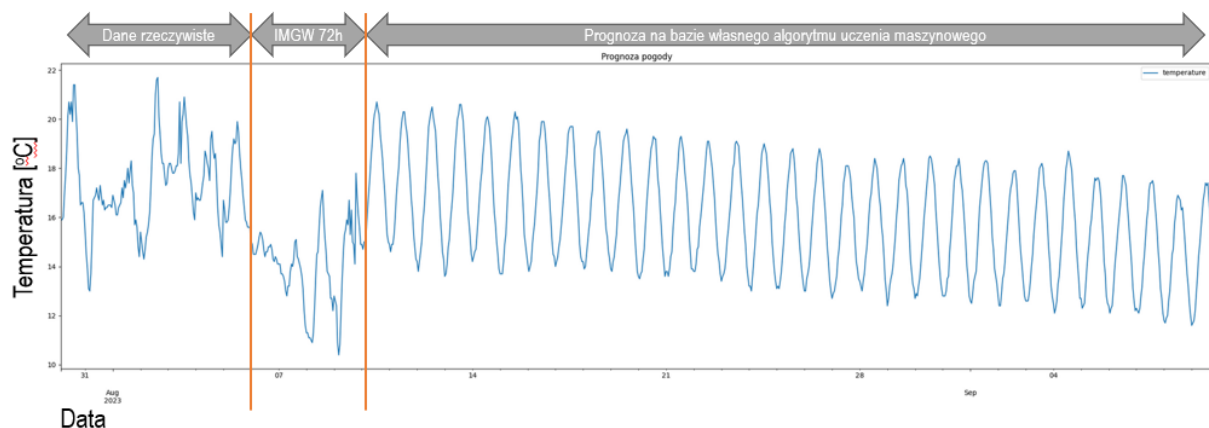
8. Rozszerzona prognozy pogody.

8.1. Opis mechanizmu.

Opisane wcześniej mechanizmy do prognozy zapotrzebowania na:

- moc ciepłą na cele centralnego ogrzewania dla odbiorcy końcowego,
- moc ciepłą na cele ciepłej wody użytkowej dla odbiorcy końcowego,
- moc ciepłą w źródle opartym o kotły gazowe oraz silniki kogeneracyjne,
- paliwo gazowe do produkcji prognozowanej ilości ciepła w elektrociepłowni,

opierają się na prognozie pogody udostępnionej z Instytutu Meteorologii i Gospodarki Wodnej. Informacje te są pobierane w sposób automatyczny na podstawie zawartej umowy pomiędzy powyższym podmiotem a obiektem, w którym nastąpiło wdrożenie. Otrzymywane dane to prognoza na najbliższe 72 godziny dla miasta Białogard z lokalizacją elektrociepłowni przy ul. Słowińskiej 1. Konsekwencją tak krótkiej prognozy pogody jest fakt, że wszystkie opisane wcześniej mechanizmy mają z góry narzucony limit okna predykcyjnego na najbliższe 3 dni. Taki horyzont dla planowania pracy oraz bieżącego sterowania źródła ciepła może być wystarczający. Jednak w celu podejmowania decyzji zakupowych związanych z kontraktowaniem paliwa gazowego lub sprzedaży energii elektrycznej do Krajowego Systemu Elektroenergetycznego jest zdecydowanie za krótki. W związku z powyższym podjęto próbę opracowania modelu do prognozy wszystkich parametrów jakie są publikowane przez IMGW na kolejne 744 godziny (ich zestawienie zostało zaprezentowane w punkcie 4.5), natomiast ideę jego funkcjonowania przedstawiono na Rys. 8.1.



Rys. 8.1. Wykres prezentujący ideę rozszerzonej prognozy pogody o kolejne 744 godziny dla temperatury powietrza zewnętrznego.

Opisywany mechanizm został zbudowany w oparciu o rekurencyjne sieci neuronowe. Tego typu struktura jest dedykowana do zastosowań, w których istnieją wewnętrzne powiązania

(albo zakładamy ich istnienie) pomiędzy prognozowanymi parametrami [125]. W szczególności, jeżeli dane z poprzedniego kroku w szeregu czasowym mogą wpłynąć na wartości w analizowanym momencie. Mają one jednak bardzo duże zapotrzebowanie na moc obliczeniową w trakcie trenowania danego modelu. Dodatkowo muszą być dostępne wcześniejsze rzeczywiste dane, aby tego typu sieć nauczyła się trendu i „zrozumiała” w pewnym stopniu zachodzące relacje pomiędzy parametrami. Z tego powodu we wcześniejszych zastosowaniach nie zdecydowano się na ich wykorzystanie. Wynikało to przede wszystkim z faktu, że założone modelowanie dotyczyło wszystkich budynków przyłączonych do sieci ciepłowniczej. Także i takich, które nie posiadały żadnych danych historycznych i z tego powodu nie mogły udzielić informacji na cele wytrenowania modelu.

W przypadku prognozowania danych pogodowych dostępnych jest w lokalnej bazie, wg stanu na dzień 07.03.2025 r., 46 528 godzinowych rekordów (co odpowiada okresowi ponad 5 lat). Taki zbiór informacji może posłużyć do wygenerowania modelu, który będzie prognozował dane meteorologiczne na kolejne 744 h biorąc wyłącznie pod uwagę dane historyczne.


Algorytm w pierwszej kolejności pobiera wszystkie dane z bazy dotyczącej pogody tj.:

- datę i godzinę,
- temperaturę powietrza zewnętrznego,
- prędkość i kierunek wiatru,
- ciśnienie atmosferyczne,
- wilgotność względną,
- typ i wielkość opadu atmosferycznego.

Następnie realizowana jest normalizacja danych z ich konwersja dotycząca:

- prędkości i kierunku wiatru,
- daty i godziny,

na wartości funkcji trygonometrycznych opisanych w punkcie nr 5 . W kolejnym etapie, za który odpowiada funkcja `gas_weather_electricity_prediction()`, dane są odpowiednio przygotowywane do wytrenowania modelu. Funkcja ta ma za zadanie ustawić je w odpowiednio zdefiniowany szereg, który uzależniony jest od tego ile danych wejściowych ma być wykorzystanych do prognozowania kolejnych 744 godzin. Funkcjonalny schemat algorytmu został przedstawiony na Rys. 8.2.



Rys. 8.2. Schemat opracowanego algorytmu do rozszerzonej prognozy danych meteorologicznych.

W tym zastosowaniu założono poniższe parametry:

- zakres godzinowych danych historycznych do modelu jest wielokrotnością okna prognozy tj. 744 godzin oraz liczby miesięcy wstecz od jednego do dwunastu (przy założeniu, że maksymalna liczba godzin w roku wynosi 8760),
- liczba neuronów w jednej warstwie typu LSTM (Long Short-Term Memory) przyjmująca wartości 12, 24, 32, 64, 128, 256, 512,
- funkcja aktywacji ustawiona domyślnie na tangens hiperboliczny,
- szybkość uczenia ustawiona domyślnie na 0,001,
- parametr próbek (batch_size) przyjmujący wartości 12, 24, 32, 64, 128, 256.

Dla przykładu, jeżeli algorytm będzie miał wytrenować model, który na wejściu ma wprowadzone 8 760 godzin danych historycznych to będzie on działał następująco:

- począwszy od najstarszych danych zaczynając od godziny 0, przeanalizuje pierwsze 8 760 godzin danych i zestawia je z kolejnymi 744 godzinami,
- następnie „przesunie się” o +744 godzin i zaczynając od tego miejsca przeanalizuje ponownie 8 760 godzin i zestawia je z kolejnymi 744 godzinami,
- powyższy proces będzie realizowany do momentu, w którym możliwe będzie zestawienie pełnego zaprogramowanego okresu danych wsadowych z horyzontem prognozy.

Tak przekonwertowane dane zostają przekazane do funkcji trenującej rekurencyjną sieć neuronową. Ma ona za zadanie tak dopasować wagi w sieci neuronowej, aby jak najlepiej prognozować wszystkie parametry meteorologiczne na kolejne 744 godzin. Analogicznie jak w poprzednich przypadkach na Rys. 8.3 przedstawiono graf prezentujący uniwersalną rekurencyjną strukturę sieci neuronowej, wykorzystującą warstwę LSTM w różnych konfiguracjach.



Rys. 8.3. Uniwersalna struktura rekurencyjnej sieci neuronowej wykorzystana do generowania modeli do rozszerzonej prognozy pogody.

Wyżej opisane parametry konfiguracyjne różnych sieci neuronowych pozwoliły na wygenerowania 504 modeli.

8.2. Akceptowalna niedokładność.

Akceptowalna niedokładność w tym zastosowaniu będzie odnosiła się do dokładności osiągananej przez Instytut Meteorologii i Gospodarki Wodnej. W Tabeli 8.1 zaprezentowano dokładności prognozy pogody dostarczanej przez IMGW, która poprawia się wg światowych statystyk [126], [127]. Średnia jej sprawdzalność, w oparciu o parametr temperatury powietrza zewnętrznego dla najbliższych 24 godzin dla wszystkich stacji meteorologicznych na terenie Polski w 2023 roku, wynosiła 77,84 %. Natomiast dla dłuższego horyzontu ta wartość spada do 60,66 %, co przekłada się na niedokładność wynoszącą 39,34 %. Z tego powodu założono, że wygenerowany model będzie mógł zyskać akceptację jeżeli jego walidacja w założonym okresie predykcji zyska lepszą dokładność niż ta uzyskiwana przez IMGW.

Tabela 8.1. Procentowa sprawdzalność za 2023 – średnia dla wszystkich polskich stacji synoptycznych. Źródło: dane udostępnione przez IMGW.

Miesiąc	Ciśnienie atmosferyczne [%]	Temperatura [%]	Prędkość wiatru [%]	Kierunek wiatru [%]	Zachmurzenie [%]
styczeń	98,7	86,3	85,9	89,5	82,0
luty	97,5	82,0	82,3	86,8	74,7
marzec	98,2	77,4	84,7	86,4	74,1

Miesiąc	Ciśnienie atmosferyczne [%]	Temperatura [%]	Prędkość wiatru [%]	Kierunek wiatru [%]	Zachmurzenie [%]
kwiecień	99,6	82,4	87,4	83,5	68,5
maj	99,9	74,5	88,9	82,3	68,8
czerwiec	99,5	68,4	88,1	77,4	61,6
lipiec	98,9	69,1	87,9	73,8	57,8
sierpień	99,8	72,4	92,1	85,1	64,8
wrzesień	99,1	72,5	86,6	76,3	61,1
październik	99,1	81,8	79,8	86,6	71,3
listopad	97,9	84,4	83,4	87,3	72,9
grudzień	98,5	83,0	81,1	89,3	80,7
Średnia	98,9	77,8	85,7	83,7	69,9

8.3. Walidacja.

Opracowany zestaw funkcji napisany w języku Python wygenerował różnie skonfigurowane modele sieci neuronowej. Pomimo wykorzystywania maszyny obliczeniowej wyposażonej w karty graficzne, czas trenowania modelu w zależności od jego skomplikowania, wahał się od 30 minut do jednej godziny. Biorąc pod uwagę pewne ograniczenia dostępu do jednorazowego ciągłego użytkowania maszyny obliczeniowej, całkowity czas poświęcony na wygenerowanie wszystkich modeli wynosił 21 dni.

Powyższa informacja potwierdza, że sieci rekurencyjne są bardzo wymagające pod względem mocy obliczeniowej. Dla porównania liczba wag w wykorzystywanych wcześniej jednokierunkowych sieciach neuronowych nie przekraczała 100 tysięcy, natomiast w przypadku rekurencyjnych sieci neuronowych przewyższyły 4,5 miliona połączeń. Pomimo tego, że w drugim przypadku zdecydowano się na zastosowanie jednej warstwy typu LSTM, a dla sieci jednokierunkowych generowały były architektury zawierające nawet 4 warstwy. Z tego powodu pewne analizy różnych funkcji aktywacji oraz współczynnika szybkości uczenia, jakie były rozważane w jednokierunkowych sieciach neuronowych, w tym zastosowaniu zostały ograniczone do wartości domyślnej oferowanej przez bibliotekę TENSORFLOW.

Opracowany algorytm walidacji modelu do prognozowania szeregów czasowych różni się od rozwiązania opartego o jednokierunkowe sieci neuronowe. W tym rozwiązaniu konieczne jest wprowadzenie do wytrenowanego modelu odpowiednich danych do warstwy wejściowej, wygenerowanie prognozy i w kolejnym etapie porównanie jej z wartościami rzeczywistymi. Przy czym należy mieć na uwadze, że efektem prognozy nie jest pojedyncza wartość danego parametru, a ciąg 744 następujących po sobie wartości, które zawierają informacje o:

- temperaturze zewnętrznej powietrza,
- prędkości i kierunku wiatru,
- ciśnienia atmosferycznego,
- wilgotności względnej powietrza,
- typu i wielkości opadu,
- daty i godziny.

W tym zastosowaniu zdecydowano się na wybranie temperatury powietrza zewnętrznego jako wyznacznika jakości predykcji, z racji na największą zmienność tego parametru w ciągu roku. Zaimplementowany w języku programowania algorytm walidujący można zapisać w następujący sposób:

1. wczytaj pierwszy wygenerowany model sieci neuronowej (tj. nr „x” z 504),
2. określ dla jakiej liczby godzinowych danych wejściowych wytrenowany został model (zakres od 744 do 8 760 ze skokiem co 744),
3. pobierz dane historyczne dane z IMGW,
4. wprowadź do modelu sieci neuronowej historyczne dane wszystkich parametrów meteorologicznych (np. dla parametru określonego w punkcie nr 2 równego 8 760 godzin będzie to okres od 04.11.2019 r. do 04.11.2020 r.),
5. wygeneruj prognozę wszystkich parametrów dla kolejnych 744 godzin (dla przykładu z punktu nr 4 będzie to okres od 05.11.2020 r. do 05.12.2020 r.),
6. porównaj wartość prognozowanej temperatury zewnętrznej dla 744 godzin z wartościami rzeczywistymi w tym okresie wykorzystując średni błąd procentowy określony równaniem:

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_{prog} - y_{rz}|}{y_{rz}} \cdot 100\%$$

gdzie:

- n – liczba analizowanych godzin prognozy narastająco w każdej kolejnej iteracji (wielokrotność 744),
 - y_{rz} – godzinowa rzeczywista wartość temperatury powietrza zewnętrznego,
 - y_{pred} – godzinowa prognozowana wartość temperatury powietrza zewnętrznego.
7. przejdź do kolejnej iteracji przesuując wprowadzane historyczne dane do modelu sieci neuronowej w liczbie określonej w punkcie nr 2 powiększonej o +744 godzin i wygeneruj prognozowane dane meteorologiczne na kolejne 744 godzin,
 8. wyznacz na nowo błąd MPE w stosunku do wartości prognozowanej i rzeczywistej temperatury powietrza zewnętrznego uwzględniając błąd z poprzedniej iteracji,
 9. zakończ pętlę gdy data prognozy parametrów nie będzie miała pokrycia w wartościach rzeczywistych zapisanych w bazie.

Dla tak skonstruowanej funkcji wyznaczone zostały wartości niedokładności 504. modeli, które częściowo zostały zaprezentowane w Tabeli 8.2. Wykorzystując opracowaną metodę oceniono niedokładność wygenerowanych modeli w zakresie od 30,71 % do 43,68 %.

Posługując się wcześniej opisaną *zasadą najmniejszego działania* jako najlepsze rozwiązanie do analizowanego problemu, oznaczone na miejscu czwartym w Tabeli 8.2, wybrano następującą strukturę sieci neuronowej:


- do prognozy parametrów na najbliższe 744 godziny należy wprowadzić do modelu informację o poprzednich 7 440 godzinach dla wszystkich danych meteorologicznych,
- liczba neuronów w warstwie LSTM wynosząca 64,
- wielkość próbek (`batch_size`) ustawiona na 12,
- funkcja aktywacji ustawiona domyślnie na tangens hiperboliczny,
- szybkość uczenia się ustawiona domyślnie na 0,001,
- liczba wag sieci odpowiadająca liczbie połączeń równa 502 800.

Tabela 8.2. Zestawienie pierwszych dziesięciu modeli do rozszerzonej prognozy pogody na kolejne 744 godziny wraz z modelem na środkowym oraz ostatnim miejscu w zestawieniu.

L. p.	Nazwa modelu	Liczba godzin historycznych [h]	Liczba godzin prognozy [h]	Liczba neuronów w warstwie LSTM [-]	Parametr batch [-]	Liczba wag sieci [-]	Niedokładność modelu [%]
1	7440_744_128_24	7440	744	128	24	1 030 928	30,71
2	7440_744_128_12	7440	744	128	12	1 030 928	30,82
3	7440_744_128_32	7440	744	128	32	1 030 928	30,83
4	7440_744_64_12	7440	744	64	12	502 800	30,84
5	7440_744_256_64	7440	744	256	64	2 185 488	30,88
6	8184_744_128_24	8184	744	128	24	1 030 928	31,00
7	7440_744_256_12	7440	744	256	12	2 185 488	31,04
8	8184_744_64_24	8184	744	64	24	502 800	31,07
9	8184_744_128_12	8184	744	128	12	1 030 928	31,09
10	7440_744_256_24	7440	744	256	24	2 185 488	31,12
252	4464_744_12_128	4464	744	12	128	97 824	37,36
504	744_744_12_128	744	744	12	128	97 824	43,68

8.4. Wyniki i analizy.

Wykorzystując rekurencyjne sieci neuronowe można prognozować dane meteorologiczne na podstawie parametrów historycznych na najbliższe 744 godziny ze średnią dokładnością, wyliczoną dla temperatury powietrza zewnętrznego, oscylującą w granicach 70 %. Ponad połowa z wygenerowanych modeli (386 z 504) spełniła określone kryterium akceptowalnej dokładności wynoszącej 60,66 %. Pierwszych 200 modeli posortowanych wg dokładności prognozy zawiera na wejściu ponad 5 208 godzin danych historycznych co przekłada się na minimalną wartość 7-u miesięcy.




Rys. 8.4. Zestawienie prognozowanych parametrów meteorologicznych na najbliższe 744 godziny tj. temperatury powietrza zewnętrznego, ciśnienia atmosferycznego, wilgotności względnej oraz ilości opadu atmosferycznego.

Na Rys. 8.4 zaprezentowano wygenerowane wykresy prognozy w okresie od 21. marca do 20. kwietnia 2025 r. zawierające przebieg wartości:

- temperatury powietrza zewnętrznego,
- ciśnienia atmosferycznego,
- wilgotności względnej,
- całkowitej ilości opadu atmosferycznego.

W przypadku temperatury powietrza zewnętrznego oraz wilgotności względnej można zaobserwować dobowe wahania wartości związane z aktywnością słońca. W przypadku ciśnienia atmosferycznego jest to wartość podlegająca niewielkim wahanom, natomiast w przypadku ilości opadu jest to funkcja stała. Dla porównania, wygenerowane zostały wykresy dla wartości rzeczywistych w tym samym okresie (Rys. 8.5). Widać jednoznacznie, że wartości charakteryzują się większą dynamiką zmian niż te wynikające z wygenerowanej wcześniej prognozy.



