

**Uniwersytet Zielonogórski**

**Wydział Elektrotechniki,  
Informatyki i Telekomunikacji**

**Rozprawa doktorska**

**Algorytmy rozpoznawania zespołu QRS  
w sygnałach elektrokardiograficznych  
pochodzących od pacjentów  
z wszczepionym układem stymulującym**

**Agnieszka Duraj**

Promotor:  
Prof. dr hab. inż. Andrzej Krawczyk

Zielona Góra 2007

## Streszczenie

Analiza sygnału elektrokardiograficznego rejestrowanego metodą Holtera w przypadku pacjentów z wszczepionym układem stymulującym pracę serca ma bardzo duże znaczenie diagnostyczne, zarówno pod względem oceny stanu zdrowia pacjenta, jak również pracy samego stymulatora. Skalę zapotrzebowania na prowadzenie badań związanych z analizą sygnałów elektrokardiograficznych rejestrowanych metodą Holtera dla pacjentów z wszczepionym układem stymulującym, można oszacować według liczby wszczepianych stymulatorów, która wzrasta średnio od 8% do 10% rocznie.

Niniejsza rozprawa poświęcona jest zagadnieniu detekcji zespołu QRS i klasyfikacji rytmu endogennego w sygnałach elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca. Szczególny nacisk położono na zastosowanie sieci falkowo – neuronowej do wyżej wymienionej tematyki badań. Sprawdzono również efektywność detekcji zespołu QRS dla algorytmów działających w dziedzinie czasu.

W pierwszej części rozprawy podsumowano aktualny stan wiedzy dotyczący pojęć związanych z elektrokardiografią i stymulatorami. Wskazano na problemy techniczne pojawiające się w trakcie analizy sygnału elektrokardiograficznego oraz rejestrowania sygnału EKG metodą Holtera. Dokonano również konkluzji metod detekcji i klasyfikacji zespołu QRS, wyodrębniając pięć grup, a także porównano wybrane metody.

Druga część rozprawy przedstawia wiadomości dotyczące stosowanych sieci falkowo – neuronowych. Prezentowane są wyniki badań detekcji zespołu QRS oraz klasyfikacji rytmu endogennego pacjentów z wszczepionym układem stymulującym pracę serca. Dodatkowo dokonano analizy i oceny efektywności algorytmów Friesena działających w dziedzinie czasu.

# Abstract

This dissertation presents the problem of detection and classification of QRS complexes with ECG signals coming from patients with implanted cardiac pacemaker. Special attention was focused on the use of wavelet – neural networks in above mentioned subject matter of investigation. Efficiency of detection of QRS complex was examined by algorithms working in time domain.

In the first part of the dissertation, the current knowledge of electrocardiography and pacemaker was summed up. Technical problems with analysing and recording signals by means of the Holter method were indicated. The methods of detection and classification of QRS complex were discussed five groups, not three groups as indicated in literature, were identified. The comparison of the methods was carried out.

Second part was the presentation of knowledge of the use of wavelet – neural networks. It mainly presents the results of detection of QRS complex and classification of the endogenic rhythm. The efficiency of algorithms working in time domain was analysed and evaluated.

PhD dissertation has six chapters. The order of the chapters, except introduction and conclusions, reflects the chronology of research work.

The first chapter is of introductory nature and is divided into three parts. In this chapter the notions connected with electrocardiography, pacemaker and stimulation were explained. The final part was devoted to technical problems connected with digital representation of electrocardiography signal directly.

The second chapter presents a sort of characteristics of the methods of detection and classification of QRS complexes. Five groups of methods were identified. They include algorithms based on:

- 1) time domain;
- 2) frequency domain;
- 3) time-frequency domain;
- 4) artificial intelligence like
  - a. neural networks

- b. support vector machine
  - c. genetic algorithms
- 5) different mathematic algorithms.

In the third chapter comparative analysis of chosen algorithms of QRS complex detection was carried out. Assessment of the effectiveness of their performance was shown on the basis of four problematic standard signals taken from freely available MIT-BIH database (<http://ecg.mit.edu>). Conclusions resulting from the analysis point at a necessity of research continuation as well as a search for the best detection method for stimulator electrocardiograph signals, which will be discussed in next chapters.

The subject-matter of the fourth chapter IV was divided into two parts. In the first one, characteristics of pacemaker electrocardiography signals gathered in the base was made. A great differentiation of the signals was observed with respect to content of endogenic rhythm, the applied mode of stimulation and the clinical recognition. The final part of this chapter introduced the results of investigations on detection of QRS complex for nine Friesen algorithms. The Friesen algorithms work in time domain and are based on amplitude and the first derivative, the first and second derivative, the first derivative only, and digital filters.

The fifth Chapter V presents the basis of mathematical method which was suggested in the dissertation. This chapter was divided into three parts due to the combination of two disciplines such as wavelet transform and neural networks. Two parts describe these disciplines. The final part characterizes the combination of these two methods the description of adopted wavelet-neural networks solution.

The sixth Chapter VI presents the results of investigation regarding the detection of QRS complex and its classification for applied wavelet – neural networks. During the investigation a lot of attention was paid to good selection of level decomposition, good choice of detection threshold as well as choice of wavelet transformation. In case of identification of endogenic rhythm attention was paid to architecture of feedforward neural network, selection of teaching file and the accuracy of classification depending on the activation function used.

Conducted research has led to the formulation of following conclusions:

- 1) Neural networks and wavelet transform can be used with good result as algorithms for detection of QRS complex in standards electrocardiography signals. (Above conclusion was showed in chapter III)
- 2) Friesen algorithms working in time domains as the detectors of QRS complex generate a lot of false (negative) detection (FN) and true (positive) detection (FP) for pacemaker electrocardiography signals. (This conclusion was showed in chapter IV).
- 3) Friesen algorithms lead to very big detection error and very low sensitivity in case of pacemaker electrocardiography signals. (This conclusion was showed in chapter IV).
- 4) Friesen algorithms should not be used in real analysis systems for pacemaker electrocardiography signals.
- 5) In case of the proposed wavelet-neural networks for pacemaker electrocardiography signals, to achieve best classification results it is necessary to apply:
  - a. fourth level decomposition,
  - b. detection threshold equaling 0,6
  - c. bioorthogonal wavelet
  - d. feedforward neural networks composed of three hidden layer with 30 hidden neuron

On the basis of the above results, it can be concluded, that it is possible to detect QRS complex and classify the endogenic rhythms in electrocardiography signals coming from patients with implanted pacemaker by means of wavelet – neural networks.

The results of this detection and classification are comparable with results presented in chapter II, III and IV regarding efficiency and accuracy. **The main thesis of dissertation has was proved.**

# Spis treści

<b>Streszczenie .....</b>	<b>i</b>
<b>Abstract.....</b>	<b>ii</b>
<b>Wykaz wybranych skrótów .....</b>	<b>5</b>
<b>Wstęp .....</b>	<b>6</b>
Motywy podjęcia badań .....	8
Tezy pracy .....	9
Cele i zadania pracy .....	10
Ograniczenia prowadzonych badań.....	10
Układ pracy .....	11
<b>Rozdział I</b>	
<b>Wprowadzenie teoretyczne do zagadnień elektrokardiografii i układów stymulujących – pojęcia ogólne.....</b>	<b>13</b>
1.1    Elektrokardiografia.....	14
1.1.1    Zespół QRS .....	15
1.2    Układ stymulujący pracę serca.....	17
1.2.1    Typy stymulacji i system ich oznaczania .....	19
1.2.2    Analiza stymulatorowego zapisu EKG .....	22
1.3    Problemy techniczne związane z rejestracją i analizą sygnału elektrokardiograficznego.....	22
1.3.1    Dyskretna reprezentacja sygnału.....	22
1.3.2    Zakłócenia .....	25
1.3.3    Sposoby redukcji zakłóceń.....	27
1.3.3.1    Uśrednianie sygnału .....	27
1.3.3.2    Sposoby redukcji zakłóceń – filtracja .....	29
1.4    Podsumowanie rozdziału.....	30
<b>Rozdział II</b>	
<b>Metody detekcji i klasyfikacji zespołu QRS.....</b>	<b>32</b>
2.1    Detekcja zespołu QRS w dziedzinie czasu.....	34
2.2    Detekcja zespołu QRS w dziedzinie częstotliwości.....	36
2.3    Detekcja i klasyfikacja w dziedzinie czasowo – częstotliwościowej....	38
2.4    Detekcja i klasyfikacja oparta o sztuczną inteligencję.....	40
2.4.1    Algorytmy oparte o sieci neuronowe .....	41
2.4.1.1    Rozmyte sztuczne sieci neuronowe.....	43
2.4.1.2    Sieci falkowo – neuronowe .....	45
2.4.2    Algorytmy oparte o klasyfikatory maksymalno-odległościowe ...	46
2.4.3    Algorytmy oparte o algorytmy genetyczne .....	47
2.5    Inne rozwiązania algorytmiczne.....	48
2.6    Podsumowanie rozdziału.....	48

**Rozdział III**  
**Analiza porównawcza metod detekcji sygnałów elektrokardiograficznych pochodzących z bazy MIT-BIH..... 50**

3.1	Metody oceny testowania algorytmów detekcji zespołu QRS.....	51
3.2	Analiza porównawcza wybranych algorytmów detekcji zespołu QRS dla sygnałów elektrokardiograficznych z bazy MIT-BIH.....	54
3.2.1	Analiza porównawcza algorytmów dla sygnału 105.....	57
3.2.2	Analiza porównawcza algorytmów dla sygnału 108.....	60
3.2.3	Analiza porównawcza algorytmów dla sygnałów 203 i 222.....	63
3.3	Podsumowanie rozdziału.....	65

**Rozdział IV**  
**Ocena działania wybranych algorytmów detekcji zespołu QRS dla sygnałów EKG stymulatorowych..... 68**

4.1	Charakterystyka zgromadzonych sygnałów elektrokardiograficznych stymulatorowych .....	69
4.2	Ocena algorytmów z dziedziny czasu .....	73
4.2.1	Analiza algorytmów Friesena opartych o amplitudę i pierwszą pochodną .....	74
4.2.2	Analiza algorytmów Friesena opartych o pierwszą pochodną .....	78
4.2.3	Analiza algorytmów Friesena opartych na pierwszej i drugiej pochodnej.....	82
4.2.4	Analiza algorytmów Friesena opartych o filtry cyfrowe.....	85
4.3	Uwagi podsumowujące .....	86

**Rozdział V**  
**Zastosowanie sieci falkowo – neuronowej Opis metody ..... 89**

5.1	Przekształcenia falkowe .....	89
5.1.1	Przekształcenia falkowe .....	90
5.1.1.1	Ciągłe przekształcenie falkowe.....	92
5.1.1.2	Dyskretne przekształcenie falkowe.....	92
5.2	Wielorozdzielcza dekompozycja sygnału .....	94
5.2.1	Postulaty wprowadzające .....	96
5.2.1.1	Analiza podanych warunków początkowych.....	96
5.2.2	Algorytm wielopoziomowej dekompozycji sygnału.....	97
5.3	Przykłady konstrukcji dwóch wybranych falek .....	102
5.3.1	Falka Haara.....	102
5.3.2	Falki Daubechies .....	104
5.4	Sztuczne sieci neuronowe .....	108
5.5	Wybrane typy sieci neuronowych i ich sposoby uczenia.....	110
5.5.1	Sieci jednokierunkowe wielowarstwowe .....	110
5.6	Sieć falkowo – neuronowa .....	114
5.6.1	Koncepcja klasyczna .....	114
5.6.2	Koncepcja intuicyjna.....	115
5.6.3	Rozwiązanie WNN przystosowane do zdefiniowanego w rozprawie problemu .....	116

5.6.3.1	Blok I – Dekompozycja sygnału .....	117
5.6.3.2	Blok II – Stosowane struktury sieci neuronowych.....	118
5.7	Podsumowanie rozdziału.....	120
<b>Rozdział VI</b>		
<b>Wyniki badań.....</b>		<b>121</b>
6.1	Dobór poziomu dekompozycji .....	121
6.2	Dobór progu detekcyjnego .....	128
6.3	Dobór falki .....	132
6.3.1	Detekcja zespołu QRS a dobór falki .....	134
6.4	Rozpoznanie rytmu endogennego .....	140
6.4.1	Dobór zbioru uczącego.....	140
6.4.2	Dobór architektury sieci neuronowej .....	141
6.4.3	Dokładność sieci neuronowych w zależności od stosowanej funkcji aktywacji.....	144
6.5	Podsumowanie rozdziału – wnioski .....	146
<b>Zakończenie .....</b>		<b>148</b>
<b>Literatura .....</b>		<b>153</b>
<b>Spis tabel .....</b>		<b>172</b>
<b>Spis rysunków .....</b>		<b>174</b>
<b>Dodatek A</b>		
<b>Odprowadzenia i techniki rejestracji badania EKG.....</b>		<b>178</b>
<b>Dodatek B</b>		
<b>Związki zachodzące w sercu i ich wpływ na zmiany pola elektrycznego oraz związany z tym proces tworzenia elektrokardiogramu.....</b>		<b>184</b>
<b>Dodatek C</b>		
<b>Przykłady sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym.....</b>		<b>185</b>



## Wykaz wybranych skrótów

<b>Skrót</b>	<b>Nazwa w języku polskim</b>	<b>English</b>
BD	błąd detekcyjny	<i>detection error</i>
BP	algorytm wstecznej propagacji błędu	<i>error back – propagation</i>
CWT	ciągłe przekształcenia falkowe	<i>continuous wavelet transform</i>
DWT	dyskretne przekształcenia falkowe	<i>discrete wavelet transform</i>
DyWT	diadyczne przekształcenia falkowe	<i>dyadic wavelet transform</i>
EKG	Sygnal elektrokardiograficzny	<i>electrocardiography signal</i>
FN	detekcja fałszywie negatywna	<i>false-negative detection</i>
FP	detekcja fałszywie pozytywna	<i>false-positive detection</i>
MLP	Jednokierunkowe sieci neuronowe wielowarstwowe (wielowarstwowe perceptrony)	<i>multi-layer perceptrons, feedforward neural networks</i>
PPV (+P)	dodatnia wartość prognostyczna	<i>positive predictivity value</i>
QRS	Zespół QRS	<i>QRS complex</i>
R	odsetek poprawnych detekcji	<i>reliability</i>
SE	czułość	<i>sensitivity</i>
TP	detekcja prawdziwie pozytywna	<i>true-positive detection</i>
WNN	sieci falkowo-neuronowych	<i>wavelet neural networks</i>
WT	przekształcenia falkowe	<i>wavelet transform</i>

# Wstęp

W ostatnich kilkunastu latach postęp w technologii układów elektronicznych oraz inżynierii oprogramowania sprawił, iż medycyna wzbogaciła się o nowe jakościowo techniki z zakresu diagnostyki i terapii. Szczególnym zainteresowaniem cieszą się nieinwazyjne metody diagnostyczne, dzięki którym można „zajrzeć” do wnętrza ludzkiego organizmu i prześledzić budowę anatomiczną, a także dynamikę działania narządów. Tego typu badaniem jest m.in. elektrokardiografia.

Analiza sygnału elektrokardiograficznego rejestrowanego metodą Holtera w przypadku pacjentów z wszczepionym układem stymulującym pracę serca ma bardzo duże znaczenie diagnostyczne, zarówno pod względem oceny stanu zdrowia pacjenta, jak również pracy samego stymulatora. Badanie holterowskie umożliwia w szczególności: wykrycie zaburzeń sterowania i stymulacji, „proarytmiczny” wpływ stymulacji, kontrolę prawidłowego funkcjonowania czynności czujników (tzw. biosensorów), optymalny dobór wszystkich parametrów (stymulacji i sterowania) dla danego pacjenta, statystyczną analizę zachowania się stymulatora w trakcie codziennej aktywności pacjenta. Skalę zapotrzebowania na prowadzenie badań związanych z analizą sygnałów elektrokardiograficznych rejestrowanych metodą Holtera dla pacjentów z wszczepionym układem stymulującym można oszacować według liczby wszczepianych stymulatorów, która wzrasta średnio od 8% do 10% rocznie.

Ogromne zainteresowanie sygnałem elektrokardiograficznym wynika nie tylko z ludzkiej ciekawości i chęci poznania zjawisk zachodzących w narządach człowieka, ale także z doniosłości układu krążenia. Dużą rolę odgrywają tutaj takie cechy badania elektrokardiograficznego, jak nieinwazyjność, dzięki której można powtórzyć wielokrotnie diagnozę u tego samego pacjenta oraz niski koszt, pozwalający na znaczny wzrost liczby wykonywanych co roku na świecie rejestracji elektrokardiograficznych. Złożona natura sygnału elektrokardiograficznego oraz szereg uwarunkowań technicznych stymuluje ciągły rozwój prac badawczych w tym zakresie.

Duże zainteresowanie naukowców sygnałem elektrokardiograficznym, a także informatyczna rewolucja ubiegłego stulecia stworzyły nowe perspektywy

rozwoju wielu dziedzin nauki, także medycyny. Pierwszy rozkwit badań przypadający na lata 60. i 70. dotyczył wykorzystania komputerów do przetwarzania i uśredniania sygnału elektrokardiograficznego. W obliczu minionego czasu wielu autorów uważa, iż podstawowym zastosowaniem komputera w kardiologii jest właśnie analiza elektrokardiogramów [204, 140].

Obecnie w literaturze naukowej można odnaleźć kilka nurtów badań w tym zakresie. Pierwszy z nich dotyczy filtracji z sygnału wszystkich zakłóceń i szumów, które mają zasadniczy wpływ na komputerową analizę sygnału EKG. Drugi kierunek badań, to kompresja sygnału elektrokardiograficznego i związane z nią zagadnienia redukcji objętości plików oraz wiernego odtworzenia wszystkich informacji diagnostycznych zawartych w analizowanym sygnale. Jest to bardzo istotne w przypadku długookresowego rejestrowania i monitorowania sygnału EKG, na przykład podczas rejestracji sygnału elektrokardiograficznego metodą Holtera. Tę grupę badań można odnaleźć w licznych pracach zagranicznych np. [113, 177, 257] oraz wielu publikacjach krajowych np. [18, 20]. Nie sposób wymienić wszystkich opracowań dotyczących tej problematyki. Warto jednak zapoznać się choćby z pracami Augustyniaka. Przykładowo w [20] autor dokonuje bardzo obszernej syntezy literatury z zakresu metod kompresji sygnałów elektrokardiograficznych, a także proponuje własne czasowo – częstotliwościowe algorytmy. Kolejnym nurtem badań jest rozpoznawanie i analiza wartości diagnostycznych sygnału. Proces detekcji poszczególnych odcinków jest bardzo trudny i złożony. W pracy omówiony został jedynie mały fragment całkowitej analizy sygnału elektrokardiograficznego, a mianowicie wykrycie zespołu QRS z pominięciem pozostałych fal. W literaturze, oprócz publikacji dotyczących wykrycia fal P, T, odnaleźć można także badania z zakresu kardiologii dziecięcej i płodowej. Sygnały EKG pochodzące od wyżej wymienionych grup pacjentów charakteryzują się innymi właściwościami, dlatego też stanowią oddzielną grupę badań związanych z analizą sygnału EKG, którą pominięto w niniejszej rozprawie. Zainteresowani mogą znaleźć szczegółowe informacje w pracach Jeżewskiego [121], Moczko [180] i wielu innych.

## **Motywy podjęcia badań**

Analiza przetwarzanych sygnałów elektrokardiograficznych, jak wykazano wyżej, jest niezwykle potrzebna, ciekawa i inspirująca. Z drugiej strony, ta nowa, bardzo wymagająca i jednocześnie niełatwa, dziedzina wiedzy ma szerokie perspektywy rozwoju. Analiza krajowej i zagranicznej literatury przedmiotu dotyczącej wszystkich kierunków badań związanych z elektrokardiografią wykazała brak opracowań dotyczących prowadzenia badań w zakresie wykrywania zespołu QRS w sygnałach EKG pochodzących od pacjentów z wszczepionym układem stymulującym.

Dodatkowo, podjęta w niniejszej rozprawie problematyka badawcza, uzyskała duże poparcie środowiska medycznego (ośrodków implantujących układy stymulujące serca). Rozpoczęta współpraca z Instytutem Kardiologii w Warszawie, Katedrą i Kliniką Kardiologii Akademii Medycznej w Warszawie oraz Collegium Medicum Uniwersytetu Jagiellońskiego w Krakowie potwierdza słuszność wyboru takiego zakresu badań. We wszystkich ośrodkach medycznych stwierdzono, iż:

- 1) detekcja zespołu QRS w badanych rozrusznikach nie daje jednoznacznej odpowiedzi co do jego występowania, a przez to nie jest wiarygodnym źródłem informacji;
- 2) wyniki, uzyskane za pomocą funkcji diagnostycznych stymulatora są traktowane przez kardiologów z wielką ostrożnością;
- 3) funkcjonujące oprogramowanie oceniające rytm endogeny w stymulatorach nie może służyć jako jedyna wiarygodna metoda diagnostyczna.

Detekcja zespołu QRS stanowi punkt wyjścia w całej analizie sygnału elektrokardiograficznego oraz stanowi integralną część każdego systemu. Istotny jest również fakt, iż dokładność wykrycia zespołu QRS wpływa na jakość działania całego systemu.

Wydaje się zatem, iż zaproponowany problem badawczy nie jest do końca rozpoznany zarówno w kraju, jak i na świecie. Istnieją zatem przesłanki do prowadzenia badań w tym właśnie zakresie.

Niniejsza rozprawa ma charakter interdyscyplinarny, dotyczy rozpoznawania zespołu QRS z jednoczesną klasyfikacją rytmu endogenego w sygnałach elektrokardiograficznych pochodzących od pacjentów

z wszczepionym układem stymulującym, które w dalszej części pracy skrótowo nazywane będą sygnałami elektrokardiograficznymi – stymulatorowymi.

## **Tezy pracy**

Konieczność poszukiwania nowych algorytmów, udoskonalających proces detekcji zespołu QRS i rozpoznawania rytmu własnego (endogennego) pacjenta, jest bezsporna i jak najbardziej uzasadniona. Analiza literatury przedmiotu daje nadzieję na podwyższenie precyzji i niezawodności algorytmów poprzez łączenie różnych technologii cyfrowego przetwarzania sygnałów. Wydaje się, iż sieci falkowo – neuronowe, jako nowoczesna metoda, mogą spełnić te oczekiwania, podwyższyć precyzję i dokładność rozpoznania oraz klasyfikacji. W niniejszej rozprawie postawiono zatem następującą główną tezę oraz wysuniętą z przesłanek literaturowych tezę pomocniczą.

### **TEZA GŁÓWNA:**

Możliwa jest detekcja zespołu QRS i klasyfikacja rytmu endogennego w sygnałach elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca przy wykorzystaniu sieci falkowo - neuronowej.

Wyniki detekcji są porównywalne lub lepsze, w sensie dokładności rozpoznawania i klasyfikacji, w stosunku do metod opisywanych w literaturze.

### **TEZA POMOCNICZA:**

Algorytmy Friesena działające w dziedzinie czasu generują dużą liczbę detekcji fałszywie pozytywnej oraz fałszywie negatywnej w przypadku sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca.

## **Cele i zadania pracy**

Głównym celem niniejszej rozprawy jest zaproponowanie **algorytmu wykrywającego zespół QRS z jednoczesną klasyfikacją rytmu endogenego w sygnałach elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca.**

W trakcie prowadzonych badań wyznaczono również następujące zadania:

1. Dokonanie analizy i porównania algorytmów detekcji zespołu QRS dla sygnałów elektrokardiograficznych pochodzących z bazy MIT-BIH. Porównanie to ma na celu wyznaczenie algorytmów uzyskujących najlepszą czułość, a zarazem najmniejszy błąd detekcyjny;
2. Dokonanie oceny działania algorytmów detekcji zespołu QRS dla sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca;
3. Propozycja nowego sposobu detekcji zespołu QRS i klasyfikacji rytmu endogenego dla sygnałów elektrokardiograficznych – stymulatorowych;
4. Sprawdzenie wad i zalet nowo zaproponowanego narzędzia dla postawionego zadania detekcji zespołu QRS i rozpoznania rytmu endogenego pacjentów z wszczepionym układem stymulującym.

## **Ograniczenia prowadzonych badań**

W trakcie realizacji powyżej omówionych celów oraz badań poprawności postawionych tez wprowadzono następujące ograniczenia:

1. W przeprowadzonych badaniach dotyczących rozpoznawania zespołu QRS i jego klasyfikacji na rytm endogeny oraz stymulatorowy nie stosowano filtracji sygnału elektrokardiograficznego – stymulatorowego. Nie wyznaczano tzw. współczynnika poziomu szumu w sygnale. Usunięcie szumów i artefaktów mogłoby stanowić odrębne opracowanie, dlatego też nie brano pod uwagę procesu i metod filtracyjnych. Stosowane zaś metody czasowo – częstotliwościowe tylko częściowo radzą sobie z zawartym w sygnale szumem, nieznacznie wygładzając sygnał EKG;
2. W trakcie analizowania sygnałów, poprzez wyznaczenie zespołów QRS oraz dokonanie klasyfikacji rytmu, nie podawano typu stymulacji oraz typu biegunowości układu stymulującego.

3. Na potrzeby niniejszej rozprawy wszystkie wykonywane badania dotyczyły tylko jednego kanału. Nie stosowano automatycznej zmiany ścieżki.

Niestabilność biologicznych uwarunkowań sygnału jest powodem projektowania algorytmów, w których wybór kanału sygnału podlega ciągłej optymalizacji. Takie rozwiązanie, z automatyczną zmianą ścieżki zapisu sygnału, proponują np. Augustyniak, Wrześniowski w [21]. Detektor wykorzystujący kilka odprowadzeń i zmieniający kanał ma wiele zalet m.in.: powoduje polepszenie stosunku sygnał – szum, ponieważ w różnych kanałach zakłócenia są ze sobą nieskorelowane. Dodatkowo, jeżeli w jednym odprowadzeniu zespół QRS jest mały, to w innym duży (największy efekt uzyskuje się dla odprowadzeń ortogonalnych).

Wydaje się, iż na wyniki detekcji zespołu QRS mogą wpływać wszystkie powyżej wymienione ograniczenia.

## **Układ pracy**

Kolejność sześciu rozdziałów zawartych w niniejszej rozprawie, oprócz wstępu i zakończenia, odpowiada chronologii wykonywanych prac badawczych.

Rozdział I ma charakter wprowadzający i został podzielony na trzy części. Przedstawione w tym rozdziale rozważania służą wyjaśnieniu pojęć związanych z elektrokardiografią i stymulacją. W ostatnim punkcie omówiono zaś problemy techniczne, bezpośrednio związane z dyskretną reprezentacją sygnału elektrokardiograficznego.

Rozdział II prezentuje krótką charakterystykę metod detekcji i klasyfikacji zespołu QRS, z wyodrębnieniem pięciu grup. Należą do nich: algorytmy działające w dziedzinie czasu, w dziedzinie częstotliwości, w dziedzinie czasowo–częstotliwościowej, algorytmy opierające się na sztucznej inteligencji (w tym: sieciach neuronowych, klasyfikatorach maksymalnodległościowych, algorytmach genetycznych) oraz na innych rozwiązaniach algorytmicznych.

W rozdziale III dokonano analizy porównawczej wybranych algorytmów detekcji zespołu QRS opisanych w rozdziale II. Ocena poprawności ich działania ukazano na podstawie czterech problemowych sygnałów elektrokardiograficznych pochodzących z ogólnodostępnej bazy MIT – BIH. Wnioski płynące z analiz oparte zostały na omówionych w tym rozdziale metodach oceny testowania

algorytmów detekcji zespołu QRS. Przedstawienie porównania algorytmów detekcji wydaje się konieczne z punktu widzenia dalszej kontynuacji prac badawczych i poszukiwania najlepszej metody detekcyjnej dla omawianych w kolejnych rozdziałach pracy sygnałów elektrokardiograficznych – stymulatorowych.

Tematyka rozdziału IV pracy podzielona została na dwie części. W pierwszej dokonano charakterystyki zgromadzonej bazy sygnałów elektrokardiograficznych – stymulatorowych. Wykazano duże zróżnicowanie sygnałów zarówno pod względem zawartości rytmu endogennego, zastosowanego trybu stymulacji, jak i rozpoznania klinicznego. W kolejnym punkcie przedstawiono zaś wyniki badań dotyczące wykrywania zespołu QRS przy wykorzystaniu dziewięciu algorytmów Friesena działających w dziedzinie czasu.

