



AGH

AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE

DZIEDZINA NAUK INŻYNIERYJNO-TECHNICZNYCH

DYSCYPLINA AUTOMATYKA, ELEKTRONIKA, ELEKTROTECHNIKA I
TECHNOLOGIE KOSMICZNE

AUTOREFERAT ROZPRAWY DOKTORSKIEJ

Implementacja brzegowa adaptacyjnej transformaty falkowej
w celu efektywniejszej kompresji danych z czujników w Smart
Grid

Autor: Kamil Prokop

Promotor rozprawy: dr hab. inż. Andrzej Bień, prof. AGH
Promotor pomocniczy: dr inż. Szymon Barczentewicz

Praca wykonana: Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie,
Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej

Kraków, 2025

Streszczenie

Rozprawa dotyczy zagadnienia kompresji danych pomiarowych w systemach Internetu Rzeczy stosowanych w inteligentnych sieciach elektroenergetycznych, ze szczególnym uwzględnieniem ograniczeń transmisyjnych, pamięciowych i obliczeniowych urządzeń końcowych. Współczesne systemy Smart Grid generują strumienie danych o wysokiej rozdzielczości czasowej, których akwizycja, przechowywanie i transmisja stanowią istotne obciążenie infrastruktury systemowej.

W pracy przeprowadzono analizę właściwości sygnałów elektroenergetycznych, w tym ich niestacjonarności oraz obecności krótkotrwałych stanów przejściowych, które ograniczają skuteczność klasycznych metod kompresji. Na tej podstawie przedstawiono przegląd metod kompresji danych stosowanych w sieciach elektroenergetycznych, ze szczególnym uwzględnieniem podejść opartych na dyskretniej transformacji falkowej oraz ich parametrów wpływających na jakość rekonstrukcji i stopień redukcji danych.

Głównym celem rozprawy było opracowanie metody adaptacyjnej parametryzacji dyskretniej transformacji falkowej, obejmującej dobór rodzaju falki, poziomu dekompozycji oraz wartości progowych, w sposób dostosowany do aktualnych właściwości sygnału wejściowego. Proces doboru parametrów realizowany jest z wykorzystaniem procedury eksploracyjnej opartej na optymalizacji bayesowskiej, służącej do efektywnego przeszukiwania przestrzeni parametrów i identyfikacji konfiguracji zapewniających korzystniejszy kompromis pomiędzy stopniem kompresji a błędem rekonstrukcji w porównaniu z rozwiązaniami referencyjnymi. W celu ograniczenia złożoności obliczeniowej procesu parametryzacji zaproponowano wykorzystanie sieci neuronowej uczonej na wynikach procedury eksploracyjnej. Sieć pełni rolę aproksymatora relacji pomiędzy cechami sygnału a parametrami transformacji falkowej, umożliwiając ich wyznaczanie w czasie porównywalnym z czasem standardowego przetwarzania sygnału. Parametryzacja może być realizowana równolegle do procesu kompresji, bez wprowadzania dodatkowego narzutu czasowego w torze przetwarzania.

Badania eksperymentalne wykazały, że proponowana metoda umożliwia uzyskanie lepszych współczynników kompresji w porównaniu z wybranymi algorytmami referencyjnymi, przy zachowaniu porównywalnego lub niższego poziomu błędu rekonstrukcji. Zastosowanie sieci neuronowej pozwoliło na ponad 3000-krotne zmniejszenie nakładu obliczeniowego związanego z doбором parametrów w stosunku do bezpośredniego stosowania procedury eksploracyjnej. Uzyskane wyniki wskazują na przydatność metody w systemach analizy jakości energii oraz w aplikacjach wymagających wykrywania lokalnych zjawisk przejściowych. Rozprawa wnosi wkład w rozwój adaptacyjnych metod kompresji danych dla inteligentnych sieci elektroenergetycznych, łącząc klasyczne techniki przetwarzania sygnałów z metodami uczenia maszynowego w kontekście systemów wbudowanych i przetwarzania w czasie rzeczywistym.

Spis treści

1	Wprowadzenie	1
1.1	Teza badawcza	1
1.2	Metodologia	1
1.3	Oczekiwane rezultaty	2
1.4	Struktura rozprawy	3
2	Metody kompresji danych w systemach Smart Grid oraz parametryzacja transformacji falkowej	5
2.1	Podejścia do kompresji danych w sygnałach elektroenergetycznych	5
2.1.1	Metody fazorowe i predykcyjne	5
2.1.2	Transformacje częstotliwościowe i metody niskiego rzędu	6
2.1.3	Compressed Sensing	6
2.1.4	Podsumowanie metod	6
2.2	Transformacja falkowa i jej parametryzacja	6
2.2.1	Wybór falki	7
2.2.2	Poziom dekompozycji	7
2.2.3	Progowanie współczynników	7
2.3	Wnioski	7
3	Proponowane rozwiązanie	9
3.1	Architektura proponowanego systemu	10
3.1.1	Generowanie sygnałów	10
3.1.2	Optymalizacja bayesowska	10
3.1.3	Etykietowanie sygnałów	11
3.1.4	Trening sieci neuronowej	11
3.2	Zalety w środowiskach Internetu Rzeczy	12
3.2.1	Skalowalność	12
3.2.2	Zdolność adaptacji	12
3.2.3	Usprawnione zarządzanie danymi	12
3.2.4	Efektywność kosztowa	13
4	Wyniki	15
4.1	Dane rzeczywiste	16

4.1.1	Współczynnik kompresji	17
4.1.2	Straty kompresji	17
4.1.3	Wnioski	18
4.2	Dane syntetyczne	18
4.2.1	Współczynnik kompresji	19
4.2.2	Straty kompresji	20
4.2.3	Wnioski	20
4.3	Czas parametryzacji	21
5	Podsumowanie i wkład pracy	23

Rozdział 1

Wprowadzenie

Rozwój Internetu Rzeczy znacząco zmienił dziedzinę systemów elektroenergetycznych, umożliwiając szerokie gromadzenie danych oraz monitorowanie w czasie rzeczywistym za pomocą sieci połączonych czujników. Gwałtowny wzrost ilości danych generuje istotne wyzwania związane z efektywnością ich przechowywania i transmisji. Aby im sprostać, konieczne jest opracowanie zaawansowanych technik kompresji danych, które nie tylko redukują ilość danych, ale jednocześnie zachowują ich integralność oraz umożliwiają przetwarzanie wrażliwe na czas. Rozprawa przedstawia kompleksowe badania oraz rozwój adaptacyjnego systemu kompresji danych opartego na sieciach neuronowych, zaprojektowanego specjalnie dla sieci czujników Internetu Rzeczy w inteligentnych sieciach elektroenergetycznych, wykorzystującego dyskretną transformację falkową do kompresji danych szeregów czasowych.

1.1 Teza badawcza

Algorytmy kompresji wykorzystujące dyskretną transformację falkową do kompresji szeregów czasowych z dopuszczalnym zniekształceniem w inteligentnych sieciach elektroenergetycznych mogą zostać ulepszone poprzez adaptację parametrów transformacji falkowej — funkcji falkowej, poziomu dekompozycji oraz wartości progowania — do próbkowanego sygnału. Parametryzację tę można zaimplementować w sposób niewprowadzający dodatkowych kosztów czasowych podczas działania systemu.