Rys. 8.5. Zestawienie rzeczywistych dostępnych parametrów meteorologicznych w okresie od 21. marca do 20 kwietnia 2025 r.

Jednak pomimo wyżej opisanych ograniczeń, wygenerowana w ten sposób rozszerzona prognoza pogody umożliwia jej wykorzystanie w modelach sieci neuronowej opracowanych do prognozy:


- zapotrzebowania na moc cieplną na cele centralnego ogrzewania i ciepłej wody użytkowej dla odbiorcy końcowego,
- zapotrzebowania na moc cieplną w źródle ciepła,
- zapotrzebowania na paliwo gazowe w ujęciu dobowym,

z akceptowalną dla tego rozwiązania dokładnością.

8.5. Wdrożenie.

Opracowany model może stanowić osobną funkcjonalność dającą informacje o prognozie pogody w dłuższym horyzoncie. Jednak w zrealizowanej aplikacji zintegrowanej z systemem sterowania elektrociepłownią jest wykorzystywany w głównej mierze jako źródło danych do pozostałych modeli opracowanych w niniejszej rozprawie.

Wartość temperatury powietrza zewnętrznego jest prezentowana operatorowi w celach informacyjnych za pośrednictwem aplikacji opublikowanej na stronie <https://dawid.czajor.com.pl/phd/> w postaci wykresu zaprezentowanego na Rys. 8.6.



Rys. 8.6. Skumulowany wykres prezentujący wartość temperatury powietrza zewnętrznego dla danych pozyskanych z IMGW oraz własnej predykcji w ostatnich trzydziestu dniach.

9. Prognoza ceny energii elektrycznej na Rynku Bilansującym.

9.1. Opis mechanizmu.

Planowanie pracy elektrociepłowni związane jest przede wszystkim z określeniem:


- wymaganej ilości ciepła do wyprodukowania
- oraz wygenerowanej energii elektrycznej.

W przypadku drugiego parametru może on być realizowany na kilka sposobów:

1. wykorzystując własną sieć dystrybucyjną i generując taką ilość energii jaką potrzebują przyłączeni klienci,
2. wykorzystując własną sieć dystrybucyjną oraz przyłączy do Krajowego Systemu Elektroenergetycznego i generując większą ilość energii niż wymagają przyłączeni klienci, eksportując jej nadwyżki na Rynek Bilansujący,
3. wykorzystując wyłącznie przyłączy do Krajowego Systemu Elektroenergetycznego i generując całą energię na Rynek Bilansujący.


W pierwszym przypadku generowany przychód uzależniony jest od stawek wynikających z zatwierdzonych cen przez Urząd Regulacji Energetyki oraz na podstawie zawartych umów z klientami. Natomiast drugi i trzeci wariant umożliwia uzyskanie przychodu od podmiotu, który będzie skupował wygenerowaną na Rynek Bilansujący energię elektryczną. Zakup może być realizowany na podstawie stałej stawki w okresie trwania umowy lub w oparciu o stawki na Towarowej Giełdzie Energii. Stała stawka jest rozwiązaniem bezpiecznym oraz dedykowanym dla podmiotów, które z różnych powodów są zobowiązane do ciągłej generacji energii (np. praca w priorytecie obciążenia cieplnego na potrzeby grzewcze sieci ciepłej). Większy przychód można jednak wygenerować analizując ceny na TGE oraz uruchamianie generacji w tych godzinach, które mają najwyższą stawkę za MWh energii elektrycznej.

Takie podejście wymaga jednak zaimplementowania odpowiednich algorytmów sterowania, które w okresie odstawienia agregatu kogeneracyjnego uruchomią kotły gazowe w celu zapewnienia odpowiednich parametrów pracy systemu ciepłowniczego. Dodatkowo należy mieć na uwadze, że generacja energii elektrycznej na Rynek Bilansujący wiąże się z ryzykiem cenowym sprzedaży energii. Rzeczywista cena energii w każdej godzinie na rynku jest pochodną pomiędzy zapotrzebowaniem a jej zużyciem w ujęciu całego Krajowego Systemu Elektroenergetycznego. Na koniec każdej godziny analizowana jest ilość energii jaka została wprowadzona do systemu oraz jej zużycie i w konsekwencji publikowana jest cena za MWh. Takie rozwiązanie skutkuje tym, że wytwórca nie ma wiedzy po jakiej cenie będzie sprzedawał energię w danej godzinie. Dodatkowo coraz większa generacja ze źródeł odnawialnych w godzinach południowych, wpływa w znaczny sposób na jej cenę. Nawet w miesiącu styczniu 2024 r., zarejestrowano wartości ujemne pomimo relatywnie niewielkiego nasłonecznienia w tym miesiącu, co zostało zaprezentowane na Rys. 9.1.



Rys. 9.1. Wykres ceny energii elektrycznej na Rynku Bilansującym w styczniu 2024 r.

W czerwcu 2024 roku odnotowano 4 dni z cenami ujemnymi. Natomiast już w marcu 2025 roku odnotowano ich 12 co zostało przedstawione na Rys. 9.2.

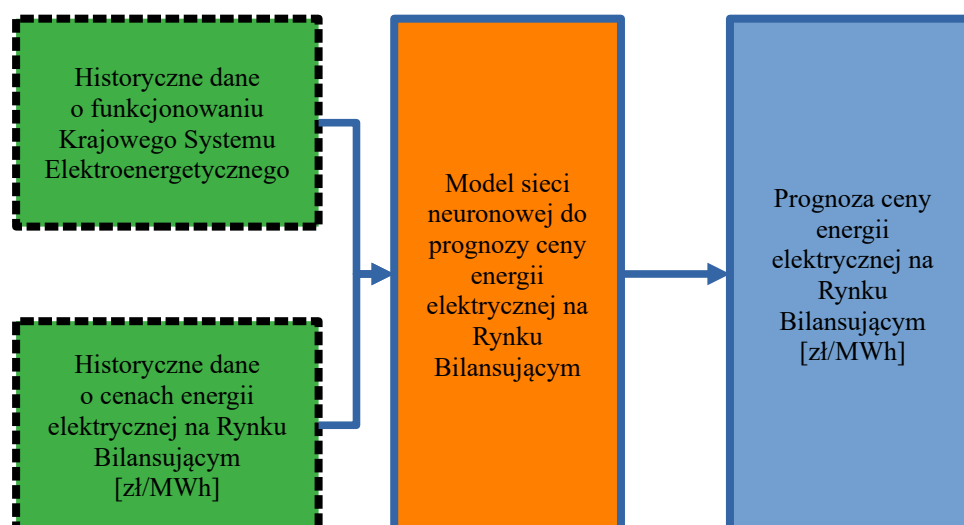


Rys. 9.2. Wykres ceny energii elektrycznej na Rynku Bilansującym w marcu 2025 r.

Biorąc pod uwagę powyższe, w celu zapewnienia elastyczności układu i generowania większego przychodu z tytułu sprzedaży energii elektrycznej na Rynek Bilansujący, konieczne jest opracowanie metody, która będzie prognozowała godzinowe ceny energii elektrycznej. Zrealizowane narzędzie wykorzystuje przy tym dane jakie są zapisywane w lokalnej bazie, zgromadzone w oparciu o wcześniej skonstruowane algorytmy. Dotyczą one wielu parametrów technicznych związanych z przepływem energii na terenie Polski oraz państw ościennych, jak również samej ceny megawatogodziny. Taki zakres informacji jest wystarczający, aby wykorzystując rekurencyjne sieci neuronowe, prognozować cenę energii elektrycznej w określonym horyzoncie czasu. Przedmiotowe zagadnienie jest zbliżone, pod względem programistycznym, do rozszerzonej prognozy pogody. Algorytm w pierwszej kolejności pobiera dane dotyczące:

- ceny energii elektrycznej na Rynku Bilansującym,
- generacji energii elektrycznej z elektrowni:
 - wodnych,
 - wiatrowych,
 - fotowoltaicznych,
 - ciepłych,
- łącznej generacji oraz zapotrzebowania na energię w Krajowym Systemie Elektroenergetycznym.

Dane są łączone w celu utworzenia jednej wspólnej tablicy, która w kolejnym etapie przechodzi przez proces normalizacji danych. Schemat funkcjonowania mechanizmu został przedstawiony na Rys. 9.3. Na dzień 15.03.2025 r. w bazie zarejestrowanych jest ponad 1,3 mln rekordów dotyczących parametrów technicznych funkcjonowania KSE (zarejestrowanych od dnia 17.12.2021 r.) oraz prawie 90 tys. pozycji związanych z ceną energii elektrycznej na Rynku Bilansującym (zarejestrowanymi od 01.01.2015 r.).



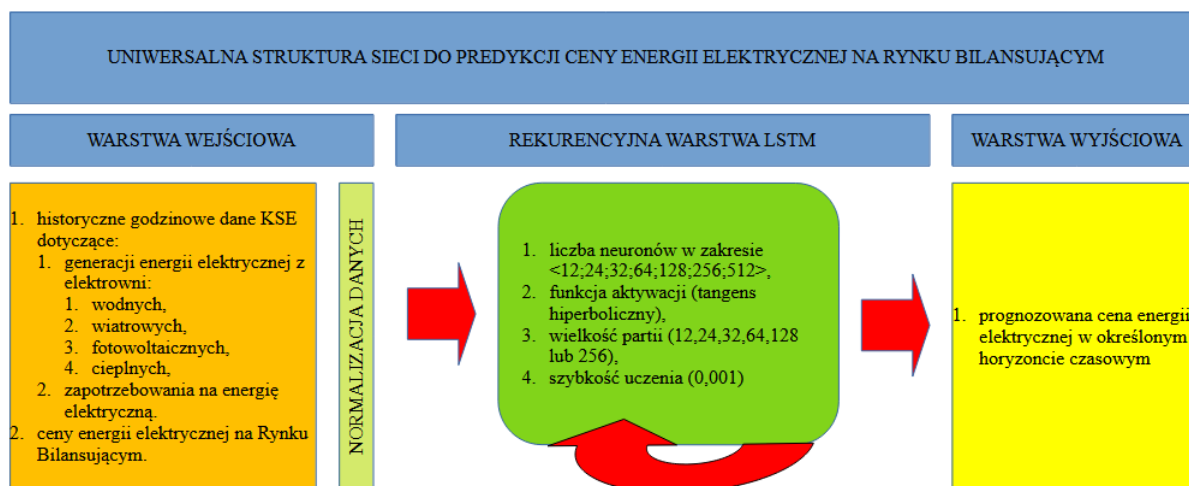
Rys. 9.3. Schemat opracowanego algorytmu do prognozy ceny energii elektrycznej na Rynku Bilansującym.

W opisywanym algorytmie zastosowane zostały poniższe parametry do wielowariantowej generacji modeli:

- zakres danych historycznych wprowadzanych do modelu obejmuje:
 - 60 godzin,
 - 48 godzin,
 - 24 godziny,
 - 12 godzin,
 - 1 godzinę,
- horyzont prognozy jest zdefiniowany identycznie jak zakres danych wejściowych,
- liczba neuronów w jednej warstwie typu LSTM przyjmująca wartości 12, 24, 32, 64, 128, 256, 512,
- funkcja aktywacji ustawiona domyślnie na tangens hiperboliczny,
- szybkość uczenia ustawiona domyślnie na 0,001,
- parametr próbek (batch_size) przyjmujący wartości 12, 24, 32, 64, 128, 256.

W zależności od wybranego zakresu danych historycznych oraz okresu prognozy, algorytm łączy odpowiednio rekordy aby przygotować je do trenowania. Proces ten przebiega analogicznie jak w przypadku metody dla rozszerzonej prognozy pogody z tą różnicą, że zakres danych będzie ograniczony od dnia 17.12.2021 r. tj. od momentu, w którym dostępne są dane o parametrach technicznych w KSE oraz cenach energii na RB. Na Rys. 9.4

przedstawiono graf ze strukturą uniwersalnej rekurencyjnej sieci neuronowej do prognozy ceny energii elektrycznej.



Rys. 9.4. Uniwersalna struktura rekurencyjnej sieci neuronowej wykorzystana do generowania modeli do prognozy ceny energii elektrycznej na Rynku Bilansującym.

Na podstawie tak skonfigurowanego algorytmu wygenerowanych zostało 833 modeli.

9.2. Akceptowalna niedokładność.

W poprzednich przykładach akceptowalną niedokładność zdefiniowano na podstawie obowiązujących przepisów funkcjonowania rynku ciepłowniczego. Zakładano, że przekroczenie jakiegokolwiek prognozowanego parametru o wartość większą niż wynika to z odpowiednich przepisów Prawa Energetycznego bądź uchwalanych na jej podstawie rozporządzeń, skutkuje odpowiedzialnością finansową. Jednak w przypadku ceny energii elektrycznej na Rynku Bilansującym, akceptowalność jest bardziej kwestią decyzji finansowej danego przedsiębiorstwa. Granicę można określić wykorzystując stosunek poziomu kosztów prowadzenia działalności gospodarczej do sprzedaży energii elektrycznej po prognozowanej cenie. Jednak w zależności od przedsiębiorstwa może ona być kwestią bardzo indywidualną. Z tego powodu zaproponowano aby akceptowalna niedokładność nawiązywała do modelu naiwnej prognozy ceny energii elektrycznej. Jest ona dla każdego przedsiębiorstwa wartością identyczną, ponieważ dotyczy cen na Rynku Bilansującym. Metoda polega na założeniu, że prognozowana cena jest w danej godzinie identyczna jak ta występująca w poprzedniej dobie. Jeżeli wygenerowany model sztucznej sieci neuronowej uzyska lepszą dokładność niż „podejście naiwne” to będzie on mógł uzyskać akceptację. Granica zostanie wyznaczona w oparciu o równanie na średni błąd procentowy:

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_{prog} - y_{rz}|}{y_{rz}} \cdot 100\%$$

gdzie:

- n – liczba godzinowych rekordów ceny energii elektrycznej zapisanych w bazie (wg stanu na 24.03.2025 r. wynosi ona 11 973),
- y_{rz} – rzeczywista cena energii elektrycznej w danej godzinie [zł/MWh],
- y_{pred} – „naiwna” cena energii elektrycznej odpowiadająca wartości rzeczywistej 24 godziny wstecz [zł/MWh].

Na podstawie powyższych założeń wyznaczono granicę dokładności dla wszystkich danych wraz z podziałem na poszczególne lata zaprezentowaną w Tabeli 9.1.

Tabela 9.1. Akceptowalna niedokładność generowanych modeli do prognozy ceny energii elektrycznej oparta na porównaniu do metody naiwnej.

Zakres danych źródłowych	Próg akceptowalności modelu [%]
rok 2022 i wcześniej	brak dostępnych danych
rok 2023	26,04
rok 2024	27,52
rok 2025 (do 23 marca)	22,04
wszystkie dostępne	26,26

W tym zastosowaniu jako granicę akceptowalności należy przyjąć wartość 26,26 %, wyznaczoną w oparciu o metodę naiwną.

9.3. Walidacja.

Wykorzystując dostępną maszynę obliczeniową, czas generacji wszystkich modeli nie przekroczył łącznie 7 dni. Był to wynik trzykrotnie krótszy w stosunku do zastosowania opisanego przy rozszerzonej prognozie pogody. Wynikał on z faktu, że zakres danych wejściowych w opisywanym zastosowaniu wynosił maksymalnie 60 dni w porównaniu do poprzedniego, który wynosił 365 dni.

Napisana funkcja, w celu określenia dokładności wygenerowanych modeli, miała następującą postać:

1. wczytaj pierwszy wygenerowany model sieci neuronowej (tj. nr „x” z 833),
2. określ dla jakiej liczby godzinowych danych wejściowych oraz wyjściowych został wytrenowany model,

3. pobierz dane historyczne dotyczące ceny energii elektrycznej oraz parametrów technicznych Krajowego Systemu Elektroenergetycznego,
4. wprowadź do modelu historyczne dane w liczbie odpowiadającej danym wejściowym w trakcie procesu trenowania,
5. wygeneruj prognozę ceny energii elektrycznej dla zdefiniowanego horyzontu określonego w punkcie nr 2,
6. porównaj wartości prognozowane z wartościami rzeczywistymi w tym okresie, posługując się średnim błędem procentowym określonym równaniem:

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_{prog} - y_{rz}|}{y_{rz}} \cdot 100\%$$

gdzie:

- n – liczba analizowanych godzin prognozy narastająco w każdej kolejnej iteracji,
- y_{rz} – godzinowa rzeczywista wartość ceny energii elektrycznej na Rynku Bilansującym,
- y_{pred} – godzinowa prognozowana cena energii elektrycznej na Rynku Bilansującym.
7. dodatkowo wyznacz błąd MPE dla wartości prognozowanych w pierwszej godzinie horyzontu prognozy,
 8. przejdź do kolejnej iteracji przesuając wprowadzone dane historyczne o okres odpowiadający horyzontowi prognozy w przyszłość,
 9. wyznacz na nowo błąd MPE porównując wartości prognozowane i rzeczywiste uwzględniając błąd z poprzedniej iteracji,
 10. zakończ pętlę gdy data prognozy ceny energii elektrycznej wybiegnie w przyszłość tak, że nie będzie możliwości jej porównania z wartością rzeczywistą,
 11. przejdź do kolejnego modelu (tj. „x” + 1 z 833).


Wykorzystując wyżej opisaną funkcję oceniono 833 modele, których część zaprezentowano w Tabeli 9.2.

Tabela 9.2. Zestawienie przykładowych modeli do prognozy ceny energii elektrycznej na Rynku Bilansującym.