W rozdziale V prezentowane są matematyczne podstawy proponowanej w rozprawie metody wykorzystującej sieci falkowo – neuronowe do detekcji zespołu QRS dla sygnałów elektrokardiograficznych – stymulatorowych. Ze względu na połączenie dwóch dziedzin, rozdział ten podzielony został na trzy części. Pierwsze dwa punkty dotyczą problematyki z zakresu przekształceń falkowych oraz stosowanych jednokierunkowych sieci neuronowych. Ostatnia część charakteryzuje zaś sposób połączenia tych dyscyplin i przyjętego rozwiązania sieci falkowo – neuronowej.

Rozdział VI prezentuje wyniki badań dotyczące detekcji zespołu QRS i jego klasyfikacji na rytm endogeny i stymulatorowy dla zastosowanej sieci falkowo – neuronowej. W trakcie przeprowadzania badań dużą uwagę skoncentrowano na odpowiednim doborze poziomu dekompozycji, wyborze progu detekcyjnego oraz wyborze falki. Przy rozpoznawaniu rytmu endogenego zwrócono uwagę na dobór zbioru uczącego, architekturę sieci oraz dokładność klasyfikacji w zależności od stosowanej funkcji aktywacji.



# **Rozdział I**

## **Wprowadzenie teoretyczne do zagadnień elektrokardiografii i układów stymulujących – pojęcia ogólne**

W organizmie człowieka istnieje pole elektromagnetyczne o różnym pochodzeniu, które jest mierzalne i można je modelować matematycznie. Matematyczny opis środowiska elektromagnetycznego jest jednak trudny i skomplikowany, zależy on od wielu czynników (np. częstotliwości, własności elektrycznych, rozmiarów organizmu, itp.). Szeroko problem ten wyjaśniony został m.in. w pracy [75].

Źródłem prądów bioelektrycznych, odpowiedzialnych za powstawanie w organizmie człowieka zmiennego pola elektrycznego oraz magnetycznego, są mechanizmy przemieszczające jony przez błony komórek mięśnia sercowego. Zgodnie z teorią pola elektromagnetycznego Maxwella, zmiany pola magnetycznego inicjują zmienne pole elektryczne. Przy bardzo małych częstotliwościach fal elektromagnetycznych, z którymi mamy do czynienia podczas pracy serca (są to tzw. niskoczęstotliwościowe fale elektromagnetyczne), uzasadnione jest oddzielne rozpatrywanie pola elektrycznego i pola magnetycznego. W związku z tym, pominięto zmiany powstałe w wyniku działania pola magnetycznego (tzw. magnetokardiografię), a w dalszej części tego rozdziału omówiono jedynie zmiany pola elektrycznego – elektrokardiografię.

W niniejszym rozdziale zostaną przedstawione jedynie podstawowe informacje z zakresu elektrokardiografii oraz stymulacji, bezpośrednio łączące się z przedmiotem badań zawartych w rozprawie. Szerzej, choć także w ograniczony sposób, zostaną omówione problemy techniczne związane z dyskretną reprezentacją sygnału (tj.: próbkowanie, ograniczanie, uśrednianie i filtracja sygnału). W rozdziale tym można zatem wyróżnić trzy części. Pierwsze dwie części odnoszące się do wiadomości z zakresu elektrokardiografii, z pominięciem informacji z podstaw budowy, funkcjonowania serca oraz kardiochirurgii, a ściślej układu stymulującego pracę serca (typy i rodzaje stymulacji). Kolejny

punkt rozdziału wprowadza w tematykę problemów związanych z rejestracją i analizą sygnału elektrokardiograficznego.

## 1.1 Elektrokardiografia

Rezultatem złożonych zjawisk bioenergetycznych oraz bioelektrycznych jest aktywność elektryczna i magnetyczna serca. Komórki układu przewodzenia, zwane inaczej komórkami rozrusznikowymi, mają właściwości autonomicznej powolnej depolaryzacji, bez zewnętrznych pobudzeń. Do komórek rozrusznikowych zalicza się komórki: węzła zatokowo – przedsionkowego, węzła przedsionkowo – komorowego, pęczka Hisa, a także komórki włókien Purkiniego [81]. Elektrokardiografia jest nieinwazyjną metodą badania w czasie różnicy potencjałów elektrycznych występujących między wybranymi punktami ciała pacjenta (na powierzchni lub wewnątrz ścian serca) mierzonych za pomocą elektrod. Często używa się pojęcia „odprowadzenie elektrokardiograficzne” doprecyzowanego zgodnie z definicją 1.1.

### **Definicja 1.1**

**Odprowadzeniem elektrokardiograficznym** nazywamy obwód elektryczny składający się z dwóch elektrod, umieszczonych na powierzchni ciała pacjenta i połączonych przewodami z galwanometrem elektrokardiografu, który wskazuje różnicę napięć między elektrodami.

Pierwszy wykres zmian napięć wytwarzanych przez serce zarejestrował W. Einthoven w 1903 roku. Badania opublikował w 1906 r. w miesięczniku „La electrocardiogramme”, zaś w 1924 r. za odkrycie mechanizmu elektrokardiogramu został uhonorowany nagrodą Nobla (patrz [79]).

Ponad stuletni rozwój cyfrowego przetwarzania sygnałów, a przede wszystkim zróżnicowanie informacji diagnostycznych, które uzyskuje się w każdej technice rejestracji, spowodował wyodrębnienie kilku gałęzi dotyczących zapisu sygnału elektrokardiograficznego. Są to m.in.: standardowe 12 – odprowadzeniowe badanie EKG, 24 – godzinny zapis EKG metodą Holtera, elektrokardiograficzny test wysiłkowy, jak również elektrokardiografia wysokiej rozdzielczości. Szersze wiadomości dotyczące odprowadzeń

elektrokardiograficznych oraz sposobów rejestracji sygnału EKG przedstawiono w Dodatku A niniejszej rozprawy.

Celem elektrokardiografii jest dostarczanie informacji o zmieniającym się polu elektrycznym na powierzchni zewnętrznej organizmu, w wyniku zachodzących procesów bioelektrycznych, a przede wszystkim zdiagnozowanie pracy serca na podstawie obserwacji tych zjawisk. Sekwencje wychyleń sygnału EKG oznaczone zostały przez Einthovena kolejnymi literami alfabetu P, Q, R, S, T i związane są z polaryzacją oraz depolaryzacją przedsionków, i komór serca. W dodatku B zamieszczono schemat obrazujący związki zachodzące w sercu i ich wpływ na zmiany pola elektrycznego oraz związany z tym proces tworzenia elektrokardiogramu.

Należy podkreślić, iż właściwości sygnału elektrokardiologicznego są bardzo zróżnicowane. Zależą zarówno od czynników fizjologicznych, takich jak indywidualne cechy anatomiczne człowieka (budowa klatki piersiowej, wiek, płeć), dużej różnorodności w kształtach odcinków, dużej zmienności częstości rytmu serca (ulega zmianie od 60 do 200 uderzeń na minutę) [14,63], jak i od uwarunkowań technicznych pochodzących od zjawisk elektromagnetycznych, elektrostatycznych oraz magnetycznych. Są to głównie błędy techniczne, zanieczyszczenie elektrod, drżenia mięśniowe, szумы harmoniczne. Wszelkie normy i granice dotyczące wystąpienia, czasu trwania i wysokości poszczególnych odcinków elektrokardiogramu wynikają z nagromadzonych doświadczeń wielu specjalistów.


### **1.1.1 Zespół QRS**

Mianem zespołu QRS określa się trzy występujące obok siebie punkty elektrokardiogramu tworzące wychylenie w kształcie wąskiego impulsu. Zespół QRS odzwierciedla elektryczną aktywność serca podczas skurczu komorowego. Reprezentuje pobudzenie, czyli depolaryzację komór. Jego ukształtowanie zależy od odprowadzenia i już w prawidłowych warunkach ulega znacznym wahaniom, które wiążą się z powyżej wymienionymi właściwościami sygnału (z położeniem serca i skręcaniem dookoła jego osi).

Zespół QRS charakteryzuje się najwyższym wychyleniem i najkrótszym czasem trwania, co sprawia, że posiada on szerokie widmo częstotliwościowe. Charakterystyczny kształt tego zespołu oraz czas jego pojawiania się dostarcza

najwięcej informacji diagnostycznych o bieżącym stanie serca i dlatego też jest punktem wyjściowym do klasyfikacji schematu cyklu sercowego. Służy też jako podstawa do automatycznego określania rytmu. Wykrycie zespołu QRS dostarcza podstawowych zasad i informacji dla prawie wszystkich automatycznych algorytmów analizy EKG. Umożliwia prowadzenie prac nad określeniem prawidłowego działania stymulatora w przypadku sygnałów pochodzących od pacjentów z wszczepionym układem stymulującym.

Czas trwania i wysokość zespołu QRS zależy od wielu czynników. Przyjmuje się jednak, iż dla osoby dorosłej i zdrowej średni czas trwania powinien obejmować 7 – 18 mm, zaś wysokość 0,7 – 1,8 mV. Natomiast czas szerzenia się depolaryzacji komórek nie powinien przekroczyć 90 ms (jest zależny od częstości rytmu serca). Sygnał elektrokardiograficzny z zaznaczonym zespołem QRS oraz pozostałymi załamkami przedstawiono na Rys. 1.1. Proces tworzenia poszczególnych załameków elektrokardiogramu wyjaśniono w Dodatku B niniejszej rozprawy.



Rys. 1.1 Sygnał elektrokardiograficzny z zaznaczonymi załamkami.

## 1.2 Układ stymulujący pracę serca

Pierwsze próby oddziaływania elektrycznego na serce rozpoczęły się na początku XX wieku (1929 – 1932) w Niemczech (Siemens), Australii (Lidwell) oraz Stanach Zjednoczonych (Hyman) [87, 278]. Okres II Wojny Światowej i pierwsze lata powojenne nie sprzyjały badaniom nad elektrostymulacją. Dopiero w 1952 roku, po licznych spostrzeżeniach dotyczących oddziaływania prądu elektrycznego na różne tkanki (w tym również serce), Zoll zastosował zewnętrzny stymulator i elektrody wkuwane w klatkę piersiową. Za początek rozwoju elektrostymulacji można uznać rok 1957 i osiągnięcia Weiricha, który wprowadził na powierzchnię klatki piersiowej elektrody nasierdziowe i dołączył do stymulatora zewnętrznego oraz rok 1958, kiedy to Sening w Szwecji dokonał wszczepienia rozrusznika. W Polsce jako pierwsi implantowali rozrusznik Kieturakis, Kozłowski oraz Penson w Gdańsku w 1963 roku. Od tego momentu, przez ponad 40 lat, rozwój mikropotencjałów, a przede wszystkim różnych dziedzin informatyki, doprowadził do udoskonalenia stymulatorów. Dokładny rys historyczny rozwoju elektrostymulacji można odnaleźć zarówno w publikacjach krajowych [87, 91, 166, 167], jak i zagranicznych [88].

Przyczyn nieprawidłowości pracy serca wskazujących na konieczne wszczepienie rozrusznika jest bardzo wiele. Najczęściej układ stymulujący wszczepiany jest w przypadku:

- przedłużającej się asystolii, która może doprowadzić do nagłego zgonu pacjenta,
- patologicznej bradykardii, powodującej często u pacjentów nagłą utratę przytomności,
- zbyt częstych skurczów (tachykardii) lub zbyt rzadkich (bradykardii),
- niewydolności węzła zatokowego, w wyniku którego niemożliwe jest utrzymanie właściwego rytmu serca,
- bloku przedsionkowo – komorowego, (w tym przypadku uzyskujemy niesynchroniczną pracę przedsionków i komór), itp.

Bardzo dokładny opis, jak i precyzyjnie sformułowane wymagania dotyczące wskazań wszczepienia układu stymulującego serce podane są w licznych opracowaniach Polskiego Towarzystwa Kardiologicznego (PTK) (patrz np. [252, 253, 254, 279, 12, 93, 151, 146]). Warto zaznaczyć, iż stanowisko American

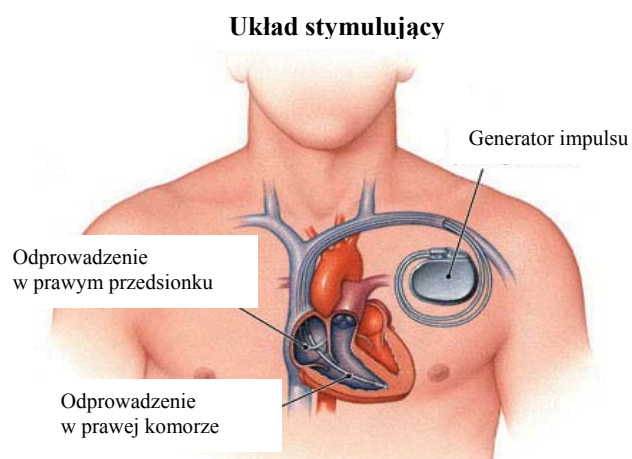
College of Cardiology/American Heart Association (ACC/AHA) [1] nie pokrywa się ze wskazaniami PTK.

Niniejsza rozprawa dotyczy problemu detekcji zespołu QRS w sygnałach elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym. Wydaje się zatem uzasadnione podanie definicji układu stymulującego. (Definicja 1.2).

### **Definicja 1.2**

**Układem stymulującym pracę serca**, inaczej zwanym kardiostymulatorem, stymulatorem lub też rozrusznikiem serca (*ang. cardiac*), nazywamy urządzenie medyczne wszczepiane do organizmu człowieka wytwarzające bodźce elektryczne i sztucznie pobudzające mięsień serca.



Stymulator złożony jest z: generatora impulsów, elektrod stymulujących oraz rejestrujących, baterii oraz układu kontrolującego. Jego zadaniem jest sztuczne pobudzanie mięśnia sercowego w sytuacji, gdy z przyczyn chorobowych dochodzi do uszkodzenia jego naturalnego układu bodźcotwórczego i bodźcoprzewodzącego. Wysyłane przez elektrodę z rozrusznika sygnały (impulsy) w pobliże lub też bezpośrednio do komórek mięśnia sercowego, doprowadzają do natychmiastowej zmiany potencjału wnętrza komórki mięśniowej, czyli do depolaryzacji (patrz [220, 230]). Przykładowy układ stymulujący pokazano na Rys. 1.2.



**Rys. 1.2 Układ stymulujący.**

Obecne stymulatory serca są bardzo precyzyjnymi, elektronicznymi urządzeniami, analizującymi rytm serca pacjenta i podejmującymi stymulację bądź pozostającymi w stanie gotowości (czuwania). Te dwie podstawowe funkcje mogą być dodatkowo uzupełnione rozbudowanym algorytmem analizy. Algorytm ten podejmuje decyzję o wysłaniu impulsu lub wyczuwając rytm własny, może zahamować swoją aktywność – aktywność rozrusznika. Dane techniczne dla kilku stymulatorów aktualnie wszczepianych w Polsce przedstawia Tabela nr 1.1.

**Tabela nr 1.1 Dane techniczne przykładowych stymulatorów.**

	THERA	PHYSIOS TC 01 BIOTRONIC
Amplituda impulsu prądowego	2 i 3 mA	3mA
Impedancja systemu z elektrodą jednobiegunową	< 1kΩ	< 1kΩ
Napięcie zasilania	<4,8V	<4,8V
Bateria litowa		
Napięcie	6,4V	2,8V
Wydajność	1,8Ah	2,0Ah
Waga	23 gramy	38g
Wymiary		8,8x45x51mm
Wygląd		

## 1.2.1 Typy stymulacji i system ich oznaczania

Stymulatory można podzielić ze względu na liczbę pobudzanych jam na:

- stymulatory jednojamowe, które pobudzają przedsionek lub komorę;
- stymulatory dwujamowe pobudzające zarówno przedsionek, jak i komorę;
- stymulatory trój- czterojamowe, w których występuje jednoczesne sterowanie w przedsionku i komorze.

Każdy ze stymulatorów, oprócz wszystkich dobrodziejstw wynikających z ich funkcjonowania, ma także pewne ograniczenia. I tak na przykład, do zalet stymulatorów jednojamowych zaliczyć można niską cenę, prostotę zabiegu wszczepiania i łatwiejszą diagnostykę pacjenta. Wieloletnie badania kliniczne wskazują jednak na pewne niedoskonałości kardiostymulacji jednojamowej.

A mianowicie, u osób z obecnym wstecznym przewodzeniem przedsionkowo – komorowym może pojawić się tzw. syndrom stymulatorowy, którego powodem jest długotrwała praca serca bez prawidłowej synchronizacji przedsionkowo – komorowej (patrz np. [124, 145, 278, 280]).

Obecnie w nazewnictwie polskim stosuje się terminy i skróty dotyczące elektrostymulacji określone przez Północnoamerykańskie i Brytyjskie Towarzystwo Elektrostymulacji (*ang. North American Society of Pacing and Electrophysiology/British Pacing and Electrophysiology Group*) (NASPE/BPEG). Są to pięcioliterowe, choć w Polsce występują najczęściej trzyliterowe, kody opisujące funkcjonowanie danego stymulatora.

Pierwsza litera kodu oznacza miejsce stymulacji. W przypadku stymulacji z pierwszą literą A (*ang. atrium*) wiadomo, iż stosowany jest stymulator jednojamowy, wykorzystujący jedną elektrodę umiejscowioną w prawym przedsionku, a w sygnale elektrokardiograficznym, bezpośrednio po impulsie stymulatora, widoczny jest załamek P. Jeżeli pierwszą literą jest V (*ang. ventricle*), to jedna elektroda umieszczona jest w prawej komorze i bezpośrednio po impulsie stymulatora w sygnale elektrograficznym widoczny jest wystymulowany oraz poszerzony zespół QRS. Istnieje również trzecia opcja – litera D (*ang. dual*), oznaczająca jednoczesną stymulację przedsionka i komory. W tym przypadku następuje para wyładowań stymulatora, tzn. bezpośrednio po pierwszym impulsie następuje załamek P, zaś po drugim impulsie rozszerzony zespół QRS.

Druga litera kodu NASPE/BPEG wskazuje miejsce odbierania impulsów sterujących pracą stymulatora. I tak, w przypadku litery A oznacza, że impulsy sterujące znajdują się w przedsionku, dla V w komorze. Jeśli występuje na drugim miejscu litera D, wówczas odbieranie potencjałów sterujących może odbywać się zarówno w przedsionku, jak i komorze.

Trzecia zaś, określa sposób odpowiedzi stymulatora na rozpoznawany sygnał. Mamy tu do czynienia z następującymi literami: I – hamowanie (*ang. inhibits*), dotyczy jamy, w której został wykryty impuls, T – wyzwalenie (*ang. triggered*), dotyczy drugiej jamy, najczęściej komory. D oznacza zaś połączenie blokowania – hamowania oraz wyzwiania.

Od kilku lat pojawiły się w Polsce czteroliterowe kody stymulacji oznaczające funkcję adaptowalnej częstości stymulacji (*ang. rate adaptive, rate*



response). Ta opcja zawiera informacje typowe dla osób programujących stymulatory, nie zawiera zaś informacji elektrofizjologicznych. Używane są litery:

- P – programowanie proste (*ang. Simple Programmable*), umożliwiające np. w stymulatorze typu AAIP/VVIP zmianę stymulacji z AAI/VVI na AAO/VVO oraz podstawowych parametrów, tj. częstość stymulacji i amplituda napięcia impulsu stymulującego.
- M – programowanie wieloparametrowe (*ang. Multiprogrammable*), oprócz zmian dostępnych w programowaniu prostym, umożliwia także zmianę: szerokości impulsu stymulującego, czułości impulsu własnego, okresu refraktacji stymulatora.
- C – komunikacja dwukierunkowa (*ang. Communicating*), oznaczająca możliwość programowania stymulatora w różnych zakresach, bądź też telemetrycznego komunikowania się z nim. Wyjątek stanowi tutaj użycie litery R (*ang. rate modulation*), bowiem oznacza ona możliwość (zdolność) do zwiększenia częstości stymulacji.

Szczegóły można znaleźć w następującej literaturze [124, 187, 278, 280], zaś uproszczoną wersję aktualnie używanych kodów stymulacji przedstawiono w Tabeli nr 1.2.

**Tabela nr 1.2 Kody stymulacji. Opracowano na podstawie [187].**

Kody NASPE/BPEG					
Pozycja w kodzie	1	2	3	4	5
Opisywany parametr	Miejsce stymulowania jamy	Miejsce odbioru potencjałów sterujących	Sposób odpowiedzi stymulatora	Dodatkowe opcje programowania	Funkcje antyarytmiczne
Oznaczenia	O – brak	O – brak	O – brak	O – brak	B – seria impulsów
	A – przedsionek	A – przedsionek	T – wyzwalenie	P – programowanie proste	N – wolny rytm sztywny
	V – komora	V – komora	I – hamowanie	M – programowanie wieloparametrowe	S – stymulacja programowalna
	D = A + V	D = A + V	D = T + I	C – komunikacja dwukierunkowa  R – adaptacja częstotliwości stymulacji do wysiłku	

## **1.2.2 Analiza stymulatorowego zapisu EKG**

Badanie elektrokardiograficzne, bardzo często wykonywane u osób z wszczepionym układem stymulującym, wprowadza szereg dodatkowych trudności w interpretacji zapisu. Jego prawidłowa ocena i analiza wymaga wiedzy teoretycznej i praktycznej zarówno z zakresu elektrofizjologii klinicznej (podstaw i znajomości zaburzeń przewodzenia, rytmu itp.), jak i podstawowych funkcji poszczególnych typów stymulacji, wzajemnych zależności między funkcjami rozrusznika i występującymi zaburzeniami.

Zaburzenia pracy układu stymulującego, takie jak: brak impulsów stymulatora, nieskuteczna stymulacja, zaburzenia sterowania, czy też zmiany częstotliwości podstawowego rytmu rozrusznika, są widoczne w zapisie elektrokardiograficznym. Jednak nieumiejętna interpretacja EKG może doprowadzić do błędnej diagnozy stanu pacjenta. W trakcie analizy sygnału elektrokardiograficznego u pacjenta z wszczepionym układem stymulującym należy stwierdzić obecność stymulacji, a przede wszystkim określić rytm własny.

W przypadku stymulatorów jednojamowych mamy do czynienia z wysoką amplitudą impulsu stymulacji. Iglica stymulatora jest bardzo dobrze widoczna w zapisie EKG, a mimo to, dochodzi bardzo często do błędnego rozpoznania zespołu QRS. Przykłady sygnałów elektrokardiograficznych przedstawiających zarówno prawidłowe stymulacje typu AAI oraz VVI, jak i nieskuteczne stymulacje związane z zaburzeniami stymulacji i czuwania rozrusznika, zawarte są w Dodatku C niniejszej rozprawy. Szeroki zakres problemów związanych z interpretacją medyczną zapisów EKG pochodzących od pacjentów z wszczepionym układem stymulującym można odnaleźć w publikacji Walczaka i Baranowskiego „Podstawy EKG u pacjenta ze stymulatorem serca” [278].

## **1.3 Problemy techniczne związane z rejestracją i analizą sygnału elektrokardiograficznego**

### **1.3.1 Dyskretna reprezentacja sygnału**

Problemy rejestracji sygnałów są związane z dyskretną reprezentacją sygnału elektrokardiograficznego. W treści rozprawy pominięte zostały problemy dotyczące elektronicznych urządzeń pomiarowych, bezpieczeństwa pacjenta, czy

też niestałości warunków pomiarowych. Szersze informacje na ten temat podano np. w pracach [18, 187]. Przepisy dotyczące przeprowadzania badań i konstrukcji aparatów elektrokardiograficznych można odnaleźć w branżowych normach (patrz np. norma branżowa „Elektrokardiografy, ogólne wymagania i badania”, BN – 89/5963 – 02 [188]). W literaturze przedmiotu, związanej z teorią i analizą sygnału (zobacz choćby fundamentalne opracowania dotyczące cyfrowego przetwarzania sygnałów następujących autorów: Beauchampa [28], Oppenheima [191, 192], Borodziejczka [37], Boxa, Jenkinsa [40], Glissona [89], Lyonsa [163] i wielu innych), rozróżnia się dwa zjawiska dotyczące dziedziny czasu tj.: próbkowanie i ograniczanie.

**Próbkowanie** związane jest z ograniczeniem pasma częstotliwościowego od góry, czyli zmianą ciągłej funkcji sygnału analogowego w funkcję istniejącą tylko w chwilach próbkowania. Wynika to bezpośrednio z twierdzenia Shannona, które mówi, że częstotliwość próbkowania musi być co najmniej dwa razy większa od częstotliwości najwyższej składowej fourierowskiej wchodzącej w skład próbkowanego sygnału ciągłego [28]. Domyślnie przyjmuje się, iż próbkowanie sygnału dokonywane jest ze stałą precyzją amplitudową (stałą częstotliwością), bądź też ze stałym interwałem czasowym, zgodnie ze wzorami (1.1), (1.2). Pierwszy dotyczy wymnożenia sygnału  $s(t)$  poprzez szereg impulsów  $i(t)$ , gdzie  $\delta(t)$  jest funkcją (delta) Diraca,  $k$  jest liczbą całkowitą, zaś  $T$  jest okresem próbkowania. Drugi (1.2) dotyczy dziedziny częstotliwości, gdzie  $S(f)$ ,  $I(f)$  oznaczają transformaty Fouriera sygnału  $s(t)$  oraz  $i(t)$ , a  $f=1/T$  jest częstotliwością próbkowania.

$$s_p(t) = s(t) * i(t) = s(t) * \sum_{k=-\infty}^{+\infty} \delta(t - kT) \quad (1.1)$$

$$S_p = S(f) * I(f) = \frac{1}{T} \sum_{f=-\infty}^{+\infty} S(f - kf) \quad (1.2)$$

W przypadku częstotliwości sygnału równej częstotliwości próbkowania pojawia się, na tle wskazanego tu zjawiska, istotna trudność – tzw. niejednoznaczności rekonstrukcji sygnału, wynikająca z przesunięcia w fazie sygnału i taktu próbkowania. Rzeczywisty sygnał elektrokardiograficzny ma nietatwą do scharakteryzowania szerokość pasma i dodatkowo zawiera bardzo

przypadkowe zakłócenia [18, 58]. Znaczącym problemem pojawiającym się przy próbkowaniu sygnału jest błąd kwantyzacji związany z rozdzielczością przetwornika. Wiadomo, że im większa jest rozdzielczość przetwornika, tym większą liczbę różnych stanów może on rozróżnić. Na przykład, przetworniki analogowo – cyfrowe określają trzy parametry, takie jak: częstotliwość próbkowania ustaloną programowo w pewnym zakresie, rozdzielczość jako wartość stałą określoną przez liczbę bitów w rejestrze oraz zakres napięć wejściowych. Jednak nawet najszybsza częstotliwość próbkowania 200 Gs/s nie zapewnia ciągłości próbkowania. Efekt tzw. schodków prawie znika dla 8-bitowego przetwornika ( $2^8 = 256$ ), zaś napięcia wejściowe z zakresu (0,10)V 16-bitowych przetworników są niewystarczające dla sygnałów elektrokardiograficznych o amplitudach napięciowych mikro-, miliwoltów (np. dla sygnałów elektrokardiograficznych płodu). Ograniczenie pomiaru wynikające bezpośrednio z długości rejestru wpływa na proces zbierania, zapamiętywania, jak i przetwarzania danych. Następnym błędem próbkowania, wynikającym ze skończonego czasu trwania procesu próbkowania ( $T < \infty$ ), jest ograniczona rozdzielczość częstotliwościowa. To powoduje, iż nie jest możliwe rozróżnienie składowych sygnału, których częstotliwości odległe są od siebie o mniej niż  $\Delta f = 1/T$ . Zdaniem Moczko, Kramer [180], jest to ograniczenie słuszne tylko dla fragmentu sygnału wycinanego oknem prostokątnym. Zwiększenie rozdzielczości częstotliwościowej można uzyskać jedynie poprzez wydłużenie analizowanego sygnału. Ich zdaniem, błędnym sposobem jest dodanie do analizowanego sygnału o długości  $T$ , sygnału o zerowej amplitudzie i czasie trwania  $T_z$  (tzw. efekt zero – *padding*), gdyż powoduje to pojawienie się w widmie większej liczby detali, a nie zmienia rozdzielczości częstotliwościowej.

