



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**

AUTOFERERAT ROZPRAWY DOKTORSKIEJ

Promotor:

dr hab. inż. Łukasz Amanowicz, prof. PP

Promotor pomocniczy:

dr inż. Karol Bandurski

Poznań, lipiec 2025 r.

Spis treści

1. Wprowadzenie.....	3
1.1. Problematyka wykorzystania sztucznych sieci neuronowych w istniejącym systemie ciepłowniczym.....	3
1.2. Teza i cel pracy.....	4
1.3. Zakres pracy.....	5
2. Opis wdrożenia algorytmów uczenia maszynowego z wykorzystaniem sieci neuronowych w istniejącym systemie ciepłowniczym.....	11
2.1. Opis systemu ciepłowniczego.....	11
2.2. Wymagania sprzętowe.....	12
2.3. Dane źródłowe.....	12
2.4. Aplikacja.....	13
3. Podsumowanie, wnioski i uwagi końcowe.....	13
3.1. Weryfikacja postawionej tezy.....	13
3.2. Dyskusja wyników pracy.....	15
3.3. Wnioski.....	20
3.4. Propozycje dalszych prac.....	21
4. Dotychczas opublikowane prace.....	23
5. Inne osiągnięcia autora.....	23

1. Wprowadzenie.

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

Zgodnie z aktualną strategią energetyczną, 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. Zarządzając 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 wspomagania 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, 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 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. Równocześnie zauważono, że wielu badaczy publikuje wyniki predykcji modeli w analizowanych zastosowaniach ale bardzo rzadko opisują jaka konkretna struktura została wykorzystana. Analiza literatury wskazuje, że w chwili obecnej nie ma jednej najlepszej metodologii do zaplanowania architektury sieci neuronowej. W swoim skrypcie, Krawiec K. Stefanowski J. „Uczenie maszynowe i sieci neuronowe” 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”. Zatem dobór odpowiednich parametrów konfiguracyjnych architektury sieci neuronowej może być kluczowy w celu uzyskania jej akceptowalnej dokładności.


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 ciepłowej,
- 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.

Opracowany mechanizm (przedstawiony na Rys. 1.1) 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.