L. p.	Nazwa modelu [-]	Liczba godzin historycznych [h]	Liczba godzin prognozy [h]	Liczba neuronów w warstwie LSTM [-]	Parametr batch [-]	Liczba wag sieci [-]	Niedokładność modelu w pierwszej godzinie prognozy [%]	Niedokładność modelu w całym okresie prognozy [%]
1	24_1_256_128	24	1	256	128	2 185 488	4,56	4,56
2	24_1_256_32	24	1	256	32	2 185 488	4,81	4,81
3	24_1_512_128	24	1	512	128	4 887 824	4,87	4,87
4	24_1_64_24	24	1	64	24	502 800	4,88	4,88
162	24_12_24_24	24	12	24	24	189 360	11,75	22,75
163	24_12_256_64	24	12	256	64	2 185 488	11,1	22,78
164	48_12_24_24	48	12	24	24	189 360	9,97	22,92
220	24_24_128_32	24	24	128	32	1 030 928	21,23	25,76
221	12_24_256_64	12	24	256	64	2 185 488	13,93	25,78
422	48_48_128_128	48	48	128	128	1 030 928	27,63	31,31
423	60_48_128_24	60	48	128	24	1 030 928	32,19	31,32
529	24_60_12_256	24	60	12	256	97 824	37,80	33,08
530	48_60_512_12	48	60	512	12	4 887 824	23,44	33,08

832	12_60_64_32	12	60	64	32	502 800	26,41	43,12
833	12_48_12_64	12	48	12	64	97 824	19,73	43,30

Pierwsze cztery modele o najmniejszej niedokładności dotyczą prognozy ceny energii elektrycznej na najbliższą godzinę przy wykorzystaniu ostatnich 24 godzin. Posługując się *zasadą najmniejszego działania*, sugerowanym modelem do wyboru powinien być ten opisany na pozycji numer 4 tj. 24_1_64_24, który osiąga niedokładność na poziomie 4,88 %. Jednak z punktu planowania pracy elektociepłowni, horyzont prognozy najbliższej godziny może się okazać za krótki w celu podjęcia słusznej decyzji o załączeniu silników kogeneracyjnych. Urządzenia te, pomimo dużej elastyczności pracy, mają swoje ograniczenia dotyczące liczby uruchomień w ciągu doby oraz rekomendowanego ciągłego czasu pracy po uruchomieniu. Z tego powodu zdecydowano się na implementację w aplikacji wdrożeniowej modelu, który będzie prognozował cenę energii elektrycznej z horyzontem 12 godzinnym. Analiza wygenerowanych modeli wskazuje, że wraz ze zwiększeniem zakresu prognozy parametru do wartości maksymalnej tj. 60 godzin, dokładność predykcji spada i w skrajnych przypadkach może przekroczyć 43 %. Z tego powodu horyzont 12 godzinny może być kompromisem pomiędzy dokładnością predykcji oraz funkcjonalnością algorytmu. W tym przypadku zdecydowano o wykorzystaniu modelu 48_12_24_24. Ma on niedokładność dla całego horyzontu predykcji gorszą o 0,17 p.p., w stosunku do modelu znajdującego się o 2 pozycje wyżej w zestawieniu, jednak jego dokładność dla pierwszej godziny predykcji jest o 1,78 p.p. lepsza. Dla wybranej architektury rekurencyjnej sieci neuronowej wygenerowano prognozę ceny energii oznaczoną kolorem niebieskim wraz z wartościami rzeczywistymi (Rys. 9.5).



Rys. 9.5. Wartość rzeczywistej i prognozowanej ceny energii elektrycznej dla okresu od 30.04.2025 r. do 01.05.2025 r.

Ma ona następującą konfigurację:

- 48 godzin danych historycznych na wejściu do modelu,
- liczba neuronów w jednej warstwie LSTM wynosząca 24,
- wielkość próbek analizowanych jednocześnie przy każdej epoce ustawiona na 24,
- funkcja aktywacji ustawiona domyślnie na tangens hiperboliczny,
- szybkość uczenia ustawiona domyślnie na 0,001,
- liczba wag odpowiadająca liczbie połączeń pomiędzy neuronami równa 189 360.

Wykorzystując tak skonfigurowany model uzyskujemy niedokładność dla pierwszej godziny prognozy ceny energii elektrycznej 9,97 %, a dla całego horyzontu 22,92 %. Decyzję o uruchomieniu lub wyłączeniu danego agregatu kogeneracyjnego należy podjąć, analizując oba parametry. Pierwszy daje odpowiedź na pytanie o opłacalności tej operacji natomiast drugi jak długo przewidywane jest utrzymywanie takiego poziomu cen i czy wypełniony zostanie warunek minimalnej pracy urządzenia po jego uruchomieniu. Wybrany model 48_12_24_24 prognozuje cenę energii elektrycznej w perspektywie najbliższych 12 godzin i spełnia on warunek akceptowalnej dokładności.

9.4. Wyniki i analizy.

Dysponując odpowiednią strukturą rekurencyjnej sieci neuronowej oraz ilością danych do jej wytrenowania, można prognozować cenę energii elektrycznej na Rynku Bilansującym. Dokładność tego mechanizmu jest ściśle powiązana z horyzontem prognozy. Im jest on dłuższy, tym dokładność maleje. Zakres uzyskanych wyników dla całego okresu prognozy wynosi od 4,56 % (dla 1 godziny w przyszłość) do 43,30 % (dla 48 godzin) oraz 43,12 % (dla 60 godzin). Biorąc pod uwagę fakt, że algorytm dość dobrze sobie radzi z prognozą na najbliższe kilka godzin zaproponowano podejście hybrydowe, w którym prezentowana jest dokładność modelu dla najbliższej godziny prognozy oraz dla całego horyzontu predykcji. Takie podejście umożliwia podjęcie decyzji o uruchomieniu silnika na podstawie krótkoterminowej prognozy, przy jednoczesnej podpowiedzi z prognozy długoterminowej o szacunkowym czasie pracy urządzenia do jego wyłączenia. Przyjęta zasada akceptowanej niedokładności przy tym zastosowaniu oznacza, że prognozy wykorzystujące model sieci neuronowej dla horyzontu predykcji wynoszącej 1, 12 oraz 24 godziny go spełniają. W przypadku dłuższego zakresu model uzyskuje gorszą dokładność w stosunku do metody naiwnej. Możliwe zatem byłoby stosowanie metody mieszanej tj. dla okna prognozy do 24 godzin polegającej na modelach sieci neuronowych, natomiast w dłuższej perspektywie na metodzie naiwnej.

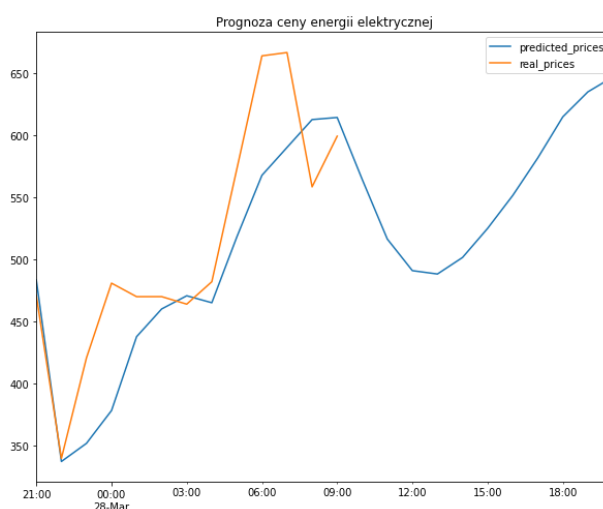
Wraz z rosnącą dynamiką kształtowania się ceny energii elektrycznej na Rynku Bilansującym, stosowanie tego typu mechanizmów ma jak najbardziej uzasadnienie. Rosnący udział energii z OZE będzie się przyczyniał do znacznych dysproporcji pomiędzy cenami w okresie intensywnego nasłonecznienia w godzinach południowych oraz bezwietrznymi wieczorami. Ciągła analiza tych zjawisk oraz podejmowanie decyzji w czasie rzeczywistym o uruchamianiu generacji z własnych układów kogeneracyjnych, umożliwi wypracowanie zakładanych wskaźników finansowych.

9.5. Wdrożenie.

Wybrany model na podstawie którego realizowana jest prognoza ceny energii elektrycznej na najbliższe 12 godzin, uruchamiany jest automatycznie co 15 minut. Odpowiada za to wbudowany w system Linux mechanizm CRON, który wywołuje funkcję `generate_ee_prices_forecast()`. Jako zmienne przyjmuje ona wszystkie wymagane parametry do skonstruowania wybranej struktury sieci neuronowej. Na tej podstawie generowane jest zestawienie prognozowanych cen energii elektrycznej (Rys. 9.6).

Prezentowane w ten sposób dane umożliwiają podjęcie decyzji przez operatora obiektu związanej z ewentualnym uruchomieniem produkcji energii elektrycznej. Równocześnie prognoza ta jest wykorzystywana przez kolejne funkcje, które mogą w sposób automatyczny wysyłać żądania uruchomienia generacji.

	real_prices	predicted_prices	error
2025-03-27 20:00:00	549.29	570.6	3.88
2025-03-27 21:00:00	470.90	483.5	2.68
2025-03-27 22:00:00	339.87	337.4	-0.73
2025-03-27 23:00:00	420.74	352.0	-16.34
2025-03-28 00:00:00	480.84	378.4	-21.30
2025-03-28 01:00:00	469.97	437.8	-6.85
2025-03-28 02:00:00	470.01	460.1	-2.11
2025-03-28 03:00:00	463.96	470.7	1.45
2025-03-28 04:00:00	482.00	465.1	-3.51
2025-03-28 05:00:00	572.84	518.1	-9.56
2025-03-28 06:00:00	663.65	567.6	-14.47
2025-03-28 07:00:00	666.32	590.0	-11.45
2025-03-28 08:00:00	558.30	612.4	9.69
2025-03-28 09:00:00	NaN	570.0	NaN
2025-03-28 10:00:00	NaN	519.1	NaN
2025-03-28 11:00:00	NaN	481.7	NaN
2025-03-28 12:00:00	NaN	461.7	NaN
2025-03-28 13:00:00	NaN	462.2	NaN



Rys. 9.6. Prognoza ceny energii elektrycznej dla modelu 48_12_24_24 na Rynku Bilansującym w formie tabelarycznej (po lewej) oraz wykresu (po prawej) dla losowo wybranego dnia, publikowane na stronie internetowej aplikacji.

W związku z ciągłą postępującą rozbudową odnawialnych źródeł energii, konieczne jest okresowe trenowanie modelu na podstawie nowych danych źródłowych. Zagwarantuje to utrzymanie akceptowalnego poziomu dokładności dla wybranego modelu i przełoży się na realizację zakładanych przychodów ze sprzedaży energii elektrycznej.


10. Prognoza ceny paliwa gazowego.

10.1. Opis mechanizmu.

Opracowany w poprzednim punkcie algorytm do prognozy ceny energii elektrycznej na Rynku Bilansującym, musi być skorelowany z ceną paliwa gazowego stosowanego do napędu urządzeń wytwórczych w elektrociepłowni. Informacja o cenie po jakiej wyprodukowana energia będzie sprzedawana bez dokładnej wiedzy o koszcie paliwa uniemożliwia ekonomiczne podejście do tego typu działalności gospodarczej. Mechanizm zakupu gazu może być realizowany w dwóch wariantach:

1. zawarta jest umowa z dostawcą na stałą cenę przez dany okres czasu (np. rok kalendarzowy lub sezon grzewczy),
2. zawarta jest umowa z dostawcą na zmienną cenę, która oparta jest na wartościach publikowanych na Towarowej Giełdzie Energii.

Pierwszy model zapewnia bezpieczeństwo pracy pod względem ekonomicznym i nie jest narażony na wahania cen, które w zależności od sytuacji geopolitycznej mogą w skrajnych sytuacjach przesądzić o niewypłacalności danego podmiotu gospodarczego. Wybór tego rozwiązania byłby konieczny przy podjętej wcześniej decyzji o podpisaniu umowy na stałą cenę sprzedaży energii elektrycznej na Rynek Bilansujący. Drugi bardziej ryzykowny jednak dający większe możliwości w zakresie generacji dodatkowego zysku, przy odpowiedniej relacji ceny energii elektrycznej do paliwa gazowego [68]. Wymaga jednak posiadania zaplecza technicznego do prognozy tego typu parametru jak również odpowiednio przemyślanej strategii funkcjonowania samego źródła ciepła, która w sytuacjach nieopłacalności uruchomienia agregatów kogeneracyjnych ma w swojej dyspozycji kotły gazowe, będące w stanie przejąć całkowite obciążenie cieplne.




Rys. 11.1. Wykres ceny paliwa gazowego na Towarowej Giełdzie Energii w okresie od 2019 do 2024 r.

Cena gazu przez wiele lat była bardzo stabilnym parametrem, która przekroczyła nigdy wcześniej nieobserwowane wartości w 2022 r. (Rys. 11.1). Konsekwencją tej sytuacji była rozpoczęta wojna pomiędzy Rosją a Ukrainą pod koniec 2021 r. Pomimo względnej stabilizacji w 2024 r. widać trend wzrostowy, który w pierwszym kwartale 2025 r. kształtował się na poziomie około 200 zł netto / MWh, co stanowiło prawie trzykrotną wartość przed wybuchem wojny. Sytuacja ta w sposób jednoznaczny pokazała jak silnie powiązany jest ten parametr z sytuacją polityczną na świecie.

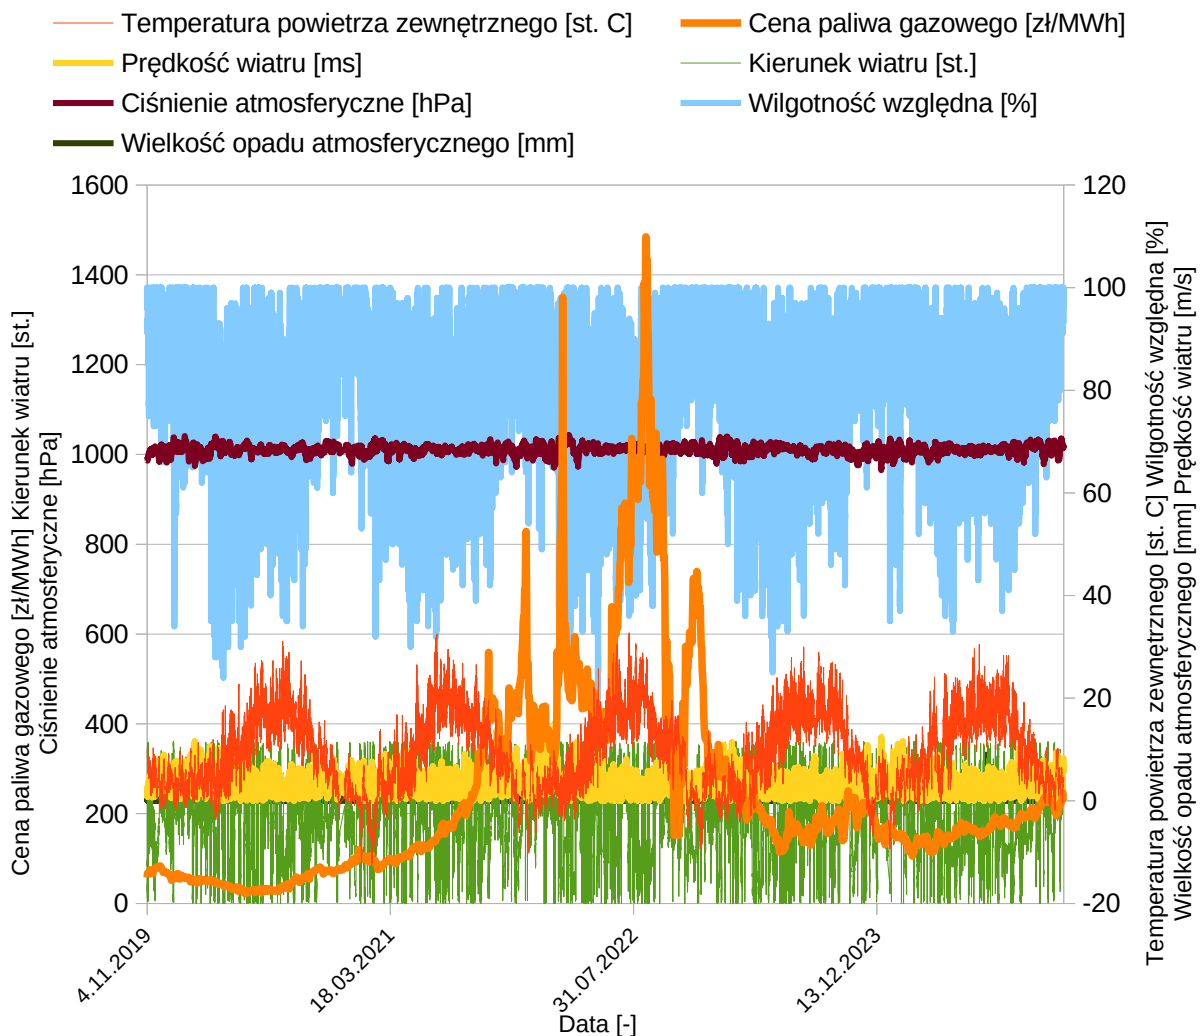
Do lokalnej bazy danych zapisywana jest rzeczywista cena po jakiej można było zakupić gaz na TGE. Nie został zdefiniowany żaden dodatkowy parametr, który mógłby odzwierciedlić sytuację geopolityczną oraz nastroje na światowym rynku paliw. Z tego powodu zaproponowane zostały modyfikacje danych źródłowych, do wytrenowania modelu. Ich zastosowanie może skutkować zarówno zwiększeniem lub obniżeniem dokładności predykcji w stosunku do oryginalnych danych źródłowych, co zostanie sprawdzone w ramach opracowanego mechanizmu do walidacji. Zaproponowane warianty kształtują się następująco:

1. podstawowy zakłada wykorzystanie wyłącznie historycznych danych o cenie gazu i na tej podstawie wyznaczenie jej predykcji w przyszłości,
2. pierwsza modyfikacja uzupełnia podstawowe dane o informacje zaczerpnięte z funkcjonowania Krajowego Systemu Energetycznego tj. o cenę energii elektrycznej, ilości jej generacji oraz zapotrzebowaniu. Analiza danych wykazała, że istnieje pewna korelacja pomiędzy ceną a tymi parametrami co przedstawia Rys. 11.2,



Rys. 11.2. Wykres prezentujący cenę paliwa gazowego na TGE wraz z ceną energii elektrycznej na Rynku Bilansującym w okresie 2019–2024 r.

- ostatnia modyfikacja, na wzór poprzedniej, uzupełnia dane podstawowe o prognozę pogody wszystkich parametrów meteorologicznych jakie są pozyskane z Instytutu Meteorologii i Gospodarki Wodnej. To podejście ma stanowić pewien eksperyment i sprawdzenie jaki będzie efekt końcowy predykcji. W szczególności, że nie zaobserwowano korelacji pomiędzy parametrami meteorologicznymi, a ceną paliwa gazowego co przedstawia Rys. 11.3.