1.2 Metodologia

W celu systematycznej realizacji założeń badawczych praca opiera się na następujących krokach metodologicznych:

- **Przegląd literatury** — Przeprowadzono szczegółowy przegląd istniejących technik kompresji danych stosowanych w inteligentnych sieciach elektroenergetycznych oraz w innych sieciach czujników Internetu Rzeczy. Ocenie poddano zarówno metody bezstratne, jak i stratne, analizując ich efektywność, złożoność obliczeniową oraz przydatność w środowiskach o ograniczonych zasobach.
- **Opracowanie i projekt systemu** — Na podstawie wniosków z analizy literatury zaprojektowano nową adaptacyjną architekturę systemu kompresji danych. Etap ten obejmował rozwój kluczowych

komponentów: oprogramowania do przygotowania danych, sieci neuronowej do parametryzacji dyskretnej transformacji falkowej, oprogramowania wbudowanego w C++ oraz platformy walidacyjnej.

- **Projekt i trening sieci neuronowej** — Opracowano i wytrenowano sieć neuronową z wykorzystaniem obszernego zbioru danych reprezentującego zróżnicowane typy danych z czujników Internetu Rzeczy. Trening skoncentrowano na uzyskaniu dobrej generalizacji dla nieznanych danych, aby zwiększyć efektywność kompresji i jednocześnie zminimalizować koszty obliczeniowe podczas działania.
- **Implementacja i testowanie oprogramowania** — Oprogramowanie wbudowane opracowano w C++ z myślą o bezpośrednim wdrożeniu na urządzeniach Internetu Rzeczy. Przeprowadzono szerokie testy — jednostkowe, integracyjne i użytkowe — aby potwierdzić niezawodność oraz wydajność systemu w różnych warunkach.
- **Rozwój platformy walidacyjnej** — Utworzono kompleksową platformę służącą weryfikacji skuteczności systemu kompresji dla danych typowych dla inteligentnych sieci elektroenergetycznych. Oprócz danych symulowanych wykorzystano również rzeczywiste pomiary z różnych konfiguracji mikrosieci.

1.3 Oczekiwane rezultaty

Badania mają przyczynić się do rozwoju technik kompresji danych dla systemów inteligentnych sieci elektroenergetycznych poprzez następujące osiągnięcia:

- **Adaptacyjny system kompresji danych** — Opracowanie systemu adaptacyjnej kompresji osiągającego lepsze współczynniki kompresji niż istniejące rozwiązania oparte na dyskretnej transformacji falkowej, a jednocześnie w pełni gotowego do wdrożenia w aplikacjach rzeczywistych.
- **Architektura systemu** — Szczegółowy projekt proponowanej architektury, ułatwiający jej zrozumienie oraz umożliwiający replikację w innych zastosowaniach Internetu Rzeczy. Kluczowym założeniem projektu jest eliminacja dodatkowych kosztów czasowych w czasie pracy — wszystkie dodatkowe kroki realizowane są na etapie rozwoju, wdrożenia lub równolegle z aplikacją.
- **Oprogramowanie wbudowane** — Opracowanie oprogramowania w C++ zgodnego z urządzeniami użytkowników, zapewniającego szeroką interoperacyjność i stabilność na różnych platformach Internetu Rzeczy.
- **Parametryzacja oparta na sieciach neuronowych** — Wprowadzenie metody opartej na sieciach neuronowych, która znacząco redukuje czas potrzebny do wyboru parametrów dyskretnej transformacji falkowej, zwiększając efektywność kompresji i poprawiając przydatność rozwiązania w aplikacjach wymagających działania w czasie rzeczywistym.

1.4 Struktura rozprawy

Rozprawa składa się z 15 rozdziałów. Zawiera wprowadzenie do sygnałów w sieciach elektroenergetycznych oraz metod komunikacji, definiuje główny problem, omawia metody kompresji stosowane w inteligentnych sieciach elektroenergetycznych, a także opisuje architekturę, projekt oraz implementację proponowanego systemu. Ostatnie rozdziały analizują wyniki, porównują je z innymi podejściami oraz wskazują kierunki dalszych badań.

Funkcja poszczególnych rozdziałów jest następująca:

1. **Wprowadzenie** — Definicja problemu badawczego oraz ogólny opis proponowanego rozwiązania.
2. **Sygnały w sieciach elektroenergetycznych** — Charakterystyka sygnałów w sieciach elektroenergetycznych oraz kluczowych cech wykorzystywanych w analizie jakości energii elektrycznej.
3. **Komunikacja w inteligentnych sieciach elektroenergetycznych** — Opis metod komunikacji stosowanych we współczesnych sieciach elektroenergetycznych oraz podstawowe zasady teorii komunikacji.
4. **Podstawy teoretyczne i przegląd literatury dotyczącej kompresji danych w inteligentnych sieciach elektroenergetycznych** — Szczegółowy przegląd aktualnych badań nad kompresją danych w inteligentnych sieciach elektroenergetycznych, z uwzględnieniem podstaw teorii informacji oraz porównań z technikami kompresji stosowanymi w dojrzałych domenach, takich jak audio i wideo.
5. **Różne podejścia do kompresji danych w sygnałach elektrycznych** — Analiza najczęściej stosowanych metod kompresji w inteligentnych sieciach elektroenergetycznych oraz uzasadnienie wyboru podejścia opartego na dyskretnej transformacji falkowej.
6. **Kompresja z wykorzystaniem transformacji falkowej** — Szczegółowa analiza technik kompresji opartych na transformacji falkowej.
7. **Parametryzacja systemu kompresji** — Opis metod parametryzacji kompresji opartej na dyskretnej transformacji falkowej oraz wprowadzenie strategii parametryzacji przyjętej w rozprawie.
8. **Proponowane rozwiązanie** — Szczegółowy opis architektury i kluczowych koncepcji dynamicznie parametryzowanego systemu kompresji opartego na dyskretnej transformacji falkowej.
9. **Zbiór danych** — Informacje o danych wykorzystanych do trenowania sieci neuronowej oraz walidacji systemu.
10. **Sieć neuronowa** — Opis kluczowego komponentu odpowiedzialnego za parametryzację systemu kompresji.
11. **Komponent oprogramowania wbudowanego** — Omówienie projektu kodu C++ współpracującego z systemem parametryzacji oraz strategii efektywnego wykonywania kompresji i inferencji z wykorzystaniem przetwarzania równoległego.

12. **Wyniki** — Prezentacja osiągniętego współczynnika kompresji, poprawy średniego błędu kwadratowego oraz redukcji kosztów obliczeniowych dzięki zastosowaniu sieci neuronowych.
13. **Wkład** — Podsumowanie kluczowych osiągnięć rozprawy.
14. **Podsumowanie** — Omówienie wyników badań, zastosowanych metod oraz ogólnego wkładu pracy.
15. **Kierunki dalszych badań** — Propozycje dalszego rozwoju technik kompresji danych w inteligentnych sieciach elektroenergetycznych.

Rozdział 2

Metody kompresji danych w systemach Smart Grid oraz parametryzacja transformacji falkowej

Rozdział przedstawia syntetyczny przegląd metod kompresji danych stosowanych w inteligentnych sieciach elektroenergetycznych oraz wprowadza zagadnienie parametryzacji dyskretnej transformacji falkowej. Celem jest wskazanie głównych klas rozwiązań opisanych w literaturze, ich właściwości w kontekście sygnałów elektroenergetycznych oraz uzasadnienie wyboru transformacji falkowej jako podstawy dalszych badań.