Z brakiem możliwości rozróżnienia niskich i wysokich częstotliwości w sygnale związany jest kolejny rodzaj błędu tzw. *aliasing*. Powstaje on najczęściej w wyniku niewłaściwego doboru częstotliwości próbkowania w stosunku do zawartości częstotliwościowej badanego sygnału analogowego i uniemożliwia w ten sposób odtworzenie oryginalnej informacji. Odpowiedni dobór częstotliwości próbkowania określony jest ściśle twierdzeniem Nyquista, które mówi o tym, iż jeśli najwyższą częstotliwością występującą w sygnale jest  $f$ , to w celu właściwego zapisania tego sygnału w postaci cyfrowej należy go próbować z częstotliwością co najmniej dwukrotnie większą ( $f_N = f/2$ , gdzie  $f_N$  –

częstotliwość Nyquista,  $f_s$  – częstotliwość próbkowania). Jeśli zatem sygnał analogowy składa się z częstotliwości 10 Hz, 20 Hz, 50 Hz, 70 Hz, 150 Hz, a będziemy wykonywali próbkowanie z częstotliwością  $f_s=100$  Hz, to częstotliwości 70 Hz, 150 Hz będą źle interpretowane, jako 30 Hz oraz 50 Hz. Wiele przykładów dotyczących aliasingu podano w [180, 181].

Drugie, z wymienionych wyżej zjawisk dyskretnej reprezentacji sygnału, związane jest z ograniczaniem długości rejestrowanego sygnału od dołu. Bezpośrednio problem ten wiąże się z pojemnością nośników, w których zapisywane są sygnały cyfrowe (dyski twarde). Rezultatem ograniczania jest dyskretyzacja widma. Następuje bowiem zmiana nieograniczonej w dziedzinie czasu funkcji sygnału analogowego w funkcję ograniczoną długością pomiaru (patrz np. [18]).

Powyżej zostały jedynie wskazane problemy rejestracji sygnału związane z próbkowaniem i ograniczaniem. Ciekawe przykłady i szersze wyjaśnienie opisanych tu zjawisk dla sygnałów elektrodiagnostycznych podają w swych opracowaniach Augustyniak [18] oraz Moczko [180]. Informacje dotyczące zaawansowanych technik próbkowania oraz błędów wynikających z cyfrowej reprezentacji sygnału można również odnaleźć w wielu innych publikacjach np. [32, 58, 96, 129, 163, 225].

### **1.3.2 Zakłócenia**

W literaturze przedmiotu najczęściej wyodrębnia się trzy zasadnicze kategorie zakłóceń sygnału EKG, a mianowicie: wolnozmienne, sieciowe i mięśniowe. Oczywiście zakłócenia sygnału EKG mogą być także skutkiem innych zjawisk czy zdarzeń wymienionych w dwóch powyższych punktach tego rozdziału, do których należy choćby zaliczyć szum aparaturowy, błąd kwantyzacji i maskowania, nierównomierność próbkowania, piki i skoki linii izoelektrycznej oraz szumy generowane przez inny sprzęt elektrotechniczny.

Najistotniejsza, z punktu widzenia analizy sygnału EKG, jest eliminacja zakłóceń wolnozmiennych (niskoczęstotliwościowych), które mogą być wywołane ruchem, oddechem pacjenta, czy też obluźwaniem się elektrod. Z kolei zakłócenia sieciowe, skutkujące najczęściej poszerzeniem grubości linii zapisu lub całkowitym zniekształceniem elektrokardiogramu, spowodowane są zarówno polem elektrycznym generowanym wokół przewodów zasilających, jak

i polem magnetycznym wytwarzanym przez różnego rodzaju urządzenia elektrotechniczne.

Gdy chodzi zaś o zakłócenia mięśniowe, to wynikają one z nakładania się widoku zakłóceń i sygnału na długim odcinku częstotliwości. Ten rodzaj zakłóceń uważa się za najbardziej kłopotliwy z uwagi na to, że skurczy mięśni inicjowanych impulsami przekazywanymi drogą nerwową nie da się wyeliminować, gdyż komórki mięśniowe grupujące jednostki motoryczne są zbyt małe, a odstęp pomiędzy pobudzającymi impulsami jest przypadkowy.

Niniejsza rozprawa dotyczy sygnałów elektrokardiograficznych – stymulatorowych, w odniesieniu do których oprócz wyżej wymienionych zakłóceń, dochodzi do wielu interferencji elektromagnetycznych wpływających na działanie całego układu stymulującego pracą serca. Postęp technologiczny sprawia, iż aktualnie stosowane rozruszniki tzw. czwartej generacji, wykorzystujące mikroprocesory jednoukładowe, są bardziej uodpornione na liczne zewnętrzne zakłócenia w porównaniu z pierwszymi trzema generacjami technologicznymi. Na przykład, w pierwszej generacji stosowano w rozrusznikach obudowy z żywicy epoksydowej, pokrywane w niektórych przypadkach lakierem silikonowym. W wyniku tego, stymulatory te były bardzo podatne na zewnętrzne zakłócenia pól elektromagnetycznych małej i wielkiej częstotliwości. Generacja druga, to obudowy metalowe otaczające zarówno układ elektroniczny, jak i baterie. W tym przypadku został wyeliminowany wpływ zakłóceń ze strony pól elektromagnetycznych. W trzeciej zastosowano natomiast monolityczne układy hybrydowe, dzięki czemu nastąpiła poprawa funkcji filtrujących zakłócenia. Obecna czwarta generacja, cechuje się dużą niezawodnością w porównaniu do swych poprzedników i umożliwia cyfrową filtrację zakłóceń [205]. Mimo wszystko, dochodzi do zaburzeń funkcji stymulatora serca w wyniku działania pola elektromagnetycznego w ich otoczeniu.

Interferencje elektromagnetyczne u osób z wszczepionym układem stymulującym serce to zakłócenia działania układu stymulującego spowodowane polem elektromagnetycznym. Zakłócenia pochodzą od: telefonów komórkowych, kuchenek mikrofalowych, bramek ochronnych oraz szeregu różnych urządzeń elektromagnetycznych stosowanych w medycynie.

W literaturze można odnaleźć wiele opracowań na temat interferencji pola elektromagnetycznego na kardiostymulator [142, 216, 296, 297, 254, 161]. Ciekawe prace dotyczą wpływu telefonii komórkowej na układ stymulujący (patrz np. [141, 298, 299, 144, 147]). Według nich, korzystanie z telefonu komórkowego może, w specyficznych układach, powodować zakłócenia zarówno pracy układu stymulującego serce, jak i zapisu Holterowskiego. Skuteczne metody identyfikacji zakłóceń elektromagnetycznych w kardiostymulatorach przedstawiono także w pracy [215].

### 1.3.3 Sposoby redukcji zakłóceń

#### 1.3.3.1 Uśrednianie sygnału

Rejestrowany analogowy sygnał elektrokardiograficzny powinien być przetwarzany przetwornikiem o rozdzielczości 12 bitów na postać cyfrową z częstotliwością próbkowania co najmniej 1000 Hz. Jak podaje Instytut Biocybernetyki i Inżynierii Biomedycznej Polskiej Akademii Nauk [187] pomimo rejestrowania sygnału o rozdzielczości przetwarzania 16 bitów i częstotliwości próbkowania 4000 Hz, poziom szumu sygnału EKG zawiera od kilku do kilkunastu  $\mu\text{V}$ . W celu poprawy stosunku **sygnału do szumu** wykorzystywane jest najczęściej tzw. uśrednianie sygnału. W przypadku sygnałów elektrokardiograficznych zastosowanie znajdują następujące metody:

- a) **Metoda uśredniania w dziedzinie próbek** polegająca na sumowaniu wartości chwilowych sygnałów aktywacji pobudzeń. Sygnały pojawiające się w tych samych momentach dodawane są zawsze do tych samych komórek elektronicznego układu uśredniającego. Wadą tej metody, oprócz długiego czasu badania, jest gubienie informacji pojawiających się nieperiodycznie, co jest charakterystyczne dla wszelkiego rodzaju arytmii. Powstają dodatkowo znaczne zniekształcenia w przebiegach poszczególnych fal. Zmianie ulegają także wartości i zależności czasowe.
- b) **Metoda uśredniania współbieżnego**. W przypadku zastosowania układu o odpowiedniej konfiguracji równolegle połączonych ze sobą  $n$  niskoszumowych wzmacniaczy o wzmocnieniu  $k$  i  $N$  szumach, wzmocnienie sumaryczne wynosi  $n*k$ , zaś szumy  $\sqrt{n} * N$ . Stosunek sygnału do szumu ulega wówczas  $\sqrt{n}$  krotnemu zwiększeniu. Następuje zatem

zdecydowane wzmocnienie sygnału, a słabsze wzmocnienie szumów. Jednak w zespole QRS pojawia się zmiana nachylenia poszczególnych jego odcinków, a to jest przyczyną błędnego określenia chwili występowania maksimum fali R.

- c) **Metoda korelacji wzajemnej** (*ang. cross – correlation*). Uśrednienie sygnału polega tutaj na porównaniu kolejno wszystkich cykli sygnału przewidywanych do uśrednienia z ustalonym wcześniej wzorcem. Zwykle wzorcem tym jest fragment sygnału (około 40 ms), w skład którego wchodzi zespół QRS.

Więcej wiadomości dotyczących metod uśredniania odnaleźć można na przykład w publikacjach [129, 163].

Zauważmy także, iż dla sygnałów EKG spełniających warunek sygnału okresowego, przy zastosowaniu dużej ilości uśredniania cyfrowego, poprawa stosunku sygnału do szumu charakteryzuje się wysoką skutecznością. Jednakże, zgodnie z definicją sygnału okresowego, podawaną przez Beauchampa w [28] (Definicja 1.3), sygnałem okresowym jest sygnał, którego przebieg powtarza się dokładnie po określonym czasie, a taki warunek w przypadku sygnałów elektrokardiograficznych jest spełniony zazwyczaj tylko dla rytmu zatokowego.

**Definicja 1.3 Sygnału okresowego wg Beauchampa.**

„Postać matematyczna wielkości fizycznych reprezentowanych przez sygnał deterministyczny, jeżeli jest znana (lub założona) stanowi przebieg powtarzający się ciągle w regularnych odstępach czasu. (...) Sygnały okresowe można uważać za sygnały składające się z jednego lub wielu przebiegów sinusoidalnych uzależnionych od okresu powtarzania T.”

Warto także podkreślić, iż dla sygnałów okresowych uśrednianie sygnału, bez synchronizacji czasowej sumowanych cykli, może doprowadzić do tzw. zjawiska *trigger jitter*, w którym następuje morfologiczna zmiana sygnału. Najczęściej składowe wyższej częstotliwości są w takiej sytuacji wygładzane [173]. Natomiast dla sygnałów elektrokardiologicznych nieperiodycznych, w których następują znaczne zmiany morfologiczne, uśrednianie cyfrowe dość często powoduje ich rozmazywanie lub gubienie. W przypadku uśredniania



analogowego poprawa stosunku sygnału do szumu jest niewystarczająca, choć dla sygnałów nieperiodycznych, spełniających dodatkowo warunek wysokiej koherencji dla sygnału i niskiej koherencji dla szumu, powyższa wada rozmywania nie występuje.

Obecnie w wielu publikacjach naukowych, w celu poprawy stosunku sygnału do szumu wykorzystywana jest filtracja adaptacyjna [16, 42, 128, 130, 207, 208, 264, 266]. Podstawy teoretyczne dotyczące filtracji adaptacyjnej szeroko opisuje np. Rutkowski w [228].

Warto w tym miejscu również dodać, że choć postęp w komputerowym uśrednianiu sygnałów elektrokardiograficznych przyczynił się do częściowego zmniejszenia niektórych zakłóceń (sieć energetyczna, niedoskonałość aparatury), to producenci aparatury bardzo często nie określają metody uśredniania sygnału. Może to prowadzić zarówno do modyfikacji zapisu, jak również do fałszowania wyników [157].

### **1.3.3.2 Sposoby redukcji zakłóceń – filtracja**

Metody usuwania zakłóceń opierają się na wykorzystywaniu pewnych cech sygnału i porównywaniu zakłócenia z sygnałem użytecznym. Bardzo często stosuje się do tego odpowiednie przekształcenia sygnału w celu uwypuklenia danej cechy czy różnicy. W literaturze przedmiotu spotkać można wiele opracowań poświęconych problematyce redukcji zakłóceń sygnału elektrokardiograficznego. I tak na przykład, w celu zredukowania pierwszego rodzaju zaburzeń wolnozmiennych używane są funkcje: sinusoidalna, trójkątna, filtrowany proces Markowa [60] itp. Z kolei przy zakłóceniach sieciowych, najczęściej stosowane są filtry selektywne, które mają szerokie (bądź wąskie) pasmo tłumienia częstotliwości. Podczas wykorzystywania powyższych filtrów może powstać tzw. zjawisko „dzwonienia filtru” i dlatego też wielu autorów poszukuje nowych, bardziej skutecznych, metod usuwania zakłóceń sieciowych (patrz np. [218, 219]).

W przypadku zakłóceń mięśniowych bardzo popularna jest metoda uśredniania ewolucji (i jej liczne modyfikacje) [7,8], opierająca się na założeniu okresowości sygnału EKG. Jeśli zakłócenia są przypadkowe (nieskorelowane sygnałem), to uśrednienie prowadzi do ich redukcji, podczas gdy sygnał okresowy jest niezmienny.

Powszechną metodą redukcji zakłóceń mięśniowych jest też filtracja dolnoprzepustowa. Niestety podczas stosowania tej metody nie zawsze uzyskuje się zadowalające wyniki. Popularne są także filtry wygładzające i filtry adaptacyjne. Dość często do usuwania tego typu zakłóceń stosowane są również różnorodne przekształcenia sygnału, np. odwracalna krótkookresowa transformata Fouriera [60]. W tym przypadku dokonuje się wydzielenia odcinków sygnału za pomocą odpowiednio skonstruowanego okna. Wynikiem transformacji jest zaś płaszczyzna czasowo – częstotliwościowa charakteryzująca analizowany sygnał. Metody wykorzystujące różnego rodzaju filtry mają ograniczenia wynikające zarówno z operacji na liczbach zespolonych w dziedzinie transformaty, jak również z konieczności powrotu do rzeczywistej dziedziny czasu. Obiecującymi metodami redukcji zakłóceń mięśniowych są przekształcenia falkowe posiadające własność wielorozdzielczości [9, 18, 20, 223]. Na uwagę zasługuje także przekształcenie Karhuhena – Loevego [162], polegające na rzutowaniu sygnału na wektory własne jego macierzy autokowariancji, co w konsekwencji prowadzi do powstania bardzo zwartej reprezentacji sygnału. Filtracja sygnału elektrokardiograficznego jest przedmiotem badań wielu autorów i mogłaby stanowić odrębne opracowanie, dlatego też zainteresowanych tą tematyką odsyłam do bogatej w tej dziedzinie literatury.

## **1.4 Podsumowanie rozdziału**

Rozważania niniejszego rozdziału dotyczą podstawowych pojęć związanych z analizą sygnału elektrokardiograficznego. Intencją autorki jest jedynie zasugerowanie problematyki prac badawczych związanych z elektrokardiografią i pojawiających się na tym tle problemów. Tematyka rozdziału podzielona na trzy części (elektrokardiografię, układ stymulujący, problemy techniczne) wydaje się być uzasadniona, bowiem podkreśla wieloaspektowy charakter rozprawy.

Należy również zauważyć, iż w opracowanym rozdziale wskazane zostały jedynie trzy podstawowe typy błędów, które powodują częściową utratę informacji w trakcie procesu konwersji analogowo – cyfrowej. A mianowicie: utrata informacji o małych zmianach amplitud w wyniku błędu konwersji; utrata informacji o powolnych zmianach w przypadku ograniczenia

w czasie; utrata informacji o szybkich zmianach w wyniku mierzenia sygnału w ściśle określonych (dyskretnych) punktach osi czasu.

Świadomie zostało pominiętych wiele pojęć zarówno z tematyki medycznej, jak i informatycznej (np. efekt dudnienia, efekt sztchetowy). Ze względu na rozległość omówionych zagadnień, które mogłyby stać się przedmiotem odrębnych monografii, celowo ograniczono zakres rozważań w rozprawie. W literaturze przedmiotu z łatwością odnaleźć można interesujące pozycje, które nie mogły być wymienione w opracowaniu, a poszerzają zaprezentowaną wiedzę (patrz np. [22]).

## Rozdział II

# Metody detekcji i klasyfikacji zespołu QRS

Obecnie wiele nowoczesnych metod elektrokardiografii komputerowej związanych jest z detekcją zespołu QRS. Jest to najbardziej charakterystyczny odcinek elektrokardiogramu, dostarczający wielu bardzo istotnych informacji o pracy serca. W praktyce stosowane są systemy automatycznej interpretacji sygnału elektrokardiograficznego, które umożliwiają odczytywanie ciągłego, przetworzonego sygnału już podczas jego zapisu i wyznaczają prawie wszystkie zmiany w charakterystykach sygnału (np. wielkość serca, rytm serca, wystąpienie poszczególnych załamków itp.). Niektóre z nich zawierają moduły rozpoznawania arytmii serca. Są to, między innymi, takie systemy, jak: TICKER [112], EINTHOVEN [282], CARMEN [105, 106], KARDIOASSIST [164].

Pomimo stosowanych w praktyce systemów rozpoznających fale elektrokardiograficzne czy też arytmie serca, detekcja zespołu QRS nadal jest przedmiotem badań wielu naukowców. Powodem takiej sytuacji, oprócz złożoności sygnału i różnorodności morfologicznej załamków EKG, są pojawiające się liczne szумы i artefakty, które znacznie utrudniają analizę sygnału. Wskazane powyżej względy narzucają również bardzo surowe wymagania wobec tych algorytmów. Dlatego też musi je cechować nie tylko duża szybkość, ale także doskonała (prawie stuprocentowa) dokładność, efektywność oraz wydajność. Algorytmy detekcji zespołu QRS są bowiem punktem wyjściowym w całej analizie sygnału elektrokardiograficznego. Ich dokładność wpływa znacząco na jakość działania całego systemu analizującego sygnał EKG.

Wykrywanie zespołu QRS można podzielić na dwa zasadnicze etapy. Pierwszy z nich polega na dokonaniu matematycznych przekształceń sygnału z wyodrębnieniem cechy zespołu QRS i minimalizacją pozostałych cech sygnału, wraz z szumem oraz zakłóceniami. W wyniku wstępnego przetwarzania oryginalnego sygnału otrzymujemy funkcję detekcyjną, której miarą jest stromość narastania, jak i opadania zboczy na granicy odcinka QRS. Funkcja ta, jak podaje

Łęski [164], powinna posiadać gładką falę dla każdego zespołu QRS oraz wykazywać brak fal dla pozostałych załamków i zakłóceń. Zdaniem Augustyniaka [18], najlepiej jeśli funkcja detekcyjna spełnia następujący warunek:

***Posiada jak największe wartości w obrębie zespołu QRS, zaś poza zespołem jak najmniejsze wartości oraz dokładnie jedno maksimum na każdy zespół QRS.***

Drugi etap wykrywania zespołu QRS polega na progowaniu, które służy do znalezienia punktów sklasyfikowanych jako zespoły QRS. Najczęściej wartość progu ustawiana jest adaptacyjnie z zastosowaniem późniejszych korekt. Zasadniczy cel progowania polega na odnalezieniu lokalnego maksimum. Bardzo często wykorzystywaną metodą jest sprawdzenie znaku pochodnej. Jeśli próg zostaje przekroczony, to punkt  $x$  jest punktem detekcji, w przeciwnym zaś przypadku następuje sprawdzenie maksimum i modyfikacja wartości progowej. Szerokie informacje na temat funkcji detekcyjnych podaje Augustyniak w [18] oraz Borna Ayad w [36]. Łęski w [164] charakteryzuje także kilka sposobów wyznaczających prawidłowy poziom detekcji. Są to m.in. metody określające:

- procent średniej maksimumów fal lub procent median funkcji detekcyjnej odpowiadający określonej liczbie ostatnio wykrytych zespołów QRS;
- kombinację liniową poprzedniego poziomu detekcji i maksimum fal funkcji detekcyjnej dla wykrytego ostatniego zespołu QRS;
- zmniejszenie o pewien procent poziomu detekcji, jeżeli zespół QRS nie wystąpi po przewidywanym czasie;
- stosowanie okresu niewrażliwości detektora po wykryciu zespołu QRS.

Algorytmy detekcji i klasyfikacji zespołu QRS są przedmiotem badań wielu autorów. Analiza poglądów wyrażanych w literaturze pozwala wyodrębnić trzy zasadnicze grupy metod detekcyjnych, a mianowicie algorytmy opierające się o: pochodne sygnału, sztuczne sieci neuronowe oraz przekształcenia falkowe. Zaprezentowany tutaj podział nie jest zbyt wnikliwy i dlatego też, lepszym rozwiązaniem będzie wyszczególnienie pięciu poniżej wskazanych grup algorytmów i dokonanie ich syntezy:

- 1) algorytmy działające w dziedzinie czasu (*ang. algorithms based on time domain*),
- 2) algorytmy działające w dziedzinie częstotliwości (*ang. algorithms based on frequency domain*),
- 3) algorytmy działające w dziedzinie czasowo – częstotliwościowej (*ang. algorithms based on time – and – frequency domain*),
- 4) algorytmy opierające się na sztucznej inteligencji:
  - a) sieci neuronowe (*ang. algorithms based on neural network models*),
  - b) klasyfikatory maksymalnodległościowe (*ang. support vector machine*),
  - c) algorytmy genetyczne (*ang. genetic algorithms*),
- 5) i inne rozwiązania algorytmiczne.

Niniejszy rozdział poświęcony jest krótkiej charakterystyce metod detekcji i klasyfikacji zespołu QRS, z uwzględnieniem powyższego pięciopunktowego podziału. Dokonano analizy tylko kilku wybranych z literatury przedmiotu algorytmów, inne nowatorskie rozwiązania jedynie wymieniono.

## **2.1 Detekcja zespołu QRS w dziedzinie czasu**

W analizie czasowej sygnału najistotniejszym problemem jest sposób, w jaki zmienia się amplituda sygnału w czasie. Jak już sugerowano powyżej, odnalezienie lokalnego maksimum w sygnale bardzo często odbywa się za pomocą różnych algorytmów wykorzystujących rachunek pochodnych. Można je zaliczyć do metod detekcji zespołu QRS działających w dziedzinie czasu i jednocześnie podzielić – na podstawie kryterium sposobu różniczkowania – na algorytmy oparte o: amplitudę i pierwszą pochodną, tylko pierwszą pochodną, pierwszą i drugą pochodną oraz o filtry cyfrowe.

W przypadku algorytmów opartych o pochodne sygnału, wykrycie zespołu QRS jest dokonywane poprzez porównanie poszukiwanej cechy (zespołu QRS) – oznaczmy ją przez  $c(n)$ , z ustalonym progiem. Najczęściej wartości progowe są wyliczonymi zależnymi sygnału, dla których jest możliwa adaptacja (dopasowanie) do zmieniających się charakterystyk sygnału. W większości algorytmów wykrywających zespół QRS, logika wykrycia szczytu R jest uzupełniana dodatkowymi regułami nakładającymi heurystyczne ograniczenia dotyczące czasu trwania lub znaku cechy. Reguły te opisuje np. Łęski w [164].

Wprowadzane są także dodatkowe (drugorzędne) progi, w celu wykluczenia z sygnału EKG segmentów nie będących zespołami QRS (patrz np. [10, 108]).

Ciekawą pracą, na którą powołuje się wielu naukowców, jest publikacja Friesena [84]. Porównano w niej dziewięć algorytmów opartych o pochodne sygnału i filtry cyfrowe oraz zbadano ich odporność na różnego rodzaju szumy. Niestety, autorzy nie opublikowali użytych reguł progowania. Działanie algorytmów Friesena w odniesieniu do sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym będzie szerzej omówione w rozdziale czwartym niniejszej rozprawy.

W literaturze przedmiotu związanej z metodami detekcji w dziedzinie czasu, można odnaleźć wiele opracowań, w których – w celu wykrycia zespołu QRS – stosowane są różnego rodzaju filtry cyfrowe (patrz np. [11, 17, 47, 132, 159, 160]). Najczęściej autorzy prac, takich choćby, jak np. [154, 222], korzystają *a priori* z zasad wprowadzonych przez Hamiltona, Tompkinsa [99, 100] oraz Pana, Tompkinsa [206]. W celu liniowej filtracji autorzy ci, zamiast ogólnie używanego filtru pasmowoprzepustowego o częstotliwości środkowej 10–25Hz i paśmie 5–10Hz, zaproponowali skorzystanie z filtru średniej ruchomej stosowanego na sumie modułów (lub sumie kwadratów) sygnałów wyjściowych filtracji liniowej dla wykorzystanych odprowadzeń. Inni [120, 273] stosują drobne modyfikacje tego algorytmu.

Kolejnym bardzo popularnym algorytmem jest zastosowanie przez Suna i Suppappola [249] nieliniowego przekształcenia MOBD (*and. multiplication of backward difference*). Autorzy definiują poszukiwaną cechę, oznaczmy ją  $c(n)$ , jako (2.1) i ustalają próg na maksimum cechy dla  $N=4$ .

$$c(n) = \prod_{k=0}^{N-1} |x(n-k) - x(n-k-1)| \quad (2.1)$$

MOBD wyznacza punkt R w przypadku, gdy sygnał spada o połowę względem maksymalnej wartości. Algorytm ten wykorzystują w swoich pracach także inni autorzy, np. [149], modyfikując progi.

W literaturze spotkać można również zastosowanie rekursyjnych i nierekursyjnych filtrów medianowych. Na przykład, w pracy [290] zaproponowane jest wykorzystanie filtru środkowoprzepustowego powstałego w wyniku kombinacji dwóch filtrów medianowych z filtrem wygładzającym.

Z kolei w [43] stosowana jest tzw. krzywa długości  $L(k, q)$  zdefiniowana wzorem (2.2) w przedziale czasu  $[k, k+q]$  na różnych kanałach, gdzie  $x_j(i)$  jest próbką sygnału EKG kanału  $j$  czasu  $i$ .

$$L(k, q) = \sum_{i=k}^{k+q} \sqrt{\sum_{j=1}^n [1 + (x_j(i) - x_j(i+1))^2]} \quad (2.2)$$

Wielkość  $L(k, q)$  jest określana przez autorów jako próg, od którego zależy podjęcie decyzji o wyznaczeniu zespołu QRS.

Nagin, Selishchev [186], w celu wykrycia zespołu QRS, obliczają dwie wartości adaptacyjnych progów  $T_i$ ,  $T_f$  i porównują je w każdym kroku. Funkcję charakteryzującą prawdopodobieństwo wystąpienia fali R autorzy opisują zależnością (2.3)

$$\Theta(n) = \begin{cases} 1 & \text{dla } T_i[n] < Y_i[n], T_f[n] < Y_f[n] \\ 0 & \text{pozostałe przypadki} \end{cases} \quad (2.3)$$

gdzie  $T_i$ ,  $T_f$  są wyznaczonymi progami, zaś  $Y_i$  określa poziom sygnału. Warto zauważyć, iż prawdopodobieństwo  $\Theta(n)=1$  zawarcia fali R w rzeczywistości jest dosyć wysokie. Adaptacyjne progi w celu rozpoznania zespołu QRS stosuje także Varanini [277]. Autorzy używają algorytmu LMS (*ang. least mean square*), jako procedury optymalizacji dostosowania wag filtra, zaś w celu uaktualnienia wag wykorzystują tzw. algorytm najmniejszej średniej (LMA) (*ang. least mean absolute*). Warto zaznaczyć, iż algorytm LMS, wprowadzony przez Widrowa, Stearnsa [283], ze względu na zastosowanie specjalnej estymaty gradientu, koniecznej w adaptacyjnym liniowym sumatorze ważonym, jest metodą dość ograniczoną w swoim zastosowaniu. Wady i zalety LMS podane są w np. pracy [246].

Należy podkreślić także fakt, iż pojawiające się wraz z upływem lat nowe metody detekcji zespołu QRS nie przekreślają całkowicie algorytmów opartych o pochodne sygnału. W literaturze przedmiotu nadal można odnaleźć prace, które wzorują się na powyżej omówionych metodach (patrz np. [185, 50, 64, 115]).