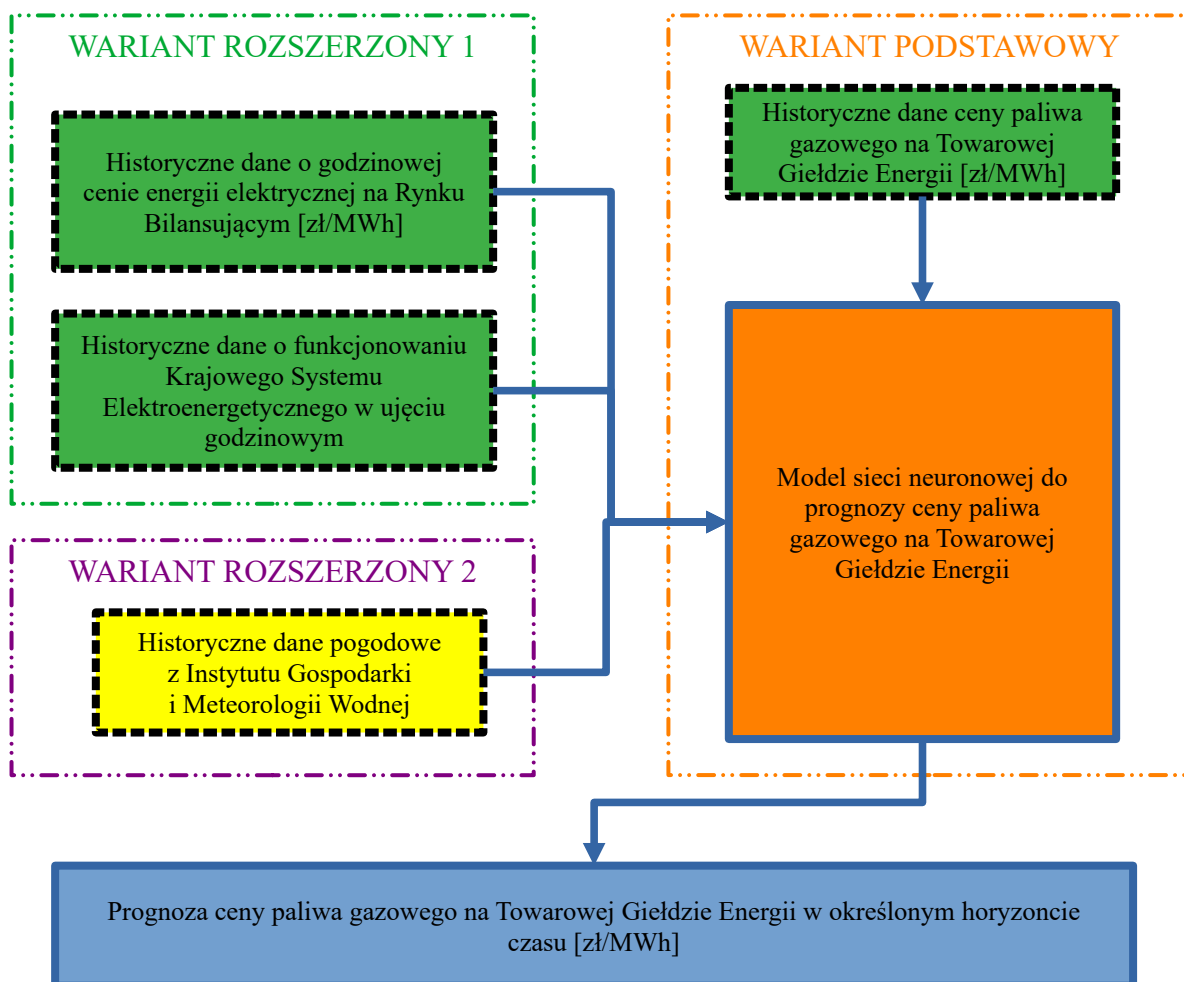


Rys. 11.3. Wykres prezentujący cenę paliwa gazowego na TGE wraz parametrami meteorologicznymi pozyskanymi z IMGW w okresie od 2019–2024 r.

Analogicznie jak w przypadku prognozy ceny energii elektrycznej, opisywane rozwiązanie jest przykładem prognozowania szeregów czasowych i wykorzystania rekurencyjnej sieci neuronowej. Różnica polega na tym, że zaplanowano sprawdzenie modelu pod kątem zarówno różnej struktury wewnątrz sieci neuronowej jak również biorąc pod uwagę różne warianty danych wejściowych. W zależności od podjętego wyboru, zaprezentowano schematycznie jak będzie funkcjonował mechanizm zarówno na etapie uczenia jak i późniejszej predykcji (Rys. 11.4).

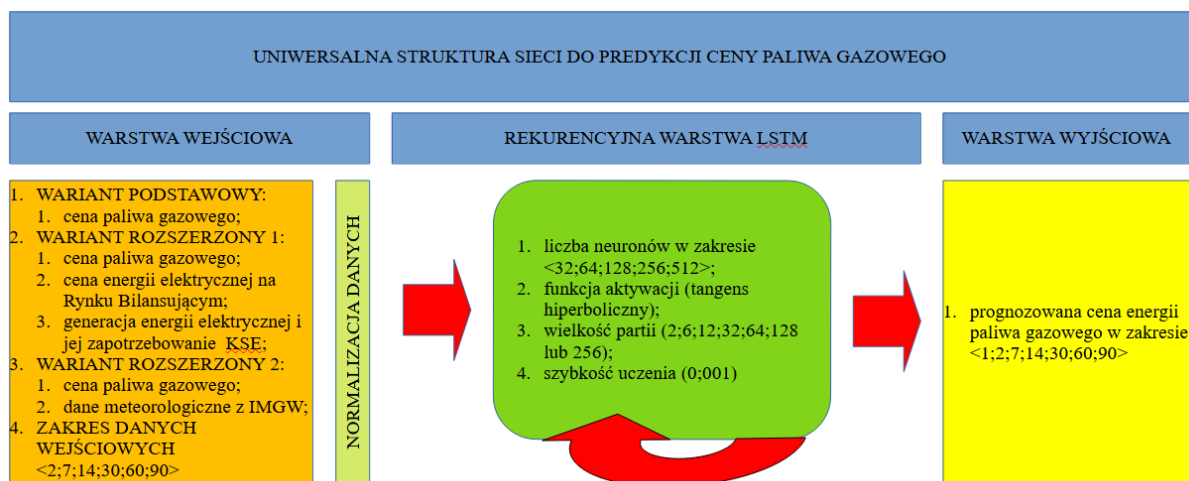
W opisywanym algorytmie zastosowano następujące parametry konfiguracyjne rekurencyjnej sieci neuronowej:

- zakres danych historycznych obejmuje 90, 60, 30, 14, 7, 2 dni,
- horyzont prognozy obejmuje 90, 60, 30, 14, 7, 2, 1 dni,
- liczba neuronów w jednej warstwie LSTM przyjmująca wartości 32, 64, 128, 256, 512,
- funkcja aktywacji ustawiona domyślnie na tangens hiperboliczny,
- szybkość uczenia ustawiona domyślnie na 0,001,
- wielkość partii (batch_size) przyjmujący wartości 2, 6, 12, 32, 64, 128, 256.



Rys. 11.4. Schemat opracowanego algorytmu do prognozy ceny energii elektrycznej na Rynku Bilansującym.

W oparciu o dany zakres danych historycznych oraz wybrany wariant danych źródłowych modelu, opracowany algorytm łączy odpowiednie informacje, które następnie przechodzą przez proces normalizacji. Efektem końcowym jest prognoza ceny paliwa gazowego w określonym horyzoncie w przyszłości, zgodnie z opracowanym grafem (Rys. 11.5).



Rys. 11.5. Uniwersalna struktura rekurencyjnej sieci neuronowej wykorzystana do generowania modeli do prognozy ceny paliwa gazowego na Towarowej Giełdzie Energii.

W oparciu o instrukcje zapisane w Rys. 11.5 zdefiniowanych zostało 4 410 modeli, których wygenerowanie zajęło maszynie obliczeniowej wyposażonej w karty graficzne 7 dni.

10.2. Akceptowalna niedokładność.

Bazując na definicji sformułowanej w poprzednim punkcie dotyczącej prognozy ceny energii elektrycznej, opracowano tabelę prezentującą wyliczenia progu akceptowalnej dokładności dla wygenerowanych modeli sieci neuronowej. Opierają się one na tym samym „naiwnym” mechanizmie, że prognozowana cena gazu na następny dzień jest identyczna jak w dniu poprzednim. Do wyznaczenia granicy akceptowalności wykorzystany został średni błąd procentowy określony równaniem:

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_{prog} - y_{rz}|}{y_{rz}} \cdot 100\%$$

gdzie:

- n – liczba dobowych rekordów ceny paliwa gazowego zapisanych w bazie (wg stanu na 26.03.2025 r. wynosi ona 2 100),
- y_{rz} – dobowa rzeczywista cena paliwa gazowego [zł/MWh],
- y_{pred} – „naiwna” cena paliwa gazowego odpowiadająca wartości z poprzedniej doby [zł/MWh].

Tabela 10.1. Zestawienie zdefiniowanych progów akceptowanej niedokładności dla modeli prognozujących cenę paliwa gazowego.

Zakres danych źródłowych	Próg akceptowalnej niedokładności modelu [%]
rok 2018 i wcześniej	brak dostępnych danych
rok 2019	4,90
rok 2020	3,46
rok 2021	4,00
rok 2022	6,41
rok 2023	4,05
rok 2024	2,09
rok 2025 (do 25 marca)	2,12
wszystkie dostępne	4,78

Wykorzystując opracowane kryterium akceptowalności danego modelu, którego niedokładność dla całego okresu predykcji nie może przekroczyć wartości 4,78 %, zakwalifikować można pierwszych 957 modeli. Znajdują się w tym zbiorze różne konfiguracje rekurencyjnej sieci neuronowej. Dotyczą ona zarówno kwestii liczby neuronów, zakresu wprowadzanych danych historycznych czy zastosowanego wariantu. Jednak żaden z nich nie przekracza 14-to dniowego horyzontu prognozy. Oznacza to, że żaden z wygenerowanych modeli o horyzoncie predykcji wynoszącym 30, 60 lub 90 nie spełnia powyższego kryterium akceptowalnej niedokładności. Analogicznie jak w przypadku prognozy ceny energii elektrycznej sugeruje się zastosowanie metody mieszanej. Polega ona na wykorzystaniu metody opartej na sztucznych sieciach neuronowych w horyzoncie krótkoterminowym (tj. do 14 dni), a na metodzie naiwnej w dłuższej perspektywie.

10.3. Walidacja.

Funkcja weryfikująca dokładność modeli ma zapisane następujące instrukcje postępowania:

1. wczytaj pierwszy wygenerowany model sieci neuronowej (tj. nr „x” z 4410),
2. określ dla jakiej liczby godzinowych danych wejściowych oraz wyjściowych został wytrenowany model,

3. pobierz dane historyczne dotyczące ceny paliwa gazowego,
4. pobierz dane historyczne w zakresie danych elektroenergetycznych z PSE (w przypadku wariantu nr 1) lub w zakresie danych meteorologicznych z IMGW (w przypadku wariantu nr 2),
5. wprowadź do modelu historyczne dane w zakresie odpowiadającym danym wejściowym w trakcie procesu trenowania,
6. wygeneruj prognozę ceny paliwa gazowego dla zdefiniowanego horyzontu określonego w punkcie nr 2,
7. porównaj wartości prognozowane z wartościami rzeczywistymi w tym okresie, posługując się średnim błędem procentowym określonym równaniem:

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_{prog} - y_{rz}|}{y_{rz}} \cdot 100\%$$

gdzie:

- n – liczba analizowanych godzin prognozy narastająco w każdej kolejnej iteracji,
 - y_{rz} – godzinowa rzeczywista wartość ceny paliwa gazowego na Towarowej Giełdzie Energii,
 - y_{pred} – godzinowa prognozowana cena paliwa gazowego na TGE.
8. dodatkowo wyznacz średni błąd procentowy dla wartości prognozowanych w pierwszym dniu horyzontu prognozy,
 9. przejdź do kolejnej iteracji przesuując wprowadzone dane historyczne o okres odpowiadający horyzontowi predykcji,
 10. wyznacz na nowo średni błąd procentowy porównując wartości prognozowane i rzeczywiste uwzględniając błąd z poprzedniej iteracji,
 11. zakończ pętlę gdy data prognozy ceny paliwa gazowego wbiegnie na tyle w przyszłość, że nie będzie możliwości jej porównania z wartością rzeczywistą,
 12. przejdź do kolejnego modelu (tj. „x” + 1 z 4410).

Na podstawie tak opisanej funkcji walidacji oceniono wszystkie modele, z których część zaprezentowano w Tabeli 10.2.

Tabela 10.2. Zestawienie przykładowych wygenerowanych modeli do prognozowania ceny paliwa gazowego.

L. p.	Nazwa modelu [-]	Wariant	Liczba dni historycznych [-]	Liczba dni prognozy [-]	Liczba neuronów w warstwie LSTM [-]	Parametr batch [-]	Liczba wag sieci [-]	Niedokładność modelu w pierwszym dniu prognozy [%]	Niedokładność modelu w całym okresie prognozy [%]
1	30_1_64_12	1	30	1	64	12	502 800	1,29	1,29
2	30_1_128_12	1	30	1	128	12	1 030 928	1,37	1,37
3	30_1_128_2	1	30	1	128	2	1 030 928	1,44	1,44
4	30_1_64_256	1	30	1	64	256	502 800	1,49	1,49
5	2_1_32_2	1	2	1	32	2	251 024	1,54	1,54
6	30_1_64_128	1	30	1	64	128	502 800	1,56	1,56
7	30_1_64_64	1	30	1	64	64	502 800	1,56	1,56
8	2_1_32_6	1	2	1	32	6	251 024	1,60	1,60
9	2_1_32_32	1	2	1	32	32	251 024	1,60	1,60
10	14_1_512_256	1	14	1	512	256	4 887 824	1,60	1,60
267	90_7_256_32	2	90	7	256	32	2 185 488	3,08	3,11
268	90_7_64_12	2	90	7	64	12	502 800	2,78	3,12
1960	30_7_512_2	0	30	7	512	2	4 887 824	5,88	6,95
1961	60_14_128_12	0	60	14	128	12	1 030 928	7,74	6,96
4408	30_90_256_64	2	30	90	256	64	2 185 488	45,51	64,50

L. p.	Nazwa modelu [-]	Wariant	Liczba dni historycznych [-]	Liczba dni prognozy [-]	Liczba neuronów w warstwie LSTM [-]	Parametr batch [-]	Liczba wag sieci [-]	Niedokładność modelu w pierwszym dniu prognozy [%]	Niedokładność modelu w całym okresie prognozy [%]
4409	30_90_256_2	2	30	90	256	2	2 185 488	44,68	65,79
4410	30_90_256_32	2	30	90	256	32	2 185 488	46,78	67,60

Na pierwszych dziesięciu miejscach znajdują się modele, które prognozują cenę paliwa gazowego na jeden dzień w przyszłość w oparciu o wariant rozszerzony nr 1. Uzyskały one najlepsze oceny w zakresie od 1,29 % do 1,60 %. Na dziesiątym miejscu znajduje się model o najbardziej rozbudowanej strukturze tj. 512 neuronów w warstwie LSTM oraz parametrze `batch_size` o wartości 256, co odpowiada ponad 4 milionom połączeń w sieci neuronowej. Interesujące jest to, że pomimo maksymalnych parametrów architektury, model ten nie wykazał lepszej dokładności w porównaniu z inną mniej skomplikowaną strukturą. Jest to dowód na przyjętą *zasadę najmniejszego działania*, w której do rozwiązania dowolnego problemu prostsza architektura sieci neuronowej może osiągać lepsze rezultaty.

Wariant rozszerzony numer 2 wystąpił dopiero na 28. miejscu z niedokładnością wynoszącą 1,70 %. Pojawia on się coraz częściej w kolejnych pozycjach w różnych konfiguracjach sieci, jednak wciąż z jednodniowym horyzontem prognozy. Dopiero na miejscu 91. sklasyfikowany został model o nazwie `2_2_32_2` wykorzystany do prognozy na dwa następne dni. Zaraz za nim znajduje się model `2_2_32_12` o takim samym oknie prognozy o strukturze i niedokładności gorszej o 0,01 p.p. Wraz ze zwiększeniem horyzontu prognozy niedokładność modeli rośnie i w skrajnych przypadkach dla predykcji na 90 kolejnych dni z wykorzystaniem 30 historycznych, ich błąd w całym okresie przekracza 67 %. W zdecydowanej większości modele oparte o dane rozszerzone z Krajowego Systemu Elektroenergetycznego jak również o dane meteorologiczne z IMGW nieznacznie lepiej sobie radzą z prognozą ceny paliwa gazowego. Modele oparte o sam wariant podstawowy możemy znaleźć dopiero na miejscu 272 i dalszych.

Biorąc pod uwagę powyższe, w aplikacji wdrożeniowej zdecydowano się na wybranie modelu `2_1_32_2`, który prognozuje cenę paliwa gazowego wyłącznie na następny dzień biorąc pod uwagę dwa dni historyczne. Charakteryzuje się on niedokładnością na poziomie 1,54 % i następującymi parametrami sieci:

- dane źródłowe oparte są na wariancie nr 1 tzn. oprócz danych historycznych ceny paliwa gazowego wprowadzone są do modelu również informacje o cenie energii


elektrycznej wraz z parametrami technicznymi funkcjonowania Krajowego Systemu Elektroenergetycznego,

- 32 neurony w jednej warstwie LSTM,
- wielkość partii (batch_size) wynoszący 2,
- szybkość uczenia ustawiona domyślnie na 0,001,
- funkcja aktywacji ustawiona domyślnie na tangens hiperboliczny,
- liczba wag odpowiadająca liczbie połączeń pomiędzy neuronami równa 251 024.

Decyzja o wyborze modelu do prognozowania na 1 dzień wynika z następujących założeń:


- uruchamianie silnika gazowego do produkcji energii elektrycznej uzależnione jest od relacji ceny energii elektrycznej w stosunku do ceny gazu,
- prognoza ceny energii elektrycznej jest realizowana z wykorzystaniem opracowanego wcześniej modelu o 12-to godzinnym horyzoncie predykcji,
- istnieje możliwość kontraktowania gazu z jednodniowym wyprzedzeniem.

W tego typu zastosowaniu wątpliwe wydaje się prognozowanie w dłuższym horyzoncie, ponieważ jest ono powiązane bezpośrednio z bieżącą eksploatacją układu kogeneracyjnego. Natomiast w przypadku chęci zakupu większej ilości gazu na najbliższy kwartał w celu zabezpieczenia produkcji ciepła oraz energii elektrycznej z elektrociepłowni, model wykorzystujący jednodniowe okno predykcyjne nie będzie miał praktycznego zastosowania. Dla tak zdefiniowanego zagadnienia konieczne będzie wykorzystanie modelu o dłuższym horyzoncie. Na tej podstawie wygenerowano trzy prognozy dla zakresu 30, 60 oraz 90 dni, które zostały porównane z danymi historycznymi. Dla prognozy 30-to dniowej wybrany został model 90_30_512_64 wykorzystujący prawie 5 milionów połączeń neuronowych sklasyfikowany na 3 168 miejscu. Opiera on się wyłącznie na danych historycznych paliwa gazowego (wariant podstawowy) i osiąga niedokładność dla całego horyzontu prognozy 15,02 % (Rys. 11.6).



Rys. 11.6. Prognoza ceny paliwa gazowego wygenerowana przy użyciu modelu 90_30_512_64 wraz z rzeczywistą ceną w tym samym okresie.

Dla prognozy 60–cio dniowej wybrany został model 2_60_32_128 z liczbą neuronów równą 251 024 znajdujący się na miejscu 3 255. Wykorzystuje on wariant nr 1 tj. cena paliwa gazowego rozszerzona o ceny energii elektrycznej. Niedokładność dla całego okresu prognozy jest równa 16,18 % (Rys. 11.7).



Rys. 11.7. Prognoza ceny paliwa gazowego wygenerowana przy użyciu modelu 2_60_32_128 wraz z rzeczywistą ceną w tym samym okresie.

Natomiast 90–ciodniowa prognoza ceny gazu wykorzystuje model 2_90_64_256 oraz wariant nr 1. Model sklasyfikowany jest na miejscu 3 445 i posiada 502 800 wag sieci neuronowej przy niedokładności równej 19,49 % (Rys. 11.8).



Rys. 11.8. Prognoza ceny paliwa gazowego wygenerowana przy użyciu modelu 2_90_64_256 wraz z rzeczywistą ceną w tym samym okresie.