2.1 Podejścia do kompresji danych w sygnałach elektroenergetycznych

Sygnały pomiarowe w systemach Smart Grid charakteryzują się silną korelacją czasową, a często również przestrzenną. W literaturze dominują rozwiązania łączące kompresję stratną i bezstratną, wykorzystujące nadmiarowość danych w dziedzinie czasu, częstotliwości lub przestrzeni pomiarowej. Wybór metody zależy od architektury systemu, dostępnych zasobów obliczeniowych oraz dopuszczalnych strat rekonstrukcji.

2.1.1 Metody fazorowe i predykcyjne

W systemach synchronizacyjnych przebiegi napięcia i prądu modelowane są jako sygnały sinusoidalne:

$$x(t) = X_m \cos(\omega t + \theta), \quad (2.1)$$

gdzie informacja o sygnale zawarta jest głównie w amplitudzie X_m i kącie fazowym θ . W warunkach ustalonych skuteczna jest kompresja różnicowa:

$$\Delta X_k = X_k - X_{k-1}, \quad (2.2)$$

oraz metody predykcyjne, w których transmitowany jest skwantowany błąd predykcji:

$$e_k = x_k - \hat{x}_k. \quad (2.3)$$

Podejścia te cechują się niską złożonością obliczeniową, lecz ich skuteczność maleje w obecności szybkich zjawisk przejściowych i niestacjonarności sygnału.

2.1.2 Transformacje częstotliwościowe i metody niskiego rzędu

Dyskretna transformacja kosinusowa oraz Fouriera są często stosowane do kompresji sygnałów okresowych. Energia sygnału koncentruje się w niewielkiej liczbie współczynników:

$$X_k = \sum_{n=0}^{N-1} x_n \cos \left(\frac{\pi}{N} \left(n + \frac{1}{2} \right) k \right), \quad (2.4)$$

co umożliwia skuteczne progowanie i kwantyzację.

Dla wielowymiarowych danych pomiarowych wykorzystuje się dekompozycję według wartości osobliwych:

$$\mathbf{X} \approx \mathbf{U}_r \mathbf{\Sigma}_r \mathbf{V}_r^T, \quad (2.5)$$

która redukuje objętość danych przy zachowaniu dominujących zależności czasowo-przestrzennych. Metody te są jednak kosztowne obliczeniowo dla dużych strumieni danych oraz nie zachowują często informacji o dynamicznych zjawiskach przejściowych.

2.1.3 Compressed Sensing

Compressed Sensing zakłada, że sygnał $\mathbf{x} \in \mathbb{R}^N$ jest rzadki w pewnej bazie:

$$\mathbf{x} = \mathbf{\Psi} \mathbf{s}, \quad \|\mathbf{s}\|_0 \ll N, \quad (2.6)$$

a wektor pomiarowy ma postać:

$$\mathbf{y} = \mathbf{\Phi} \mathbf{x}. \quad (2.7)$$

Rekonstrukcja wymaga rozwiązania zadania minimalizacji normy ℓ_1 , co zapewnia dużą redukcję danych, lecz wiąże się z wysoką złożonością obliczeniową, oraz potrzebą ingerencji w architekturę urządzenia pomiarowego ograniczając zastosowanie tej metody w urządzeniach końcowych.

2.1.4 Podsumowanie metod

Metody fazorowe i predykcyjne są lekkie obliczeniowo, lecz wrażliwe na niestacjonarność. Transformacje częstotliwościowe skutecznie kompresują sygnały okresowe, ale słabiej odwzorowują lokalne zdarzenia. Compressed Sensing i metody niskiego rzędu oferują wysoką redukcję danych kosztem dużego nakładu obliczeń. W praktycznych zastosowaniach Smart Grid wymagane jest rozwiązanie kompromisowe pomiędzy efektywnością kompresji, jakością rekonstrukcji i możliwością implementacji w systemach czasu rzeczywistego.

2.2 Transformacja falkowa i jej parametryzacja

Dyskretna transformacja falkowa umożliwia wielorozdzielczą analizę sygnału, łącząc reprezentację czasową i częstotliwościową. Dla sygnału dyskretnego $x[n]$ współczynniki falkowe wyznaczane są w kolejnych

poziomach dekompozycji za pomocą filtrów dolno- i górnoprzepustowych. Kluczową cechą transformacji falkowej jest możliwość jej konfigurowania w zależności od charakterystyki sygnału.

2.2.1 Wybór falki

W praktyce stosuje się najczęściej falki Haara, Daubechies, Symlet oraz Coiflet, różniące się lokalizacją w czasie i częstotliwości. Funkcja falkowa $\psi(t)$ musi spełniać warunek dopuszczalności:

$$\int_{-\infty}^{\infty} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty. \quad (2.8)$$

Dobór falki wpływa na zdolność odwzorowania zjawisk przejściowych oraz struktury widmowej sygnału.

2.2.2 Poziom dekompozycji

Poziom dekompozycji J określa liczbę iteracji rozkładu sygnału i może być w przybliżeniu oszacowany jako:

$$J = \log_2 \left(\frac{N}{L} \right), \quad (2.9)$$

gdzie N jest długością sygnału, a L długością filtra. Większa liczba poziomów zwiększa koszt obliczeniowy i liczbę współczynników.

2.2.3 Progowanie współczynników

Kompresja falkowa realizowana jest poprzez progowanie współczynników:

$$\tilde{w}_i = \begin{cases} 0, & |w_i| < \lambda, \\ w_i, & \text{w przeciwnym razie,} \end{cases} \quad (2.10)$$