## **2.2 Detekcja zespołu QRS w dziedzinie częstotliwości**

Analiza sygnałów w dziedzinie częstotliwości wiąże się z badaniem właściwości widmowych. Szeroko na temat analizy widmowej w różnego typu sygnałach (okresowych, nieokresowych, losowych) piszą np.: Ozimek [203],



Kwiatkowski [152]. Najczęściej wykorzystywaną w praktyce metodą analizującą sygnał w dziedzinie częstotliwości jest przekształcenie Fouriera i jego różne odmiany. Szersze przedstawienie tego zagadnienia wykracza poza ramy niniejszej rozprawy. W literaturze przedmiotu można odnaleźć wiele monografii omawiających matematyczne podstawy przekształceń Fouriera wraz z licznymi przykładami ich zastosowań. Własności transformaty Fouriera oraz algorytm obliczenia szybkiej dyskretnej transformaty Fouriera (FFT) w dziedzinie czasu oraz w dziedzinie częstotliwości podaje np. Izydorczyk [116] (patrz również monografie tj.: [163, 243, 41]) i wiele innych opracowań z zakresu cyfrowego przetwarzania sygnałów.

Dla sygnałów elektrokardiograficznych w praktyce stosowane jest tzw. dyskretne przekształcenie Fouriera (*ang. discrete Fourier transform*) (DFT), z którego wynika własność perfekcyjnej konstrukcji sygnału. Jak podaje bowiem Augustyniak [19, 20], „sygnał dyskretny w dziedzinie czasu oraz jego reprezentacja w dziedzinie częstotliwości składają się z takiej samej liczby próbek”. Metody Fourierowskie, choć często stosowane, nie należą jednak do rozwiązań optymalnych. Wynika to z faktu, iż do identyfikacji poszczególnych składowych sygnału często wykorzystuje się tzw. widmo mocy, bądź też funkcję gęstości mocy. Zgodnie z definicją, wyznaczenie widma gęstości energii następuje dwuetapowo. W pierwszym etapie obliczane jest widmo amplitudowe, w drugim zaś, na podstawie wyznaczonego widma, oblicza się widmo gęstości energii, najczęściej wykorzystując funkcję autokorelacji sygnału (patrz np. [152]). Należy jednak zauważyć, iż na podstawie funkcji gęstości mocy, jako wygładzonego widma mocy, nie jest możliwe odtworzenie sygnału. Gęstość widmową mocy można wyznaczyć numerycznie w oparciu o następujące metody:

- 1) Blackmana – Tukeya, która podczas obliczeń korzysta z przekształcenia Fouriera funkcji autokorelacji;
- 2) Cooleya – Tykeya, która bezpośrednio z FFT uzyskuje ciągi dyskretnych wartości sygnału;
- 3) filtracyjną, która opiera się na odpowiednio zaprojektowanych cyfrowych filtrach rekursywnych.

Powyżej wymienione metody są szeroko opisane w pracy [203].

W dziedzinie częstotliwości wykorzystuje się także transformację Gabora. W tym przypadku analizę częstotliwościową sygnału wykonuje się kolejno na

fragmentach wyciętych z całości przez tzw. funkcję okna, która jest przesuwana w czasie o pewien odstęp równy szerokości wyznaczonego okna. Dzięki temu analiza dla kolejnych odcinków sygnału jest niezależna i możliwe jest powiązanie energii poszczególnych widm z czasem, co pozwala na wyznaczenie momentu ich wystąpienia. Wadą metody Gabora jest bez wątpienia tylko raz dobierana szerokość okna analizy, co powoduje zarówno ograniczenie precyzji w dziedzinie czasu, jak również ograniczenie zakresu częstotliwości (patrz np. [189]).

Do metod detekcyjnych w dziedzinie częstotliwości należy także zaliczyć transformację Hilberta. Matematyczne podstawy transformaty Hilberta podane są w pracach [236, 246]. W literaturze przedmiotu przekształcenia te zostały zaproponowane do detekcji zespołu QRS po raz pierwszy przez Boltona i Westphala w 1984 roku [34, 35]. W późniejszym okresie wykorzystywali je także inni autorzy (patrz np. [29, 30, 48]). Szeroko na temat analizy częstotliwościowej w sygnałach elektrokardiograficznych wypowiadają się Augustyniak [20], oraz Moczko [180].

### **2.3 Detekcja i klasyfikacja w dziedzinie czasowo – częstotliwościowej**

W ostatnich latach przekształcenia falkowe odgrywają kluczową rolę w analizie sygnałów elektrokardiograficznych. Jako metoda działająca w dwóch połączonych dziedzinach (dziedzinie czasu i dziedzinie częstotliwości), godnie zastępują rozwiązania oparte o tradycyjne metody Fouriera (patrz np.[245]). W literaturze przedmiotu można odnaleźć wiele publikacji dotyczących zastosowania przekształceń falkowych, szczególnie do badania zjawisk, z którymi istniejący tradycyjny aparat matematyczny nie daje sobie rady. Upraszczając należy stwierdzić, iż analiza sygnału EKG w połączonej dziedzinie czasowo–częstotliwościowej umożliwia udzielenie odpowiedzi na pytanie, które składowe częstotliwościowe wystąpiły w sygnale i jakie były ich relacje czasowe.

Przekształcenia falkowe (*ang. wavelet transform*) (WT), których podstawy matematyczne będą wyjaśnione w rozdziale piątym niniejszej rozprawy, jako metoda rozpoznawania fal sygnału elektrokardiograficznego, zostały po raz pierwszy zaproponowane przez Hassani'ego i innych w [104]. Autorzy ci, stosowali WT do detekcji zespołu QRS, a także do rozpoznania tachykardii oraz

syndromu przedłużonego odcinka QT. W literaturze przedmiotu największa grupa algorytmów związanych z przekształceniami falkowymi wykorzystywanymi do detekcji zespołu QRS, opiera się na podejściu Mallata i Hwang'a [169]. Autorzy badają zgodność pomiędzy osobliwościami funkcji  $f(t)$  (*ang. singularities of a function*) i lokalnymi maksimumami w transformacie fali sygnału. Klasyfikacja szczytu jest dokonywana poprzez obliczenie stopnia szczególności tzw. lokalnej regularności Lipschitz'a  $\alpha$ , która jest oszacowana na podstawie rozkładu współczynników falkowych. Po raz pierwszy algorytm Mallata – Hwanga został wykorzystany do detekcji zespołu QRS w pracy [158]. Odnajdywano fałę R poprzez wykrycie modułu maksimum (*ang. modulus maxima*) jednocześnie we wszystkich skalach przekształcenia falkowego. Mianem zespół QRS oznaczano zaś jeden punkt, dla którego WT, na określonej skali pomiędzy dodatnim maksimum a ujemnym minimum, było większe od wyznaczonego progu. Według opracowania [158], regularność Lipschitz'a dla wykrytego prawidłowo szczytu R musi być większa od zera ( $\alpha > 0$ ), zaś w innych przypadkach (poza tym warunkiem) należy stosować reguły heurystyczne. Bezpośrednio z powyżej opisanego algorytmu korzystali m.in.: [23, 221, 231, 256, 257]. Drobne modyfikacje wprowadza zaś Martínez [174]. Nie stosuje analizy regularności, a jedynie kryteria oparte na amplitudzie. Bierze pod uwagę także inny proces aktualizowania progów. W przeciwieństwie do pracy [158], w której aktualizowano progi po każdym uderzeniu, w [174] uaktualnienie progów następuje dla każdej  $2^{16}$  próbki.

Kadambe i współautorzy [123] detekcję zespołu QRS opierają zaś na diadycznym przekształceniu falkowym (DyWT) (*ang. dyadic wavelet transform*). Wykorzystują oni wartość bezwzględną przekształcenia DyWT. Charakterystyczne punkty wykrywane są poprzez porównanie współczynników dyskretnego przekształcenia falkowego na wybranych skalach z ustalonymi progami. Detekcja fali R odpowiada zaś lokalizacji odnalezionej wartości bezwzględnej maksimum przekroczonego progu przylegających skal, a próg obliczany jest dla każdego segmentu.

Rozpoznawaniem zespołu QRS i pozostałych fal sygnału elektrokardiograficznego w dziedzinie czasowo – częstotliwościowej, za pośrednictwem przekształceń falkowych, zajmowało się także wielu innych

autorów. Na przykład, w pracy [237] do detekcji zespołu QRS wykorzystano trzy typy falek (falkę Daubechies, spline oraz Morleta), w [235] zastosowano ciągłe przekształcenie falkowe z falką Morleta, zaś w [289] pakiety falkowe (funkcję Gabora, falki Haara, Morleta i innych) (patrz również [231, 232,233,241,247,69]).

Jak wykazało wielu autorów, zarówno ciągłe (CWT), jak i dyskretne przekształcenia falkowe (DWT) mogą być z powodzeniem stosowane nie tylko do detekcji, ale również do klasyfikacji anomalii sygnału oraz do rozpoznawania arytmii serca. I tak na przykład, Chazal w [49] do klasyfikacji sygnału elektrokardiograficznego użył rodziny falek Daubechies różnych rzędów. Z kolei Addison [4,5] wykorzystał przekształcenia falkowe do badania sygnału elektrokardiograficznego podczas migotania komorowego. Stosował dyskretną transformatę falkową oraz ciągłe przekształcenie falkowe. Z kolei autorzy opracowania [183] dokonali analizy sygnału elektrokardiograficznego pod kątem klasyfikacji patologicznych cykli, wykorzystując do tego celu dyskretne przekształcenie falkowe. Używali oni różnych funkcji falkowych z rodziny Daubechies i różnych klasyfikatorów (np. klasycznego klasyfikatora bayesowskiego dla rozkładu normalnego, klasyfikatora  $k$ -tego najbliższego sąsiada oraz klasyfikatora  $\alpha$  najbliższych sąsiadów). Pojęcie klasycznego klasyfikatora bayesowskiego dla rozkładu normalnego wyjaśniono np. w [150]. Definicję klasyfikatora  $\alpha$  najbliższych sąsiadów podano np. w [259].

Metody analizy falkowej wykorzystywano również w pracach: [111] do detekcji późnych potencjałów, [56, 57] do detekcji komorowej tachykardii (patrz także [224, 156, 176, 72]). Szeroki przegląd zastosowań przekształceń falkowych w analizie sygnału elektrokardiograficznego podaje np. Addison [6].

## **2.4 Detekcja i klasyfikacja oparta o sztuczną inteligencję**

Intensywny rozwój elektroniki, a przede wszystkim informatyki, pod koniec XX wieku doprowadził do bardzo dużego zainteresowania tematyką sztucznej inteligencji. Warto w tym miejscu zaznaczyć, iż w literaturze przedmiotu (patrz np. [226]) dokonuje się podziału sztucznej inteligencji na dwie kategorie. Pierwsza kategoria (tzw. silna), związana jest z „budową komputerów

wyposażonych w proces myślowy zbliżony do rozumowania człowieka”. Druga kategoria (tzw. słaba), to ukierunkowanie na rozwiązywanie wąskiej klasy zadań, czyli „symulowanie inteligencji – zwykle na użytek wąskiej klasy zadań”. Mianem inteligencji określa się zaś zdolność do przyswajania wiedzy oraz umiejętnego jej wykorzystywania w zakresie formułowania i gradacji celów, a także zdolność używania zgromadzonej wiedzy do planowania i realizacji skutecznych działań. Zdaniem Michalewicza, sztuczna inteligencja to pewna forma inteligencji, świadomie wytworzona przez inną formę. Takie ujęcie wskazuje, iż oprogramowanie inteligentne to oprogramowanie adaptacyjne, zatem nawet wyszukany system ekspertowy z ustalonymi statystycznymi regułami nie należy do klasy systemów inteligentnych [143]. W niniejszym punkcie nastąpi omówienie algorytmów detekcji zespołu QRS i klasyfikacji związanej z trzema kategoriami sztucznej inteligencji, a mianowicie: sieciami neuronowymi, algorytmami genetycznymi oraz klasyfikatorami maksymalnodległościowymi.

#### **2.4.1 Algorytmy oparte o sieci neuronowe**

Na początku lat 90., przede wszystkim ze względu na zdolność uczenia się i równoległego przetwarzania informacji, środowisko informatyczne zafascynowało się sieciami neuronowymi (*ang. neural networks*) (SN). Powstała do dnia dzisiejszego ogromna ilość publikacji na ten temat. W literaturze zagranicznej zobacz choćby Bishop [33], zaś w literaturze polskiej Nałęcz [187], Rutkowski [229], Tadeusiewicz [261, 258], Szczepaniak [255] i wielu innych. Przegląd zastosowań sieci neuronowych w obszarze biocybernetyki i inżynierii biomedycznej (z licznymi przykładami) prezentuje Tadeusiewicz [263], Miller [179], Baxt [26], zaś w obszarze kardiologii np. Itchaporía [114]. Warto zauważyć, iż pierwsze aplikacje wykorzystujące sztuczne sieci neuronowe w diagnostyce klinicznej dotyczyły właśnie problematyki kardiologicznej – wykrycia obecności ostrego zawału serca (patrz np. [27, 102]).

Jako pierwsze z tej grupy metod zostały zastosowane jednokierunkowe sieci neuronowe oraz wielowarstwowe sieci neuronowe *backpropagation* (*ang. multilayer back propagation neural networks*). Na temat matematycznych podstaw jednokierunkowych sieci neuronowych (ANN) i ich praktycznych zastosowań w wielu dziedzinach piszą Tadeusiewicz [261, 258], Osowski [193,

195], Korbicz [136]. Ogólne założenia tej grupy SN zostaną także opisane w rozdziale piątym niniejszej rozprawy. Detekcji zespołu QRS za pośrednictwem jednokierunkowej trzywarstwowej sieci neuronowej dokonuje wielu autorów np. Xue [287, 288], Hu [109, 110], Morabito [184], Kestler [131]. Wyżej cytowani autorzy stosowali najprostszy algorytm uczenia wstecznej propagacji błędu (*ang. backpropagation*)(BP). Można także w literaturze przedmiotu odnaleźć prace, w których autorzy wykorzystują liczne modyfikacje i ulepszenia algorytmu uczenia BP. Na przykład, autorzy pracy [83] wykazują, iż dobrym sposobem poprawy szybkości uczenia jest algorytm Levenberg - Marquardt. Algorytm ten, oparty na metodzie Gaussa – Newtona i gwałtownym redukowaniu czasu uczenia, szeroko omówiony został w pracy [97].

Szczególną cechą sztucznych sieci neuronowych jest ich zdolność do klasyfikacji. Wielu autorów, stosuje sieci neuronowe dopiero po wyznaczeniu zespołu QRS, co dokonywane jest za pomocą innych, często najprostszymi metod, jak choćby poprzez zastosowanie pierwszej pochodnej sygnału (patrz [65, 210]). W klasyfikacji zespołu QRS stosowane są, oprócz wyżej wymienionych sieci MLP, także sieci o radialnych funkcjach bazowych (*ang. radial basic functions*) (RBF) oraz sieci z adaptacyjną teorią rezonansu (*ang. adaptive resonance theory*) (ART). Adaptacyjna teoria rezonansu dotyczy uczenia sieci neuronowych bez nauczyciela. Ideą działania tego typu sieci jest rozpoznawanie konkurencyjne zapamiętanych wcześniej danych (obrazów binarnych). Nowe wzorce są zapamiętywane, jeśli stopień prawdopodobieństwa (określa go tzw. próg czujności sieci) do aktualnie przechowywanych danych (obrazów) jest zbyt mały. Sieć ART składa się z dwóch warstw. Pierwsza (tzw. warstwa porównująca), jak sama nazwa wskazuje, porównuje dane wejściowe z przechowywanymi w pamięci i określa ich stopień podobieństwa. Druga zaś warstwa określa klasę, do której będzie dana wejściowa należeć (patrz np. [229]). Sieci neuronowe o radialnych funkcjach bazowych, często zwane radialnymi sieciami neuronowymi, charakteryzują się natomiast tym, że ich neurony ukryte realizują funkcję zmieniającą się radialnie wokół wybranego tzw. centrum. Neurony przyjmują wartości niezerowe w otoczeniu tego punktu [195, 117, 229]. Sieci neuronowe typu ART wykorzystywano do detekcji zespołu QRS w pracach [250, 68]. Z kolei klasyfikację zespołu QRS z użyciem radialnych sieci neuronowych zastosowano np. w [43, 168, 133].

W literaturze przedmiotu istnieje znaczna ilość publikacji, które łączą sztuczne sieci neuronowe z innymi metodami. I tak na przykład, praca [182] łączy sieci neuronowe ART2 z metodą dopasowania wzorców. Natomiast w [71, 73] autorzy wykorzystują kilka typów sieci (takich jak: sieć GAL, sieć MLP oraz sieć Kohonena), wykazując przy tym przewagę, pod względem dokładności i szybkości, tej pierwszej. Warto nadmienić, iż algorytm nauki sieci GAL (*ang. grow and learn*) umożliwia, oprócz modyfikacji wag, także modyfikowanie struktury samej sieci (liczby neuronów i ich połączeń). Działanie sieci Kohonena dokładnie omawiają np. Żuranda [300], Osowski [193]. W przypadku detekcji i klasyfikacji zespołu QRS należy także zwrócić uwagę na publikację Silipo [239], gdzie następuje porównanie działania sieci RBF z siecią Kohonena. Sieci neuronowe do detekcji oraz klasyfikacji wykorzystuje w swoich pracach także wielu innych (patrz np. [122, 127, 126, 202]).

Wszyscy powyżej cytowani autorzy jednoznacznie wykazują, iż sztuczne sieci neuronowe znacznie dokładniej rozpoznają i klasyfikują zespoły QRS niż inne algorytmy stosowane w literaturze, takie choćby, jak: Bayes, czy K - Nearest Neighbor (K-NN) (porównaj np. z [222,240,24,109]).

#### **2.4.1.1 Rozmyte sztuczne sieci neuronowe**

Szerokie zastosowanie w sygnałach biomedycznych znalazły także reguły rozmyte, wprowadzone przez Zadeha w 1965 roku. Sieci neuronowo - rozmyte, w odróżnieniu od klasycznych sieci neuronowych bazujących na logice boolowskiej, implementują zasady logiki rozmytej. Rozmyte sieci neuronowe wykorzystują inne zasady wnioskowania, w istocie są układem adaptacyjnym [227, 198, 229]. W literaturze przedmiotu można spotkać bogatą różnorodność metod stosujących rozmyte sieci neuronowe (*ang. fuzzy neural networks*) (FNN), służących zarówno do rozpoznawania, jak i klasyfikacji zespołu QRS (patrz np. [53]). I tak w szczególności, Ham w [98] wprowadza rozmyte sieci typu ARTMAP. Z kolei autorzy pracy [293] badają rozmyto – neuronowy system, który łączy algorytm grupowania c-mean (*ang. c-mean clustering*) z algorytmem wstecznej propagacji. Różne typy algorytmów grupowania, także algorytm c-means, szeroko omawia Rutkowski [229]. Natomiast Acharya w [2] wykorzystuje jednokierunkową sieć neuronową ANN w powiązaniu z rozmytym klasyfikatorem oraz metodą uczenia backpropagation. Warto także zwrócić uwagę

na opracowania [3, 125, 212, 80], w których zaproponowano rozmyte grupowanie sieci neuronowych (*ang. fuzzy clustering neural networks*) (FCNN) w sygnałach elektrokardiograficznych.

Natomiast Osowski [194] stosuje do rozpoznawania i klasyfikacji rytmów EKG rozmyte sieci neuronowe w połączeniu ze statystyką wyższego rzędu (*ang. higher order statistic*) (HOS). Przetworzone punkty danych z HOS autorzy przekształcają na wektory cech i wprowadzają do klasyfikującej sieci neuronowej. Podobną metodę wykorzystuje także Panoulas [209], opierając się na samoorganizującej się rozmytej sieci neuronowej. Do rozstrzygnięcia najistotniejszego problemu związanego z budową sieci rozmytej, jakim niewątpliwie jest generacja reguł wnioskowania, autor proponuje metodę grupowania rozmytego danych Gustafsona-Kessela (GK). (Rozmyte grupowanie danych polega na przypisaniu wektorów uczących  $x$  do różnych klastrów z współczynnikiem przynależności  $u_{ij}$  oznaczającym przynależność  $j$ -go wektora  $x$  do  $i$ -go klastra tak, aby zminimalizować sumaryczną wartość funkcji błędu.) Algorytm GK zapewnia zatem minimalizację liczby reguł i dobrą inicjację wstępnych wartości parametrów. Jak podają autorzy [200, 229], do głównych zalet zaproponowanej metody należy zaliczyć jej prostotę, wydajność, szybkość pracy (praktycznie w czasie rzeczywistym) oraz dokładność. W kolejnych badaniach nad rozpoznawaniem sygnałów elektrokardiograficznych i przypisywaniem ich do odpowiednich klas, Osowski [200] ponownie proponuje wykorzystanie algorytmu Gustafsona-Kessela i rozmytej sieci neuronowej Takagi – Sugeno – Kanga (TSK). Szersze wiadomości na temat sieci TSK można odnaleźć np. w opracowaniach: [271, 272, 284, 229]. Inne rozwiązania dotyczące zbiorów rozmytych, wykorzystywanych do detekcji i klasyfikacji zespołu QRS, podane są np. w [92, 291, 292, 196, 165, 39, 61].

Należy również zauważyć, że w pracy [197] zaproponowano rozmyto – hybrydową sieć neuronową złożoną z dwóch podsieci połączonych kaskadowo. Są nimi: warstwa rozmytego grupowania (*ang. fuzzy self – organizing layer*), która odpowiada za wstępną klasyfikację i grupowanie oraz wielowarstwowy perceptron (MLP) działający jako końcowy klasyfikator zespołów QRS, który jednocześnie dokonuje podziału na odpowiednie klasy. Podobne rozwiązanie zastosowano także w [71]. Na etapie wstępnej klasyfikacji, którego celem było utworzenie wektora cech, zastosowano dwie metody, a mianowicie



przekształcenie Fouriera oraz analizę falkową. Do określania wag neuronów sieci MLP wykorzystano zaś algorytm genetyczny (patrz [44, 45]).

### **2.4.1.2 Sieci falkowo – neuronowe**

Omówione powyżej algorytmy związane z przekształceniami falkowymi działającymi w dziedzinie czasu i częstotliwości, a także liczne zastosowania sieci neuronowych do detekcji i klasyfikacji zespołu QRS sprawdzają się na ogół w praktyce. Nadal jednak poszukuje się nowych rozwiązań. Pod pojęciem sieci falkowo – neuronowych w literaturze przedmiotu określa się metody, które łączą ze sobą sieci neuronowe i przekształcenia falkowe. Istota tego stosunkowo nowego rozwiązania oraz sposób jego działania zostaną szerzej omówione w rozdziale piątym niniejszej rozprawy.

Wykorzystanie połączenia sieci neuronowych z przekształceniami falkowymi do diagnostyki sygnału elektrokardiograficznego jako pierwsi zaproponowali Celler, Chazal [46]. Do dekompozycji sygnału EKG na sześć poziomów autorzy zastosowali falki Daubechies oraz Symlet, a uzyskane w ten sposób parametry statystyczne użyli jako dane wejściowe do neuronowej sieci, która nie posiadała warstw ukrytych. Dyskretnych przekształceń falkowych, jako etapu wstępnego przetwarzania i ekstrakcji cech podanych na wejście trzywarstwowej sieci neuronowej, używa także Sternickel [244]. Autor w swej metodzie stosuje trzy rodzaje falek, a mianowicie: Haara, Daubechies oraz Coiflet, a także algorytm backpropagation. Z kolei w [15] dla automatycznego wykrywania i klasyfikowania arytmii zaproponowano radialną sieć neuronową z przetwarzaniem wstępnym, która wykorzystuje falkę Daubechies czwartego rzędu.

W pracy [238] zastosowano natomiast przekształcenia falkowe oraz rozmyte sieci neuronowe do rozpoznawania przedwczesnych skurczów komorowych. Istotą tej metody jest powtórne wykorzystanie informacji do wykrycia zespołu QRS. Zespoły QRS są obliczane zgodnie z algorytmem podanym w pracy [158], jednak w celu zredukowania nakładu obliczeń autorzy dokonują pewnych uproszczeń. A mianowicie, brane są pod uwagę tylko wartości bezwzględne z trzeciej i czwartej skali przekształcenia falkowego. Dodatkowo, stosowana jest procedura normalizacji, która polega na uśrednieniu amplitudy fali R w zestawie treningowym. Jako narzędzie klasyfikujące przedwczesne skurcze

komorowe autorzy wykorzystali pięciowarstwową rozmytą sieć neuronową z algorytmem uczenia wstecznej propagacji błędu.

Na uwagę zasługuje także rozprawa doktorska Wrześniowskiego [286] stosująca falkowe sieci neuronowe do klasyfikacji ewolucji serca w przypadku badań holterowskich.

## **2.4.2 Algorytmy oparte o klasyfikatory maksymalnodległościowe**

Sztuczne sieci neuronowe, jak wykazało wielu autorów, są skutecznym detektorem zespołu QRS oraz dobrym klasyfikatorem. Dążąc jednak do minimalizacji funkcji błędu poprzez stosowanie klasycznych algorytmów uczenia, bardzo dokładnie omówionych w [195], sieci te mają również wiele istotnych wad. Przykładowo, w trakcie minimalizowania funkcji błędu, która jest funkcją wielomodalną o wielu lokalnych minimach, proces uczenia może utknąć w jednym z minimów. Ponadto, przyjęta architektura sieci neuronowej bezpośrednio wpływa na jej zdolności generalizacji, które nie zależą od wybranego algorytmu uczenia, bowiem algorytm ten nie kontroluje złożoności sieci.

Nowym podejściem proponowanym obecnie w literaturze przedmiotu jest *Support Vector Machine* (SVM). W języku polskim metoda ta jest nazywana techniką wektorów podtrzymujących lub klasyfikatorami maksymalnodległościowymi. Określenia te zaproponowali odpowiednio Osowski [199] oraz Szczepaniak [255]. SVM jest specjalną formą sztucznych sieci neuronowych typu ANN wprowadzoną przez Boser'a, Guyon'a, Vapnik'a w 1993 roku [38]. Cel tej metody – w dużym uproszczeniu – koncentruje się na dokonaniu separacji danych, przy zachowaniu dość ostrych wymagań statystycznych, poprzez poszukiwanie minimum globalnego pewnej wypukłej funkcji kosztu. Matematyczne podstawy związane z SVM opisują m.in.: [276, 234, 59, 255]. Wiele informacji znajduje się także na stronach internetowych, takich choćby jak: <http://www.support-vector.net>; <http://www.kernel-machines.org>.

Ciekawą koncepcję zmierzającą do wyselekcjonowania pewnych cech sygnału elektrokardiograficznego, która łączy dwie bardzo szybko rozwijające się obecnie metody (takie jak klasyfikatory maksymalnodległościowe oraz teorie

falek) zaproponował Jankowski [118, 119]. Algorytm detekcji rozpatruje kształt niepodzielnego zapisu cyklu serca z rozróżnieniem depolaryzacji przedsionkowej i komorowej. Support Vector Machine w badaniach klasyfikacji rytmu serca wykorzystuje także Osowski [201, 199].

### **2.4.3 Algorytmy oparte o algorytmy genetyczne**

Kolejną metodą zaproponowaną w literaturze przedmiotu do rozpoznawania i klasyfikacji sygnałów elektrokardiograficznych są algorytmy genetyczne (*ang. genetic algorithm*) (GA), umożliwiające efektywne poszukiwanie optymalnych parametrów zarówno w przestrzeni dyskretnej, jak i ciągłej. Najważniejszą czynnością algorytmu genetycznego jest stworzenie osobnika, który stanowi potencjalne rozwiązanie danego problemu. Jednak zła konstrukcja osobnika, bez względu na zastosowaną procedurę krzyżowania, selekcji czy też mutacji, często skutkuje niekorzystnymi rezultatami dalszej pracy. Warto również zauważyć, iż algorytmy genetyczne bardzo rzadko prowadzą do optymalnego rozwiązania. W większości przypadków osobniki populacji znajdują się wokół poszukiwanej wartości i nigdy jej nie osiągają. Ogólne wiadomości na temat algorytmów genetycznych można odnaleźć w wielu źródłach internetowych i literaturze fachowej. Są one podane w postaci formuł o różnym stopniu skomplikowania. Na szczególną uwagę zasługują opracowania: Kopczyńskiego [135], Bargieła [25], Michalewicza [178], Rutkowskiej [227], Goldbergera [90] itp. Obszerną bibliografię dotyczącą wykorzystania ewolucyjnych algorytmów i genetycznego programowania w medycynie przytacza Peña-Reyes [213].