10.4. Wyniki i analizy.

Wykorzystując rekurencyjne sieci neuronowe można prognozować ceny paliwa gazowego z akceptowalną dokładnością przy ograniczonym horyzoncie prognozy do kilku dni. Najlepsze rezultaty uzyskały modele, które wykorzystują wariant rozszerzony danych wejściowych nr 1 oraz nr 2. W przypadku wariantu nr 2 ciekawe jest to, że nawet brak zauważalnej dla człowieka korelacji pomiędzy ceną paliwa gazowego a danymi meteorologicznymi z IMGW, skutkowało zwiększeniem dokładności modelu w stosunku do wariantu podstawowego. Metoda ta jak najbardziej może być wykorzystana do krótkoterminowego kontraktowania gazu oraz planowania pracy jednostek kogeneracyjnych.

Wraz ze wzrostem horyzontu prognozy na 30, 60 czy 90 dni, każdy z wygenerowanych modeli przekraczał akceptowalny próg niedokładności. Jak zostało przedstawione na Rys. 11.6, Rys. 11.7, Rys. 11.8, modele w dłuższym horyzoncie prognozują cenę w sposób bardzo stabilny, nieumiejący przewidzieć tygodniowych wahań ceny paliwa rzędu kilkunastu złotych za megawatogodzinę. Taki mechanizm nie będzie satysfakcjonującym narzędziem do kształtowania polityki zakupu gazu dla całego zakładu elektrociepłowniczego. W takiej sytuacji przyjęcie do analizy ceny z ostatniej doby dla dłuższego horyzontu prognozy, może być obciążone mniejszym błędem jak również mniej wymagające pod względem:

- akwizycji danych historycznych,
- opracowaniu odpowiedniego oprogramowania,

- dostępu do znacznych mocy obliczeniowych.

Możliwe, że wprowadzenie do modelu dodatkowych parametrów opisujących sytuację geopolityczną, światowe nastroje na giełdach papierów wartościowych czy poziom wypełnienia magazynów gazu w europie, zwiększyłyby dokładność prognozy w dłuższym horyzoncie czasowym.

10.5. Wdrożenie.

Opisany mechanizm prognozy ceny paliwa gazowego w perspektywie krótkoterminowej stanowi źródło danych do algorytmu decydującego o pracy układów kogeneracyjnych. Kluczowa jest relacja tego parametru w stosunku do prognozowanej ceny energii elektrycznej na najbliższe 12 godzin. Jednak pomimo tego sama prognoza ceny paliwa gazowego jest prezentowana w opracowanym systemie informatycznym w sekcji danych dotyczących źródła (Rys. 11.9).

Dane aktualne

Aktualizacja	2025-03-27 23:00:03
Prognozowana cena gazu ziemnego	192.28 [zł/MWh]

Rys. 11.9. Prognoza ceny paliwa gazowego wygenerowana dla modelu 2_1_32_2 i prezentowana na stronie internetowej aplikacji.

Jak zostało uzasadnione w punkcie poprzednim, w aplikacji wykorzystano model o nazwie 2_1_32_2, który wykorzystuje rozszerzone dane wejściowe w wariacie pierwszym. Za odpowiednie sformatowanie danych oraz ich zapisanie w lokalnej bazie odpowiada funkcja `generate_gas_prices_forecast()`, która jako zmienne może przyjmować wszystkie kluczowe parametry modelu.

11. Opis wdrożenia algorytmów uczenia maszynowego z wykorzystaniem sieci neuronowych w istniejącym systemie ciepłowniczym.

11.1. Dane o aktualnym systemie informatycznym w przedsiębiorstwie.

Istniejący system informatyczny stosowany przez przedsiębiorstwo, w którym realizowane jest wdrożenie, jest stosowany do kompleksowego sterowania wszystkimi procesami w elektrociepłowni. Rejestruje on w czasie rzeczywistym parametry pracy urządzeń wytwórczych oraz węzłów cieplnych. Umożliwia wizualizację oraz archiwizację zgromadzonych danych w celu bieżącej kontroli pracy układu jak i analizy historycznej w przypadku wystąpienia anomalii. Wykorzystuje do tego protokoły komunikacyjne zaimplementowane w sterownikach:

- silników kogeneracyjnych,
- układów pomocniczych przy kogeneracji,
- stabilizacji ciśnienia w sieci ciepłowniczej,
- palników gazowych kotłów wodnych,
- ciśnienia dyspozycyjnego na wyjściu ze źródła,
- pracy węzłów cieplnych przyłączonych do sieci (ze zdalną komunikacją),
- rejestratorów urządzeń pomiarowych zainstalowanych w elektrociepłowni i w węzłach cieplnych,
- układu automatyki zarządzającej procesami uruchamiania i zatrzymywania silników oraz kotłów gazowych, dla których sygnał zmiany trybu pracy jest wymuszany przez operatora.

Wszystkie zbierane informacje trafiają do serwerów pracujących w trybie redundantnym za pośrednictwem wewnętrznej sieci telekomunikacyjnej, zlokalizowanych na terenie elektrociepłowni. Komunikacja z nimi jest ograniczona z racji na bardzo rygorystyczne podejście do bezpieczeństwa pracy tego typu obiektu oraz zamknięty kod oprogramowania elektrociepłowni. Aktualnie nie jest możliwa ingerencja w algorytmy sterujące procesami technologicznymi mająca na celu zdalne załączanie silników kogeneracyjnych oraz kotłów gazowych wraz z regulacją ich mocy. Ten zakres wymaga zmian informatycznych po stronie przedsiębiorcy i nie jest objęty zakresem niniejszej rozprawy. Z tego powodu uruchomiono opracowaną aplikację na zewnętrznym serwerze WWW. Publikuje ona wymagane parametry pracy źródła wygenerowane z wykorzystaniem sztucznej sieci neuronowej, tak aby operator mógł na tej podstawie realizować sterowanie. Dodatkowo jest on informowany za pomocą wiadomości tekstowych na telefon komórkowy oraz poprzez wiadomość e-mail o wymaganej zmianie parametrów pracy źródła.

11.2. Wymagania sprzętowe.

W ramach niniejszej rozprawy wygenerowanych zostało 12 147 modeli sieci neuronowych, które zostały poddane ocenie. Taka ilość przetworzonych danych wymagała zastosowania maszyny roboczej o dużych możliwościach obliczeniowych. Dzięki środkom przyznanych przez Ministerstwo Nauki i Szkolnictwa Wyższego z programu „Doktorat Wdrożeniowy” nr umowy DWD/5/0017/2021, możliwe było sfinansowanie takiego urządzenia. Udostępniony komputer wykorzystywał osiem kart graficznych NVIDIA A100 (6912 rdzeni CUDA , 19.5 TFLOPS w FP32, 156 TFLOPS w Tensor Float 32, pamięć karty 80 GB), limit 8 rdzeni CPU i pamięci operacyjnej RAM 256 GB. Konfiguracja i dostęp do urządzenia odbywała się za pomocą protokołu SSH z wykorzystaniem środowiska CONDA. Czas wymagany do przeliczenia wszystkich modeli, nawet z wykorzystaniem kart graficznych (GPU), zajął kilka tygodni przy zajęciu powierzchni dysku ponad 117 GB (rozpiętość pomiędzy najmniejszym a największym modelem w zakresie od 87 KB do 57 312 KB).

Opracowany system, który wykorzystuje wybrane modele do prognozowania i sterowania procesami elektrociepłowni został uruchomiony na osobnym komputerze. Stanowi on własność prywatną, na którą składa się laptop o następujących parametrach:

- procesor Intel Core i5–2430M @ 2,4 GHz,
- pamięć operacyjna 8 GB,
- dysk SSD o pojemności 256 GB,
- zainstalowany system Debian GNU/Linux w wersji 12.

Zainstalowano na nim następujące oprogramowanie:

- Python w wersji 3.9.2 wraz z najważniejszymi bibliotekami:
 - Beautifulsoup4 w wersji 4.12.2,
 - Pandas w wersji 1.5.3,
 - Numpy w wersji 1.24.2,
 - Tensorflow w wersji 2.15.0,
 - Matplotlib w wersji 3.7.1,
 - Keras w wersji 2.15.0,
- Jupyter–notebook w wersji 6.2.0,
- Nginx w wersji 1.22.1,
- PHP w wersji 8.2.20.

Wykorzystując powyższe urządzenie opracowane zostały moduły oprogramowania, które odpowiadają za bieżącą aktualizację danych, wysyłanie sygnałów sterujących i publikowanie prognoz na serwerze. Całkowita liczba wierszy w opracowanej aplikacji wdrożeniowej napisanej w języku programowania Python wynosi 12 225.

11.3. Moduły oprogramowania.

Podstawowymi mechanizmami działającymi w tle są następujące algorytmy uruchamiane automatycznie przez harmonogram zadań systemu GNU/Linux:

- co piętnaście minut następuje wywołanie wszystkich funkcji służących do zbierania danych,
- również co 15 minut ale począwszy od piątej minuty każdej godziny, rozpoczyna działanie funkcja konwertująca zapisane w lokalnej bazie danych informacje z poprzedniego punktu, do dokumentów w formacie JSON lub CSV. Umożliwia ona szybszy dostęp do znacznej liczby rekordów bez nadmiernego obciążania procesora i może być udostępniona na serwerze WWW,
- z takim samym interwałem ale począwszy od dziesiątej minuty każdej godziny, aktywowane są funkcje odpowiadające za wygenerowanie prognoz:
 - zapotrzebowania na ciepło,
 - zapotrzebowania na paliwo gazowe w źródle,
 - rozszerzonych danych meteorologicznych,
 - ceny energii elektrycznej oraz paliwa gazowego,

oraz ich przesłanie wyżej na stronę internetową <http://dawid.czajor.com.pl/phd>. Za te działania odpowiadają instrukcje zawarte w plikach `forecast.ipynb` oraz `heat_load_prediction.ipynb`.

Prezentacja powyższych danych w aplikacji jest podzielona na następujące sekcje:

- dane aktualne (Rys. 11.1) – parametry techniczne elektrociepłowni wraz z informacją o rzeczywistej oraz prognozowanej cenie paliwa gazowego w kolejnym dniu,

Dane aktualne

Aktualizacja	2025-03-31 23:45:02
Prognozowana cena gazu ziemnego	184.09 [zł/MWh]
Jutrzejsza rzeczywista cena gazu ziemnego	183.85 [zł/MWh]
Dzisiejsza rozliczeniowa cena gazu ziemnego	184.37 [zł/MWh]
Generacja	Wartość
Moc elektryczna GPZ	0.74 MW
Moc cieplna	4.870 MW
Parametry EC	Wartość
Zadana temperatura zasilania	78.9 °C
Rzeczywista temperatura zasilania	75.5 °C
Rzeczywista temperatura powrotu	44.4 °C
Natężenie przepływu	138.4 m ³ /h
Temperatura zewnętrzna	2.1 °C
Parametry urządzeń	Wartość
Silnik nr 1 - moc czynna	0 kWe
Silnik nr 2 - moc czynna	1202 kWe
Silnik nr 3 - moc czynna	0 kWe
Silnik nr 1 - moc cieplna	0 MWt
Silnik nr 2 - moc cieplna	1.28 MWt
Silnik nr 3 - moc cieplna	0 MWt
Silnik nr 1 - zużycie gazu	0 m ³ /h
Silnik nr 2 - zużycie gazu	277.38 m ³ /h
Silnik nr 3 - zużycie gazu	0 m ³ /h
Silnik nr 1 - temperatura spalin	20.9 °C
Silnik nr 2 - temperatura spalin	133.8 °C
Silnik nr 3 - temperatura spalin	16.9 °C
Kocioł nr 1 - moc cieplna	3.87 MWt
Kocioł nr 2 - moc cieplna	0 MWt
Kocioł nr 3 - moc cieplna	0 MWt
Kocioł nr 1 - zużycie gazu	407.94 m ³ /h
Kocioł nr 2 - zużycie gazu	0 m ³ /h
Kocioł nr 3 - zużycie gazu	0 m ³ /h

Rys. 11.1. Aktualne dane elektrociepłowni prezentowane na stronie internetowej aplikacji.

- dane prognozowane (Tabela 11.1) – na które składają się:
 - dobową sprzedaż ciepła przez odbiorców końcowych,
 - dobową prognozę oraz rzeczywistą produkcję ciepła w źródle,
 - dobową prognozę oraz rzeczywiste zużycie paliwa gazowego,
 - godzinową prognozę oraz rzeczywistą wartość ceny energii elektrycznej.

Tabela 11.1. Prognozowane dane elektrociepłowni prezentowane na stronie internetowej aplikacji.

Data	Prognoza produkcji ciepła w źródle [GJ]	Rzeczywista produkcja ciepła [GJ]	Różnica [%]	Sprzedaż ciepła do odbiorców [GJ]	Prognoza zużycia gazu [MWh]	Rzeczywiste zużycie gazu [MWh]	Różnica [%]
[1]	[2]	[3]	[4]	[5]	[6]	[7]	[8]
2025-03-25	320	339	-5,60	229	145	159,2	-8,92
2025-03-26	338	326	3,68	247	152	148,7	2,22
2025-03-27	337	353	-4,53	248	164	172,2	-4,76
2025-03-28	327	317	3,15	239	147	149,5	-1,67
2025-03-29	330	306	7,84	239	148	145,5	1,72
2025-03-30	328	320	2,50	237	146	146,8	-0,54
2025-03-31	359	335	7,16	278	160	155,3	3,03
2025-04-01	352	347	1,44	261	157	157,1	-0,06
2025-04-02	321	236 (do godz. 17:00)	36,02	225	132	108,5 (do godz. 17:00)	21,66
2025-04-03	302	-	-	205	118	-	-
2025-04-04	328	-	-	232	136	-	-
2025-04-05	355	-	-	261	151	-	-
2025-04-06	349	-	-	254	148	-	-
2025-04-07	348	-	-	255	147	-	-


Dane dotyczące prognozowanej produkcji ciepła mogą być wyznacznikiem dla operatora w zakresie sterowania mocą cieplną urządzeń wytwórczych, jak również umożliwić raportowanie zużycia paliwa gazowego w ujęciu dobowym.

11.4. Moduły wykonawcze.

Na podstawie generowanych prognoz opracowanych zostało kilka mechanizmów, które mają na celu automatyzować proces zarządzania elektrociepłownią kogeneracyjną tj.:

1. codzienne raportowanie prognozowanego zapotrzebowania na paliwo gazowe przesyłane na adres poczty elektronicznej dostawcy gazu,
2. codzienne raportowanie do operatora w zakresie czasu pracy układu kogeneracyjnego w celu wyprodukowania prognozowanej ilości ciepła (tryb pracy w priorytecie produkcji ciepła),
3. cegodzinne raportowanie do operatora w zakresie pracy układu kogeneracyjnego przy satysfakcjonującej relacji ceny energii elektrycznej w stosunku do ceny paliwa gazowego (tryb pracy w priorytecie produkcji energii elektrycznej).

Pierwsze dwa moduły zostały opisane w części wdrożeniowej punktów dotyczących prognozowania zapotrzebowania na ciepło oraz paliwa gazowego w źródle. Trzeci moduł jest przykładem sterowania opartego głównie na produkcji energii elektrycznej. Wymaga on ustalenia kryterium pracy w tym trybie tj. minimalnego wskaźnika relacji prognozowanej ceny energii elektrycznej w stosunku do prognozowanej ceny paliwa gazowego. W opracowanym systemie wskaźnik ten ustalono na wartość 2,5. W zależności od wartości, algorytm sprawdza czy w danej godzinie prognozy relacja jest większa czy mniejsza. Większa wartość jest równoznaczna z wysłaniem sygnału do załączenia silników gazowych, mniejsza do ich zatrzymania. Powyższa informacja przekazywana jest operatorowi w formie graficznej (Rys. 11.2) oraz za pomocą wiadomości na telefon jak również z wykorzystaniem poczty elektronicznej. Zawiera ona informację na jak długo oraz ile generatorów należy uruchomić. Maksymalny czas pracy tych urządzeń będzie limitowany ilością ciepła jaką należy dostarczyć do układu ciepłowniczego, co wynika z prognozy zapotrzebowania na ciepło dla źródła.



Rys. 11.2. Zaplanowany harmonogram pracy silników kogeneracyjnych wygenerowany przez opracowany system.

Kolumny w kolorze zielonym przedstawiają godziny, w których powinna być realizowana produkcja energii elektrycznej. Natomiast kolorem żółtym zaznaczono godziny, w których relacja cen stanowi 85 % założonego wskaźnika. Praca w tych godzinach pozostaje do decyzji operatora. Opracowany automatyczny mechanizm będzie komunikował żądanie pracy układu kogeneracyjnego wyłącznie w okresach zaznaczonych kolorem zielonym.

Dla tak zdefiniowanych założeń uruchomiony został algorytm, który przeanalizował pierwszy kwartał 2025 roku. Wykorzystując prognozowane ceny energii elektrycznej w stosunku do prognozowanej ceny paliwa gazowego, określił godziny w których należało pracować układem kogeneracyjnym. Dane te zostały zsumowane w ujęciu miesięcznym i porównane z wartościami rzeczywistymi, co zostało przedstawione w Tabeli 11.2.

Tabela 11.2. Porównanie rzeczywistego czasu pracy układu kogeneracyjnego z zaplanowanym harmonogramem wygenerowanym przez system.

Miesiąc i rok	Rzeczywisty czas pracy układu kogeneracyjnego [h]	Teoretyczny czas pracy układu kogeneracyjnego przy wykorzystaniu opracowanego narzędzia [h]	Różnica ([3] – [2]) [h]	Udział procentowy ($([4]/[2]*100)$ [%])
[1]	[2]	[3]	[4]	[5]
styczeń 2025	794	1187	393	49
luty 2025	772	1159	387	50
marzec 2025	774	1224	450	58
Łącznie	2252	3570	1318	59

Efektem działania algorytmu, jest prognozowana częstsza praca silników gazowych o ponad 1 300 godzin w całym analizowanym okresie. Stanowi to prawie 60 % rzeczywistego czasu ich pracy. Tak duży wolumen będzie miał pozytywny wpływ zarówno na wynik finansowy przedsiębiorstwa, jak również zwiększenie udziału ciepła z kogeneracji w systemie ciepłowniczym.

11.5. Uproszczona analiza finansowa.

W celu zaprezentowania wpływu dodatkowych godzin pracy silników gazowych na wynik finansowy przedsiębiorstwa, konieczne jest podjęcie następujących założeń:

- koszt zakupu gazu przyjęto w kwocie 241 zł/MWh. Składa się na nią średnia cena gazu na Towarowej Giełdzie Energii w pierwszym kwartale 2025 r. (219 zł/MWh) powiększona o 10 % marżę przedsiębiorstwa dostarczającego paliwo,
- przychód ze sprzedaży energii cieplnej będzie rozliczony wg średnich kwot obowiązujących dla źródeł opalanych paliwem gazowym w 2024 r. (wg raportu Prezesa URE [128]) tj. 144,18 zł/GJ co odpowiada wartości 519,05 zł/MWh,
- przychód ze sprzedaży energii elektrycznej będzie przeliczany na podstawie rzeczywistych cen na Rynku Bilansującym obowiązujących w godzinach, w których algorytm podjął decyzję o uruchomieniu generacji,
- koszt serwisu agregatów kogeneracyjnych będzie odniesiony do godziny pracy jednostki i ustalony został na kwotę 50 zł/h.