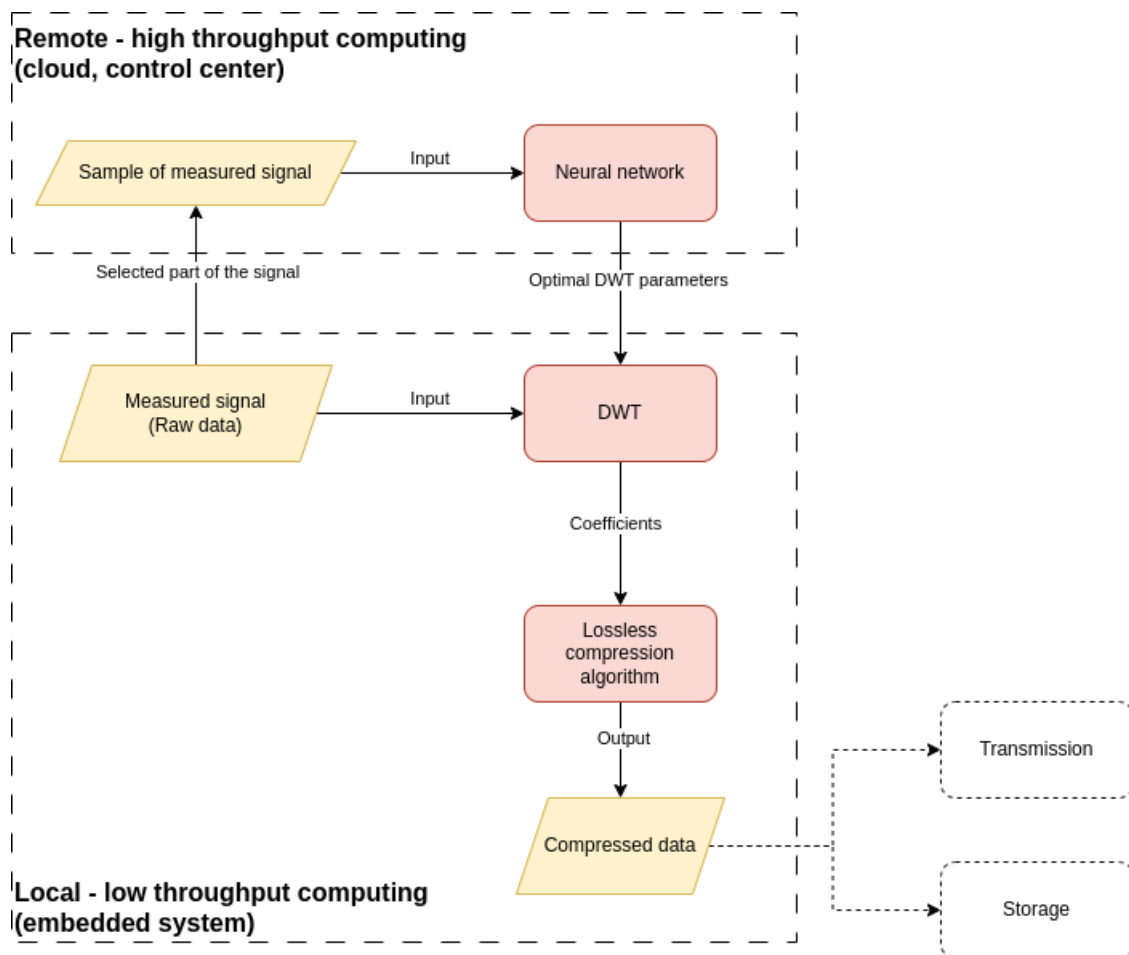
lub jego odmiany miękkie. Wartość progu λ bezpośrednio wpływa na kompromis pomiędzy stopniem redukcji danych a błędem rekonstrukcji i może być dobierana w sposób adaptacyjny.

2.3 Wnioski

Analiza metod kompresji danych w systemach Smart Grid wskazuje, że dyskretna transformacja falkowa oferuje korzystne połączenie odporności na niestacjonarność sygnałów, umiarkowanej złożoności obliczeniowej oraz możliwości parametryzacji. Cechy te czynią ją odpowiednią podstawą do dalszych badań nad adaptacyjnymi metodami kompresji danych w inteligentnych sieciach elektroenergetycznych.

Rozdział 3

Proponowane rozwiązanie



Rysunek 3.1: Logiczna architektura proponowanego rozwiązania z punktu widzenia użytkownika. Elementy zaznaczone na żółto to bloki danych dostarczane przez system; elementy zaznaczone na czerwono to bloki instrukcji dostarczane przez implementatora systemu kompresji.

W rzeczywistych, szerokoobszarowych systemach pomiarowych sygnały mierzone przez czujniki w różnych punktach sieci będą się od siebie różnić. Celem proponowanego systemu jest dynamiczna parametryzacja dyskretniej transformacji falkowej osobno dla każdego czujnika w sieci. Aby system był skalowalny,

nakład obliczeniowy związany z parametryzacją musi być relatywnie niski. Jak pokazano na rysunku 3.1, większość obciążenia obliczeniowego może być przetwarzana równolegle. Obciążenie to można przenieść na scentralizowany klaster obliczeniowy (taki jak platforma chmurowa lub wysoko wydajny komputer nadzorczy) albo na inny rdzeń procesora, unikając tym samym narzutu obliczeniowego w czasie wykonywania zadania kompresji.

3.1 Architektura proponowanego systemu

Architektura przedstawiona na rysunku 3.2 obejmuje trzy główne etapy: generowanie sygnałów, optymalizację bayesowską oraz trening i wdrożenie sieci neuronowej. System jest zaprojektowany tak, aby generować zniekształcone sygnały, dobierać parametry kompresji, etykietować sygnały, trenować sieć neuronową oraz wykorzystywać wytrenowaną sieć w systemach pomiarowych opartych na układach wbudowanych. Każdy etap procesu został opisany poniżej.

3.1.1 Generowanie sygnałów

Proces generowania sygnałów obejmuje tworzenie sygnałów o określonych charakterystykach zdefiniowanych przez harmoniczne oraz zjawiska przejściowe.

Harmoniczne

Harmoniczne są definiowane przez swoje wartości minimalne i maksymalne. Parametry te kontrolują podstawowe składowe częstotliwościowe generowanych sygnałów.

Zjawiska przejściowe

Zjawiska przejściowe określa się poprzez ich liczbę oraz wartości minimalne i maksymalne. Parametry te wprowadzają do sygnałów składniki niestacjonarne, symulując rzeczywiste zniekształcenia.

3.1.2 Optymalizacja bayesowska

Zniekształcone sygnały są następnie przekazywane do modułu optymalizacji bayesowskiej. Moduł ten dobiera parametry kompresji, które minimalizują rozmiar skompresowanego sygnału przy zachowaniu średniego błędu kwadratowego poniżej z góry zdefiniowanego progu.

Kompresja i dekompresja

Moduł optymalizacji bayesowskiej obejmuje pętlę operacji kompresji i dekompresji. Sygnał jest kompresowany, a następnie dekompresowany, po czym wykonywane jest sprawdzenie średniego błędu kwadratowego w celu oceny wierności procesu kompresji.

Obliczanie współczynnika kompresji

Współczynnik kompresji jest obliczany w celu oceny efektywności zastosowanego algorytmu. Proces doboru parametrów jest iteracyjny i dąży do znalezienia takich parametrów, które zapewniają możliwie najmniejszy współczynnik kompresji przy jednoczesnym utrzymaniu akceptowalnych wartości średniego błędu kwadratowego.

3.1.3 Etykietowanie sygnałów

Sygnały są etykietowane dobranymi parametrami zgodnie z określonym schematem nazewnictwa:

```
signal<No>_<wavelet_function>_<decomposition_level>_<threshold>.csv
```

Zbiór danych składa się z 4000 oznaczonych plików sygnałowych przeznaczonych do treningu oraz 1000 losowo wybranych sygnałów do walidacji.

3.1.4 Trening sieci neuronowej

Sieć neuronowa jest trenowana z wykorzystaniem oznaczonych plików sygnałowych. Celem jest nauczenie sieci przewidywania optymalnych parametrów dyskretnej transformacji falkowej dla różnych typów sygnałów.

Dane treningowe

Zbiór danych treningowych obejmuje początkowo 547 rzeczywistych sygnałów, a następnie 12 000 sztucznie wygenerowanych i oznaczonych plików sygnałowych. Każdy plik jest powiązany z parametrami bliskimi optymalnym, uzyskanymi w wyniku optymalizacji bayesowskiej.

Dane walidacyjne

Walidacja jest przeprowadzana z wykorzystaniem 50 rzeczywistych sygnałów oraz 1000 sygnałów syntetycznych, aby upewnić się, że sieć neuronowa dobrze uogólnia działanie na dane nieobserwowane podczas treningu.