Metodę GA do sygnałów elektrokardiograficznych po raz pierwszy zastosowali Poli i Cognoli [217]. Wykazali oni, iż algorytmy genetyczne, w połączeniu z filtrami wielomianowymi, efektywnie radzą sobie z szumem, artefaktami i różnorodnością morfologii EKG, poprzez wykorzystywanie nieliniowego przetwarzania. Zaprojektowanie modułu wykrywającego zespół QRS w przypadku GA wymaga zdefiniowania charakterystycznych cech filtra wielomianowego oraz odpowiedniego doboru współczynników i parametrów. Rząd wielomianu i liczba próbek wejściowych wpływa na ilość operacji. W celu osiągnięcia maksymalnej wydajności algorytmu autorzy zaproponowali użycie wielomianów niskiego rzędu i bardzo ograniczonej liczby próbek wejściowych. Z drugiej jednak strony wykazali, iż niewielka ilość próbek niekoniecznie

oznacza, że filtr będzie pracował na krótkim obszarze sygnału EKG (ze względu na opóźnienia GA). Po odpowiednim wyborze parametrów, bardzo duże znaczenie ma również określenie właściwej funkcji przystosowania. Jak wiadomo, funkcja ta powinna być malejącą funkcją ilości błędnych wykryć, zarówno fałszywie pozytywnych, jak i fałszywie negatywnych, dokonanych podczas przetwarzania sygnału EKG.

Algorytmy genetyczne do detekcji zespołu QRS wykorzystywane są także w pracach [190, 86, 274].

## **2.5 Inne rozwiązania algorytmiczne**

W literaturze przedmiotu zostały zaproponowane również inne – od wyżej przedstawionych – metody rozpoznawania i klasyfikacji zespołu QRS. Jedną z nich są algorytmy składniowe (*ang. syntactic algorithms*). Autorzy w celu usunięcia szumów w pierwszym etapie wykonują filtrację sygnału EKG. W drugim zaś, następuje zastosowanie odpowiednio stworzonych reguł decyzyjnych, które wyszukują, a także potwierdzają wystąpienie fali R (patrz np.[242, 137, 275]).

Sukcesem okazały się również algorytmy wykorzystujące ukryte modele Markowa (*ang. hidden Markov models*), występujące także w literaturze informatycznej pod nazwą probabilistycznych automatów z wyjściem. Metoda ta polega na wykryciu sekwencji danych poprzez zastosowanie funkcji prawdopodobieństwa. Parametry funkcji odpowiadają za różne właściwości statystyczne obserwowanych danych. Dzięki temu może być wyznaczony nie tylko zespół QRS, ale również fale P i T. Niestety przy stosowaniu tej metody należy przeprowadzić ręczną segmentację i wykonać szereg prób przed analizą zapisu, co nie jest proste w przypadku sygnałów elektrokardiograficznych (patrz np.: Cost [55], Laguna [153, 155], Koski [138], Coast [52]). Inne algorytmy oparte na różnych przekształceniach matematycznych podane są np. w pracach [82, 101, 269, 270].

## **2.6 Podsumowanie rozdziału**

Przedstawiona w niniejszym rozdziale synteza wiedzy z zakresu detekcji zespołu QRS wskazuje na duże zainteresowanie tym problemem, a przede wszystkim uwidacznia liczne wady i zalety wszystkich powyżej omówionych

metod. Warto zaznaczyć, iż wymienione zostały tylko nieliczne, choć najbardziej ciekawe z naukowego punktu widzenia prace.

Należy podkreślić, że zaprezentowane w niniejszym rozdziale rozważania dotyczą jedynie algorytmów detekcji zespołu QRS oraz klasyfikacji dla sygnałów elektrokardiograficznych pochodzących z różnych ogólnodostępnych baz internetowych, bądź też zbiorów własnych autorów. Nie odnoszą się zaś bezpośrednio do sygnałów EKG pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca. Dotychczas w literaturze przedmiotu, według wiedzy autorki rozprawy, nie podjęto prób opracowania metody detekcji i klasyfikacji zespołu QRS dla sygnałów elektrokardiograficznych – stymulatorowych. Najwięcej publikacji dotyczących kardiostymulatorów poświęconych jest ich związkom z polem elektromagnetycznym, co nie jest przedmiotem badań. Przykłady literatury związanej z tymi zagadnieniami częściowo wykazane zostały w rozdziale pierwszym niniejszej rozprawy. Inne [54], opisują zaś różne procedury rozpoznawania arytmii, jednak tylko z punktu widzenia podjęcia decyzji o wszczęciu kardiostymulatora.

W kolejnym rozdziale zostanie przedstawiona analiza porównawcza wybranych algorytmów opisanym w niniejszym rozdziale.

## Rozdział III

# Analiza porównawcza metod detekcji sygnałów elektrokardiograficznych pochodzących z bazy MIT-BIH

Twórcy metod detekcji zespołu QRS, cytowani w poprzednim rozdziale, wykonywali doświadczenia i eksperymenty na różnych bazach danych zawierających testowe sygnały elektrokardiograficzne. Do najpopularniejszych należą między innymi:

- a) The Massachusetts Institute of Technology – Beth Israel Hospital Arrhythmia Database (MIT – BIH) – zawiera osiem katalogów z różnymi zaburzeniami wykrywanymi metodą Holtera. Najczęściej testowaniu podlega 48 zapisów z katalogu MITDB, w którym znajdują się: plik z sygnałem, plik nagłówekowy (zawiera informacje o pacjencie) oraz plik informacji diagnostycznych (zawiera sygnał w postaci binarnej). Częstotliwość próbkowania tych sygnałów wynosi 360 Hz, a rozdzielczość 12 bitów, choć kanały zapisane są w formacie 16-bitowym naprzemiennie (patrz np. [18] oraz <http://ecg.mit.edu>).
- b) Common Standard for Quantitative Electrocardiography (CSE) – do testowania przygotowane są dwa zestawy po 125 sygnałów (zawierające sygnały oryginalnie opisane i sygnały sztuczne) oraz katalog składający się z 1200 sygnałów nieopisanych. Częstotliwość próbkowania dla tej bazy wynosi 500Hz, zaś rozdzielczość 16-bitów (patrz [18]).
- c) The American Heart Association ECG Database (AHA DB) – rozdzielczość 12 bitów, częstotliwość próbkowania 250Hz.

Kolejną grupę sygnałów testowych stanowiły bazy sygnałów elektrokardiograficznych pochodzących z mniej popularnych serwerów np.:

- Ann Arbor Electrogram Libraries (<http://electrogram.com>)
- Physikalisch-Technische Bundesanstalt (<http://www.berline.ptb.de/8/83/831/dbaccess/ecgrefdataset.html>)
- VTT IMPROVE library (<http://www.vtt.fi/tte/samba/projects/improve>)

- oraz z własnych zbiorów autorów.

Najczęściej przez autorów wykorzystywana była baza MIT-BIH, na co wskazuje Tabela nr 3.1.

**Tabela nr 3.1 Przykładowe wyniki detekcji zespołu QRS dla kilku wybranych autorów. Maksymalna czułość (SE) uzyskana przez nich dla różnych baz sygnałów elektrokardiograficznych tj. MIT-BIH, AHA oraz własnych zbiorów sygnałów.**

SE	MIT-BIH	AHA	Inne
99%	V.X. Afonso (i inni, 1999) M. Bahoura (i inni, 1997) P.S. Hamilton, W.J. Tompkins (1986) C. Li (i inni, 1995) R. Poli (i inni, ) D. Benitez (i inni, 2001)	Y.H. Hu (i inni, 1993) J. S. Sahambi (i inni, 1997a) Q. Xue (i inni, 1992) I.A. Dotsinsky, T.V. Stoyanov (2004)	B.C. Yu (i inni, 1985)
95%- 98%	S. Suppappola, Y. Sun (1994)	D.A. Coast (i inni, 1993) S. Kadambe (i inni, 1999)	
90%- 94%		P.E. Trahanias (i inni, 1993)	

Poniżej podjęta zostanie próba analizy porównawczej algorytmów detekcji opisanych w poprzednim rozdziale na podstawie tej samej grupy danych. Do tego celu wykorzystano bazę MIT-BIH. Ocenę poprawności działania algorytmów z dziedziny czasu, dziedziny czasowo – częstotliwościowej oraz algorytmów opartych na sztucznej inteligencji, wykonano na podstawie miar omówionych w punkcie 3.1 niniejszego rozdziału. Analiza została przeprowadzona dla wszystkich 48 sygnałów, w pracy ukazano jedynie wybrane i najbardziej problemowe sygnały z bazy MIT – BIH.

### **3.1 Metody oceny testowania algorytmów detekcji zespołu QRS**

Ocena działania algorytmu związana bezpośrednio z zastosowaniem medycznym jest niezwykle trudna. Ogólnie znane miary, takie jak błąd średniokwadratowy czy też współczynnik autokorelacji, jak się wydaje, nie są miarodajne. W przypadku analizy algorytmów wspomagających diagnostykę medyczną istotna jest bowiem informacja medyczna jaką rozpoznaje algorytm.

Rozpatrzmy zatem wszystkie możliwe przypadki uzyskiwane na podstawie algorytmu detekcji, przedstawione w Tabeli nr 3.2, w stosunku do faktycznego stanu istniejących zespołów QRS występujących w zapisie sygnału elektrokardiograficznego.

**Tabela nr 3.2 Różne przypadki wykrycia zespołu QRS.**

Stan prawdziwy Detekcja QRS	Brak QRS w EKG	QRS występuje w EKG
Nie wykryty	<b>TN</b>	<b>FN</b>
Wykryty	<b>FP</b>	<b>TP</b>

W przypadku sprawdzenia poprawności działania algorytmu detekcji zespołu QRS, analizie podlegają cztery ewentualne rozwiązania:

a) dwa przypadki prawidłowego wykrycia zespołu QRS:

- prawdziwie dodatni (prawdziwie pozytywny) – TP (*ang. true-positive*) – co oznacza wykrycie istniejącego zespołu
- prawdziwie ujemny (prawdziwie negatywny) – TN (*ang. true-negative*) – co oznacza, niewykrycie nie istniejącego zespołu QRS dla każdej próbki

b) dwa przypadki błędnego wykrycia zespołu QRS:

- fałszywie dodatni (fałszywie pozytywny) – FP (*ang. false-positive*) – wykrycie nie istniejącego zespołu QRS
- fałszywie ujemny (fałszywie negatywny) – FN (*ang. false-negative*) – niewykrycie istniejącego zespołu QRS.

W literaturze przedmiotu często wykorzystywaną miarą jest tzw. **czułość** metody (*ang. sensitivity*) (SE) (3.1), określana jako stosunek liczby wykrytych zespołów QRS do liczby zespołów QRS *de facto* występujących w zapisie sygnału elektrokardiograficznego.

$$SE = \frac{TP}{TP + FN} \quad (3.1)$$

Kolejną miarą jest tzw. **specyficzność** metody (*ang. specificity*) (SP) lub inaczej swoistość metody, zdefiniowana wzorem (3.2). Miara ta określa liczbę TN zespołów QRS, które prawidłowo nie zostały wykryte do sumy QRS-ów, które występują w sygnale EKG, a zostały wykryte, bądź też nie zostały wykryte (FP+TN).

$$SP = \frac{TN}{TN + FP} \quad (3.2)$$



Warto zauważyć, iż czułość i specyficzność są miarami przeciwstawnymi, co w konsekwencji prowadzi do analizy detekcji fałszywie pozytywnych i fałszywie negatywnych. Duża liczba wykryć FP lub FN może być przyczyną wielu błędów. Zwykle następstwem detekcji FP jest utworzenie dodatkowej klasy (jakiegoś wzorca), która reprezentuje odcinek sygnału EKG nie zawierający zespołu QRS. Pominięcie zespołu QRS, które wiąże się z detekcjami FN, powoduje często utratę cennych informacji diagnostycznych. Z powyższych względów dopuszcza się większą liczbę detekcji fałszywie pozytywnych, jako tzw. mniej groźnych. W przypadku detektora zespołu QRS, bardzo trudno jest wyznaczyć specyficzność, z uwagi na występującą w podanym wzorze (3.2) liczbę detekcji TN. Należy przyjąć, że zdarzenie TN, dla algorytmu detekcji zespołu QRS, jest to odpowiedź prawdziwie negatywna, czyli nie wykrycie nie istniejącego zespołu QRS dla każdej próbki. W zależności od częstotliwości próbkowania odpowiedzi TN jest 100 – 1000 razy więcej niż TP. Można także przyjąć, iż powyższe miary dyskryminacji cech (czułość i specyficzność) lokalizują obecność lub nieobecność danej poszukiwanej cechy, zatem możliwe jest obliczanie tylko jednej z nich. W związku z powyższym, w przypadku detekcji zespołu QRS, w kolejnym punkcie tego rozdziału, a także w rozdziale czwartym i szóstym niniejszej rozprawy, nie będą wyznaczone obie powyżej opisane miary (tj. miara czułości oraz miara specyficzności), a uwagę skupiono jedynie na pierwszej z nich.

W literaturze przedmiotu często obliczany jest także **błąd detekcyjny** (*ang. detection error*) (BD), zdefiniowany wzorem (3.3), jako stosunek liczby zespołów QRS, które zostały błędnie wykryte do sumy wszystkich zespołów QRS.

$$BD = \frac{FP + FN}{OgółemQRS} * 100\% \quad (3.3)$$

Ponadto wyznaczana jest również **dokładność** (*ang. accuracy*) (D), która w przypadku detekcji zespołu QRS określa liczbę prawidłowo wykrytych zespołów QRS w odniesieniu do wszystkich QRS-ów występujących w sygnale elektrokardiograficznym (3.4).

$$D = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.4)$$

Oprócz czułości, specyficzności i wyznaczania błędu detekcyjnego, niektóre publikacje wprowadzają dodatkowo tzw.  **dodatnią wartość prognostyczną** (*ang. positive predictivity value*) (PPV lub +P) zdefiniowaną wzorem (3.5) oraz **ujemną wartość prognostyczną** (*ang. negative predictivity value*) (NPP lub -P) określoną wzorem (3.6) (patrz np. [30, 134, 248]).

$$PPV = \frac{TP}{TP + FP} \quad (3.5)$$

$$NPV = \frac{TN}{FN + TN} \quad (3.6)$$

Augustyniak [18] definiuje także **odsetek poprawności detekcji** (*ang. reliability*) (R), jako stosunek ilości zespołów QRS obecnych w EKG pomniejszony o sumę liczby zespołów wykrytych nadmiarowo (FP) i zespołów nie wykrytych (FN) do ilości zespołów obecnych w zapisie (3.7).

$$R = \frac{(TP + TN) - (FP + FN)}{(TP + TN)} \quad (3.7)$$

Według tego autora, wprowadzona miara R dla sygnałów dobrej jakości, powinna wynosić nie mniej niż 99,7%, natomiast dla sygnałów zawierających szum nie powinna być mniejsza niż 92%.

W kolejnym punkcie tego rozdziału, w oparciu o błąd detekcji, liczbę detekcji fałszywie pozytywnej i fałszywie negatywnej, a także na podstawie miar wprowadzonych powyżej (tj. czułość, odsetek poprawności detekcji i dodatniej wartości prognostycznej), dokonane zostanie porównanie algorytmów detekcyjnych dla standardowych sygnałów elektrokardiograficznych. W czwartym zaś rozdziale niniejszej rozprawy, miary te będą wykorzystane do oceny działania algorytmów stosowanych wobec sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca.

### **3.2 Analiza porównawcza wybranych algorytmów detekcji zespołu QRS dla sygnałów elektrokardiograficznych z bazy MIT-BIH**

W przypadku bazy MIT – BIH brany jest pod uwagę katalog zawierający 48 zapisów sygnałów elektrokardiograficznych trwających od 15 minut do 24 godzin, o częstotliwości 360 Hz. Każdy zapis posiada dwa kanały zarejestrowane

naprzemiennie w 16 – bitowym formacie. W trakcie prowadzonych badań porównawczych przeanalizowano wszystkie 48 sygnałów, jednak wyniki przedstawione w niniejszym rozdziale pokazano jedynie dla wybranych czterech sygnałów. Są to sygnały o następujących numerach, charakteryzujące się odpowiednio:

- 105 – bardzo dużym szumem;
- 108 – wysoką amplitudą fali P (często błędnie wykrywaną jako R);
- 203 – wysoką amplitudą fali T (często błędnie wykrywaną jako R);
- 222 – szumem bardzo podobnym do zespołu QRS.

Sygnały te prezentowane są na Rys. 3.1, kolejno a) dla sygnału 105; b) dla sygnału 108; c) dla sygnału 203; d) dla sygnału 222.



**Rys. 3.1** Fragmenty zapisów sygnałów elektrokardiograficznych z bazy MIT – BIH omawianych w niniejszym rozdziale pracy (a) sygnał 105 (b) sygnał 108 (c) sygnał 203 (d) sygnał 222.

W trakcie analizy szczególną uwagę przywiązywano do sygnałów zawierających znaczny poziom szumów, artefaktów i zmian morfologicznych. Jak wynika z literatury przedmiotu, wyżej wymienione sygnały z bazy MIT – BIH są najbardziej problemowe i autorzy uzyskiwali dla nich najniższe wyniki. Dla każdego sygnału sprawdzono zarówno liczbę detekcji fałszywie negatywnej, jak i fałszywie pozytywnej oraz wyznaczono miarę czułości, błąd detekcyjny, dodatnią wartość prognostyczną i odsetek poprawnych detekcji.

Do analizy wybrano jedynie takie algorytmy z rozdziału drugiego niniejszej rozprawy, których autorzy podali dokładne wyniki dla danego sygnału elektrokardiograficznego. Należy podkreślić, iż w literaturze przedmiotu w wielu pracach wykazano jedynie średnią czułość lub średni uzyskany błąd detekcyjny. Na potrzeby tego rozdziału odrzucono także te prace, w których podano wyniki działania algorytmów dla przygotowanej przez autorów bazach danych.

Analizę porównawczą wykonano dla następujących algorytmów, a mianowicie:

- metod czasowych: reprezentowanych przez algorytm: Pana – Tompkinsa [206], Hamiltona – Tompkinsa [99, 100], Afonso [7].
- metod częstotliwościowych – rozpoznawanie QRS za pomocą przekształceń Hilberta – algorytm Beniteza [29, 30].
- metod czasowo – częstotliwościowych: Li [158], Bauhoura [23], Szilagyi [256, 257], Sahambi [231].
- metod sztucznej inteligencji – algorytm genetyczny zastosowany przez Poli’ego [217], sieć neuronowa Xue [287, 288], Cohen [53]
- przekształceń matematycznych: Ferdy [82]


Wybór powyżej wymienionych algorytmów spowodowany jest z jednej strony dużą ich popularnością, z drugiej zaś, rzetelną prezentacją wyników dokonaną przez cytowanych wyżej autorów. Rezultaty wielu nowatorskich prac są porównywane z wyżej wymienionymi metodami.

W przypadku algorytmów z dziedziny częstotliwościowej autorzy nie podają szczegółowych wyników. Jedynie w pracy [29] wyczerpująco i starannie zaprezentowano osiągnięte rezultaty dla wszystkich 48 sygnałów z bazy MIT – BIH. Nie można jednak mówić o optymalności całej grupy algorytmów należących do metod częstotliwościowych, tylko w oparciu o jeden algorytm.

W związku z tym, z analizy porównawczej zostanie wykluczona grupa metod działających w dziedzinie częstotliwości. Rezultaty Beniteza będą jedynie przytaczane sporadycznie, dla czterech omawianych sygnałów. Z tej samej przyczyny, z analizy porównawczej wykluczono algorytmy oparte o klasyfikatory maksymalnodległościowe (SVM), algorytmy syntaktyczne i inne przekształcenia matematyczne.

### 3.2.1 Analiza porównawcza algorytmów dla sygnału 105

Analizę porównawczą algorytmów w poszczególnych dziedzinach (dziedzinie czasu, dziedzinie czasowo–częstotliwościowej oraz sztucznej inteligencji) rozpoczęto od wyznaczenia błędu detekcyjnego, który przedstawiono na Rys. 3.2.




Rys. 3.2 Błąd detekcyjny dla sygnału 105 dla przykładowych algorytmów. Kolor żółty – metody czasowe, zielony – metody częstotliwościowe, niebieski – metody czasowo–częstotliwościowe, czerwony – sztuczna inteligencja.

W przypadku podziału na przedstawione w poprzednim rozdziale kategorie algorytmów, na podstawie obliczonego błędu detekcyjnego dla ogólnej ilości 109908 zespołów QRS dla sygnału 105 okazuje się, iż uzyskano najmniejszy błąd detekcyjny 0,39% dla algorytmu działającego w dziedzinie częstotliwości – algorytmu zaproponowanego przez Beniteza w [29, 30], opartego na przekształceniach Hilberta. Wydaje się, że wnioskowanie o optymalności tej grupy metod jest jednak nieuprawnione. Jak opisano w poprzednim punkcie, z analizy porównawczej wykluczono grupę metod działających w dziedzinie

częstotliwości. W związku z powyższym, rozpatrzmy algorytmy pozostałych kategorii. Największy błąd detekcji dla rozpatrywanych metod, wynoszący 6,03%, podano w [231]. Biorąc jednak pod uwagę pozostałe algorytmy zaliczane do grupy metod czasowo – częstotliwościowych, dla których błąd detekcyjny wynosił średnio 1,13%, można stwierdzić, iż jest to grupa algorytmów z wynikami średniej klasy. Najmniejszy błąd detekcyjny otrzymano właśnie przy zastosowaniu metod czasowo–częstotliwościowych, zaś największy dla zaproponowanego przez Poli’ego w [217] algorytmu genetycznego.

Z kolei analizując średnią liczbę detekcji FP oraz FN dla algorytmów z trzech grup (tj. algorytmów dziedziny czasu, dziedziny czasowo–częstotliwościowej oraz opartych o sztuczną inteligencję), najmniejszą liczbę detekcji fałszywie pozytywnej otrzymano dla dziedziny czasowo–częstotliwościowej, największą zaś dla dziedziny czasu. W przypadku FN, najmniejszą liczbę detekcji uzyskano przy zastosowaniu sieci neuronowych. Na Rys.3.3 zaprezentowano powyżej omówioną analizę średniej liczby detekcji fałszywie pozytywnej i fałszywie negatywnej dla poszczególnych algorytmów należących do omawianych grup, a mianowicie z dziedziny czasu, dziedziny czasowo - częstotliwościowej oraz sieci neuronowych.

**Średnia liczba detekcji FP i FN w sygnale 105 dla trzech kategorii algorytmów**




**Rys.3.3 Średnia liczba detekcji FP i FN dla sygnału 105 dla trzech kategorii: T – dziedzina czasu, T-F – dziedzina czasowo – częstotliwościowa, SN – sieci neuronowe.**

Biorąc pod uwagę kolejne miary (tj. dodatnią wartość prognostyczną oraz odsetek poprawnych detekcji), dla sygnału 105 w poszczególnych kategoriach omawianych algorytmów, sytuacja przedstawia się następująco. Metody czasowo

– częstotliwościowe oraz metody opierające się na modelach sieci neuronowych uzyskują takie same wyniki – dla +P wynoszą one 99,36%, zaś R jest o 0,14% większy dla sieci neuronowych niż dla przekształceń falkowych (patrz Rys.3.4).

**Średnia wartość +P i R w poszczególnych grupach dla sygnału 105**




**Rys. 3.4 Dodatnia wartość prognostyczna (+P) oraz odsetek poprawnych detekcji (R) dla sygnału 105 w poszczególnych grupach.**

Podsumowując analizowane wartości wyznaczonych miar dla algorytmów detekcji zespołu QRS w przypadku rozpatrywanego sygnału 105, największe znaczenie mają dwie grupy algorytmów, a mianowicie algorytmy oparte na przekształceniach falkowych oraz sieciach neuronowych. Należy jednak podkreślić, iż różnice pomiędzy tymi dwoma grupami metod detekcyjnych są bardzo niewielkie. Nie można również całkowicie wykluczyć metod działających w dziedzinie czasu. W niniejszym rozdziale dokonano analizy tylko kilku wybranych algorytmów z całej grupy, nie może to więc powodować zupełnego wykluczenia wszystkich algorytmów działających w dziedzinie czasu z dalszej analizy, a także świadczyć o zdecydowanie niższym poziomie ich wykrywalności.

### 3.2.2. Analiza porównawcza algorytmów dla sygnału 108

W przypadku sygnału 108 zawierającego wysoką amplitudę fali R okazuje się, iż większość algorytmów uzyskała dużo gorsze rezultaty niż dla sygnału 105. Analogicznie, jak w przypadku sygnału 105, przygotowano Rys.3.5 przedstawiający błąd detekcyjny dla kilku wybranych algorytmów. I tak na przykład, dla algorytmu Pana - Tompkinsa [206] dla sygnału 105 błąd wynosił 0,71%, zaś w przypadku sygnału 108 – aż 12,54%. Podobnie sytuacja wygląda dla algorytmu Poli’ego [217], bowiem dla sygnału 105 błąd detekcyjny wynosił 3,54%, a dla sygnału 108 wzrósł do 9,53%. Dla omawianych dwóch sygnałów 105 oraz 108 nastąpił zatem wzrost błędu detekcyjnego o odpowiednio 11,83% oraz 5,59%. Spośród wszystkich algorytmów wybranych do analizy w niniejszym rozdziale, powyżej wymienione dają najgorsze wyniki. Pozostałe metody, w świetle omawianych dwóch sygnałów (105 i 108), zarówno z dziedziny czasowo–częstotliwościowej, jak również oparte na sieciach neuronowych, wykazują średni wzrost błędu detekcyjnego o 2,5%.

**Błąd detekcyjny dla sygnału 108**




**Rys. 3.5 Błąd detekcyjny. Kolor żółty – metody czasowe, zielony – metoda częstotliwościowa oparta o przekształcenia Hilberta, niebieski – metody czasowo – częstotliwościowe, czerwony – sieci neuronowe i algorytm genetyczny.**

Analizując liczbę błędnie wykrytych zespołów QRS okazuje się, iż w przypadku algorytmów działających w dziedzinie czasu znacznie wzrasta wykrycie FP. Rozważając detekcje FP i FN w pozostałych kategoriach, następuje także znaczny wzrost wykryć fałszywie negatywnych. Na podstawie danych



można zauważyć, iż najgorsze wyniki, podobnie jak dla sygnału 105, uzyskuje się dla metod czasowych, zaś najlepsze dla metod czasowo – częstotliwościowych (patrz Rys.3.6 – trzy pierwsze kolumny oznaczone T, T-F, AI). Jeśli jednak przeprowadzimy dokładną analizę metod opartych o sztuczną inteligencję okazuje się, iż najlepiej – dla sygnału 108 – spośród wszystkich metod z różnych grup, zespół QRS wykrywa algorytm zaproponowany przez Cohena [53]. Wykrywa on tylko 4 zespoły FP i 3 zespoły FN. Eliminując więc z grupy AI algorytm genetyczny zaproponowany przez Poli'ego [217], dla którego uzyskuje się 143 zespoły FP i 25 FN (najsłabszy rezultat) i który znacznie wpływa na pogorszenie wyników całej tej kategorii metod określanych jako metody sztucznej inteligencji, oraz analizując grupę metod związanych tylko z modelami sieci neuronowych, otrzymujemy ciekawą sytuację (patrz Rys.3.6 – ostatnia kolumna SN w porównaniu z kolumną T i T-F). Algorytmy z dziedziny czasowo – częstotliwościowej uzyskują nieco gorsze wyniki niż sieci neuronowe. Wydaje się zatem, co uzasadniają wyniki, iż dla sygnału 108 najlepszym rozwiązaniem jest zastosowanie sieci neuronowych.