- praca silnikówysterowana była na maksymalną wartość generowanej mocy elektrycznej, a ogólna sprawność układu wynosiła 85 %.

W Tabeli 11.3 przedstawiono uproszczony wynik finansowy przedsiębiorstwa przed wdrożeniem algorytmu. Elektrociepłownia pracowała przez cały okres w podstawie jednym silnikiem gazowym, natomiast w określonych godzinach uruchamiane były ręcznie przez operatora dodatkowe agregaty. Brakująca ilość ciepła, w celu utrzymania odpowiednich parametrów pracy sieci ciepłowniczej była generowana w kotłach gazowych. W tym scenariuszu wynik finansowy przedsiębiorstwa wyniósł niewiele ponad 1 milion złotych.

Tabela 11.3. Uproszczony wynik finansowy przedsiębiorstwa przed wdrożeniem algorytmu.

Miesiąc i rok	Rzeczywisty czas pracy układu kogeneracyjnego [h]	Koszt serwisu [zł]	Koszt paliwa gazowego [zł]	Przychód z ciepła [zł]	Przychód ze sprzedaży energii elektrycznej [zł]	Wynik finansowy [zł] (6+5-4-3)
[1]	[2]	[3]	[4]	[5]	[6]	[7]
styczeń 2025	794	39 700	574 062	494 551	461 155	341 944
luty 2025	772	38 600	558 156	480 848	517 858	401 950
marzec 2025	774	38 700	559 602	482 094	377 093	260 884
Łącznie	2 252	112 600	1 628 196	1 402 681	1 356 106	1 017 990

Zakładając pracę układu w oparciu o algorytm, możliwe było wygenerowanie większej ilości energii cieplnej oraz elektrycznej przy niezmiennych kosztach stałych obsługi całego obiektu. W tym scenariuszu elektrociepłownia również pracowała w podstawie jednym silnikiem gazowym, natomiast w określonych przez algorytm godzinach były uruchamiane dodatkowe agregaty. Dla takiego rozwiązania wynik finansowy był większy o ponad 620 tys. złotych i umożliwił wprowadzenie do sieci cieplnej dodatkowo prawie 5 700 GJ ciepła. Wyniki zostały zaprezentowane w Tabeli 11.4.

Tabela 11.4. Uproszczony wynik finansowy przedsiębiorstwa po wdrożeniu algorytmu.

Miesiąc i rok	Teoretyczny czas pracy układu kogeneracyjnego przy wykorzystaniu opracowanego narzędzia [h]	Koszt serwisu [zł]	Koszt paliwa gazowego [zł]	Przychód z ciepła [zł]	Przychód ze sprzedaży energii elektrycznej [zł]	Wynik finansowy [zł] (6+5-4-3)
[1]	[2]	[3]	[4]	[5]	[6]	[7]
styczeń 2025	1187	59 350	858 201	739 335	735 350	557 134
luty 2025	1159	57 950	837 957	721 895	795 444	621 432
marzec 2025	1224	61 200	884 952	762 381	646 577	462 805
Łącznie	3570	178 500	2 581 110	2 223 610	2 177 371	1 641 371

Jak zostało przedstawione powyżej, stosowanie algorytmu wpłynęło pozytywnie zarówno na kwestie finansowe działalności gospodarczej jak i zwiększenie udziału ciepła z kogeneracji. Może to przyczynić się dodatkowo do uzyskania lub utrzymania statusu sieci efektywnej energetycznie.

Tabela 11.5. Porównanie ceny sprzedaży energii elektrycznej na Rynek Bilansujący z wykorzystaniem sterowania ręcznego oraz automatycznego.

Miesiąc i rok	Cena sprzedaży energii elektrycznej netto na Rynku Bilansującym [zł/MWh]		Różnica (3-2)/2*100 [%]
	sterowanie ręczne	sterowanie automatyczne	
[1]	[2]	[3]	[4]
styczeń 2025	484	516	6,66
luty 2025	559	572	2,31
marzec 2025	406	440	8,43
Średnia	483	509	5,38


Sprowadzając powyższe wyliczenia do jednego wspólnego mianownika jakim jest cena energii elektrycznej wyrażona z złotych za megawatogodzinę, przedstawiono ich wartości w kolumnie 2 oraz 3 w Tabeli 11.5. Różnica na korzyść sterowania z wykorzystaniem algorytmu w całym kwartale 2025 roku wynosiła 5,38 %. Wynikała ona z tego, że algorytm trafnie przewidział wysokie ceny energii elektrycznej (powyżej założonego współczynnika relacji do ceny paliwa gazowego) i wygenerował sygnał żądania pracy układu kogeneracyjnego.

11.6. Wizualizacja prognozy parametrów.

Modele sieci neuronowej, które zostały wybrane na podstawie opracowanej metody walidacyjnej, wdrożono do stosowania w aplikacji od 1. marca 2025 r. Algorytmy na bieżąco odczytują parametry pracy źródła, warunki meteorologiczne oraz uwarunkowania ekonomiczne. Na tej podstawie prognozują parametry, które przedstawione zostały na wykresach:

- rzeczywistej i prognozowanej generacji ciepła w źródle Rys. 11.10,
- rzeczywistego i prognozowanego zużycia paliwa gazowego w źródle Rys. 11.10,
- rzeczywistej i prognozowanej ceny paliwa gazowego na Towarowej Giełdzie Energii Rys. 11.11,
- rzeczywistej i prognozowanej ceny energii elektrycznej na Rynku Bilansującym Rys. 11.12.


W przypadku niektórych rysunków brakuje prognozowanych wartości na wykresach. Jest to konsekwencją błędów komunikacyjnych pomiędzy serwerem danych w elektrociepłowni lub awarią usługi dostarczającej informacje o parametrach pracy Krajowego Systemu Elektroenergetycznego.



Rys. 11.10. Porównanie prognozowanej i rzeczywistej produkcji ciepła oraz zużycia paliwa gazowego w źródle.



Rys. 11.11. Porównanie prognozowanej i rzeczywistej ceny paliwa gazowego na Towarowej Giełdzie Energii.



Rys. 11.12. Porównanie rzeczywistej i prognozowanej ceny energii elektrycznej na Rynku Bilansującym.

12. Podsumowanie, wnioski i uwagi końcowe.

12.1. Weryfikacja postawionej tezy.

W niniejszej rozprawie przedstawiono możliwości wykorzystania sztucznych sieci neuronowych w systemie ciepłowniczym, na który składa się źródło ciepła wykorzystujące gazowe silniki kogeneracyjne, kotły wodne oraz sieć ciepła wraz z przyłączonymi odbiorcami. Zaprezentowano podejście holistyczne dla całego systemu prognozując zapotrzebowania na moc cieplną począwszy od odbiorców końcowych, przez źródło ciepła, a kończąc na zapotrzebowaniu na paliwo gazowe. Dodatkowo podjęto próbę wyznaczania ceny energii elektrycznej oraz paliwa gazowego na Rynku Bilansującym oraz Towarowej Giełdzie Energii.

Poczynione działania miały na celu udowodnienie przyjętej tezy: *Istnieje możliwość wykorzystania sztucznych sieci neuronowych na cele prognozy: zapotrzebowania na ciepło, ceny energii elektrycznej oraz ceny paliwa gazowego, z akceptowalną dokładnością, dla istniejącego systemu ciepłowniczego zasilanego z kogeneracyjnej elektrociepłowni gazowej.*

Cały proces przebiegał z uwzględnieniem określonych wcześniej zadań badawczych:

- opracowania koncepcji rejestracji danych pomiarowych,
- stworzenia architektury sztucznej sieci neuronowej,
- wykorzystania zebranych danych pomiarowych na cele wytrenowania modelu predykcji,
- analizy dokładności modeli predykcyjnych.

W każdym z elementów systemu określone zostały również granice akceptowalności, które kwalifikowały wygenerowane architektury do ich zastosowania w konkretnym rozwiązaniu. Zaprezentowano możliwości uzyskania danych dotyczących funkcjonowania rynku energetycznego w Polsce i ich wykorzystanie w procesie trenowania sieci neuronowej. Równocześnie wygenerowane zostały różne struktury sieci neuronowej, które miały posłużyć rozwiązaniu danego problemu. Zakres zmiennych w ich tworzeniu uwzględniał kilka podstawowych parametrów tj.:

- liczbę warstw,
- liczbę sztucznych neuronów,
- typ funkcji aktywacji,
- częstotliwość aktualizacji wag,
- szybkość uczenia.

Każdy z 12 147 modeli został oceniony na podstawie przyjętej metody walidacyjnej i przyjętego kryterium kwalifikacji. Opracowana metoda uwzględniała zarówno regulacje prawne dotyczące funkcjonowania systemów ciepłowniczych i elektroenergetycznych, jak również wykorzystywała tzw. podejście naiwne. Polega ono na przyjęciu historycznej wartości rzeczywistej jako prognozowanej. Niezależnie od poruszanego zagadnienia możliwe było wykorzystanie co najmniej kilku architektur sieci neuronowej, które potrafiły prognozować dany parametr z akceptowalną dokładnością.

Efektem końcowym było wdrożenie autorskiego systemu do wspomagania procesu decyzyjnego w zakresie pracy układu kogeneracyjnego jak i automatycznego raportowania parametrów eksploatacyjnych systemu. Wybrane modele sieci neuronowej zostały zaimplementowane w aplikacji napisanej w języku Python i umożliwiały generowanie prognoz dla istniejącego systemu ciepłowniczego. Na tej podstawie zasymulowano pracę układu kogeneracyjnego z wykorzystaniem algorytmu, który w analizowanym okresie przyczyniłby się do wygenerowania większego przychodu z tytułu sprzedaży energii cieplnej oraz elektrycznej w porównaniu do rzeczywistości.

Na postawione w punkcie 1.2 pytania badawcze można odpowiedzieć następująco:

- tak, sieci neuronowe można wykorzystać do prognozowania parametrów parametrów funkcjonowania systemu ciepłowniczego, w tym:
 - zapotrzebowania na ciepło po stronie odbiorców,
 - wymaganej generacji na ciepło w źródle,
 - zapotrzebowania na paliwo gazowe do urządzeń wytwórczych,
 - prognozowania ceny energii elektrycznej oraz paliwa gazowego na rynku energii,
- struktura sieci neuronowej ma duży wpływ na dokładność prognozowania oraz czas wykonywania obliczeń. Przedstawiono, że przy rozwiązywaniu nieskomplikowanych problemów rozbudowana jej struktura nie przynosi poprawy dokładności predykcji. Zaproponowano stosowanie metody polegającej na wykorzystywaniu jak najmniej skomplikowanych modeli. Wpływa to zarówno na uniknięcie zjawiska przeuczenia sieci neuronowej jak również na przyspieszenie procesu trenowania,
- tak, możliwe jest sterowanie źródłem ciepła w oparciu o prognozowane dane wygenerowane przez sztuczne sieci neuronowe. Opracowana aplikacja generuje sygnały, na których można oprzeć zarówno rozkazy załączania poszczególnych urządzeń wytwórczych uwzględniając aktualne parametry techniczne i warunki ekonomiczne. Równocześnie umożliwia zadawanie odpowiedniej mocy kotłów i silników gazowych, wynikających z aktualnych potrzeb odbiorców. Do pełnej implementacji konieczna jest modyfikacja istniejącego systemu kontroli i nadzoru

pracy elektrociepłowni w celu zastosowania nowych procedur automatycznego sterowania źródłem.

Mając na uwadze powyższe udowodniono, że można wykorzystywać sieci neuronowe w systemie ciepłowniczym. Metoda ta posiada bardzo duże możliwości, które wraz z aktualizacją bibliotek programistycznych oraz ewolucji systemów komputerowych, będą zyskiwały szersze zainteresowanie oraz większą częstotliwość wdrożeń w automatyzacji procesów sterowania elektrociepłownią.

12.2. Dyskusja wyników pracy.

Opracowana metoda umożliwia kompleksowe prognozowanie parametrów związanych z funkcjonowaniem systemu ciepłowniczego zasilanego z elektrociepłowni opartej o kotły wodne oraz agregaty kogeneracyjne opalane gazem ziemnym. W Tabeli 12.1 przedstawiono osiągnięte dokładności wybranych modeli do prognozowania parametrów w opracowanych zastosowaniach. Zestawiono je ze zdefiniowanymi progami akceptowalnej dokładności. W każdym z nich udało się spełnić warunek minimalnej dokładności. Udowodniono również, że wykorzystanie sieci neuronowych może być bardziej precyzyjne i uwzględniać o wiele więcej czynników zewnętrznych w porównaniu do tzw. metody naiwnej. Osiągnięcie takich wyników było możliwe pomimo ograniczeń wynikających z:

- dokładności pomiarów budynków, które opierały się na pomiarach wykonanych przy użyciu map internetowych,
- braku danych o podpiwniczeniu budynku oraz informacji czy jest on w zabudowie szeregowej czy wielorodzinnej,
- braku informacji o konstrukcji przegród zewnętrznych jak również stosunku przeszkleń do powierzchni ścian,
- nieuwzględnionego wpływu typu budynku na zużycie energii.

Tabela 12.1. Zestawienie dokładności opracowanych metod do prognozowania parametrów w systemie ciepłowniczym.

L. p.	Zastosowanie	Minimalna akceptowalna dokładność [%]	Osiągnięta dokładność [%]
1	Prognozowanie zapotrzebowania na ciepło u odbiorcy końcowego na cele centralnego ogrzewania	90,00	92,02
2	Prognozowanie zapotrzebowania na ciepło u odbiorcy końcowego na cele ciepłej wody użytkowej	90,00	94,66

L. p.	Zastosowanie	Minimalna akceptowalna dokładność [%]	Osiągnięta dokładność [%]
3	Prognozowanie zapotrzebowania na ciepło w źródle	90,00	93,69
4	Prognozowanie zapotrzebowania na paliwo gazowe dla źródła	90,00	97,76
5	Rozszerzona prognozy pogody	60,66	69,16
6	Prognoza ceny energii elektrycznej na Rynku Bilansującym na najbliższe 12 godzin	73,74	77,08
7	Prognoza ceny paliwa gazowego na najbliższy dzień	95,22	98,46

W przypadku prognozy ceny paliwa gazowego udowodniono, że prognozowanie krótkoterminowe (kilkudniowe) może być satysfakcjonujące z punktu eksploatacji źródła ciepła. W długoterminowym horyzoncie (kilkadziesiąt dni) stwierdzono, że dokładność prognozy przekracza akceptowalny próg.

W Tabeli 12.2 zaprezentowano strukturę każdego modelu sztucznej sieci neuronowej, która została wybrana do wygenerowania prognoz w danym przypadku. Oprócz nazwy modelu, w ostatniej kolumnie opisana została każda jej warstwa wraz z podstawowymi parametrami konfiguracyjnymi.

Tabela 12.2. Zestawienie modeli sieci neuronowej, które zostały wybrane do prognozy w analizowanym zastosowaniu.

L. p.	Zastosowanie	Wybrany model	Struktura
1	Prognozowanie zapotrzebowania na ciepło u odbiorcy końcowego na cele centralnego ogrzewania	5 1 elu 128 0.1	<ul style="list-style-type: none"> 64 neuronów w pierwszej warstwie gęstej z funkcją aktywacji ELU, 32 neurony w drugiej warstwie gęstej z funkcją aktywacji ELU, 16 neuronów w trzeciej warstwie gęstej z funkcją aktywacji ELU, 8 neuronów w czwartej warstwie gęstej z funkcją aktywacji ELU, wielkość próbek (batch_size) ustawiona na 128, szybkość uczenia wynosiła 0,1.

L. p.	Zastosowanie	Wybrany model	Struktura
2	Prognozowanie zapotrzebowania na ciepło u odbiorcy końcowego na cele ciepłej wody użytkowej	5 2 leaky relu 64 0.1	<ul style="list-style-type: none"> • 128 neuronów w pierwszej warstwie gęstej z funkcją aktywacji Leaky ReLU, • 64 neuronów w pierwszej warstwie gęstej z funkcją aktywacji Leaky ReLU, • 32 neurony w drugiej warstwie gęstej z funkcją aktywacji Leaky ReLU, • 16 neuronów w trzeciej warstwie gęstej z funkcją aktywacji Leaky ReLU, • 8 neuronów w czwartej warstwie gęstej z funkcją aktywacji Leaky ReLU, • wielkość próbek (batch_size) ustawiona na 64, • szybkość uczenia wynosiła 0,1.
3	Prognozowanie zapotrzebowania na ciepło w źródle	2 1 elu 128 0.1	<ul style="list-style-type: none"> • posiada jedną warstwę gęstą z 64 neuronami z funkcją aktywacji ELU, • wielkość próbek (batch_size) ustawiona na 128, • szybkość uczenia wynosiła 0,1 • liczba wag sieci do przeliczenia wynosiła 257.
4	Prognozowanie zapotrzebowania na paliwo gazowe dla źródła	2 1 gelu 64 0.1	<ul style="list-style-type: none"> • jedna warstwa gęsta zawierająca 64 neurony z funkcją aktywacji GELU, • wielkość próbek ustawiona na 64, • szybkość uczenia wynosiła 0,1, • liczba wag sieci do przeliczenia wynosiła 321.
5	Rozszerzona prognozy pogody	7440_744_64_12	<ul style="list-style-type: none"> • do prognozy parametrów na najbliższe 744 godziny należy wprowadzić do modelu informację o poprzednich 7440 godzinach dla wszystkich danych meteorologicznych, • liczba neuronów w warstwie LSTM wynosząca 64, • wielkość próbek (batch_size) ustawiony na 12, • funkcja aktywacji ustawiona domyślnie na tangens hiperboliczny, • szybkość uczenia się ustawiona domyślnie na 0,001, • liczba wag sieci odpowiadająca liczbie połączeń równa 502 800.

L. p.	Zastosowanie	Wybrany model	Struktura
6	Prognoza ceny energii elektrycznej na Rynku Bilansującym na 12 godzin	48_12_24_24	<ul style="list-style-type: none"> 48 godzin danych historycznych na wejściu do modelu, liczba neuronów w jednej warstwie LSTM wynosząca 24, wielkość próbek analizowanych jednocześnie przy każdej epoce ustawiona na 24, funkcja aktywacji ustawiona domyślnie na tangens hiperboliczny, szybkość uczenia ustawiona domyślnie na 0,001, liczba wag odpowiadająca liczbie połączeń pomiędzy neuronami równa 189 360.
7	Prognoza ceny paliwa gazowego na najbliższy dzień	2_1_32_2	<ul style="list-style-type: none"> dane źródłowe oparte są na wariancie nr 1 tzn. oprócz danych historycznych ceny paliwa gazowego wprowadzone są do modelu również informacje o cenie energii elektrycznej wraz z parametrami technicznymi funkcjonowania Krajowego Systemu Elektroenergetycznego, 32 neurony w jednej warstwie LSTM, wielkość partii (batch_size) wynoszący 2, szybkość uczenia ustawiona domyślnie na 0,001, funkcja aktywacji ustawiona domyślnie na tangens hiperboliczny, liczba wag odpowiadająca liczbie połączeń pomiędzy neuronami równa 251 024.