Wdrożenie sieci neuronowej

Wytrenowana sieć neuronowa jest wdrażana w systemach pomiarowych opartych na układach wbudowanych, gdzie służy do wyznaczania odpowiednich parametrów dyskretnej transformacji falkowej dla nieznanymi wcześniej sygnałów.

Dobór współczynników dyskretnej transformacji falkowej

Sieć neuronowa przetwarza napływające sygnały i zwraca odpowiadające im parametry dyskretnej transformacji falkowej. Parametry te są następnie wykorzystywane w systemach wbudowanych do efektywnego przetwarzania sygnałów.

3.2 Zalety w środowiskach Internetu Rzeczy

Integracja zaawansowanego systemu kompresji sygnałów z aplikacjami w inteligentnych sieciach elektroenergetycznych przynosi szereg korzyści, szczególnie w kontekście redukcji wolumenu danych względem zużycia zasobów.

3.2.1 Skalowalność

Jedną z głównych zalet proponowanego systemu jest jego skalowalność. W miarę rozbudowy inteligentnych sieci elektroenergetycznych liczba czujników i punktów pomiarowych rośnie znacząco. Architektura opisana w niniejszej pracy wspiera ten wzrost w efektywny sposób z następujących powodów:

- **Zdolność adaptacji sieci neuronowej:** Sieć neuronowa może być ponownie trenowana na nowych danych, co pozwala jej dostosowywać się do rosnącej różnorodności sygnałów bez konieczności czasochłonnej ręcznej rekalkulacji.
- **Modułowa budowa:** Modułowa struktura systemu ułatwia dodawanie nowych czujników i urządzeń monitorujących. Zdolność sieci neuronowej do uogólniania na podstawie istniejących danych umożliwia płynną integrację nowych elementów.

3.2.2 Zdolność adaptacji

Dynamiczny charakter inteligentnych sieci elektroenergetycznych, związany z wahaniami zapotrzebowania na moc oraz integracją odnawialnych źródeł energii, wymaga silnie adaptacyjnego systemu. Opisana architektura przetwarzania sygnałów jest szczególnie dobrze dopasowana do takich środowisk:

- **Optymalizacja bayesowska:** Ten komponent może dostosowywać parametry kompresji na podstawie nowo pozyskanych danych, poprawiając wydajność w odpowiedzi na aktualne charakterystyki sygnału. Zapewnia to konsekwentnie wysoką efektywność kompresji oraz jakość danych.
- **Dynamiczna parametryzacja:** Czujniki mogą przysyłać próbki mierzonego sygnału do jednostki nadzorczej i otrzymywać w czasie pracy nowe parametry kalibracyjne, lepiej dopasowane do bieżących warunków.

3.2.3 Usprawnione zarządzanie danymi

Skuteczna kompresja danych ma bezpośredni wpływ na obsługę danych i komunikację w obrębie inteligentnej sieci elektroenergetycznej:

- **Redukcja wymagań dotyczących przepustowości:** Efektywna kompresja zmniejsza przepustowość wymaganą do transmisji danych, co jest szczególnie ważne w dużych wdrożeniach, gdzie kluczowa jest niezawodność komunikacji.

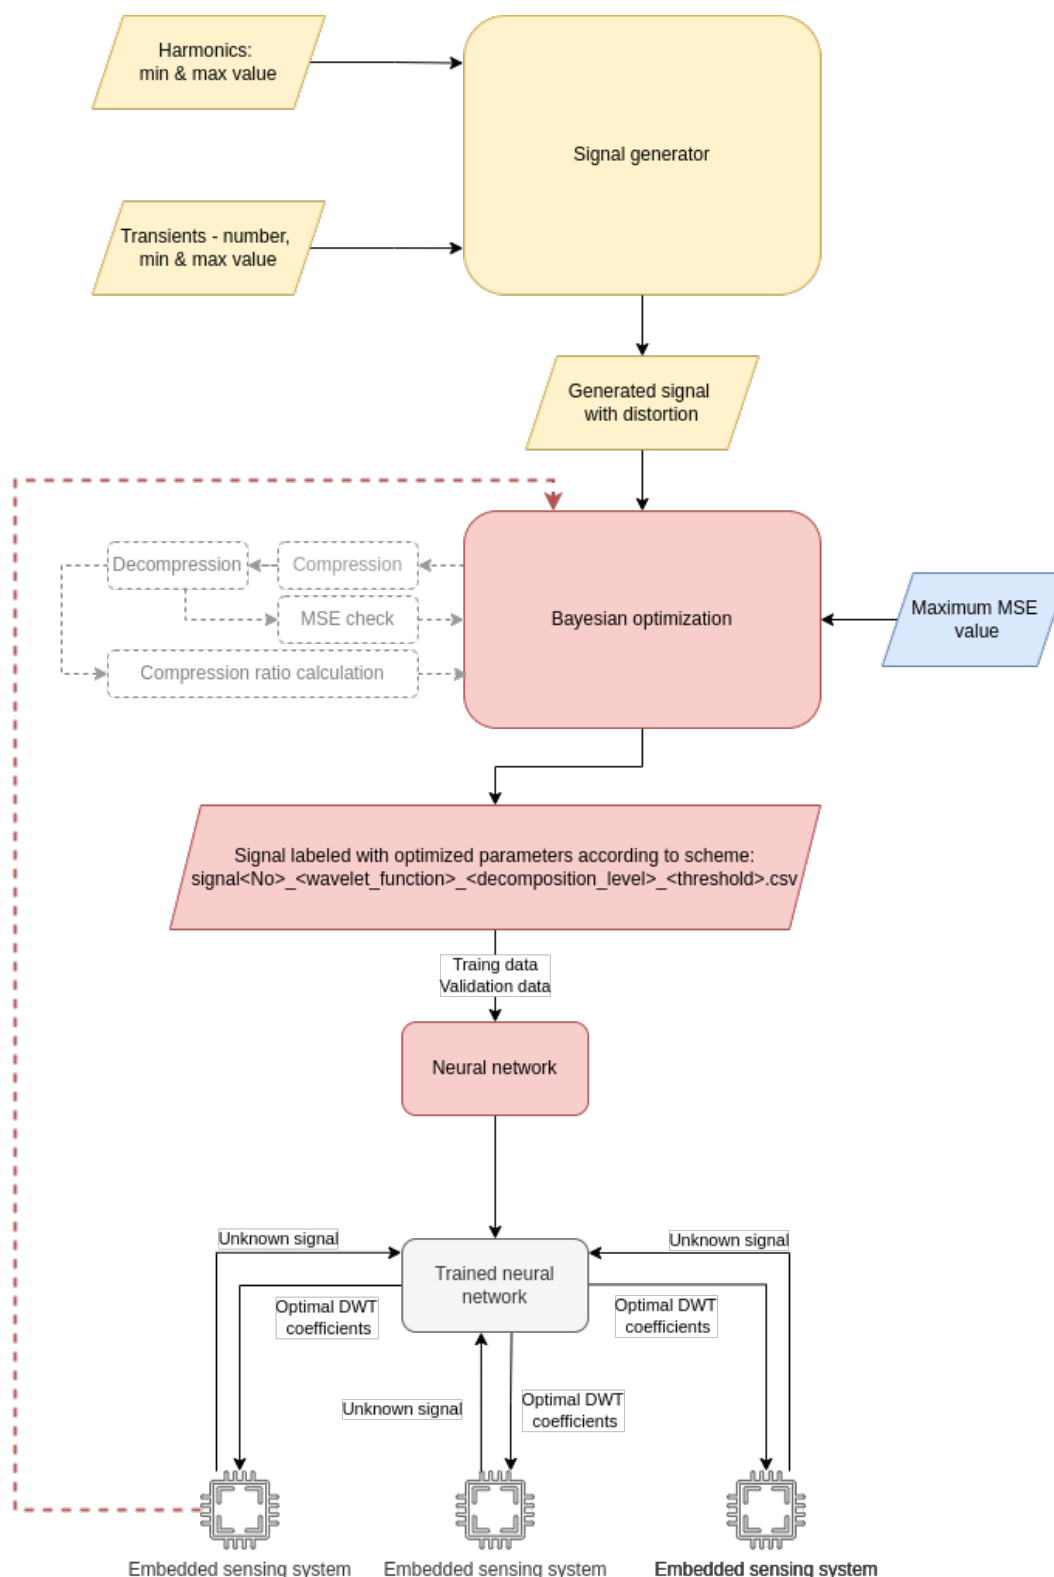
- **Poprawa efektywności przechowywania:** Dane skompresowane zajmują mniej miejsca, co umożliwia dłuższe okresy retencji oraz bardziej rozbudowaną analizę historyczną, wspierając tym samym analizę trendów i utrzymanie predykcyjne.