**Średnia liczba detekcji zespołu QRS (FP i FN)  
dla sygnału 108**



**Rys. 3.6 Średnia liczba detekcji zespołu QRS fałszywie pozytywnej (kolor niebieski) oraz fałszywie negatywnej (kolor czerwony) w sygnale 108 dla trzech grup algorytmów (T- dziedzina czasu, T-F dziedzina czasowo – częstotliwościowa, AI – sztuczna inteligencja, SN – sieci neuronowe).**

Analizując kolejne miary, takie jak +P, R, dla sygnału 108, można zauważyć, iż potwierdza się powyższy wniosek o minimalnej wyższości sieci neuronowych nad przekształceniami falkowymi. Dodatnia wartość prognostyczna dla WT jest tylko o 0,02% większa w porównaniu z SN, zaś odsetek poprawnych


detekcji jest o 1,12% wyższy dla SN od WT. Dla porównania w Tabeli nr 3.3 przedstawiono wyniki średnich wartości miar SE, +P, R dla poszczególnych grup.

Tabela nr 3.3 Miary SE, +P, R dla sygnału 105, 108 w poszczególnych kategoriach.

	105			108		
	SE	P	R	SE	P	R
T	99,23	97,14	94,14	98,15	94,38	85,82
T-F	99,63	99,36	97,9	98,93	99,21	96,76
AI	99,7	98,5	98,5	99,36	96,96	92,78
SN	99,65	99,36	99,36	99,75	99,19	97,88

Porównując średni błąd detekcji dla wyżej omówionych sygnałów 105 i 108 (Rys.3.7) potwierdza się wcześniejszy wniosek, iż algorytmy detekcji zespołu QRS dla sygnału 108 generują wyższy procent błędów niż dla sygnału 105. W przypadku detekcji FP, metody czasowo–częstotliwościowe są tylko o 0,01% skuteczniejsze od algorytmów wykorzystujących modele sieci neuronowych, zaś dla detekcji FN, to modele SN są efektywniejsze od metod WT o prawie 1% (0,99%). Obniżają się również wartości wszystkich pozostałych miar w poszczególnych grupach. Niższa jest dodatnia wartość prognostyczna dla dziedziny czasu o 2,76%, dla dziedziny czasowo – częstotliwościowej o 0,15%, dla sztucznej inteligencji o 1,54%, w tym dla sieci neuronowych o 0,17%. Natomiast odsetek poprawnych detekcji jest niższy odpowiednio o 8,32%, 1,14%, 5,72%, 1,48%. Biorąc pod uwagę pogląd Augustyniaka [18], według którego dla sygnałów wysoko zaszumionych odsetek poprawnych detekcji nie powinien być niższy niż 92%, należy zauważyć, iż algorytmy działające w dziedzinie czasu nie uzyskują tego poziomu procentowego. Wskazuje na to choćby miara R, która dla algorytmów działających w dziedzinie czasu wynosi 85,82%.

Średni błąd detekcyjny dla 105 i 108




Rys. 3.7 Średni błąd detekcji zespołu QRS dla sygnałów 105 i 108 w kategoriach: T- metod czasowych, T-F – metod czasowo – częstotliwościowych, AI – sztucznej inteligencji, SN – sieci neuronowych. (Kolor zielony – sygnał 105, kolor żółty – sygnał 108).

### 3.2.3 Analiza porównawcza algorytmów dla sygnałów 203 i 222

W przypadku sygnału 203 posiadającego wysoką amplitudę fali T oraz sygnału 222 zawierającego szum podobny do zespołu QRS, sytuacja wygląda analogicznie, jak w opisanych powyżej dwóch sygnałach 105 i 108. Najgorsze wyniki uzyskiwane są dla metod działających w dziedzinie czasu. Detektory oparte na metodach czasowo – częstotliwościowych są porównywalne z modelami sieci neuronowych, z kilku procentową korzyścią raz dla jednej grupy, innym razem dla drugiej grupy. Średni błąd detekcyjny zespołu QRS w poszczególnych kategoriach dla czterech omawianych sygnałów przedstawiono na Rys.3.8.

Średni błąd detekcji zespołu QRS w poszczególnych kategoriach dla sygnałów 105, 108, 203, 222

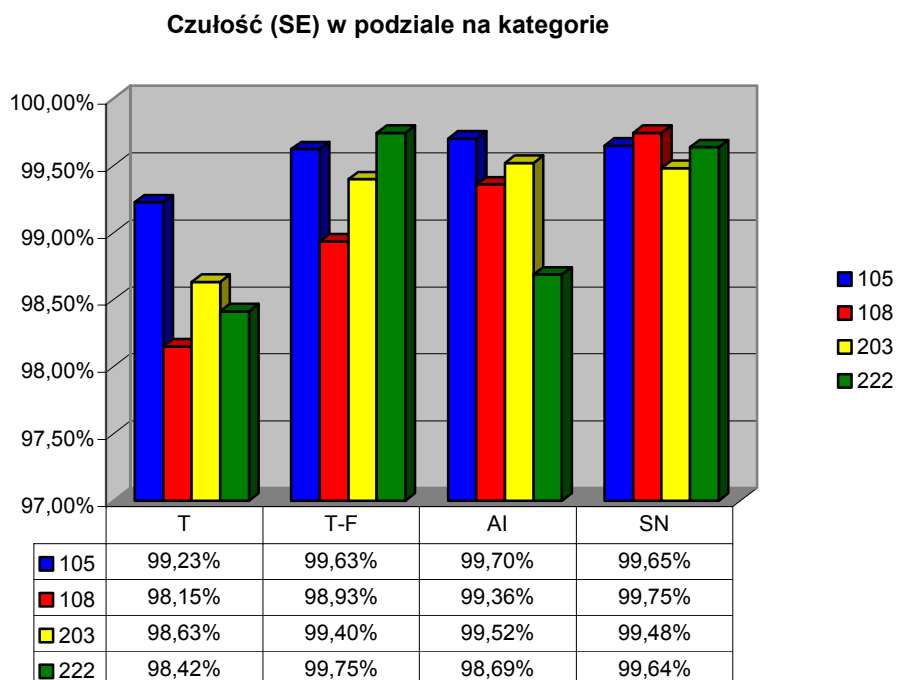


Rys. 3.8 Średni błąd detekcji zespołu QRS dla sygnałów 105, 108, 203, 222 w zależności od kategorii: T – dziedzina czasu, T-F dziedzina czasowo – częstotliwościowa, AI – sztuczna inteligencja, SN – sieci neuronowe.

Biorąc pod uwagę czułość (SE) metod, obliczaną zgodnie ze wzorem (3.2), możemy wyciągnąć następujące wnioski:


- 1) algorytmy działające w dziedzinie czasu uzyskują najmniejszą czułość 98%, jedynie dla sygnału 105 wartość tej miary niewiele przekracza ponad 99%;

- 2) w przypadku metod czasowo – częstotliwościowych tylko dla sygnału 108 czułość wyniosła poniżej 99%;
- 3) metody sztucznej inteligencji uzyskują tylko niewiele niższe rezultaty w porównaniu do metod czasowo - częstotliwościowych (patrz Rys. 3.9).




Rys. 3.9 Czułość dla poszczególnych kategorii metod dla czterech sygnałów elektrokardiograficznych 105, 108, 203, 222.

Analogiczną sytuację uzyskano także dla miar +P i R (patrz Rys.3.10 oraz Rys.3.11).



Rys. 3.10 Dodatnia wartość prognostyczna (+P) w omawianych kategoriach (T, T-F, AI, SN) dla czterech wybranych sygnałów elektrokardiograficznych (105, 108, 203, 222).

### Odsetek poprawnych detekcji



Rys. 3.11 Odsetek poprawnych detekcji zespołu QRS dla poszczególnych grup algorytmów w sygnałach 105, 108, 203, 222

### 3.3 Podsumowanie rozdziału

W przypadku analizowanych sygnałów elektrokardiograficznych pochodzących z bazy MIT-BIH, łatwo można zauważyć, iż efektywność pierwszej grupy algorytmów, związanych bezpośrednio z analizą sygnału w dziedzinie czasu, waha się w przedziale od 96% do 98%. Niektórzy autorzy wykazują, iż wprowadzenie dodatkowego przetwarzania wstępnego, umożliwiającego niekiedy usunięcie szumów i artefaktów, może zwiększyć wrażliwość detekcji. Mimo to, ta grupa algorytmów osiąga najgorsze rezultaty dla wszystkich omawianych miar.


Algorytmy związane z analizą sygnału w dziedzinie czasowo–częstotliwościowej wykazują bardzo wysoką efektywność (99%), podobnie jak trzecia grupa algorytmów oparta na modelach sztucznych sieci neuronowych. Te dwie grupy najlepiej dostosowują się do zmian morfologicznych występujących w sygnale elektrokardiograficznym. W zależności od sygnału, miary określające czułość, dodatnią wartość prognostyczną, czy też odsetek poprawnych detekcji dla tych algorytmów, zmieniają się na korzyść raz jednej, raz drugiej kategorii grup algorytmów.

Należy podkreślić, iż w analizie porównawczej sygnałów 105, 108, 203 oraz 222 nie były brane pod uwagę algorytmy z dziedziny częstotliwościowej

oraz metody związane z różnymi matematycznymi przekształceniami. Jak podają autorzy stosujący przekształcenia matematyczne, średnia czułość tej grupy wynosi około 98%, zaś algorytmy składniowe, znane w literaturze jako algorytmy lingwistyczne lub gramatyczne, wykazują czułość detekcji na poziomie 97%. Wielu autorów wymienionych w rozdziale drugim niniejszej rozprawy łączy kilka metod uzyskując bardzo wysoką wrażliwość detektorów – ponad 99,7%. Niestety, jak już sugerowano we wstępie do niniejszego rozdziału, podają oni jedynie ogólną średnią wartość jednej lub kilku miar. Nie można zatem porównać ich do opisanych powyżej rezultatów dla sygnałów 105, 108, 203, oraz 222.

Warto również zauważyć, że metody związane z dziedziną czasowo – częstotliwościową, sieciami neuronowymi, a także wiele metod łączących różne techniki detekcyjne wymaga zdecydowanie wyższej szybkości obliczeń (elementarnych matematycznych operacji na jednostkę czasu), niż algorytmy zaliczane do grupy metod z dziedziny czasu. Poza tym, algorytmy oparte na WT i SN wymagają zastosowania znacznego przedziału czasu w celu adaptacji wymaganych parametrów detekcji, co z kolei stanowi dość duże utrudnienie w przypadku wykorzystania ich w czasie rzeczywistym, gdzie wszystkie wielkości i współczynniki serca muszą być określone prawie natychmiast po rozpoczęciu badania. Z drugiej jednak strony, zapewniają one wzrost wszystkich miar określających poprawność działania algorytmów detekcji zespołu QRS w porównaniu z algorytmami z dziedziny czasu o kilka, a nawet kilkanaście procent (patrz Rys.3.12).

**Średni wzrost miar SE, +P, R pomiędzy T a T-F i SN**



**Rys.3.12 Średni wzrost miar SE, +P oraz R pomiędzy algorytmami z dziedziny czasu a algorytmami z dziedziny czasowo – częstotliwościowej i sieciami neuronowymi.**

Należy również podkreślić, iż opublikowane przez wielu autorów wartości miar, choć są dość wysokie (zwykle ponad 95%), to brak jest definicji wyznaczanej przez nich miary, a także liczby poszczególnych detekcji TP, FP, FN. To wpłynęło na decyzję o wykluczeniu takiego algorytmu z niniejszego porównania. Z drugiej jednak strony, nie można kategorycznie zaprzeczyć informacjom o podawanych przez autorów wynikach. Dlatego też w niniejszym rozdziale dokonano analizy porównawczej wybranych algorytmów z poszczególnych grup, a nie wszystkich istniejących w literaturze przedmiotu.

Przeprowadzone przez autorkę rozprawy badania potwierdzają także przydatność przekształceń falkowych do detekcji zespołu QRS. Jak wykazały eksperymenty, dla sygnałów pochodzących z bazy MIT-BIH, w porównaniu do algorytmów działających w dziedzinie czasu, uzyskano najlepsze rezultaty dla falek wyższych rzędów, ze względu na ich gładki przebieg. Wyniki opublikowano w pracy [76].

## **Rozdział IV**

# **Ocena działania wybranych algorytmów detekcji zespołu QRS dla sygnałów EKG – stymulatorowych**

W rozdziale drugim niniejszej rozprawy zaprezentowano przegląd literatury dotyczącej wykrywania zespołu QRS z podziałem na kilka grup (metody czasowe, częstotliwościowe, czasowo – częstotliwościowe oraz oparte o sztuczną inteligencję). W rozdziale trzecim nastąpiła próba porównania wybranych algorytmów, na podstawie wyników prezentowanych w literaturze dla sygnałów EKG pochodzących z ogólnodostępnej bazy MIT-BIH. W niniejszym rozdziale rozprawy dokonana zostanie ocena działania kilku wybranych algorytmów dla sygnałów pochodzących od pacjentów z wszczepionym układem stymulatorowym.

Bogata ilość metod zaprezentowanych w rozdziale drugim niniejszej rozprawy świadczy o dużym zainteresowaniu zarówno problematyką detekcji zespołu QRS, jak i analizą sygnału elektrokardiograficznego. Nie jest możliwe przeanalizowanie wszystkich algorytmów dla zgromadzonego przez autorkę zbioru, dlatego też ocena działania algorytmów detekcji dla sygnałów pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca, została ograniczona jedynie do kilku wybranych algorytmów działających w dziedzinie czasu. W analizie porównawczej algorytmów w rozdziale trzecim pominięto dziedzinę częstotliwościową, ze względu na brak dokładnych wyników w literaturze. W celu zachowania pewnej systematyczności w niniejszym rozdziale pracy, nie zostały wybrane do analizy także algorytmy z dziedziny częstotliwościowej. Dziedzina czasowo – częstotliwościowa zostanie zaś zbadana w rozdziale szóstym, dlatego też ocena działania algorytmów detekcji jest ograniczona do dziedziny czasu.

W rozdziale tym zostanie także scharakteryzowana baza sygnałów zgromadzonych przez autorkę rozprawy. Sygnały te uzyskano z Instytutu Kardiologii w Warszawie oraz firmy ASPEL z Krakowa.



## **4.1 Charakterystyka zgromadzonych sygnałów elektrokardiograficznych – stymulatorowych**


Na potrzeby pracy została przygotowana baza 150 sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym rozrusznikiem serca. Rejestracja sygnałów wykonywana była z powierzchni klatki piersiowej, przy pomocy siedmiu elektrod, dzięki którym uzyskano standardowe trzy odprowadzenia, a mianowicie:

- 1) Odprowadzenie CM – V5
  - elektroda biała (przymostkowo na rękojęści po stronie prawej, powyżej niebieskiej),
  - elektroda czerwona (w linii pachowej przedniej na 6 żebrze),
- 2) Odprowadzenie CM – V3 – kanał stymulatora
  - elektroda czarna (przymostkowo na rękojęści po stronie lewej, powyżej niebieskiej),
  - elektroda brązowa (w linii środkowo obojczykowej na 6 żebrze),
- 3) Odprowadzenie CM – V1
  - elektroda niebieska (na rękojęści mostka),
  - elektroda pomarańczowa (na żebrze, 2 centymetry na prawo od wyrostka mieczykowatego),
  - elektroda neutralna – zielona (przyśrodkowo na brzegu prawego 8 żebra).

Dokładne rozmieszczenie elektrod, zgodne z powyższym opisem, ukazane na Rys.4.1, umożliwia:

- zapis sygnału EKG na dwóch kanałach,
- rejestrację impulsów stymulatora na jednym (drugim) kanale,
- częściowo minimalizuje artefakty.

Częstotliwość próbkowania każdego zarejestrowanego metodą Holtera sygnału wynosiła 128 Hz, a rozdzielczość 8 bitów. W badanej grupie pacjentów 65% stanowili mężczyźni, 45% kobiety, zaś średnia wieku nie przekraczała 58 lat.



**Rys. 4.1** Rozmieszczenie elektrod na klatce piersiowej pacjenta z wszczepionym rozrusznikiem.

Pacjentom wszczepiono rozruszniki firmy Biotronik. W Tabeli nr 4.1 ukazano liczbę analizowanych sygnałów dla wszczepionego rozrusznika o podanej nazwie.

**Tabela nr 4.1** Liczba zgromadzonych sygnałów dla poszczególnych rozruszników firmy Biotronik.

Nazwa rozrusznika	Liczba sygnałów
Actros D	57
Actros S	32
Actros DR	4
Actros SLR	15
Actros SR	9
Logos	5
Kairos D	11
Kairos DR	4
Kairos SL	3
Kairos SR	3
Dromos DR	2
Dromos SR	4
Dromos SL	1


Powyżej wymienione układy stymulujące pracowały w różnych trybach stymulacji. Największa liczba stymulatorów pracowała w trybie DDD, zaś tylko jeden sygnał był realizowany w trybie stymulacji AAD. Dokładną liczbę sygnałów, w zależności od stosowanej stymulacji przedstawiono w Tabeli nr 4.2.

Tabela nr 4.2 Liczba sygnałów dla określonego trybu stymulacji.

Tryb stymulacji	Liczba sygnałów
AAD	1
AAI	18
DDD	72
DDI	14
VDD	21
VVI	24

Analizowana grupa sygnałów pochodzi od pacjentów o różnym rozpoznaniu klinicznym. Największą grupę stanowili mężczyźni ze zdiagnozowaną chorobą wieńcową lub zawałem serca. Na Rys. 4.2 przedstawiono liczbę sygnałów w zależności od diagnozy chorobowej pacjentów z wykorzystaniem standardowych kodów chorób, jakie są obecnie używane w medycynie.

Liczba sygnałów o podanym rozpoznaniu klinicznym

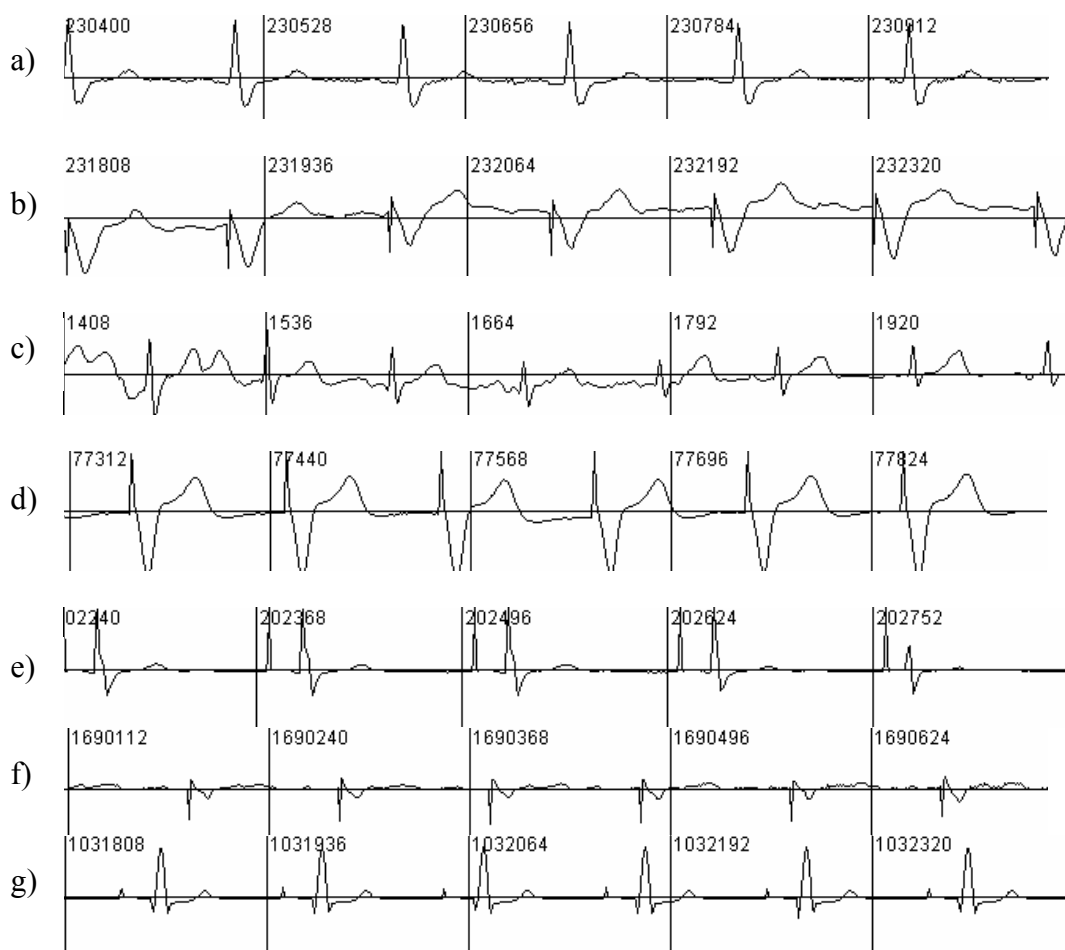


Rys. 4.2 Liczba sygnałów o podanym rozpoznaniu klinicznym. W legendzie wykorzystano standardowe kody chorób używane w prezentowanych stymulatorach. B2 - choroba układu przewodzącego; C1+C2 - choroba wieńcowa lub zawał; D1 - patologia wrodzona; E1 - powikłania chirurgiczne; E3 - ablacja; G1 - kardiomiopatia; G3 - wada zastawkowa; NZ - brak danych.

Dodatkowo dla zgromadzonych sygnałów sprawdzono częstotliwość pracy stymulatora. W przypadku omawianej grupy 150 sygnałów EKG – stymulatorowych okazało się, iż sygnały te charakteryzuje bardzo różny odsetek zawartego w nich rytmu endogennego (własnego) i stymulacyjnego (sztucznego). Przykładowe dane dla kilku wybranych sygnałów przedstawiono w Tabeli Nr 4.3, zaś fragmenty ich zapisów na Rys. 4.3.

**Tabela nr 4.3 Zawartość rytmu endogennego i stymulatorowego wyrażona w procentach dla kilku wybranych sygnałów.**

Nr sygnału	Zawartość rytmu wyważona %	
	Własny	Stymulatorowy
stym005	87%	13%
stym014	7%	93%
stym025	76%	24%
stym037	45%	55%
stym052	22%	78%
stym103	5%	95%
stym145	53%	47%



**Rys. 4.3 Przykładowe sygnały elektrokardiograficzne – stymulatorowe a) stym005; b) stym014; c) stym025 d) stym037; e) stym052; f) stym103 g) stym145.**

Należy podkreślić, iż zgromadzona grupa sygnałów charakteryzuje się dość dużym zróżnicowaniem, zarówno pod względem zawartości rytmu endogennego, zastosowanego trybu stymulacji, jak i rozpoznania klinicznego. W kolejnym punkcie tego rozdziału zostaną przedstawione wyniki badań dotyczące wykrywania zespołu QRS poprzez algorytmy z dziedziny czasu. Z kolei w rozdziale szóstym ukazane będą wyniki badań uzyskane przy wykorzystaniu zaproponowanej przez autorkę rozprawy metody dla wyżej opisanej bazy 150 sygnałów.

Warto również zaznaczyć, iż dodatkowo uzyskano 21 sygnałów z firmy ASPEL z Krakowa. Dla tej grupy sygnałów autorce rozprawy nie jest znany rodzaj rozrusznika, czy też dokładny sposób rejestracji sygnałów. Tryb stymulacji, zawartość rytmu endogennego w sygnałach oraz ich kliniczne rozpoznanie nie odbiegają od norm przedstawionych powyżej dla 150 sygnałów uzyskanych z Instytutu Kardiologii Warszawie. Sygnały te były użyte jako dodatkowa forma testowania.

## **4.2 Ocena algorytmów z dziedziny czasu**

W badaniach wykorzystane zostały algorytmy dziedziny czasu zaproponowane przez Friesena i współautorów w pracy [84]. Wybór tej grupy algorytmów podyktowany był przede wszystkim licznymi odwołaniami znajdującymi się w literaturze. Każdy z dziewięciu algorytmów zaproponowanych przez Friesena jest zmodyfikowaną wersją algorytmów istniejących w literaturze przedmiotu z lat 70. i 80. Dodatkowo sprawdzono działanie każdego algorytmu pod względem różnego rodzaju szumów zawartych w sygnale elektrokardiograficznym. Algorytmy zaproponowane przez Friesena można podzielić na cztery grupy. Są to algorytmy oparte na:

- amplitudzie i pierwszej pochodnej sygnału (AF1, AF2, AF3)
- tylko pierwszej pochodnej (FD1, FD2)
- pierwszej i drugiej pochodnej (FS1, FS2)
- filtrach cyfrowych (DF1, DF2)

Tabela nr 4.4 ukazuje szczegółowo źródło pochodzenia poszczególnych algorytmów Friesena.


**Tabela nr 4.4 Źródło pochodzenia algorytmów Friesena.**

Algorytm	Twórca	Rok
AF1	Moriet - Mahoudeaux	1981
AF2	Fraden & Neuman	1980
AF3	Gustafson	1977
FD1	Menad	1981
FD2	Holsinger	1971
FS1	Balda	1977
FS2	Alhstrom & Tompkins	1983
DF1	Engelse & Zeelenberg	1979
DF2	Okada	1979

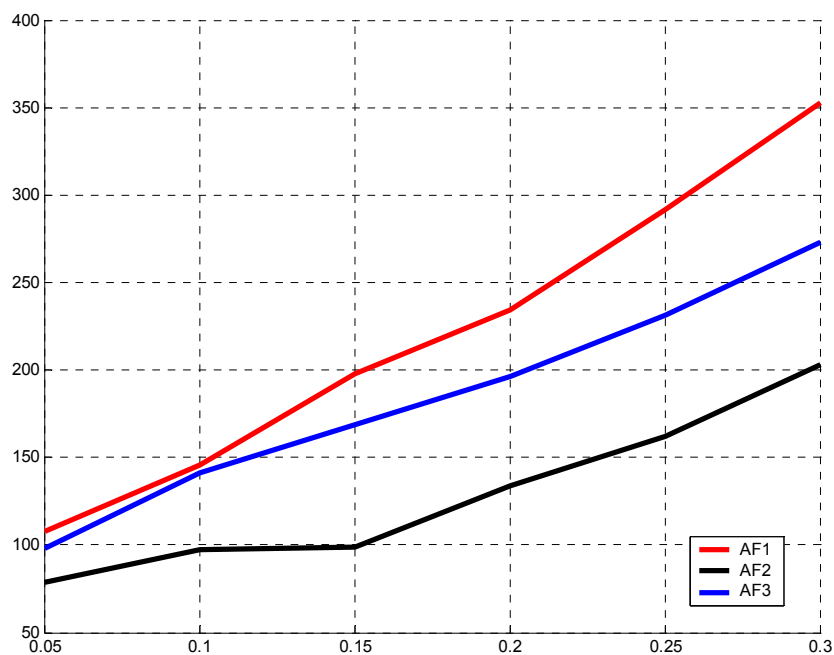
#### **4.2.1 Analiza algorytmów Friesena opartych o amplitudę i pierwszą pochodną**

Analizując pierwszą grupę algorytmów opartych o amplitudę i pierwszą pochodną (AF1, AF2, AF3) zauważono, iż bardzo duże znaczenie ma zawarty w sygnale szum o niskiej częstotliwości. Potwierdzają się zatem badania Friesena o ograniczonym działaniu algorytmów AF1 – AF3 w przypadku przesunięcia linii bazowej, spowodowane np. oddechem pacjenta. Związane jest to ze stosowanym w powyższych algorytmach kryterium identyfikacji zespołu QRS opierającego się na wartości bezwzględnej amplitudy. W przypadku dużych i nagłych zmian w linii bazowej, zespoły QRS mogą nie mieć wystarczającej amplitudy, aby spełnić kryterium.


W pierwszej grupie badanych algorytmów opartych o amplitudę i pierwszą pochodną, najlepsze rezultaty uzyskano dla sygnałów, w których dominuje rytm endogeny (własny) pacjenta. Na Rys. 4.4 przedstawiono ilość poprawnie wykrytych zespołów QRS (TP) dla różnych progów. Na podstawie tego wykresu można zauważyć, że im wyższy próg, tym liczba poprawnie wykrytych zespołów QRS maleje. Różnica w detekcjach TP pomiędzy minimalnym a maksymalnym progiem jest bardzo duża, średnio wynosi około 65%. Wybór tak niskiego progu powoduje wykrycie dużej liczby detekcji FP oraz FN. Zależności detekcji fałszywie pozytywnej oraz fałszywie negatywnej od przyjętego progu ukazano na Rys. 4.5 oraz Rys. 4.6.



Rys. 4.4 Zależność wykrycia detekcji prawdziwie pozytywnej (TP) od wybranego progu z przedziału [0,05; 0,3] dla algorytmów AF1- kolor czerwony, AF2 – kolor czarny, AF3 – kolor niebieski.