W pracy poruszono również aspekt ekonomiczny stosowania tego typu rozwiązania. Jak wykazano, praca silników kogeneracyjnych w trybie automatycznym tj. uruchamianych bezpośrednio przez opracowany algorytm, może skutkować zwiększeniem przychodu dla przedsiębiorstwa. Wynika to z faktu generowania energii elektrycznej na Rynek Bilansujący w godzinach o relatywnie wyższej cenie od wartości średniej dla całego miesiąca. Dla przeanalizowanego pierwszego kwartału 2025 roku, średnia cena sprzedaży energii była większa o 5,38 % (w zakresie od 2,31 % dla lutego do 8,43 % dla marca) w porównaniu do sterowania ręcznego. Polegało ono na planowaniu pracy układu kogeneracyjnego jednorazowo na początku każdego dnia, w przeciwieństwie do rozwiązania automatycznego, które analizowało ceny na rynku w sposób ciągły co 15 minut.

Bardzo istotnie jest odpowiednie przygotowanie danych źródłowych, które są kluczowe z punktu osiągnięcia zamierzonego celu predykcyjnego. Nawet przy dobrze dobranej strukturze sieci neuronowej, błąd w danych wejściowych może mieć duży wpływ na cały proces. Mowa jest tutaj zarówno o niewiarygodności danych np. wskutek uszkodzenia czujnika jak również błędów po stronie komunikacyjnych z regulatorem. Istotny jest również sposób prezentowania danych dla mechanizmu trenującego sieć neuronową. Należy unikać sytuacji, w których sugeruje się algorytmowi istotność jednych parametrów w stosunku do innych, nawet jeśli taka zależność rzeczywiście istnieje. Przeanalizowane architektury sieci neuronowych wykazywały bardzo duże zdolności do rozwiązywania postawionych problemów. Stwierdzono jednak, że nie zawsze większa liczba parametrów była równoznaczna z osiągnięciem lepszej dokładności. Rozbudowana przesadnie sieć zbyt dokładnie dopasowywała się do danych treningowych i nie potrafiła, z akceptowalną dokładnością, prognozować wyników dla nieznanymi danych.

Informacja dotycząca prognozy energii cieplnej jaką należy wyprodukować w źródle może być też wykorzystana do sterowania urządzeniami wytwórczymi. W klasycznym układzie sterowania obiektem, automatyka działa w układzie nadążnym z regulatorem ze sprzężeniem zwrotnym. Regulator koryguje odchyłkę od zadanego parametru dopiero po jej wystąpieniu. Dysponując informacją o prognozowanym zapotrzebowaniu na moc cieplną można wykorzystać sterowanie predykcyjne (MPC – Model Predictive Control), które jest metodą sterowania systemami dynamicznymi w układach regulacji automatycznej. Wszak rozwój tych algorytmów był już opracowany na początku lat 70. XX wieku, to dopiero wdrożenie w przedsiębiorstwach cyfryzacji układów pomiarowych oraz coraz łatwiejszy dostęp do znacznych mocy obliczeniowych, umożliwia wdrożenie tego typu sterowania do układów ciepłowniczych.

Niniejsza praca uzupełnia analizę przeprowadzoną przez [5], w której autor do prognozy zapotrzebowania na ciepło dla 16 budynków na terenie kampusu Politechniki Warszawskiej wykorzystał dane z głównego ciepłomierza na potrzeby całego kompleksu. Jak wykazano, możliwe jest prognozowanie zapotrzebowania na ciepło na cele centralnego ogrzewania oraz ciepłej wody użytkowej dla każdego budynku indywidualnie, a następnie opracowanie modelu, który będzie prognozował całkowite zapotrzebowanie na ciepło. Takie podejście generuje większą ilość danych o systemie ciepłowniczym, które mogą być przedmiotem dalszych analiz.

Opracowane w niniejszej pracy modele służące do prognozy zapotrzebowania na ciepło dla budynków mogłyby być źródłem informacji w opracowaniu [11], w którym autor do predykcji ciepła wykorzystał symulator danych. W tym samym artykule poruszana jest kwestia wysokiego kosztu oprogramowania do walidacji modelu sieci neuronowej. Jak wykazano, możliwe jest wykorzystanie otwartego języka programowania do opracowania metody oceny jakości predykcji.

Wyniki pracy mogą uzupełnić wnioski publikacji [17], [18], w których autorzy budują modele sztucznej sieci neuronowej wyłącznie w oparciu o dane z budynków, które są wyposażone w moduły do zdalnej komunikacji. Jak udowodniono, można zbudować model o akceptowalnej dokładności na podstawie 40 % odbiorców przyłączonych do sieci i prognozować zapotrzebowanie dla pozostałej liczby budynków.

Prognozowanie ceny energii elektrycznej podjęli również w swoim artykule [24]. Zajmowali się oni predykcją na najbliższe 24 godziny. Ich analizę można uzupełnić uzyskanymi wynikami i możliwością prognozy ceny energii elektrycznej z godzinowym horyzontem. Dzięki temu możliwe jest wygenerowanie większego zysku ze sprzedaży energii elektrycznej na Rynek Bilansujący w stosunku do Rynku Dnia Następnego.

W artykule [28] autorzy wykorzystują sztuczne sieci neuronowe do prognozowania zapotrzebowania na energię elektryczną zużywaną na potrzeby klimatyzacji, wentylacji oraz ogrzewania budynków. Opracowany w publikacji model, wymaga zdefiniowania grubości przegród zewnętrznych oraz współczynników przenikania ciepła w celu uzyskania prognozy. Jak zostało udowodnione w niniejszej rozprawie, możliwe jest wykorzystanie rocznego zużycia energii dla danego budynku jako substytut parametru określającego konstrukcję przegrody budowlanej.

Podobne wnioski związane z możliwością zwiększenia efektywności energetycznej sieci ciepłowniczej przy wykorzystaniu sztucznych sieci neuronowych sformułowali autorzy publikacji [33]. Wyniki ich analizy, do której wykorzystali komercyjne oprogramowanie TRANSYS, mogą być uzupełnione o wnioski z niniejszej rozprawy, w której skorzystano z ogólnodostępnych bibliotek programistycznych do opracowania modeli predykcyjnych związanych z funkcjonowaniem systemów ciepłowniczych.

12.3. Wnioski.

Systemy sterowania źródłami wytwórczymi oparte na sztucznych sieciach neuronowych będą coraz częściej implementowane w istniejących oraz nowych obiektach dostarczających ciepło do sieci ciepłowniczych. Z tego powodu przy projektowaniu tego typu rozwiązań warto wziąć pod uwagę następujące wnioski z niniejszej pracy:

- przy prognozowaniu parametrów związanych z funkcjonowaniem systemu ciepłowniczego zasilanego z gazowej elektrociepłowni, przy zachowaniu akceptowalnej dokładności, wystarczy wykorzystanie sieci neuronowej z maksymalną liczbą warstw równą 5 i rozkładem liczby neuronów w każdej z nich w liczbie od 8 do maksymalnie 128,
- do wytrenowania modelu prognozującego godzinowe zapotrzebowanie na moc cieplną budynku przyłączonego do sieci ciepłej, na cele centralnego ogrzewania oraz ciepłej wody użytkowej, wystarczy wprowadzić dane z ostatniego roku aby uzyskać prognozę z akceptowalną dokładnością,

- akceptowalna dokładność modeli prognozujących zapotrzebowanie na ciepło oraz paliwo gazowe, zgodnie z opracowaną metodą, musi wynosić co najmniej 90 % w celu uniknięcia konsekwencji finansowych prowadzenia działalności ciepłowniczej,
- model generujący dane o zapotrzebowaniu na moc cieplną na cele centralnego ogrzewania oraz ciepłą wodę użytkową dla budynku, powinien być wytrenowany na danych źródłowych z co najmniej 40 % wszystkich obiektów przyłączonych do sieci ciepłej w celu osiągnięcia akceptowalnej dokładności,
- modele prognozujące cenę energii elektrycznej oraz paliwa gazowego, wytrenowane na parametrach wejściowych uwzględniających wyłącznie dane techniczne i handlowe, nie są w stanie uzyskać akceptowalnej dokładności w horyzoncie prognozy dłuższym niż:
 - 12 godzin dla energii elektrycznej,
 - 1 dzień dla paliwa gazowego.

12.4. Propozycje dalszych prac.

W niniejszej pracy założono pewne parametry wejściowe do struktury sieci neuronowej, które były uwzględniane przy trenowaniu sieci. Możliwe, że część z nich nie stanowiła dużego wkładu do zwiększenia dokładności prognozy, a jedynie „cyfrowy balast”. Z tego powodu warto byłoby dokładnie przeanalizować wpływ poszczególnych parametrów na dokładność predykcji i w przypadku ich niewielkiego udziału, zdecydować się na ich pominięcie. Skutkiem może być obniżenie wymagań co do mocy obliczeniowej komputera przy niezmiennej jakości prognozy.

Wymaga podkreślenia, że do budowy konkretnych architektur sieci neuronowych wykorzystano wyłącznie kilka typów warstw, pomimo ich bardzo dużego wyboru. Możliwe byłoby zatem sprawdzenie jaki wpływ na dokładność prognozy miałyby wprowadzenie jeszcze większego zróżnicowania w tym zakresie.

Należy również założyć, że wybrane parametry do trenowania sieci mogłyby być rozbudowane o dodatkowe sygnały, które wpłynęłyby pozytywnie na dokładność predykcji. Przykładem może być prognoza ceny paliwa gazowego, która w dłuższym horyzoncie nie spełnia wymaganego progu akceptowalności. Możliwe, że wprowadzenie do warstwy wejściowej dodatkowych parametrów opisujących sytuację geopolityczną na świecie lub nastrojów inwestorskich na światowych giełdach, przełożyłoby się na wzrost dokładności. Założenie to wynika z przeprowadzonego eksperymentu w opisywanym zastosowaniu. Jak zostało udowodnione, nawet wprowadzenie danych o parametrach meteorologicznych do modelu prognozującego cenę paliwa gazowego, może mieć pozytywny wpływ na dokładność.

W trakcie niniejszej pracy Polskie Sieci Elektroenergetyczne, które odpowiedzialne są za funkcjonowanie Krajowego Systemu Elektroenergetycznego, opracowały nowy interfejs do

przekazywania danych technicznych. Wersja aplikacji, dostępna na koniec kwietnia 2025 r., umożliwi pobranie większej liczby parametrów w stosunku do poprzedniej. W związku z powyższym możliwe byłoby zweryfikowanie jaki wpływ na dokładność predykcji ceny energii elektrycznej będzie miało wprowadzenie nowych informacji o funkcjonowaniu KSE.

Nieodzownym elementem funkcjonowania systemów ciepłowniczych są regulacje prawne opisane w Prawie Energetycznych oraz wydanych na jego podstawie rozporządzeniach. Definiują one maksymalne dopuszczalne odchyłki od tabeli regulacyjnej określającej temperatury zasilania sieci ciepłej. W przypadku opisywanego systemu ciepłowniczego, reżim utrzymywania zadanej temperatury zasilania przy pracy w priorytecie produkcji energii elektrycznej, może być trudny do utrzymania. Nadmiar chwilowej generowanej energii ciepłej wskutek atrakcyjnych warunków ekonomicznych na Rynku Bilansującym, wymusza szybką regulację pozostałych źródeł wytwórczych, w celu utrzymania zadanej temperatury zasilania. Rozsądne w takich sytuacjach wydaje się dopuszczenie przez ustawodawcę większych wahań temperatury sieci ciepłej przy gwarancji utrzymania stabilnej pracy układu oraz zapewnieniu komfortu cieplnego odbiorców.

Opisane w niniejszej rozprawie mechanizmy, wydają się być kluczowe z pozycji sterowania elektrociepłownią w dzisiejszym porządku prawno-ekonomicznym. Jednak inne możliwości ich implementacji pozostają w sferze wyobraźni osoby odpowiedzialnej za funkcjonowanie takiego obiektu. Przy wykorzystaniu odpowiednich środków technicznych oraz programistycznych, możliwe jest wykorzystanie sztucznych sieci neuronowych do analizy wystąpienia usterki urządzeń wytwórczych czy wpływu akumulacji ciepła w sieci ciepłej na zapotrzebowanie mocy w całym układzie.

Niezależnie od zastosowania należy pamiętać, że w przeciwieństwie do klasycznej teorii sterowania, regulator predykcyjny będzie wykorzystywał dane historyczne jako źródło swojej wiedzy o danym procesie. Z tego powodu rozwój sztucznych sieci neuronowych wykorzystywanych do sterowania w systemie ciepłowniczym musi iść w parze z rozwojem technik służących do rzetelnej weryfikacji danych źródłowych.

13. Bibliografia.

- [1] Źródło internetowe, *Volume of data information created, captured, copied, and consumed worldwide from 2010 to 2023 with forecasts from 2024 to 2028*, Opublikowane w 10.12.2024, <https://www.statista.com/statistics/871513/worldwide-data-created/>,
- [2] Ministerstwo Klimatu i Środowiska, *Polityka Energetyczna Państwa do 2040 r.*, Dziennik Urzędowy Rzeczypospolitej Polskiej, 2021,
- [3] Michał Wierzbowski, Błażej Olek, Wojciech Łyżwa, *Optymalizacja krajowego miks energetycznego w kontekście polityki energetycznej*, Rynek Energii nr 5/2014, 2014,
- [4] Denis Sidorov, Fang Liu and Yonghui Sun, *Machine Learning for Energy Systems*, Energies, 2020,
- [5] Krzysztof Wojdyga, *Predicting Heat Demand for a District Heating Systems*, International Journal of Energy and Power Engineering 237-244, 2014,
- [6] V. D. Stevanovic, B. Zivkovic, S. Prica, B. Maslovaric, V. Karamarkovic, V. Trkulja, *Prediction of thermal transients in district heating systems*, Energy Conversion and Management 50 2167-2173, 2009,
- [7] D. Stevanovic, S. Prica, B. Maslovaric, B. Zivkovic, S. Nikodijevic, *Efficient numerical method for district heating system hydraulics*, Energy Conversion and Management 48 1536–1543, 2007,
- [8] Kljajić M, et al., *Use of Neural Networks for modeling and predicting boiler's operating performance*, 2012,
- [9] H. Rusinowski, W. Stanek, *Neural modelling of steam boilers*, Silesian University of Technology, Institute of Thermal Technology, 2007,
- [10] M.M. Prieto, E. Montanes, O. Menendez, *Power plant condenser performance forecasting using a nonfully connected artificial neural network*, Energy 65-79, 2001,
- [11] Soteris A. Kalogirou. Milorad Bojic, *Artificial neural networks for the prediction of the energy consumption of a passive solar building*, Energy 479-491, 2000,
- [12] T. Cholewa, *Sterowanie prognozowe dostawą ciepła na potrzeby ogrzewania*, Monografie Komitetu Inżynierii Środowiska, 2019,
- [13] Apisit Panyafonga, Nattawut Neamsornb, Chatchawan Chaichanab, *Heat load estimation using Artificial Neural Network*, Energy Reports, 2020,
- [14] Giulio Vialetto, Marco Noro, *An innovative approach to design cogeneration systems based on big data analysis and use of clustering methods*, Energy Conversion and Management, 2020,

- [15] W. J. Chmielnicki, *Application of neural networks for control of district heating*, 2010, doi.org: 10.2478/v.10169-010-0012-y
- [16] Mel Keytingan M. Shapi, Nor Azuana Ramli, Lilik J. Awalín, *Energy consumption prediction by using machine learning for smart building: Case study in Malaysia*, Energy consumption prediction by using machine learning for smart building: Case study in Malaysia , 2021,
- [17] Samuel Idowu, Saguna Saguna, Christer Ahlund, Olov Schelén, *Applied machine learning: Forecasting heat load in district heating system*, Energy and Buildings 478-488, 2016,
- [18] C. Johansson, M. Bergkvist, D. Geysen, O. Somer, N. Lavesson, D. Vanhoudt, *Operational demand forecasting in district heating systems using ensembles of online machine learning algorithms*, Energy Procedia 208-216, 2017,
- [19] Jui-Sheng Chou, Duc-Son Tran, *Forecasting Energy Consumption Time Series using Machine Learning Techniques based on Usage Patterns of Residential Householders*, 2018, doi.org: 10.1016/j.energy.2018.09.144,
- [20] Primoz Potocnik, Primoz Škerl, Edvard Govekar, *Machine-learning-based multi-step heat demand forecasting in a district heating system*, Energy & Buildings, 2021,
- [21] L. Laakkonen, T. Korpela, J. Kaivosoja, M. Vilkkó, Y. Majanne, M. Nuroranta, *Predictive supply temperature optimization of district heating networks using delay distributions*, Energy Procedia 297-309, 2017,
- [22] K. Łukaszewski, *Prognozowanie zapotrzebowania energii cieplnej sieci ciepłowniczej względem określonych warunków eksploatacyjnych tej sieci - model matematyczny*, Zeszyty Naukowe Akademii Morskiej W Gdyni 81, 2013,
- [23] Soteris A. Kalogirou, *Building heating load estimation using artificial neural networks*, 1997, https://www.researchgate.net/publication/228903198_Building_heating_load_estimation_using_artificial_neural_networks,
- [24] Piotr Żymelka, Marcin Szega, *Short-term scheduling of gas-fired CHP plant with thermal storage using optimization algorithm and forecasting models*, Energy Conversion and Management, 2021,
- [25] Jason Runge, Radu Zmeureanu, *A review of deep learning techniques for forecasting energy use in buildings*, 2021, <https://doi.org/10.3390/en14030608>,
- [26] Karol Bandurski, Rozprawa doktorska, *Wpływ użytkowników na bilans energetyczny budynków mieszkalnych – badania i modelowanie*, 2021,
- [27] E. Saloux, J. Candanedo, *Forecasting district heating demand using machine learning algorithms*, Energy Procedia 59-68, 2018,