3.2.4 Efektywność kosztowa

Zdolności kompresyjne systemu przekładają się na istotne oszczędności kosztowe:

- **Niższe koszty operacyjne:** Skuteczna kompresja danych zmniejsza ilość transmitowanych i przechowywanych informacji, redukując związane z tym koszty, co jest szczególnie korzystne w dużych infrastrukturach inteligentnych sieci elektroenergetycznych.
- **Efektywność energetyczna:** Usprawnione przetwarzanie sygnałów redukuje zapotrzebowanie na moc obliczeniową i energię związaną z obsługą danych. Ma to szczególne znaczenie w systemach pomiarowych opartych na układach wbudowanych, które często dysponują ograniczonymi zasobami energetycznymi.

Proponowany system przetwarzania sygnałów zapewnia istotne korzyści dla kompresji danych w środowisku inteligentnych sieci elektroenergetycznych. Jego skalowalność i zdolność adaptacji umożliwiają obsługę rosnącej złożoności oraz dynamicznej natury nowoczesnych sieci elektroenergetycznych. Poprzez usprawnienie zarządzania danymi, redukcję kosztów oraz utrzymanie wysokiej jakości informacji system w istotny sposób przyczynia się do poprawy efektywności, niezawodności i zrównoważonego rozwoju operacji w inteligentnych sieciach elektroenergetycznych.



Rysunek 3.2: Szczegółowa architektura proponowanego rozwiązania. Czerwone elementy tworzą główny system korzystający z rzeczywistych danych treningowych. Żółte elementy odnoszą się do przygotowania danych syntetycznych, które mogą zastępować dane laboratoryjne. Niebieski element (maksymalny średni błąd kwadratowy) jest definiowany przez użytkownika. Optymalizacja bayesowska może wykorzystywać dane syntetyczne lub prawdziwe. Przezroczyste bloki przedstawiają kroki algorytmu. Szare elementy reprezentują część przeznaczoną do wdrożenia.

Rozdział 4

Wyniki

Proponowany system został oceniony w trzech kluczowych kategoriach wydajności: współczynnik kompresji, jakość kompresji oraz narzut czasowy. Wyniki empiryczne były zbieżne z początkowymi hipotezami. Dodatkowo przeprowadzono analizę porównawczą proponowanego algorytmu z najlepiej ocenianymi metodami przedstawionymi w najnowszej literaturze. Głównym celem badań jest weryfikacja algorytmu na sygnałach zawierających zniekształcenia harmoniczne oraz zjawiska przejściowe, ponieważ zachowanie tych cech decyduje o przydatności algorytmu w systemach zabezpieczeń oraz monitoringu jakości energii elektrycznej. Ocena strat kompresji jest zadaniem trudnym i nie istnieje jedna uniwersalna miara. W przedstawionych badaniach jako podstawę porównania jakości zastosowano średni błąd kwadratowy. Metryka ta ma jednak swoje wady, ponieważ w niektórych przypadkach może prowadzić do mylących wniosków. Na przykład, jeśli duża część sygnału jest idealną sinusoidą, ale zawiera pojedynczy stan przejściowy, średni błąd kwadratowy może być niski nawet wtedy, gdy zrekonstruowany sygnał utraci stan przejściowy, a więc będzie bezużyteczny do celów zabezpieczeń lub analizy jakości energii. Z tego powodu porównywanie strat sygnałów na podstawie różnych metod przetwarzania sygnałów jest zadaniem złożonym. Wyniki porównywano jedynie z innymi metodami opartymi na dyskretnej transformacji falkowej, ponieważ metody oparte na innych prymitywach, takich jak reprezentacja fazorowa czy dyskretna transformacja kosinusowa, są wyspecjalizowane w kompresji innych klas sygnałów. Niniejsza praca koncentruje się na dyskretnej transformacji falkowej, ponieważ głównym celem proponowanego algorytmu jest obsługa sygnałów zniekształconych zjawiskami przejściowymi, które są kluczowe w takich zastosowaniach jak analiza jakości energii czy systemy zabezpieczeń.

Po uruchomieniu algorytmu na danych rzeczywistych zaobserwowano poprawę równowagi pomiędzy współczynnikiem kompresji a stratą kompresji. Ze względu na ograniczoną dostępność danych rzeczywistych przeprowadzono również badania z użyciem danych syntetycznych, aby dokładniej zbadać możliwości algorytmu. Dostarczenie algorytmowi dużej ilości wysokiej jakości danych spowodowało poprawę zarówno współczynnika kompresji, jak i strat kompresji.

Przedstawionych poniżej wyników nie należy bezpośrednio porównywać z różnymi metodami kompresji, ponieważ typowy algorytm kompresji składa się z wielu etapów. Celem niniejszych badań jest ulepszenie komponentu opartego na dyskretnej transformacji falkowej, który może zastąpić obecnie stosowaną sta-

tycznie parametryzowaną dyskretną transformację falkową w ramach algorytmów kompresji danych, a nie funkcjonowanie jako samodzielna metoda kompresji. Metoda adaptacyjna została porównana z metodami parametryzacji dyskretniej transformacji falkowej przedstawionymi we współczesnej literaturze.

4.1 Dane rzeczywiste


W celu zweryfikowania działania algorytmu wykonano pomiary w różnych scenariuszach występujących w sieciach elektroenergetycznych. Pomiary przeprowadzono w laboratorium, które symulowało rzeczywiste warunki pracy, z różnymi obciążeniami oraz źródłami energii. Scenariusze pomiarów napięcia obejmowały: zniekształcenia harmoniczne, zniekształcenia interharmoniczne, zniekształcenia przejściowe, wyspę zasilaną z generatora (niestabilna sieć z istotnym poziomem szumu), obciążenia liniowe oraz nieliniowe. Scenariusze pomiarów prądu obejmowały komutację obciążenia nieliniowego z różnymi kątami komutacji. Po podziale uzyskanych przebiegów na fragmenty o długości 1000 próbek otrzymano 547 sygnałów. Następnie przeprowadzono augmentację danych, odszumiając sygnały filtrem Savitzky'ego–Golaya, odszumiając filtrem Kalmana oraz dodając szum, co dało łącznie 2188 plików. Po oznaczeniu wszystkich sygnałów zostały one wykorzystane do treningu sieci neuronowej.