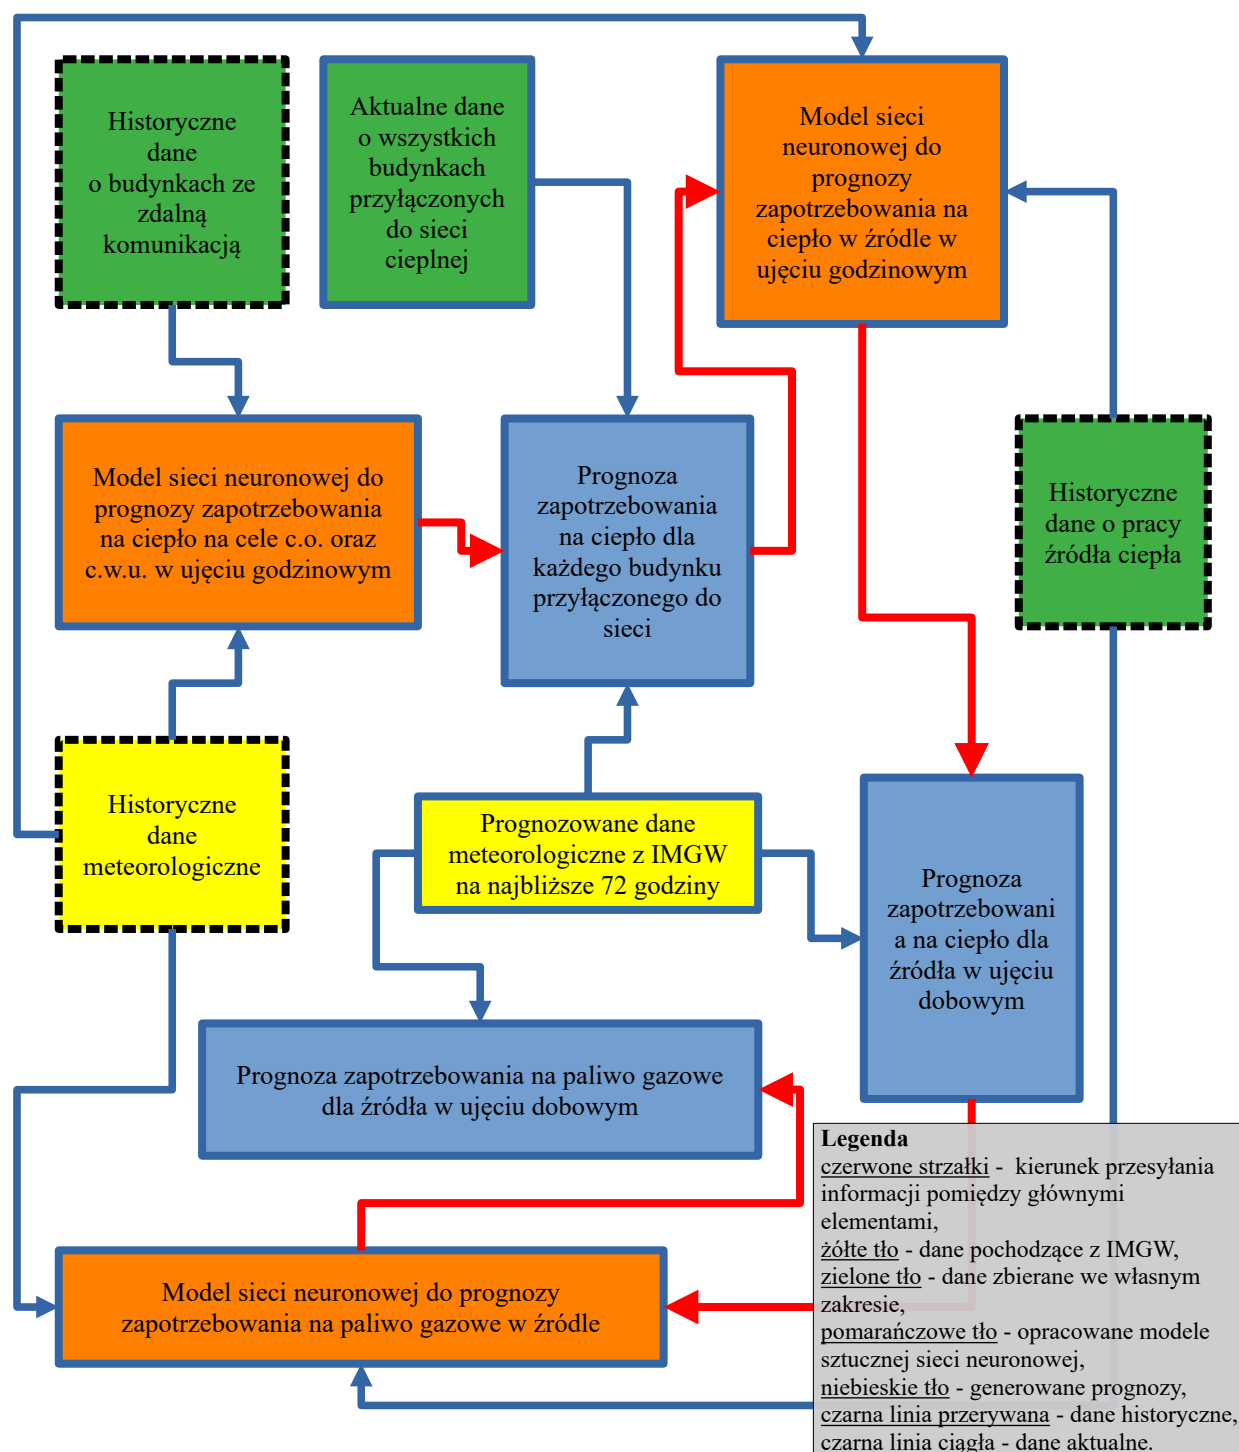
Legenda

czerwone strzałki - kierunek przesyłania informacji pomiędzy głównymi elementami,
żółte tło - dane pochodzące z IMGW, zielone tło - dane zbierane we własnym zakresie,
pomarańczowe tło - opracowane modele sztucznej sieci neuronowej,
niebieskie tło - generowane prognozy, czarna linia przerywana - dane historyczne, czarna linia ciągła - dane aktualne.