- [28] S. Agostinelli, F. Cumo, G. Guidi, C. Tomazzoli, *Cyber-physical systems improving building energy management: digital twin and artificial intelligence*, Energies, 2021,
- [29] Anam-Nawaz Khan, Naeem Iqbal, Atif Rizwan, Rashid Ahmad, Do-Hyeun Kim, *An ensemble energy consumption forecasting model based on spatial-temporal clustering analysis in residential buildings*, Energies, 2021,
- [30] Sepp Hochreiter, Jürgen Schmidhuber, *Long Short-Term Memory*, Neural Computation, 1997,
- [31] Hossein Moayedi, Amir Mosavi, *Suggesting a stochastic fractal search paradigm in combination with artificial neural network for early prediction of cooling load in residential buildings*, Energies, 2021,
- [32] Tomasz Rymarczyk, Grzegorz Kłosowski, Anna Hoła, Jan Sikora, Tomasz Wołowiec, Paweł Tchórzewski, Stanisław Skowron, *Comparison of machine learning methods in electrical tomography for detecting moisture in building walls*, Energies, 2021,
- [33] Kevin Naik, Anton Ianakiev, *Heat demand prediction: A real-life data model vs simulated data model comparison*, Energy Reports 380–388, 2021,
- [34] Rahman Azis Prasajo, Harry Gumilang, Suwarno, Nur Ulfa Maulidevi and Bambang Anggoro Soedjarno, *A Fuzzy Logic Model for Power Transformer Faults' Severity Determination Based on Gas Level, Gas Rate, and Dissolved Gas Analysis Interpretation*, Energies, 2020,
- [35] Cheng-I Chen, Chien-Kai Lan, Yeong-Chin Chen, Chung-Hsien Chen and Yung-Ruei Chang, *Wavelet Energy Fuzzy Neural Network-Based Fault Protection System for Microgrid*, Energies, 2020,
- [36] Abdullah M. Alabdullatif, Enrico H. Gerding and Alvaro Perez-Diaz, *Market Design and Trading Strategies for Community Energy Markets with Storage and Renewable Supply*, Energies, 2020,
- [37] Khikmafari Yudiantaka, Jung-Su Kim and Hwachang Song, *Dual Deep Learning Networks Based Load Forecasting with Partial Real-Time Information and Its Application to System Marginal Price Prediction*, Energies, 2020,
- [38] Oludare Isaac Abiodun, Aman Jantan, Abiodun Esther Omolara, Kemi Victoria Dada, Nahaat AbdElatif Mohamed, Humaira Arshad, *State-of-the-art in artificial neural network applications: A survey*, Helion S.A., 2018,
- [39] Giuseppe Bonaccorso, *Algorytmy uczenia maszynowego. Zaawansowane techniki implementacji*, Helion S.A., 2019,
- [40] Chris Albon, *Uczenie maszynowe w Pythonie. Receptury*, Helion S.A., 2021,

- [41] Valentino Zocca, Gianmario Spacagna, Daniel Slater, Peter Roelants, *Deep Learning. Uczenie głębokie z językiem Python. Sztuczna inteligencja i sieci neuronowe*, Helion S.A., 2017,
- [42] Shapson-Coe A, Januszewski M, Berger DR, Pope A, Wu Y, Blakely T, Schalek RL, Li PH, Wang S, Maitin-Shepard J, Karlupia N, Dorckenwald S, Sjostedt E, Leavitt L, Lee D, Troidl J, Collman F, Bailey L, Fitzmaurice A, Kar R, Field B, Wu H, Wagner-Carena J, Aley D, Lau J, Lin Z, Wei D, Pfister H, Peleg A, Jain V, Lichtman JW., *A petavoxel fragment of human cerebral cortex reconstructed at nanoscale resolution*, Science, 2024,
- [43] Josh Patterson, Adam Gibson, *Deep Learning. Praktyczne wprowadzenie*, Helion S.A., 2018,
- [44] Konrad Hryniewicz, *Schemat budowy pojedynczego sztucznego neuronu wykorzystywanego do budowy sieci neuronowej*, 2016, <https://nauka.metodolog.pl/sieci-neuronowe-zaawansowana-analiza-statystyczna/>,
- [45] Pascal Wallisch, Michael E. Lusignan, Marc D. Benayoun, Tanya I. Baker, Adam S. Dickey, Nicholas G. Hatsopoulos, *An Introduction to Scientific Computing in MATLAB*, Elsevier, 2014,
- [46] Ienye, I.D.; Swart, T.G.; Obaido, G., *Recurrent Neural Networks: A Comprehensive Review of Architectures, Variants, and Applications*, Information, 2024,
- [47] Robin M. Schmidt, *Recurrent Neural Networks (RNNs): A gentle Introduction and Overview*, Department of Computer Science Eberhard-Karls-University Tübingen Tübingen, Germany, 2019,
- [48] Pratima Kumari, Durga Toshniwal, *Deep learning models for solar irradiance forecasting: A comprehensive review*, Journal of Cleaner Production, 2021,
- [49] Konrad Hryniewicz, *Schemat połączeń neuronów pomiędzy warstwami sieci neuronowej*, 2016, <https://nauka.metodolog.pl/sieci-neuronowe-zaawansowana-analiza-statystyczna/>,
- [50] J. N. Singh, A. Dobriyal, H. Tanwar, A. K. Singh and Z. Alsalamy, *Analysis of Image Classification using CNN and ANN*, 1st International Conference on Advances in Computing, Communication and Networking (ICAC2N), 2024,
- [51] S Agatonovic-Kustrin, R Beresford, *Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research*, Journal of Pharmaceutical and Biomedical Analysis, 2000,
- [52] Juan-Roberto Jiménez-Pérez, José Negrillo-Cárdenas, Francisco R. Feito, *Techniques for automatic landmark detection of human tissue*, Digital Human Modeling and Medicine, 2023,
- [53] M. Senthilkumar, *Use of artificial neural networks (ANNs) in colour measurement*, In Woodhead Publishing Series in Textiles, 2010,

- [54] Bharath Ramsundar, Reza Bosagh Zadeh, *Głębokie uczenie z TensorFlow. Od regresji liniowej po uczenie przez wzmacnianie*, Helion S.A., 2019,
- [55] Strona internetowa, *Zestawienie popularnych funkcji aktywacji wraz z ich graficznym odwzorowaniem*, Opublikowane w 01.08.2024, <https://www.analyticssteps.com/blogs/hand-gesture-classification-using-deep-learning-keras>,
- [56] K. Hara, D. Saito and H. Shouno, *Analysis of function of rectified linear unit used in deep learning*, International Joint Conference on Neural Networks (IJCNN), Killarney, Ireland, 2015,
- [57] Mark Fenner, *Uczenie maszynowe w Pythonie dla każdego*, Helion S.A. , 2018,
- [58] Krzysztof Krawiec, Jerzy Stefanowski, *Uczenie maszynowe i sieci neuronowe*, Wydawnictwo Politechniki Poznańskiej , 2004,
- [59] Geißler, Daniel & Zhou, Bo & Liu, Mengxi & Suh, Sungho & Lukowicz, Paul, *The Power of Training: How Different Neural Network Setups Influence the Energy Demand*, Conference: AAAI-24 Workshop: Sustainable AI, 2024,
- [60] Piotr Wróblewski, *Algorytmy w Pythonie – techniki programowania dla praktyków*, Helion S.A., 2022,
- [61] Robald T. Kneusel, *Deep learning – praktyczne wprowadzenie z zastosowaniem środowiska Pythona*, Helion S.A., 2021,
- [62] Teresa Kurek, *System generujący prognozy zapotrzebowania na ciepło dla Warszawskiej Sieci Ciepłownicze*, Rozprawa Doktorska , 2022,
- [63] D. Czajor, Ł. Amanowicz, *Methodology for Modernizing Local Gas-Fired District Heating Systems into a Central District Heating System Using Gas-Fired Cogeneration Engines —A Case Study*, Sustainability, 2024,
- [64] ZEC Białogard, *Dane dotyczące systemu ciepłowniczego opublikowanego przez dostawcę ciepła*, https://www.zec-bialogard.pl/wp-content/uploads/2025/03/Informacje_siec_cieplna_ZEC_2025.pdf,
- [65] KOBIZE, *Dane o emisji dwutlenku węgla w Polsce w 2023 r. przy produkcji energii elektrycznej*, 2023, https://www.kobize.pl/uploads/materialy/materialy_do_pobrania/wskazniki_emisyjnosci/Wska%C5%BAniki_emisyjno%C5%9Bci_dla_energii_elektrycznej_grudzie%C5%84_2024.pdf,
- [66] Instytut Energetyki Odnawialnej, *Rynek fotowoltaiki w Polsce 2024*, 2024, <https://ieo.pl/raport-rynek-fotowoltaiki-w-polsce-2024>,

- [67] Oleksandr Prokhorov, Dina Dreisbach, *The impact of renewables on the incidents of negative prices in the energy spot markets*, Energy Policy, 2022,
- [68] Ł. Amanowicz, D. Czajor, *Benefity i ograniczenia instalacji układu kogeneracyjnego w istniejącej ciepłowni gazowej*, Instal, 2023,
- [69] T. Surma, A. Komorowska, P. Kaszyński, *Systemy taryfowania ciepła w wybranych państwach – rekomendacje dla Polski*, Rynek Energii, 2024,
- [70] Jacek Kalina, Janusz Skorek, *Gazowe układy kogeneracyjne*, Wydawnictwa Naukowo-Techniczne, 2004,
- [71] Kazimierz Buczek, *Kogeneracja ciepła i energii elektrycznej w małych elektrociepłowniach*, Wydawnictwo KaBe Krosno, 2018,
- [72] Urząd Regulacji Energetyki, *Raport za 2024 r.*, 2024, <https://www.ure.gov.pl/download/9/15149/BiuletynURE1-2024.pdf>,
- [73] Strona internetowa, *Dokumentacja języka programowania Python*, Opublikowane w 01.06.2025 r., <https://www.python.org/>,
- [74] Strona internetowa, *Wikipedia języka Python*, Opublikowane w 01.06.2025 r., <https://pl.wikipedia.org/wiki/Python>,
- [75] Strona internetowa, *Dokumentacja programu Jupyter*, Opublikowane w 12.06.2025 r., <https://jupyter.org/>,
- [76] Strona internetowa, *Dokumentacja programu PyCharm*, Opublikowane w 12.06.2025 r., <https://www.jetbrains.com/pycharm/>,
- [77] Strona internetowa, *Dokumentacja biblioteki Requests*, Dostęp na dzień 14.06.2025 r., <https://requests.readthedocs.io/en/latest/>
- [78] Strona internetowa, *Dokumentacja biblioteki Beautifulsoup*, Dostęp na dzień 14.06.2025 r., <https://beautiful-soup-4.readthedocs.io/en/latest/>
- [79] Strona internetowa, *Dokumentacja biblioteki Pandas*, Opublikowane w 01.06.2025 r., <https://pandas.pydata.org/>,
- [80] Strona internetowa, *Wikipedia biblioteki SQLite*, Opublikowane w 10.06.2025 r., <https://pl.wikipedia.org/wiki/SQLite>,
- [81] Strona internetowa, *Dokumentacja biblioteki SQLite*, Opublikowane w 10.06.2025 r., <https://www.sqlite.org/about.html>,
- [82] Strona internetowa, *Wikipedia biblioteki Nupy*, Opublikowane w 10.06.2025 r., <https://pl.wikipedia.org/wiki/NumPy>,

- [83] Strona internetowa, *Dokumentacja biblioteki Numpy*, Opublikowane w 10.06.2025 r., <https://numpy.org/about/>,
- [84] Strona internetowa, *Dokumentacja biblioteki TensorFlow*, Opublikowane w 10.06.2025 r., <https://www.tensorflow.org/>,
- [85] Strona internetowa, *Wikipedia biblioteki TensorFlow*, Opublikowane w 12.06.2025 r., <https://pl.wikipedia.org/wiki/TensorFlow>,
- [86] Strona internetowa, *Dokumentacja języka programowania PHP*, Opublikowane w 12.06.2025 r., <https://www.php.net/>,
- [87] Strona internetowa, *Wikipedia języka programowania PHP*, Opublikowane w 12.06.2025 r., <https://pl.wikipedia.org/wiki/PHP>,
- [88] Strona internetowa, *Wikipedia języka HTML*, Opublikowane w 12.06.2025 r., <https://pl.wikipedia.org/wiki/HTML>,
- [89] Prezes Urzędu Regulacji Energetyki, *Zatwierdzenie zmian warunków dotyczących bilansowania Polskich Sieci Elektroenergetycznych S.A. Decyzja Prezesa Urzędu Regulacji Energetyki nr DRR.WRE.744.3.2025.AOr z dnia 28 maja 2025 r.*, 2025, <https://bip.ure.gov.pl/download/3/19659/WDBPSE.pdf>,
- [90] Eric Todd, Millicent L. Li, Arnab Sen Sharma, Aaron Mueller, Byron C. Wallace, David Bau, *Function Vectors in Large Language Models*, Khoury College of Computer Sciences, Northeastern University, 2023,
- [91] P. Tąkiel, *Porównanie metod wstępnego przetwarzania i klasyfikacji danych biomedycznych*, Praca dyplomowa, 2014/2015,
- [92] J. A. Samuel, *One-Hot Encoding and Two-Hot Encoding: An Introduction*, 2024, <http://dx.doi.org/10.13140/RG.2.2.21459.76327>,
- [93] R. Tadeusiewicz, M. Szaleniec, *Leksykon sieci neuronowych*, Wydawnictwo Fundacji „Projekt Nauka”, 2015,
- [94] Krzysztof Krawiec, Jerzy Stefanowski, *Uczenie maszynowe i sieci neuronowe*, Wydawnictwo Politechniki Poznańskiej, 2003,
- [95] Sebastian Raschka, Vahid Mirjalili, *Python. Machine learning i deep learning. Biblioteki scikit-learn i TensorFlow 2*, 2021,
- [96] Geron Aurelien, *Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow : pojęcia, techniki i narzędzia służące do tworzenia inteligentnych systemów*, 2020,
- [97] Krzysztof Wojdyga, *Predicting Heat Demand for a District Heating Systems*, International Journal of Energy and Power Engineering 237-244, Opublikowane w 01.06.2025 r.,

- [98] Shiv Ram Dubey, Satish Kumar Singh, Bidyut Baran Chaudhuri, *Activation functions in deep learning: A comprehensive survey and benchmark*, Neurocomputing, 2022,
- [99] Zhu, Q., Zhuang, H., Zhao, M. et al., *A study on expression recognition based on improved mobilenetV2 network*, Sci Rep, 2024,
- [100] D. Hendrycks, K. Gimpel, *Gaussian Error Linear Units (Gelus)*, 2018, <https://arxiv.org/pdf/1606.08415v3>,
- [101] D. Clevert, T. Unterthiner, S. Hochreiter, *Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs)*, 2018, <https://doi.org/10.48550/arXiv.1511.07289>,
- [102] Ibrahim Kandel, Mauro Castelli, *The effect of batch size on the generalizability of the convolutional neural networks on a histopathology dataset*, ICT Express, 2020,
- [103] Changyong Yu, Xin Qi, Haitao Ma, Xin He, Cuirong Wang, Yuhai Zhao, *LLR: Learning learning rates by LSTM for training neural networks*, Neurocomputing, 2020,
- [104] Tamás Miseta, Attila Fodor, Ágnes Vathy-Fogarassy, *Surpassing early stopping: A novel correlation-based stopping criterion for neural networks*, Neurocomputing, 2024,
- [105] Ian H. Witten, Mark A. Hall, Eibe Frank, Christopher J. Pal, *Data Mining - Practical Machine Learning Tools and Techniques*, Elsevier, 2017,
- [106] Pramod Singh, Avinash Manure, *Learn TensorFlow 2.0: Implement Machine Learning and Deep Learning Models with Python*, Apress, 2020,
- [107] Kingma et al., *Adam: A Method for Stochastic Optimization*, 2014, <https://doi.org/10.48550/arXiv.1412.6980>,
- [108] Yunlong Feng, Qiang Wu, *A statistical learning assessment of Huber regression*, Journal of Approximation Theory, 2022,
- [109] Mariusz Przybycie, *Wykład p. t. „Metody Lagrange’a i Hamiltona w Mechanice”*, Dostęp na dzień 10.06.2025 r., https://home.agh.edu.pl/~mariuszp/wfiis_mk/wyklad_mk_5.pdf,
- [110] Mateusz Goślinowski, *Wykład pt. "Zasada najmniejszego działania"*, Dostęp na dzień 13.06.2025 r., <https://students.mimuw.edu.pl/~mg385641/docs/wyk1.pdf>,
- [111] Minister Klimatu, *Rozporządzenie Ministra Klimatu z dnia 7 kwietnia 2020 r. w sprawie szczegółowych zasad kształtowania i kalkulacji taryf oraz rozliczeń z tytułu zaopatrzenia w ciepło. Dziennik Ustaw 2020 r. poz. 718, 2020*, <https://dziennikustaw.gov.pl/DU/2020/718/D2020000071801.pdf>,
- [112] Shahrabadi, S.; Adão, T.; Peres, E.; Morais, R.; Magalhães, L.G.; Alves, V., *Automatic Optimization of Deep Learning Training through Feature-Aware-Based Dataset Splitting*, Algorithms, 2024,

- [113] Anna Dziurny, Magdalena Kawalec, *Wykorzystanie metod prognostycznych w logistyce*, Zeszyty Naukowe ASzWoj, 2017,
- [114] L. Kowalski, *Modelowanie i prognozowanie*, Materiały dydaktyczne Warszawa, 2010,
- [115] Biały W., Zasadzień M., *Prognozowanie popytu niezależnego jako element wspomagający planowanie potrzeb materiałowych w zakładach produkcyjnych*, Systemy Wspomagania W Inżynierii Produkcji Wspomaganie Zarządzania Systemami Produkcyjnymi, 2013,
- [116] A. Kucharski, *Prognozowanie szeregów czasowych metodami ewolucyjnymi*, Wydawnictwo Uniwersytetu Łódzkiego, 2013,
- [117] Thomas Nigitz, Markus Göllles, *A generally applicable, simple and adaptive forecasting method for the short-term heat load of consumers*, Applied Energy, 2019,
- [118] J. Perzyńska, *Zastosowanie sztucznych sieci neuronowych do prognozowania szeregów czasowych*, Zeszyty Naukowe ZPSB Firma I Rynek, 2018,
- [119] Riad Benelmir, Michel Feidt, *Energy cogeneration systems and energy management strategy*, Energy Conversion and Management, 1998,
- [120] Sejm Rzeczypospolitej Polskiej, *Prawo Energetyczne*, Dziennik Ustaw Rzeczypospolitej Polskiej, 1997,
- [121] Stefan Leiprecht, Fabian Behrens, Till Faber, Matthias Finkenrath, *A comprehensive thermal load forecasting analysis based on machine learning algorithms*, Energy Reports, 2021,
- [122] Faber, Till, and Matthias Finkenrath., *Load forecasting in district heating systems using stacked ensembles of machine learning algorithms*, 14th International Renewable Energy Storage Conference, 2020,
- [123] Gaz-System S.A., *Instrukcjach Ruchu i Eksploatacji Sieci Przesyłowej*, 2024, <https://www.gaz-system.pl/dam/jcr:4c0cf703-1314-4ef3-998a-a5e754fadc27/iriesp-ksp-29-pl.PDF>,
- [124] PSG Sp. z o.o., *Instrukcjach Ruchu i Eksploatacji Sieci Dystrybucyjnej*, 2024, <https://www.psgaz.pl/pobierz/56572a43-7564-4584-9871-8d82a2ad4520/page>,
- [125] Oluwatamilore Orojo, Jonathan Tepper, T.M. McGinnity, Mufti Mahmud, *The Multi-Recurrent Neural Network for State-Of-The-Art Time-Series Processing*, Procedia Computer Science, 2023,
- [126] Alley, R. B., Emanuel, K. A., & Zhang, F. , *Advances in weather prediction*, Science, 2019,
- [127] Bi, K., Xie, L., Zhang, H. et al, *Accurate medium-range global weather forecasting with 3D neural networks*, Nature, 2023,

[128] Prezes Urzędu Regulacji Energetyki, *Informacja Prezesa URE nr 16/2025 w sprawie średnich cen sprzedaży ciepła wytworzonego w jednostkach wytwórczych niebędących jednostkami kogeneracji w roku 2024, 2024*, <https://www.ure.gov.pl/pl/urzed/informacje-ogolne/komunikaty-prezesa-ure/12574,Informacja-nr-162025.html>.