Rys. 4.5 Liczba detekcji FN dla algorytmów AF1-AF3 w zależności od wybranego progu detekcyjnego. (AF1- kolor czerwony, AF2 – kolor czarny, AF3 – kolor niebieski).




**Rys. 4.6** Liczba detekcji FP dla algorytmów AF1(kolor czerwony), AF2(czarny), AF3(niebieski) w zależności od progu.


Należy zaznaczyć, iż liczba detekcji TP, FN oraz FP, przedstawiona na omawianych rysunkach (Rys.4.4 – 4.6), dotyczy 30 – minutowego losowo wybranego fragmentu sygnału (stym025.dat).

Na podstawie wyników uzyskanych dla omawianej grupy algorytmów, opierających się na amplitudzie i pierwszej pochodnej, można zauważyć, iż najlepsze rezultaty dla sygnałów EKG – stymulatorowych otrzymano dla algorytmu AF2. Analizując miary opisane w rozdziale trzecim niniejszej rozprawy, tj. czułość (3.1) oraz błąd detekcyjny (3.3), można stwierdzić, iż algorytm AF2 uzyskuje najmniejszą liczbę detekcji fałszywie negatywnej, która ma istotny wpływ na miarę czułości oraz najmniejszą liczbę detekcji fałszywie pozytywnej, która zwiększa błąd detekcyjny. Średnią czułość dla algorytmów AF1 – AF3 przedstawiono na Rys. 4.7, zaś uzyskany średni błąd detekcyjny zaprezentowano na Rys. 4.8.





**Rys. 4.7 Średnia czułość dla algorytmów AF1-AF3.**



**Rys. 4.8 Średni błąd detekcyjny algorytmów AF1 – AF3.**

Wydaje się, iż wpływ na tak niskie rezultaty algorytmów AF1 oraz AF3 ma wybór stałych wartości progowych oraz bardzo wysoki poziom szumów w badanych sygnałach. Na powyższe wyniki oddziałuje również wykorzystywana w tych algorytmach amplituda. Na przykład, algorytmy AF1 oraz AF2 wymagają użycia wysokiej amplitudy fali R, co w przypadku sygnałów–stymulatorowych nie jest częste, a wręcz przeciwnie mamy do czynienia z niską amplitudą fali R. Częstotliwość próbkowania sygnałów wynosi bowiem 128 Hz. Większa ilość detekcji fałszywie pozytywnej w przypadku algorytmów AF1, AF3 niż w porównaniu do algorytmu AF2, spowodowana jest również brakiem możliwości ich adaptacji do zmieniających się warunków sygnału (np. nagłą zmianą linii bazowej, szumem elektromiograficznym).


## 4.2.2 Analiza algorytmów Friesena opartych o pierwszą pochodną

Algorytmy oparte tylko na pierwszej pochodnej FD1 oraz FD2, jak wykazały badania, charakteryzują się lepszą skutecznością. Friesen [84] proponuje dla tych algorytmów wyznaczenie progu detekcyjnego w następujący sposób:


- a) obliczenie w każdym punkcie sygnału pierwszej pochodnej,
- b) znalezienie wartości maksymalnej,
- c) wymnożenie znalezionej maksimum przez odpowiedni tzw. mnożnik.

Należy podkreślić, iż Friesen stosuje dla FD1 mnożnik 0,7 zaś 0,45 dla FD2.


W wyniku przeprowadzonych badań dla analizowanych dwóch algorytmów (FD1, FD2), wartości stosowanych przez Friesena progów i mnożników nie pokrywają się z użytymi przez autorkę rozprawy. Dla sygnałów elektrokardiograficznych – stymulatorowych, opisanych w punkcie 4.1 niniejszego rozdziału, przy zastosowaniu mnożników 0,7 oraz 0,45, algorytmy nie wykrywały ponad 89% zespołów QRS. Poprawę rezultatów uzyskano przy wykorzystaniu bardzo niskich progów (np. dla FD2 przy progu 0,05). Analiza poprawnie wykrytych zespołów QRS, podobnie jak w opisanych powyżej algorytmach opierających się na amplitudzie i pierwszej pochodnej, dotyczy liczby detekcji TP, FP oraz FN. Maksymalną wartość poprawnie wykrytych zespołów QRS uzyskano dla najniższego badanego progu 0,05. Na wykresach (Rys. 4.9 – Rys. 4.11) przedstawiono liczbę detekcji TP, FN oraz FP dla algorytmów FD1 oraz FD2. Są to najlepsze wyniki, które otrzymano dla sygnału stym99.



Rys. 4.9 Liczba poprawnie wykrytych zespołów QRS (TP). Dla algorytmu FD1 (linia czerwona), FD2 (linia niebieska).




Rys. 4.10 Liczba detekcji FN dla algorytmu FD1 (linia czerwona), FD2 (linia niebieska).



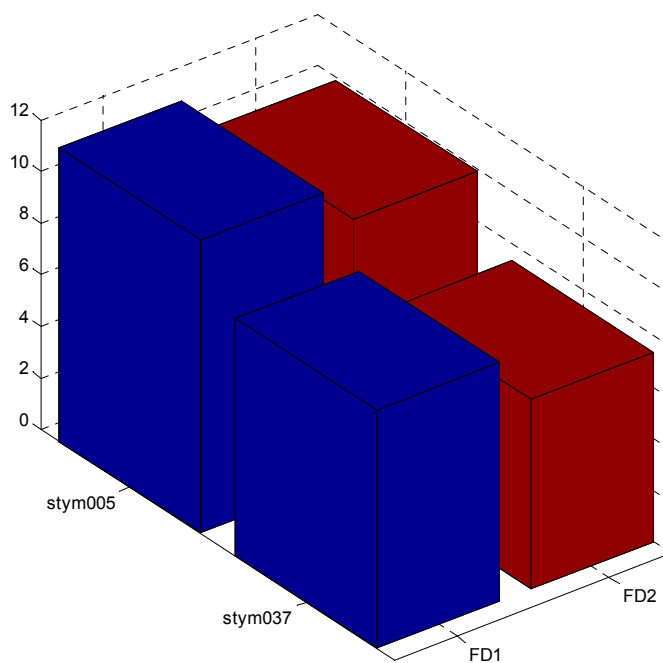
**Rys. 4.11** Liczba detekcji FP zespołów QRS. Dla algorytmu FD1 (linia czerwona), FD2 (linia niebieska).

Analizując miarę czułości dla algorytmów opartych tylko o pierwszą pochodną otrzymano lepsze rezultaty niż w przypadku omawianych powyżej algorytmów opierających się na amplitudzie i pierwszej pochodnej. Dla wszystkich analizowanych sygnałów uzyskano bowiem czułość przewyższającą 90%, co w przypadku algorytmów AF występowało stosunkowo rzadko. Jedynie średnia czułość dla algorytm AF2 wynosiła 92,27%, czułość zaś pozostałych algorytmów AF, jak ukazano na Rys. 4.6, nie przekroczyła 90%. W przypadku algorytmów FD1 oraz FD2 średnia czułość wynosi odpowiednio 93,68% oraz 93,89%. I choć algorytm FD2 należy uznać za bardziej czuły, to nie zauważono dużych rozbieżności pomiędzy tymi dwoma algorytmami. Różnice w czułości dla kilku sygnałów w przypadku omawianych algorytmów FD1, FD2, przedstawiono na Rys. 4.12.



**Rys. 4.12** Czulość algorytmów FD1, FD2 dla trzech sygnałów.

Podobne wnioski nasuwają się na podstawie analizy kolejnej miary, jaką jest błąd detekcyjny. Średni BD wynosi odpowiednio dla FD1 10,93%, a dla FD2 8,76%. Na Rys. 4.13 ukazano błąd detekcyjny dla obu algorytmów FD1 i FD2. Łatwo zauważyć, iż BD jest niższy dla FD2.



**Rys. 4.13** Błąd detekcyjny dla sygnałów stym005, stym037 algorytmów FD1, FD2.


### 4.2.3 Analiza algorytmów Friesena opartych na pierwszej i drugiej pochodnej

Cechą charakterystyczną algorytmów opartych na pierwszej i drugiej pochodnej jest stosowanie dwóch progów (oznaczymy je P1FS oraz P2FS). Z przeprowadzonych badań wynika, iż dolny próg (P1FS) dla sygnałów elektrokardiograficznych – stymulatorowych musi być ustawiony, podobnie jak dla wcześniej analizowanych algorytmów AF i FD, na 0,05. Drugi próg P2FS (tzw. górny) ma duże znaczenie w przypadku liczby detekcji fałszywie pozytywnej. Ustalono na podstawie badań, że im niższy próg P2FS, tym następuje wykrycie większej liczby detekcji FP. Związane jest to bezpośrednio z wykrywaniem artefaktów jako zespołów QRS. Dolną granicą górnego progu jest zatem 0,40. Poniżej tej granicy (0,40), detekcje FP dla 30 minutowych fragmentów przekraczają w 50% liczbę prawidłowo wykrytych QRS. Tabela nr 4.5 przedstawia wyniki dla kilku sygnałów poprawnej ilości wykrytych zespołów QRS dla różnych wartości progowych P2FS.

**Tabela nr 4.5 Przykład prawidłowych detekcji zespołu QRS (TP) dla kilku sygnałów EKG w zależności od górnego progu P2FS dla P1FS=0,05.**


Nazwa sygnału	ilość TP	Próg P2FS				
		0,4	0,45	0,5	0,55	0,6
Stym005	2657	2067	2256	2412	<b>2601</b>	2558
Stym014	2378	2078	2156	2202	<b>2287</b>	2236
Stym037	2286	1976	2059	2134	<b>2225</b>	2199
Stym103	2450	1992	2209	2356	<b>2398</b>	2357

Łatwo można zauważyć, iż liczba detekcji TP, wyrażona w procentach, dla powyżej omówionych czterech sygnałów, jest najwyższa dla progu 0,55, ale nie przekracza 97,88% (patrz Rys. 4.14). Średnio, ilość prawidłowo wykrytych zespołów QRS wyrażona w procentach dla wszystkich analizowanych sygnałów wynosi 97,03%.




**Rys. 4.14** Procent detekcji TP w kolejnych progach P2FS = [0,4; 0,45; 0,5; 0,55; 0,6; 0,65], dla sygnałów stym005, stym014, stym037, stym103.

Wybór górnego progu P2FS = 0,55 potwierdza również punkt przecięcia krzywych FP i FN usytuowany dla wszystkich badanych sygnałów – stymulatorowych między 0,55 a 0,6. (Rys. 4.15) Wysłunięto zatem wniosek, iż P2FS powinien wynosić 0,55, dla tego bowiem progu uzyskiwano najmniejszą liczbę detekcji fałszywie pozytywnej i fałszywie negatywnej oraz największą liczbę prawidłowych detekcji (TP).



**Rys. 4.15** Liczba detekcji fałszywie negatywnej (krzywa niebieska) oraz fałszywie pozytywnej (krzywa czerwona) w zależności od zmiany górnego progu algorytmów FS.

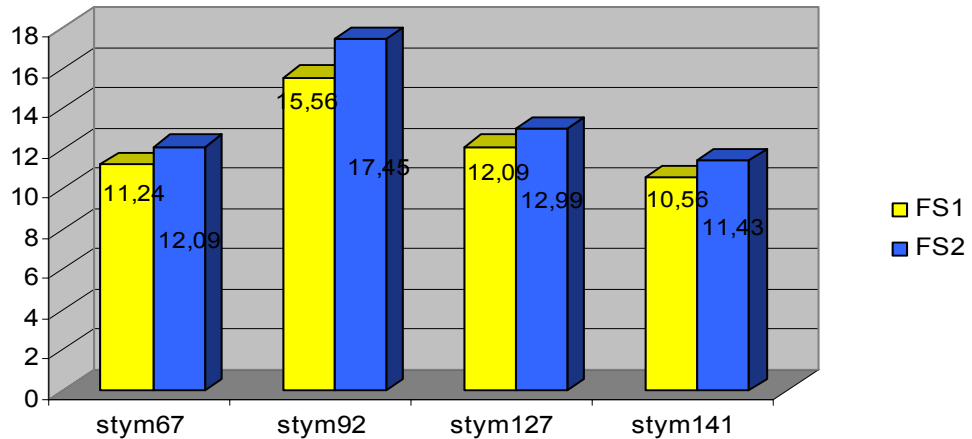
Analizując miarę czułości dla omawianych algorytmów opierających się na pierwszej i drugiej pochodnej, otrzymywano lepsze wyniki dla FS1, niż dla FS2. Różnice między czułością tych algorytmów w analizowanych sygnałach EKG były jednak bardzo niewielkie – wynosiły średnio 1,07%. Średnia czułość algorytmu FS1 wynosiła 92,25%, zaś dla FS2 91,18%. Wartości miary czułości dla kilku przykładowych sygnałów dla  $P1FS=0,05$   $P2FS=0,55$  przedstawiono na Rys. 4.16.



**Rys. 4.16** Przykładowe wartości miary czułości w przypadku algorytmów FS1 oraz FS2 dla kilku sygnałów EKG.

W podobny sposób dokonano analizy kolejnej miary opisanej w rozdziale trzecim – błędu detekcyjnego. Wartość BD, zgodnie z definicją (3.3), uzależniona jest od detekcji fałszywie negatywnej oraz fałszywie pozytywnej. Im mniejsza liczba FP i FN, tym błąd detekcyjny jest mniejszy. W przypadku niskiego progu, jak sugerowano już powyżej, następuje bardzo duża liczba detekcji FP, która w znaczny sposób podwyższa wartość błędu detekcyjnego. Na przykład, dla progu  $P2FS = 0,35$  dla sygnału stym101, liczba detekcji fałszywie pozytywnej była najwyższa i przekroczyła 950, co dla 30 minutowego fragmentu, w którym występuje około 2500 zespołów QRS stanowi 40%. Dla tego sygnału, dla obu algorytmów FS, uzyskano największą wartość BD przekraczającą 30%, choć czułość przewyższała minimalnie 91%. Wartość błędu detekcyjnego była jednak największa dla tej grupy algorytmów w porównaniu z pozostałymi algorytmami Friesena. Najniższy błąd uzyskiwano dla sygnałów, w których występował miarowy rytm własny. Na Rys. 4.17 ukazano wartości czterech najmniejszych błędów detekcyjnych. Średni błąd detekcyjny dla FS1 wynosi 12,78%, zaś dla FS2 =14,15%.







Rys. 4.17 Najmniejszy błąd detekcyjny otrzymany dla algorytmów FS1, FS2 dla sygnałów.

#### 4.2.4 Analiza algorytmów Friesena opartych o filtry cyfrowe

Ostatnią grupę algorytmów Friesena stanowią algorytmy oparte na filtrach cyfrowych DF1, DF2. Tak jak dla powyżej analizowanych grup algorytmów AF, FD oraz FS, badano liczbę detekcji prawdziwie pozytywnych, fałszywie negatywnych oraz fałszywie pozytywnych. Rozpatrywano miarę czułości i błąd detekcyjny. W przypadku algorytmów wykorzystujących filtry cyfrowe uzyskano wyniki porównywalne do algorytmów FD (opartych tylko na pierwszej pochodnej). Średnią czułość i błąd detekcyjny dla algorytmów DF przedstawiono na Rys.4.18 – 4.19. Biorąc pod uwagę miarę czułości, nie można jednoznacznie wskazać, który z omawianych algorytmów opartych o filtry cyfrowe jest skuteczniejszy. Różnica w czułości pomiędzy DF1 a DF2 wynosi tylko 0,05%, na korzyść DF1. Jednak uzyskany średni błąd detekcyjny dla algorytmu DF1 (prawie 10%), w porównaniu ze średnim błędem detekcyjnym algorytmu DF2 (8,5%), sugeruje przewagę algorytmu DF2 nad DF1 dla tej miary o 1,41%. Na podstawie czułości i błędu detekcyjnego obu algorytmów należy uznać, iż dla większości sygnałów stymulatorowych algorytm DF2 uzyskiwał lepsze rezultaty niż DF1. Różnice są jednak niewielkie i nie można jednoznacznie przesądzić o zdecydowanej wyższości algorytmu DF2 nad algorytmem DF1. Ogólnie jednak uzyskano dla tej grupy algorytmów najlepsze wyniki.



Rys. 4.18 Średnia czułość algorytmów DF1 oraz DF2.




Rys. 4.19 Średni błąd detekcyjny algorytmów DF1 oraz DF2.

### 4.3 Uwagi podsumowujące

W analizie porównawczej wykorzystano zaproponowane przez Friesena algorytmy działające w dziedzinie czasu. Dla każdego z dziewięciu algorytmów i dla wszystkich zgromadzonych przez autorkę rozprawy sygnałów, sprawdzono liczbę detekcji poprawnie wykrytych (TP), liczbę detekcji fałszywie pozytywnej (FP) oraz fałszywie negatywnej (FN). Dla każdego sygnału wyznaczano czułość i błąd detekcyjny. Podsumowując rezultaty wszystkich dziewięciu algorytmów dla sygnałów elektrokardiograficznych – stymulatorowych okazuje się, iż miara czułości nie przekroczyła 94,25%. Wynik ten nie jest zadowalający, biorąc pod uwagę rezultaty podane w rozdziale trzecim.

Analizując wartości średnich czułości dla wszystkich dziewięciu algorytmów okazuje się, iż najmniejszą czułość (poniżej 90%) uzyskano dla algorytmu AF1 oraz AF3. Czułość pozostałych algorytmów wahała się w przedziale 91% - 94,5%. Największą czułość osiągnęły algorytmy oparte


o filtry cyfrowe, nieco mniejszą zaś algorytmy wykorzystujące pierwszą pochodną. Różnica pomiędzy tymi dwoma grupami wynosiła średnio 0,4%. Na wykresie Rys. 4.20 uwzględniono średnią czułość dziewięciu omawianych algorytmów Friesena uzyskaną dla wszystkich analizowanych sygnałów.



**Rys. 4.20 Średnia miara czułości dla poszczególnych algorytmów Friesena. Kolejno kolorami zaznaczono algorytmy oparte: kolor żółty – o amplitudę i pierwszą pochodną; kolor niebieski – o pierwszą pochodną; kolor czerwony – o pierwszą i drugą pochodną; kolor zielony – o filtry cyfrowe.**

Analizując błąd detekcyjny dla wszystkich algorytmów Friesena należy stwierdzić, iż jest on dość duży. Dla algorytmów opartych o filtry cyfrowe otrzymano najniższy BD, najwyższy zaś, tak jak dla omówionej powyżej miary czułości, dla algorytmów wykorzystujących amplitudę i pierwszą pochodną. Różnica w wartości uzyskanego średniego błędu detekcyjnego pomiędzy algorytmami DF a FD jest jednak niewielka w porównaniu z algorytmami AF, czy też FS. Na Rys. 4.21 uwzględniono średni błąd detekcyjny dziewięciu algorytmów Friesena.

## BD



Rys. 4.21 Średni błąd detekcyjny dla poszczególnych algorytmów Friesena. Kolejno kolorami zaznaczono algorytmy oparte: kolor żółty – o amplitudę i pierwszą pochodną; kolor niebieski – o pierwszą pochodną; kolor czerwony – o pierwszą i drugą pochodną; kolor zielony – o filtry cyfrowe.

Biorąc pod uwagę powyżej wyznaczone miary (tj. czułość i błąd detekcyjny) dla czterech grup algorytmów, najlepsze wyniki dla detekcji zespołu QRS w przypadku sygnałów elektrokardiograficznych – stymulatorowych otrzymano dla algorytmów opartych o filtry cyfrowe (DF1, DF2), najgorsze zaś dla algorytmów wykorzystujących amplitudę i pierwszą pochodną (AF1, AF3). Dla algorytmu AF2 uzyskano wyniki porównywalne z grupą algorytmów opartych o pierwszą i drugą pochodną.

Na podstawie przeprowadzonych doświadczeń wydaje się uzasadniony wniosek o generowaniu dużej ilości detekcji fałszywie pozytywnej oraz fałszywie negatywnej. Rozpatrywane algorytmy Friesena, wykazujące czułość na poziomie 94% i charakteryzujące się wysokim błędem detekcyjnym, dochodzącym do 20% dla algorytmów AF, nie powinny być stosowane jako narzędzia detekcyjne w przypadku sygnałów elektrokardiograficznych–stymulatorowych. Jednocześnie należy podkreślić, iż przeanalizowano tylko niewielką grupę algorytmów działających w dziedzinie czasu, a zatem nieuzasadniona byłaby ogólna opinia o nieprzydatności (nieprzystosowalności) algorytmów detekcji zespołu QRS z całej dziedziny czasu dla sygnałów elektrokardiograficznych – stymulatorowych.

## **Rozdział V**

### **Zastosowanie sieci falkowo – neuronowej**

#### **Opis metody**

Na podstawie zaprezentowanej analizy porównawczej algorytmów detekcji zespołu QRS w standardowych sygnałach elektrokardiograficznych, przedstawionej w rozdziale trzecim oraz oceny działania wybranych algorytmów w przypadku sygnałów EKG zawierających impuls stymulatora, podanych w rozdziale czwartym, podjęto próbę połączenia dwóch metod. Przedmiotem rozprawy jest detekcja zespołu QRS z jednoczesnym wykryciem rytmu własnego pacjentów z wszczepionym układem stymulującym pracę serca. W niniejszym rozdziale zostaną zaprezentowane matematyczne podstawy stosowanej metody (sieci falkowo – neuronowej), łączącej cechy czasowo–częstotliwościowe z zasadniczą cechą sieci neuronowej, jaką jest klasyfikacja. Rozdział został podzielony na trzy części. Dwa pierwsze podpunkty są wprowadzeniem w tematykę sieci falkowo – neuronowej. Pierwszy dotyczy wiadomości z zakresu przekształceń falkowych, a przede wszystkim stosowanej dekompozycji sygnału. Drugi zaś przybliży problematykę odnoszącą się do zastosowanych sieci neuronowych. Zaprezentowane zagadnienia podane są w ograniczonym zakresie, jedynie w związku z potrzebami badawczymi pracy. Trzecia część niniejszego rozdziału opisuje natomiast sposób połączenia omówionych dziedzin.

#### **5.1 Przekształcenia falkowe**

Pierwsze idee konstruowania falek pojawiły się w pracach Haara już w 1909 r. Jednak rozwój tej dziedziny nauki zapoczątkowany został w latach 80. XX wieku. Dopiero w 1984 roku Grossmann i Morlet wprowadzili pojęcie transformaty falkowej [94], a Stromberg, Larmie oraz Meyer odkryli pierwszą ortogonalną falkową funkcję bazową. Jednak za przełom w dziedzinie przekształceń falkowych, który spowodował, iż analiza falkowa stała się jedną z ważniejszych gałęzi cyfrowego przetwarzania sygnałów, uważa się prace dwóch autorów, a mianowicie:

- Mallata z 1985r. o zastosowaniu falek w przetwarzaniu sygnałów sejsmologicznych oraz z 1989r. gdzie w szczególności udowodnił istnienie związków pomiędzy transformatą falkową, wielopoziomową dekompozycją sygnału, teorią banków filtrów i bazami ortonormalnych funkcji falkowych [170, 171].
- Daubechies z 1987 r. o konstruowaniu falkowych baz ortogonalnych [67].

W literaturze przedmiotu odnaleźć można bogaty zasób wiedzy dotyczącej zarówno podstaw analizy wielorozdzielczej, jak i teorii falek. Wyczerpująco zagadnienia te zostały przedstawione w opracowaniach [66,171,5,51]. W literaturze polskiej godne uwagi są zaś monografie Białasiewicza [31], oraz Wojtaszczyka [285]. Pewne elementy przekształceń falkowych odnaleźć można także w publikacjach Kwiatkowskiego [152]. W ostatnich latach pojawiły się dysertacje dotyczące zastosowań falek w różnych dziedzinach. I tak np. Augustyniak [19] przedstawia przekształcenia falkowe w zastosowaniach elektrodiagnostycznych, Hasiewicz [103] omawia falki ortogonalne o zwartym nośniku do nieparametrycznej identyfikacji systemów, Grzymkowski [95] stosuje falki w zagadnieniach brzegowych, zaś Ziółko [295] modeluje zjawiska falowe. Ponadto szereg istotnych informacji dotyczących omawianej problematyki zawierają także strony internetowe (patrz np. [www.wavelet.org](http://www.wavelet.org); [www.amara.com/current/wavelet.html](http://www.amara.com/current/wavelet.html); [www.ondelette.com/forum/](http://www.ondelette.com/forum/).)

### 5.1.1 Przekształcenia falkowe

Podstawową funkcją falkową (dopuszczalną falką podstawową) nazywa się funkcję  $\psi(t) \in L^2(R)$  w przypadku, gdy transformata Fouriera  $\Psi(\omega)$  tej funkcji spełnia warunek dopuszczalności (5.1).

$$\int_{-\infty}^{\infty} \frac{|\Psi(\omega)|}{\omega} < \infty \quad (5.1)$$

Z równania (5.1) wynika zaś wzór (5.2), co świadczy o tym, iż falka podstawowa jest dobrze skoncentrowana zarówno w czasie, jak i częstotliwości, a przede wszystkim ma charakter oscylacyjny.

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (5.2)$$


Na tej podstawie, poprzez przesuwanie i rozciąganie, można utworzyć rodzinę falek, zgodnie z zależnością (5.3)

$$\psi_{mn}(t) = a_0^{-m/2} \psi(a_0^{-m} t - nb_0) \quad (5.3)$$

gdzie  $m, n \in \mathbb{Z}$ , zaś  $a, b \in \mathbb{R}^+$ . Warunki konieczne i dostateczne powyższej zależności (5.3) szczegółowo zostały opisane w pracy [66]. Jeżeli zdefiniujemy  $a = a_0^m$  zaś  $b = nb_0$ , to otrzymujemy prostszy zapis równania (5.3) w postaci (5.4), gdzie  $a$  i  $b$  nazywamy odpowiednio współczynnikiem skali i współczynnikiem przesunięcia.

$$\psi_{ab}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (5.4)$$

Warto zauważyć, że jeśli współczynnik skalujący  $a$  jest mniejszy od jedności, to zmianie ulega zarówno kształt falki, jak i jej położenie. Wpływ elementarnych operacji, jakimi są skalowanie i przesuwanie, na tzw. kostki lokalizacji funkcji bazy, ukazano na Rys. 5.1. Oddziaływanie parametrów falki na jej kształt będzie także przedstawione dla konkretnych przykładów falek w punkcie 5.3 niniejszego rozdziału. W literaturze dotyczącej teorii falek, podobnie jak w przypadku analizy Fouriera, wykorzystuje się ciągłą lub dyskretną transformatę falkową.



**Rys. 5.1** Wpływ parametrów przesunięcia i skalowania na lokalizację funkcji bazowej. Funkcja  $\psi_1$  jest rezultatem przesunięcia w czasie o  $\tau$ ,  $\psi_2$  to wynik modulacji częstotliwościowej o  $\omega_0$ , zaś  $\psi_3$  jest wynikiem skalowania.

### 5.1.1.1 Ciągłe przekształcenie falkowe

Zgodnie z definicją podawaną w pracy [31], ciągłe przekształcenie falkowe (*ang. continuous wavelet transform*) (CWT) jest przekształceniem, w wyniku którego funkcja  $s(t)$  może być zrekonstruowana przy wykorzystaniu jej transformaty falkowej (5.5), przy czym funkcja  $s(t) \in L^2$ , zaś funkcja  $\psi(t)$  jest falką podstawową spełniającą warunek dopuszczalności (5.1).

$$CWT(a, b) = \langle s(t), \psi_{ab}(t) \rangle = \int_{-\infty}^{\infty} s(t) \psi_{ab}(t) dt \quad (5.5)$$

Biorąc pod uwagę skalowanie i przesunięcie prototypowej funkcji bazowej  $\psi(t)$ , określonej zależnością (5.4), o wartość parametrów  $a$  i  $b$ , ciągłe przekształcenie falkowe, dla kolejnych wartości obu wyżej wymienionych parametrów (parametru skali  $a$  oraz parametru przesunięcia  $b$ ), zdefiniujemy jako iloczyn skalarny poddawanego analizie sygnału  $s(t)$  i podstawowej funkcji falkowej (5.6)

$$CWT(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} s(t) \psi\left(\frac{t-b}{a}\right) dt \quad (5.6)$$

przy czym  $a \in R^+$ ,  $b \in R$ ,  $\frac{1}{\sqrt{a}}$  jest współczynnikiem normalizacji podstawowej funkcji falkowej. Warto podkreślić, iż powyższy wzór (5.6) określa także splot sygnału  $s(t)$  i funkcji falkowej w dziedzinie czasu. Porównaj na przykład z iloczynem transformat fourierowskich omówionym w opracowaniach [152, 211] (patrz również [5, 31]).