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.

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.

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

2.1. 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. 2.1. 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. 2.1. 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: [1], [3].

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.

2.2. 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. Czas wymagany do przeliczenia wszystkich modeli, nawet z wykorzystaniem kart graficznych (GPU), zajął kilka tygodni przy zajęciu powierzchni dysku ponad 117 GB. Całkowita liczba wierszy w opracowanej aplikacji wdrożeniowej napisanej w języku programowania Python wynosi 12 225.

2.3. Dane źródłowe.

Wykorzystanie algorytmów uczenia maszynowego musi być oparte na odpowiedniej ilości danych źródłowych, które będą służyły do trenowania modelu sieci neuronowej. 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 opracowano algorytmy, które umożliwiły zapis danych źródłowych w lokalnej bazie. Zaliczają się do nich:

- dane z liczników ciepła zainstalowanych w węzłach cieplnych 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.

2.4. Aplikacja.

Prezentacja generowanych danych w aplikacji jest podzielona na następujące sekcje:

- dane aktualne – parametry techniczne elektrociepłowni wraz z informacją o rzeczywistej oraz prognozowanej cenie paliwa gazowego w kolejnym dniu,
- dane prognozowane – na które składają się:
 - dobowa 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.

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

- codzienne raportowanie prognozowanego zapotrzebowania na paliwo gazowe przesyłane na adres poczty elektronicznej dostawcy gazu,
- codzienne raportowanie do operatora w zakresie czasu pracy układu kogeneracyjnego w celu wyprodukowania prognozowanej ilości ciepła (tryb pracy w priorytecie produkcji ciepła),
- codzienne 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).

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:

- produkcję ciepła w źródle,
- zużycie paliwa gazowego w źródle,
- cenę paliwa gazowego na Towarowej Giełdzie Energii,
- cenę energii elektrycznej na Rynku Bilansującym.

3. Podsumowanie, wnioski i uwagi końcowe.

3.1. 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 ciepłowniczą 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 rozprawie pytania badawcze można odpowiedzieć następująco:

- tak, sieci neuronowe można wykorzystać do prognozowania 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.

3.2. 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 3.1 przedstawiono osiągnięte dokładności wybranych modeli do prognozowania parametrów w opracowanych zastosowaniach. Zestawiono je ze zdefiniowanymi progami akceptowalnej dokładności, które określone zostały indywidualnie w zależności od poruszanego problemu. W każdym z nich udało się spełnić warunek minimalnej dokładności. W przypadku prognozowania zapotrzebowania na ciepło i paliwo gazowe, kryterium odniesienia zdefiniowały przepisy prawne regulujące funkcjonowanie tych rynków. Stanowią one o konsekwencjach finansowych wobec podmiotu energetycznego w przypadku odchyłki od wartości nominalnych lub prognozowanych przekraczających 10 %. Dla rozszerzonej prognozy pogody, kryterium stanowiła dokładność osiągana przez Instytut Meteorologii i Gospodarki Wodnej. W przypadku ceny energii elektrycznej oraz paliwa gazowego zaproponowano aby

akceptowalna niedokładność nawiązywała do tzw. modelu naiwnej prognozy. Metoda polega na założeniu, że prognozowana cena jest w danej godzinie identyczna jak ta występująca w poprzedniej dobie. 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 3.1. 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
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

Informacja dotycząca prognozy energii cieplnej jaką należy wyprodukować w źródle może być też wykorzystana do sterowania urządzeniami wytwarzającymi. Wykres prezentujący dokładność prognoz w stosunku do wartości rzeczywistych zaprezentowano na Rys. 3.1. 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 ciepłą można wykorzystać sterowanie predykcyjne (MPC – Model Predictive Control), które jest metodą sterowania systemami dynamicznymi w układach regulacji automatycznej.