Scenariusz	Zakresy zniekształceń	Mierzona wielkość
Obciążenie liniowe zasilane z sieci	N/D	Napięcie
Wyspa zasilana generatorem bez obciążenia	N/D	Napięcie
Wyspa z obciążeniem nieliniowym	N/D	Napięcie
Wyspa z obciążeniem liniowym	N/D	Napięcie
Harmoniczne	3., 5., 7., 9., 11. harmoniczna, ustawione na: 4,6 V / 9,2 V / 13,8 V / 18,4 V / 23 V / 27 V / 32,2 V / 36,8 V / 41,4 V / 46 V	Napięcie
Interharmoniczne	52 Hz / 55 Hz / 59 Hz, każda o amplitudzie 5%, 10%, 20% napięcia sieci	Napięcie
Zjawiska przejściowe	Przebiegi, podnapięcie, zanik napięcia	Napięcie
Zjawiska przejściowe	Komutacja tyrystorów	Prąd

Tabela 4.1: Scenariusze akwizycji danych

4.1.1 Współczynnik kompresji


Współczynnik kompresji został zbadany poprzez uruchomienie algorytmu na 100 losowo wybranych sygnałach, które zostały wykluczone ze zbioru uczącego. Współczynnik kompresji dla dyskretnej transformacji falkowej parametryzowanej proponowaną metodą jest na poziomie zbliżonym do innych metod, co oznacza, że proponowane podejście zapewnia podobny rozmiar zakodowanych danych jak najlepsze dostępne rozwiązania 4.1.



Rysunek 4.1: Porównanie współczynników kompresji pomiędzy wszystkimi testowanymi algorytmami.

4.1.2 Straty kompresji

Średni błąd kwadratowy pomiędzy sygnałem oryginalnym a zrekonstruowanym został obliczony jako miara bazowa do oceny jakości kompresji. W porównaniu z innymi algorytmami uzyskano znaczącą poprawę (dwukrotne zmniejszenie średniego błędu kwadratowego względem drugiego najlepszego algorytmu w tej kategorii) 4.2. Przy podobnym współczynniku kompresji parametryzowana dyskretna transformacja falkowa oferuje lepszą jakość zrekonstruowanego sygnału przy podobnym zapotrzebowaniu na pamięć lub przepustowość medium transmisyjnego.



Rysunek 4.2: Statystyki średniego błędu kwadratowego dla wszystkich porównywanych metod.

4.1.3 Wnioski

Choć proponowana metoda parametryzacji nie przewyższa innych algorytmów we wszystkich metrykach, pokazuje, że podobny współczynnik kompresji można osiągnąć przy mniejszym średnim błędzie kwadratowym. Przedstawiona metoda oferuje lepszy kompromis pomiędzy rozmiarem skompresowanych danych a jakością zrekonstruowanego sygnału niż algorytmy proponowane w aktualnej literaturze. Sieć neuronowa była trenowana na ograniczonym zbiorze danych, ze względu na wysoki koszt pozyskania wysokiej jakości pomiarów laboratoryjnych. Około 500 sygnałów, zaugmentowanych do około 2000, umożliwiło algorytmowi kompresję danych z lepszą jakością rekonstrukcji przy zachowaniu podobnego współczynnika kompresji.


4.2 Dane syntetyczne

Testy algorytmu na danych rzeczywistych przyniosły obiecujące rezultaty; jednak ilość dostępnych danych okazała się wąskim gardłem metody. Aby to zweryfikować, potrzebne są testy z większą liczbą sygnałów. Struktura sygnałów w sieciach elektroenergetycznych pozwala na wiarygodne ich generowanie. Dane syntetyczne oferują także wysoki poziom kontroli nad ilością i jakością wprowadzanych zniekształceń. Wykorzystanie danych syntetycznych pozwala badać możliwości algorytmu przy dostarczaniu większej liczby sygnałów oraz prowadzić głębszą analizę zależności pomiędzy charakterem zniekształceń a skutecznością kompresji.

Do treningu sieci neuronowej wygenerowano 12 000 próbek sygnałów. Zawierają one różne typy zniekształceń, w tym zjawiska przejściowe oraz zniekształcenia harmoniczne.

4.2.1 Współczynnik kompresji

W porównaniu z innymi algorytmami średni współczynnik kompresji dla proponowanego rozwiązania był około dwukrotnie lepszy. Pokazuje to, że dostarczenie większej ilości wysokiej jakości danych na etapie treningu dodatkowo poprawia wydajność algorytmu. Uzyskanie lepszego współczynnika kompresji wskazuje, że algorytm może zapewnić istotne oszczędności zasobów proporcjonalne do skali systemu.



Rysunek 4.3: Porównanie współczynników kompresji pomiędzy wszystkimi testowanymi algorytmami.

Dane zestawione w tabeli 4.2 wskazują na istotną poprawę współczynnika kompresji. Proponowany algorytm osiągnął minimalną poprawę współczynnika kompresji na poziomie 50,33%, maksymalną 60,18% oraz średnią 50,53% względem drugiego najlepszego algorytmu w tej kategorii.

Parametr	Różnica wartości
Minimum współczynnika kompresji	-50,33%
Maksimum współczynnika kompresji	-60,18%
Średni współczynnik kompresji	-50,53%


Tabela 4.2: Porównanie współczynnika kompresji proponowanego algorytmu i drugiego najlepszego algorytmu w kategorii.

Proponowane rozwiązanie oferowało najlepszy współczynnik kompresji dla każdej próbki w zbiorze danych. Średni współczynnik kompresji był istotnie lepszy niż przy zastosowaniu transformacji falkowej o stałych parametrach. Algorytm kompresji potrafi dostosować się do zmian w sygnale, co stanowi zaletę w nowoczesnych inteligentnych sieciach elektroenergetycznych, gdzie środowisko pracy systemu może często się zmieniać. Każda z grup sygnałów miała inny typ zniekształceń, aby przetestować algorytm w różnych scenariuszach. Ilość zniekształceń harmoniczných i zjawisk przejściowych rosła liniowo w każdej z grup,

jednak współczynnik kompresji oraz straty kompresji nie wykazywały trendu liniowego, co pokazuje, że parametryzacji transformacji falkowej nie można przeprowadzić prostymi metodami, takimi jak drzewo decyzyjne.

4.2.2 Straty kompresji

W zależności od parametryzacji danych treningowych dla sieci neuronowej, poziom średniego błędu kwadratowego może się różnić 4.4. W tym przypadku średni błąd kwadratowy uzyskany metodą kompresji był wyższy niż w metodach statycznie parametryzowanych, lecz nadal pozostawał w akceptowalnym zakresie. W większości przypadków zrekonstruowany sygnał zachowywał istotne zmiany wartości. Algorytm okazał się bardzo skuteczny w zachowaniu zjawisk przejściowych. Sygnały zawierające zniekształcenia harmoniczne również nie traciły tej informacji w procesie kompresji. Algorytm oferuje ponadto wysoką jakość rekonstrukcji dla sygnałów z niewielkimi zniekształceniami, jednocześnie zapewniając bardzo wysoki współczynnik kompresji dla takich sygnałów.