W przypadku prognozy ceny paliwa gazowego (Rys. 3.2) oraz energii elektrycznej (Rys. 3.3) udowodniono, że prognozowanie krótkoterminowe (1 dzień dla paliwa gazowego oraz 12 godzin dla energii elektrycznej) może być satysfakcjonujące z punktu eksploatacji źródła ciepła. Osiągnięto dokładności odpowiednio o 3,24 p.p. i 14,51 p.p. większe niż w przypadku metody naiwnej. W dłuższym horyzoncie (7 dni dla paliwa gazowego oraz 48 godzin dla energii elektrycznej) stwierdzono, że dokładność prognozy przekracza akceptowalny próg.



Rys. 3.1. Porównanie prognozowanej i rzeczywistej produkcji ciepła oraz zużycia paliwa gazowego w źródle.



Rys. 3.2. Porównanie prognozowanej na następny dzień i rzeczywistej ceny paliwa gazowego na Towarowej Giełdzie Energii.



Rys. 3.3. Porównanie rzeczywistej i prognozowanej ceny energii elektrycznej na Rynku Bilansującym.

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 nieznanych danych.

3.3. 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.

3.4. 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 niezmienniej 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., umożliwia 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.

4. Dotychczas opublikowane prace.

- [1] „Methodology for Modernizing Local Gas-Fired District Heating Systems into a Central District Heating System Using Gas-Fired Cogeneration Engines - A Case Study”, Dawid Czajor (WIŚiE), Łukasz Amanowicz (WIŚiE), Sustainability - 2024, vol. 16, iss. 4, s. 1401-1-1401-30,
- [2] „Analiza możliwości wykorzystania entalpii spalin do produkcji energii elektrycznej z wykorzystaniem technologii ORC w zakładzie przemysłowym - studium przypadku”, Tomasz Mróz (WIŚiE), Dawid Czajor (WIŚiE), Marcin Mróz, Rynek Energii - 2024, nr 5 (174), s. 53-59,
- [3] „Kogeneracja gazowa jako krok w kierunku neutralności węglowej lokalnych systemów ciepłowniczych”, Dawid Czajor (WIŚiE), Łukasz Amanowicz (WIŚiE), Ciepłownictwo, Ogrzewnictwo, Wentylacja - 2024, T. 55, nr 10, s. 13-17,
- [4] „Benefits i ograniczenia instalacji układu kogeneracyjnego w istniejącej ciepłowni gazowej”, Dawid Czajor (WIŚiE), Łukasz Amanowicz (WIŚiE), Instal - 2023, nr 9, s. 16-23.

5. Inne osiągnięcia autora.

- 1. Wystąpienie konferencyjne „Kogeneracja jako krok w kierunku neutralności węglowej – przykład modernizacji lokalnych ciepłowni gazowych” Poznań 19.04.2024 r.
<https://pzits.pl/2024/04/03/webinariumneutralnosc-weglowa-budynkow-nowych-i-istniejacych-okiem-inzynierow-problem-czy-szansa19-04-2024-r/>,
- 2. Wystąpienie konferencyjne „Kogeneracja gazowa w kontekście dekarbonizacji ciepłownictwa”, Poznań 08.05.2024 r.
<https://dbpie.put.poznan.pl/index.php/dbpie-2024-harmonogram-dzien-1>,
- 3. Wystąpienie konferencyjne “Perspektywy inwestycji w układ kogeneracji gazowej w dobie kryzysu energetycznego”, Air, Heat and Energy, Karpacz, 14.06.2023 r.,
- 4. Wystąpienie konferencyjne “Kogeneracja gazowa – energetyka przyszłości”, Air, Heat and Energy, Karpacz, 14.06.2023 r..