Rysunek 4.4: Statystyki średniego błędu kwadratowego dla wszystkich porównywanych metod.

4.2.3 Wnioski

Po wykorzystaniu większej liczby plików sygnałowych, z pewnością, że każdy z nich zawiera zdefiniowane zniekształcenia, algorytm wykazał znacznie lepszą wydajność, przewyższając rozwiązania uznawane za stan techniki zarówno pod względem współczynnika kompresji, jak i strat kompresji. Pokazuje to, że wydajność algorytmu rośnie proporcjonalnie do ilości i jakości danych użytych do trenowania sieci neuronowej. Porównanie współczynnika kompresji oraz jakości rekonstrukcji dla serii sygnałów o liniowo rosnącej ilości zniekształceń pokazuje, że skuteczność kompresji falkowej nie zmienia się proporcjonalnie do zawartości

zniekształceń. Wynik ten potwierdza, że adaptacja parametrów dyskretnej transformacji falkowej nie może być realizowana w prosty sposób, na przykład przy użyciu drzewa decyzyjnego.

4.3 Czas parametryzacji

Walidacja narzutu czasowego jest kluczowa dla tego rozwiązania, ponieważ ma ono być stosowane w dużych systemach Internetu Rzeczy o ograniczonych zasobach. Niski narzut czasowy jest konieczny, aby system był skuteczny i użyteczny. W porównaniu z bezpośrednim stosowaniem optymalizacji bayesowskiej na dostarczonych danych, proponowane rozwiązanie zużywa istotnie mniej zasobów. Średni czas wykonania równy 0,0011 s pozwala przeprowadzić około 78 545 454 operacji kalibracji dziennie przy uruchomieniu systemu na komputerze osobistym klasy podstawowej. Do roku 2028 w Europie przewiduje się użycie około 326 milionów inteligentnych liczników energii, co oznacza, że parametryzacja każdego inteligentnego licznika energii w Europie z użyciem pojedynczego komputera osobistego zajęłaby mniej niż 5 dni.

Czas obliczeń	Proponowana metoda	Optymalizacja bayesowska	Różnica
Minimum	0,0006 s	2,1888 s	3648 razy szybciej
Maksimum	0,0049 s	3,8016 s	775 razy szybciej
Średnia	0,0011 s	2,8743 s	2613 razy szybciej

Tabela 4.3: Porównanie czasów obliczania parametrów dyskretnej transformacji falkowej. Pomiary wykonano na komputerze Dell Inc. Latitude 5400, 16 GB RAM, procesor Intel® Core™ i5-8365U CPU @ 1,60 GHz × 8, system Ubuntu 22.04.4 LTS 64-bit, Python 3.10.12.

Podsumowując, proponowany system wykazuje lepszą wydajność pod względem współczynnika kompresji, jakości zrekonstruowanego sygnału oraz narzutu czasowego w porównaniu z istniejącymi metodami. Wyniki empiryczne potwierdzają jego potencjał do praktycznego zastosowania w dynamicznych środowiskach o ograniczonych zasobach.

Rozdział 5

Podsumowanie i wkład pracy

Celem badań było usprawnienie wykorzystania dyskretnej transformacji falkowej do kompresji danych w inteligentnych sieciach elektroenergetycznych i systemach Internetu Rzeczy. Przegląd literatury wykazał istotną potrzebę redukcji ilości danych przy zachowaniu jakości rekonstrukcji oraz ograniczenia istniejących metod w kontekście pracy w czasie rzeczywistym i efektywności energetycznej.

Głównym rezultatem pracy jest adaptacyjny system parametryzacji dyskretnej transformacji falkowej, który zapewnia lepszy współczynnik kompresji przy zachowaniu akceptowalnej jakości odtwarzanego sygnału. System jest gotowy do wdrożenia: opracowano oprogramowanie do przygotowania danych, sieć neuronową dobierającą parametry transformacji, oprogramowanie wbudowane w języku C++ oraz ramy walidacyjne. Sieć neuronowa, wytrenowana na zbiorach rzeczywistych i syntetycznych, znacząco skraca czas doboru parametrów, dzięki czemu system nadaje się do zastosowań zbliżonych do czasu rzeczywistego.

Oprogramowanie wbudowane zaprojektowano z myślą o pracy na urządzeniach końcowych Internetu Rzeczy, z naciskiem na wydajność, modułowość i łatwą adaptację do różnych platform sprzętowych. Kryteria walidacyjne umożliwiły ocenę systemu w szerokim zakresie scenariuszy pracy i wykazały przewagę opracowanego rozwiązania nad wybranymi metodami z literatury pod względem współczynnika kompresji i średniego błędu kwadratowego.

Część teoretyczna pracy dotyczyła parametryzacji kompresji falkowej oraz analizy różnych funkcji falkowych pod kątem zastosowań w systemach czujnikowych Internetu Rzeczy. Pozwoliło to zidentyfikować korzystne kompromisy pomiędzy efektywnością kompresji a złożonością obliczeniową oraz zaprojektować skuteczny schemat doboru parametrów.

Do głównych osiągnięć pracy należą:

1. **Nowy sposób parametryzacji dyskretnej transformacji falkowej**, który zapewnia lepszy współczynnik kompresji niż rozwiązania uznawane za stan techniki, przy jednoczesnym zmniejszeniu strat kompresji.
2. Metoda etykietowania sygnałów parametrami transformacji falkowej, które zapewniają najlepszy współczynnik kompresji przy zadanym progu średniego błędu kwadratowego w zdefiniowanej przestrzeni przeszukiwania.

3. Analiza współczynnika kompresji oraz średniego błędu kwadratowego w zbiorach danych w symulacji, w celu weryfikacji wpływu cech sygnału (współczynnika całkowitych zniekształceń harmonicznych oraz zjawisk przejściowych) na skuteczność kompresji.
4. **Przegląd metod kompresji danych w sieciach czujników Internetu Rzeczy.**
5. Przygotowana i przedstawiona **architektura systemu**, która może pracować z rzeczywistymi sygnałami dostarczonymi przez użytkownika lub generować sygnały syntetyczne.
6. **Oprogramowanie czujników w języku C++**, przygotowane do bezpośredniej implementacji na urządzeniach końcowych.
7. **Sieć neuronowa**, która znacząco skraca czas potrzebny na parametryzację systemu kompresji opartego na dyskretnej transformacji falkowej.
8. **Opracowanie teoretyczne** poświęcone kompresji danych, ze szczególnym uwzględnieniem parametryzacji zastosowania dyskretnej transformacji falkowej w procesie kompresji.

Opracowana metodyka ulepsza stosunek poziomu kompresji do błędu średniokwadratowego po rekonstrukcji za pomocą parametryzacji transformacji falkowej. Parametryzacja może odbywać się równolegle do procesu kompresji, dzięki czemu system nie dodaje opóźnień w transmisji sygnału. Zaprezentowane rozwiązanie udowadnia postawioną tezę badawczą oraz realizuje oczekiwane rezultaty. Adaptacyjny charakter rozwiązania oraz jego praktyczna weryfikacja tworzą podstawę do dalszego rozwoju, m.in. poprzez integrację dodatkowych technik uczenia maszynowego, uwzględnienie kryteriów energetycznych oraz wdrożenia w rzeczywistych instalacjach przemysłowych.