### 5.1.1.2 Dyskretne przekształcenie falkowe

Dyskretne przekształcenie falkowe (*ang. discrete wavelet transform*) (DWT) jest szczególnym przypadkiem ciągłej transformaty falkowej. Eliminuje główną wadę CWT tzw. redundancję, a inaczej nadmiarowość informacji w analizowanym sygnale. Jeżeli przyjmujemy, że parametry skali  $a$  będą równe kolejnym potęgom liczby 2, co wyraża próbkowanie na osi skali, ( $a_0=2^m$  oraz  $b_0=1$ ), wówczas zbiór ortonormalnych funkcji bazowych w przestrzeni  $L^2(R)$  przyjmuje postać (5.7).



$$\psi_{mn}(t) = 2^{-m/2} \psi(2^{-m}t - n) \quad (5.7)$$

W literaturze przedmiotu powyższy zapis (5.7) zbioru funkcji bazowych nazywany jest diadyczną postacią ortonormalnych funkcji bazowych, zaś dwukrotna zmiana skali (zmiana o 1 wartości parametru  $m$ ) określana jest mianem skalowania diadycznego. Możemy więc zdefiniować diadyczne przekształcenie falkowe (*ang. dyadic wavelet transform*) (DyWT) jako (5.8).

$$D_y WT_x(2^m, b) = \frac{1}{\sqrt{2^m}} \int_{-\infty}^{\infty} s(t) \psi\left(\frac{t-b}{2^m}\right) dt \quad (5.8)$$

Wykonując omówione powyżej próbkowanie parametrów dla  $a=2^m$  oraz  $t=n2^m$  otrzymujemy, analogicznie jak w przypadku współczynników szeregu Fouriera, współczynniki falkowe w postaci diadycznego szeregu falkowego. Sygnał  $s(t)$  możemy więc wyrazić w postaci podwójnej sumy (5.9), określanej nazwą dyskretnego przekształcenia falkowego.

$$s(t) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} d_{mn} \psi_{mn}(t) \quad (5.9)$$

Współczynniki  $d_{mn}$  wyznaczone są zgodnie z zależnością (5.10), zaś  $\psi_{mn}(t)$  jest funkcją bazową.

$$d_{mn} = \int_{-\infty}^{\infty} s(t) \psi_{mn}^*(2^{-m}t - n) \quad (5.10)$$

Warto podkreślić, iż współczynniki  $d_{mn}$  są wyznaczone dokładnie w miejscach, które określa tzw. siatka dyskretnego przekształcenia falkowego (*ang. dyadic grid*)(patrz [231]). Dyskretne przekształcenie falkowe jest aktualnie najczęściej wykorzystywanym przekształceniem falkowym w praktyce. Należy także zauważyć, iż w przypadku tego przekształcenia mamy do czynienia ze stałością komórki czasowo – częstotliwościowej (tzw. atomu czasowo – częstotliwościowego). Wraz ze wzrostem skali (wzrost parametru  $m$  o 1), dwukrotnie zwiększa się widmo częstotliwościowe, zaś falka staje się dwa razy krótsza. Niezmienne pozostaje tzw. pole atomu czasowo – częstotliwościowego.

## 5.2 Wielorozdzielcza dekompozycja sygnału

### 5.2.1 Postulaty wprowadzające

Analiza wielorozdzielcza sygnałów, jaką zapoczątkowali Mallat i Meyer, umożliwia ustalenie, które współczynniki, będące rozwinięciem falkowym sygnału, można pominąć. Autorzy przystosowali funkcje falkowe do znanego już wówczas w literaturze cyfrowego przetwarzania sygnałów, algorytmu opartego o lustrzane filtry kwadraturowe (*ang. conjugate quadrature filters or quadrature mirror filters (QMF)*), tworząc tzw. szybkie przekształcenie falkowe (*ang. fast wavelet transform*), będące podstawą dyskretnej transformaty falkowej.

Wielopoziomowa analiza sygnału  $s(t)$  należącego do przestrzeni  $L^2(\mathbb{R})$  polega na hierarchicznej dekompozycji sygnału do ciągu zamkniętych podprzestrzeni funkcyjnych  $\{V_m\}_{m \in \mathbb{Z}}$ , odpowiadających bazom ortogonalnych funkcji skalujących  $\varphi(t)$  kolejnych podprzestrzeni.

Podstawowym elementem wielorozdzielczej analizy sygnałów jest zatem ciąg domkniętych przestrzeni funkcyjnych  $V_M, V_{M+1}, \dots, V_m$  zawarty w przestrzeni aproksymacji  $L^2(\mathbb{R})$ , gdzie  $M$  jest dowolną liczbą całkowitą ( $M \in \mathbb{Z}$ ), dla którego spełnione są następujące warunki:

$$V_M \subset V_{M+1} \subset \dots \subset V_m \subset \dots \subset L^2(\mathbb{R}) \quad (5.11)$$

$$\bigcap_{m \in \mathbb{Z}} V_m = \{0\}, \quad \lim_{m \rightarrow -\infty} V_m = 0 \quad (5.12)$$

$$\overline{\bigcup_{m \in \mathbb{Z}} V_m} = L^2(\mathbb{R}), \quad \overline{\lim_{m \rightarrow +\infty} V_m} = L^2(\mathbb{R}) \quad (5.13)$$

$$f(t) \in V_m \Leftrightarrow f(2^m t) \in V_0 \quad \forall f \in L^2(\mathbb{R}) \forall m \in \mathbb{Z} \quad (5.14)$$

$$f(t) \in V_0 \Leftrightarrow f(t-k) \in V_0 \quad \forall f \in L^2(\mathbb{R}) \forall k \in \mathbb{Z} \quad (5.15)$$

$$f(t) \in V_m \Leftrightarrow f(t-k2^m) \in V_m \quad \forall f \in L^2(\mathbb{R}) \forall k \in \mathbb{Z} \quad (5.16)$$

*Conditio sine qua non* oznaczają odpowiednio:

- wzajemne zawieranie się kolejnych podprzestrzeni (5.11),
- nie istnienie funkcji należącej do wszystkich podprzestrzeni (5.12),
- domknięcie wszystkich podprzestrzeni daje przestrzeń funkcji o „ograniczonej energii” (5.13),

- wszystkie przestrzenie  $V_m$  są przeskalowanymi odmianami przestrzeni  $V_0$  spełniającymi relację (5.14).
- aksjomat (5.15) dotyczy niezmienniczości przestrzeni  $V_0$  względem przesunięć całkowitych i prowadzi do niezmienniczości przestrzeni  $V_m$  względem przesunięć będących całkowitą wielokrotnością  $2^m$  (5.16) dla  $n \in \mathbb{Z}$  ( $\mathbb{Z}$  – liczby całkowite).

Należy zauważyć, iż trzy pierwsze warunki są spełnione dla wielu różnych ciągów przestrzeni  $V_m$ , zatem bardzo istotne, z punktu widzenia wielorozdzielczości sygnału, stają się dodatkowe wymagania określone warunkami (5.14) – (5.16). Można także powiedzieć, iż warunki (5.14) oraz (5.15) wyrażają niezmienniczość przestrzeni  $V_m$  (dla  $m \in \mathbb{Z}$ ) względem przesunięć i dylatacji.

Jeżeli dana przestrzeń spełnia powyższe założenia, to można założyć, iż istnieje funkcja  $\varphi(t) \in V_0$ , dla której prawdziwa jest zależność (5.17), będąca bazą ortonormalną w  $V_0$ .

$$\varphi_{0,k}(t) = \varphi(t - k) \quad (5.17)$$

Funkcja  $\varphi(t)$  zwana jest funkcją skalującą i pełni ważną, a można nawet powiedzieć kluczową, rolę w transformacji falkowej. Dodatkowo wprowadza się także pojęcie tzw. przestrzeni detali  $W_M, W_{M+1}, \dots, W_m, \dots$  spełniających zależność (5.18) i również posiadających bazę ortonormalną.

$$V_{m+1} = V_m \oplus W_m \quad (5.18)$$

Dla kolejnych przestrzeni  $V_m$  oraz  $W_m$  ortonormalne funkcje bazowe, odpowiednio  $\{v_{m,n}(t)\}$  oraz  $\{w_{m,n}(t)\}$ , otrzymujemy rekurencyjnie, zgodnie z zależnością (5.19).

$$\begin{aligned} v_{m,n}(t) &= \sqrt{2}v_{m-1,n}(2t) \\ w_{m,n}(t) &= \sqrt{2}w_{m-1,n}(2t) \end{aligned} \quad (5.19)$$

Wiadomo także, iż wszystkie funkcje bazowe uzyskiwane są w wyniku skalowania oraz przesuwania pary funkcji podstawowych. Oznaczmy je  $\varphi(t)$  oraz  $\psi(t)$ . Można zapisać je zależnością (5.20).

$$\begin{aligned}
v_{m,n}(t) &= 2^{\frac{m}{2}} \varphi(2^m t - n) \cong \varphi_{m,n}(t) \\
w_{m,n}(t) &= 2^{\frac{m}{2}} \psi(2^m t - n) \cong \psi_{m,n}(t)
\end{aligned} \quad (5.20)$$

### 5.2.1.1 Analiza podanych warunków początkowych

Analizując wskazane warunki można stwierdzić, iż wyznaczenie ortogonalnych baz falkowych sprowadza się do spełnienia wyżej wymienionych wymagań przez współczynniki występujące w równaniu skalującym oraz równaniu falkowym. Zależności (5.11 – 5.18) należy określić jako podstawowe, bowiem nie nakładają one istotnych wymagań na postać przestrzeni aproksymacji  $V_m$ , jak również przestrzeni dopełnień (detali)  $W_m$ . W literaturze przedmiotu wzór (5.19), określany jest jako reguła skalowania wyrażająca fraktalną zasadę samopodobieństwa, gdyż funkcje bazowe nie zmieniają swego kształtu, a jedynie wraz ze wzrostem parametru  $m$  stają się węższe i wyższe. Należy również zaznaczyć, iż zgodnie z zależnością (5.18), przestrzeń  $V_{m+1}$  jest bogatsza od przestrzeni  $V_m$ , bowiem oprócz funkcji należących do  $V_m$  zawiera także funkcje będące ich dwukrotnym zwężeniem.

Analizując podane w poprzednim punkcie warunki, możemy zapisać, że dla każdego  $n_1, n_2 \in \mathbb{Z}$  zachodzą (5.21) oraz (5.22).

$$\forall_{n_1, n_2 \in \mathbb{Z}} \begin{cases} v_{m,n_1}(t), v_{m,n_2}(t) \in V_{m+1} \\ v_{m,n_1}(t) = \sum_{n \in \mathbb{Z}} h_{m+1,n}^{n_1} v_{m+1,n}(t) \\ v_{m,n_2}(t) = \sum_{n \in \mathbb{Z}} h_{m+1,n}^{n_2} v_{m+1,n}(t) \end{cases} \quad (5.21)$$

$$h_{m+1,n}^{n_i} = \int v_{m,n_i}(t) v_{m+1,n}(t) dt \quad (5.22)$$

Dla  $i = 1, 2$  oraz ortonormalności bazy  $\{v_{m,n}(t)\}$  mamy (5.23).

$$h_{m+1,n}^{n_i} = \sum_{n \in \mathbb{Z}} h_{m+1,n}^{n_1} h_{m+1,n}^{n_2} \quad (5.23)$$

Możemy zatem wyznaczyć współczynniki  $\{h_{m+1,n}^{n_1}\}$ ,  $\{h_{m+1,n}^{n_2}\}$  dwóch kolejnych przestrzeni aproksymacji  $V_m$ ,  $V_{m+1}$ . Analogicznie wyprowadzając współczynniki dla przestrzeni  $W_m$ ,  $W_{m+1}$  otrzymujemy (5.24).

$$\begin{cases} \sum_{n \in \mathbb{Z}} h_{m+1,n}^{n_1} h_{m+1,n}^{n_2} \\ \sum_{n \in \mathbb{Z}} g_{m+1,n}^{n_1} g_{m+1,n}^{n_2} \end{cases} = \begin{cases} 1 & n_1 = n_2 \\ 0 & n_1 \neq n_2 \end{cases} \quad (5.24)$$

Ponieważ jest spełniony warunek ortogonalności baz, to na podstawie (5.21) i analogicznie wyprowadzonego wzoru dla przestrzeni  $W_m$  mamy (5.25).

$$\forall_{n_1, n_2 \in \mathbb{Z}} \sum_{n \in \mathbb{Z}} g_{m+1,n}^{n_2} h_{m+1,n}^{n_1} = 0 \quad (5.25)$$

Uwzględniając powyższe równania (dla  $m=0$ ) otrzymujemy podstawowe funkcje falkowe w postaci (5.26) wykorzystujące wprowadzone współczynniki  $\{h_n\}$  oraz  $\{g_n\}$ , które powinny spełniać warunki określone równaniami (5.27 – 5.28).

$$\begin{cases} \varphi(t) = \sqrt{2} \sum_{n \in \mathbb{Z}} h_n \varphi(2t - n) \\ \psi(t) = \sqrt{2} \sum_{n \in \mathbb{Z}} g_n \psi(2t - n) \end{cases} \quad (5.26)$$

$$\begin{cases} \sum_{n \in \mathbb{Z}} h_n = \sqrt{2} \\ \sum_{n \in \mathbb{Z}} g_n = 0 \\ \sum_{n \in \mathbb{Z}} h_n^2 = 1 = \sum_{n \in \mathbb{Z}} g_n^2 = 1 \\ \sum_{n \in \mathbb{Z}} h_n h_{n-2k} = 0 = \sum_{n \in \mathbb{Z}} g_n g_{n-2k} = 0 \end{cases} \quad (5.27)$$

$$\forall_{k \in \mathbb{Z}} \sum_{n \in \mathbb{Z}} g_n h_{n-2k} = 0 \quad (5.28)$$

Szczegółowa analiza wymienionych postulatów, wraz z wyjaśnieniem dodatkowych pojęć, takich choćby, jak definicje bazy ortonormalnej i ortogonalnej wraz z twierdzeniami i ich dowodami, szeroko omawiane są w pracach [31,286]. Analizę wymienionych warunków podano również w [103].

## 5.2.2 Algorytm wielopoziomowej dekompozycji sygnału

Idea wielopoziomowej dekompozycji sygnału, jak to zostało już omówione w poprzednim punkcie niniejszego rozdziału, opiera się na podziale przestrzeni  $L^2(\mathbb{R})$  na dwie podprzestrzenie wzajemnie ortogonalne określone zależnością (5.18). Jeżeli funkcja skalująca spełnia warunek normalizacji (5.29) to możemy zdefiniować jej bazę ortonormalną.

$$\int_{-\infty}^{\infty} \varphi(t) dt = 1 \quad (5.29)$$

W myśl powyżej wprowadzonych warunków (5.18), (5.26), sygnał  $s(t)$  możemy zapisać jako (5.30).

$$s(t) \approx \sum_{n \in \mathbb{Z}} a_{m,n} \varphi(2^{-m}t - n) = \sum_{n \in \mathbb{Z}} a_{m+1,n} \varphi(2^{-(m+1)}t - n) + \sum_{n \in \mathbb{Z}} d_{m+1,n} \psi(2^{-(m+1)}t - n) \quad (5.30)$$

Biorąc pod uwagę  $k$  – poziomów, otrzymujemy drzewiastą strukturę przestrzeni (5.31). Jeśli wprowadzimy współczynniki  $\{a_{m,n}\}$  i  $\{d_{m,n}\}$ , określone zależnościami (5.32) do równania (5.30), to sygnał  $s(t)$  możemy wyrazić wzorem (5.33).

$$V_m = V_{m+k} + \sum_{i=m+1}^{m+k} W_i \quad (5.31)$$

$$\begin{cases} a_{m,n} = \int s(t) \varphi^*(2^{-m}t - n) dt \\ d_{m,n} = \int s(t) \psi^*(2^{-m}t - n) dt \end{cases} \quad (5.32)$$

$$s(t) = \sum_{m_k, n} a_{m_k, n} \varphi(2^{-m_k}t - n) + \sum_{m=m_0}^{m_k} \sum_{n \in \mathbb{Z}} d_{m,n} \psi(2^{-m}t - n) \quad (5.33)$$

Zgodnie z monografią Augustyniaka [19], w praktyce trudne jest otrzymanie współczynników na podstawie definicji (5.31), dlatego też wykorzystuje się zespoły filtrów cyfrowych. Mówi się o zastosowaniu:

- a) teorii wielorozdzielczej aproksymacji sygnału,
- b) metod cyfrowego przetwarzania sygnału.

W pierwszym przypadku, przy wykorzystaniu wielorozdzielczej aproksymacji sygnału, obowiązują warunki omówione powyżej. W związku z tym, równanie (5.26) można zapisać jako (5.34)

$$\begin{cases} \varphi(t) = \sum_{n \in \mathbb{Z}} h(n) \varphi(2^m t - n) \\ \psi(t) = \sum_{n \in \mathbb{Z}} g(n) \psi(2^m t - n) \end{cases} \quad (5.34)$$

Funkcja skalująca  $\varphi(t)$  jest więc kombinacją liniową kilku funkcji skalujących wyższego poziomu reprezentujących detale, a odpowiadające jej współczynniki  $h(n)$  pełnią rolę filtru dolnoprzepustowego (aproksymacja mniej szczegółowa). Funkcja falkowa  $\psi(t)$  określa zaś szczegóły, zatem jej współczynniki  $g(n)$  będą reprezentowane przez filtr pasmowoprzepustowy (lub górnoprzepustowy) [19]. Z powyższych dwóch zależności (5.32, 5.34) otrzymujemy stosowane w praktyce wzory definiujące współczynniki falkowe z dwóch kolejnych poziomów (5.35).

$$\begin{cases} a_m(n) = \sum_{k \in \mathbb{Z}} h(n-2k)a_{m-1,k} \\ d_m(n) = \sum_{k \in \mathbb{Z}} g(n-2k)d_{m-1,k} \end{cases} \quad (5.35)$$

Wykorzystując teorię wielorozdzielczej aproksymacji sygnału mamy więc do czynienia ze splotem dwóch sygnałów, gdzie współczynniki  $\{a_{m,n}\}$  niższego poziomu powstają poprzez współczynniki  $\{a_{m-1,n}\}$  wyższego poziomu w wyniku filtracji dolnoprzepustowej i usunięcia co drugiej wartości tzw. decymacji drugiego rzędu lub inaczej tzw. zjawiska downsamplingu. Współczynniki  $\{d_{m,n}\}$  powstają także poprzez zastosowanie współczynników  $\{a_{m-1,n}\}$ , jednak tym razem dzieje się to na drodze filtracji górnoprzepustowej i decymacji sygnału. Splot dwóch sygnałów zdefiniowany jest zależnością (5.36) zaś decymacja określona jest przez (5.37).

$$a_m^*(n) = \sum_{k \in \mathbb{Z}} h(n-k)a_{m-1}(k) \quad (5.36)$$

$$a_m(n) = a_m^*(2n) \quad (5.37)$$

W drugim przypadku, używając metod cyfrowego przetwarzania sygnału, bierzemy pod uwagę widmo częstotliwościowe i widmo falki  $\psi(t)$  odpowiadające wykorzystywanym filtrom (dolnoprzepustowemu oraz górnoprzepustowemu) i stosujemy pasmową filtrację sygnału. W dziedzinie czasu uzyskujemy splot sygnału i analogiczne wzory do (5.35). Natomiast w dziedzinie częstotliwości, transformata sygnału na wyjściu jest równa iloczynowi transmitancji filtra i transformaty sygnału (5.38), gdzie  $H$  jest filtrem dolnoprzepustowym odpowiadającym funkcji  $\varphi(t)$ , zaś  $G$  jest filtrem górnoprzepustowym funkcji  $\psi(t)$ .

$$\begin{cases} A(\omega) = H(\omega) * S(\omega) \\ D(\omega) = G(\omega) * S(\omega) \end{cases} \quad (5.38)$$

W praktyce, algorytm dekompozycji sygnału, przy wykorzystaniu pasmowej filtracji sygnału, rozpoczyna się od ustalenia odpowiedzi impulsowej filtra dolnoprzepustowego pochodzącego od funkcji skalującej. Ciąg współczynników, które reprezentują filtr będący jego odpowiedzią impulsową (gdzie:  $h$  oznacza współczynnik filtra,  $L$  długość filtra,  $n$  numer współczynnika filtra,  $k \in \mathbb{Z}$ ) musi spełniać dwa warunki (5.39):

$$\begin{cases} \sum_{n=0}^{L-1} (h_n)^2 = 1 \\ \sum_{n=0}^{L-1} h_{2k+n} h_n = 0 \end{cases} \quad (5.39)$$

- 1) unormowania, czyli równości norm funkcji skalujących dla różnych rozdzielczości,
- 2) ortogonalności translacji funkcji skalującej, czyli wymnożenia filtru przez siebie z przesunięciem o parzystą liczbę próbek i uzyskanie w ten sposób wartości zerowej [19].

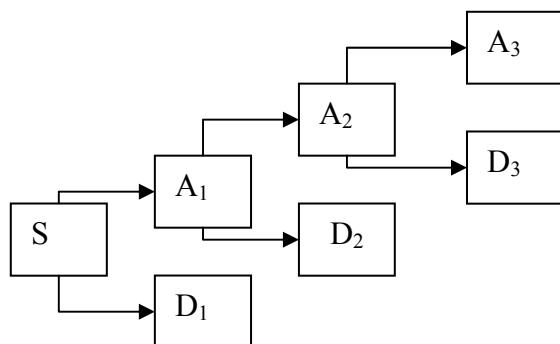
Powyższe warunki, określone zależnością (5.39), są analogiczne do przedstawionych w poprzednim punkcie tego rozdziału założeń (5.27), co czyni je wiarygodnymi. Należy jednak podkreślić, iż ograniczenia, jakie narzucają warunki (5.39), nie określają jednoznacznie postaci filtru. Po ustaleniu odpowiedzi impulsowej filtru dolnoprzepustowego  $h$  tworzone są pozostałe filtry syntezy  $h^*$  oraz  $g^*$  oraz górnoprzepustowy filtr analizy  $g$ , zgodnie z (5.40).

$$\begin{cases} g_n = (-1)^n h_{L-1-n} \\ h_n^* = h_{L-1-n} \\ g_n^* = g_{L-1-n} = (-1)^{n+1} h_n \end{cases} \quad (5.40)$$

Dodatkowe informacje dotyczące drugiego sposobu dekompozycji sygnału z wykorzystaniem filtracji pasmowej sygnału podano w pracach [19, 31, 286].

Podsumowując rozważania możemy powiedzieć, iż dekompozycja sygnału jest wielopoziomowym procesem iteracyjnym o nieograniczonej liczbie kroków. Analizowany sygnał poddawany jest filtracji dolno- oraz górnoprzepustowej w wyniku których, w każdej iteracji uzyskujemy składową wieloczęstotliwościową, zwaną detałem ( $D_i$ ), która nie ulega już zmianie, gdyż nie bierze udziału w dalszym procesie iteracyjnym oraz składową niskoczęstotliwościową ( $A_i$ ) tzw. aproksymację sygnału. Drzewo falkowej dekompozycji sygnału dla 3 – poziomów przedstawiono na Rys. 5.2.






**Rys. 5.2 Drzewo 3 poziomowej dekompozycji sygnału.**

Warto także podkreślić, iż:

- a) W każdym kroku dekompozycji sygnału, jeśli spełniony jest warunek próbkowania (częstotliwość próbkowania jest dwa razy większa od jego pasma), następuje dwukrotne zmniejszenie się częstotliwości próbkowania, gdyż zmniejsza się dwukrotnie liczba próbek sygnału, a pasmo częstotliwości w przybliżeniu jest równe połowie pasma sygnału poddawanego filtracji. Zjawisko próbkowania omówione było w rozdziale pierwszym niniejszej rozprawy (patrz [13, 286]). Podział pasma częstotliwościowego dla 3 poziomowej dekompozycji sygnału przedstawiono na Rys. 5.3.
- b) Uzyskane w wyniku dekompozycji sygnału składowe ( $D_i$ ) oraz ( $A_i$ ) charakteryzują się mniejszą rozdzielczością, która jest miarą zawartej w sygnale ilości informacji szczegółowych. Wraz ze zmniejszaniem się rozdzielczości maleje udział detali w reprezentacji sygnału oraz zawartość szczegółów w aproksymacji sygnału [19].
- c) W przypadku zmiany skali sygnału związanej ze zmianą okresu próbkowania, zwiększenie następuje w wyniku odrzucenia co drugiej próbki sygnału, zaś zmniejszenie w wyniku dodania nowych próbek sygnału w połowie okresu próbkowania.



Rys. 5.3 Podział pasma częstotliwościowego w wyniku dekompozycji sygnału.

W literaturze przedmiotu procedurę obliczeniową wielorozdzielczej dekompozycji sygnału określa się mianem algorytmu Mallata lub też jako procedurę piramidalnej filtracji podpasmowej (*ang. pyramidal subband coding scheme*). Natomiast równania skalujące, definiujące ciągi  $h_n$  oraz  $g_n$ , będące odpowiedziami impulsowymi filtrów dolnoprzepustowego oraz górnoprzepustowego, nazywa się sprzężonymi lub lustrzanymi filtrami kwadraturowymi (*ang. quadrature mirror filters (QMF)*).

## 5.3 Przykłady konstrukcji dwóch wybranych falek

### 5.3.1 Falka Haara

Najprostszym przekształceniem falkowym jest funkcja Haara, której nazwa pochodzi od prekursora konstruowania falek A. Haara, zdefiniowana zależnością (5.41).

$$H(t) = \begin{cases} 1 & \text{dla } t \in [0, \frac{1}{2}) \\ -1 & \text{dla } t \in [\frac{1}{2}, 1) \\ 0 & \text{dla } t \notin [0, 1] \end{cases} \quad (5.41)$$

Zgodnie z wprowadzonymi postulatami w punkcie 5.2.1, możemy zbudować ortonormalną bazę falkową Haara (5.42), która będzie zlokalizowana w przedziale  $[2^{-m}n, 2^{-m}(n+1))$ . Przedział ten jest jednocześnie nośnikiem tej funkcji ( $\text{supp}H_{mn}(t)$ ) o długości  $2^{-m}$  i stanowi jednostkową, elementarną oscylację o czasie  $2^{-m}$ .

$$B_H = \{2^{m/2} H(2^m - k) \quad (5.42)$$

Warto zauważyć, iż wraz ze wzrostem parametru  $m$  długość nośnika maleje, zatem każdy krótszy przedział w całości zawiera się w przedziale poprzedniego poziomu, spełniając przy tym podstawowy warunek wielorozdzielczej analizy sygnału  $V_m \subset V_{m+1}$ . Wówczas funkcję Haara  $H_{m,n}(t) \in B_H$  można opisać zależnością (5.43).

$$H_k(t) = H_{m,n}(t) = \begin{cases} 2^{-\frac{m-1}{2}} & \text{dla } \frac{n-1}{2^{m-1}} < t < \frac{2n-1}{2^m} \\ -2^{-\frac{m-1}{2}} & \text{dla } \frac{2n-1}{2^m} < t < \frac{n}{2^{m-1}} \\ 0 & \text{dla pozostałych } t \in [0,1] \end{cases} \quad (5.43)$$


gdzie  $m=1,2, \dots$  oznacza numer grupy funkcji Haara,  $n$  to numer kolejnej funkcji w ramach danej grupy  $m$ , zaś  $k$  oznacza numerowanie funkcji Haara za pomocą jednego indeksu. Indeksy porządkujące funkcje  $H(t)$  spełniają relacje (5.44).

$$\begin{cases} 1 \leq n \leq 2^{m-1} \\ k = 2^{m-1} + n - 1 \end{cases} \quad (5.44)$$

Zależności między indeksami przedstawione są w Tabeli Nr 5.1, a przykład kilku funkcji Haara przedstawiono na Rys. 5.4.

**Tabela nr 5.1 Zależności między porządkującymi indeksami dla funkcji Haara.**

M	N	K
1	1	1
2	$1 \leq n \leq 2$	2,3
3	$1 \leq n \leq 4$	4,...,7
4	$1 \leq n \leq 8$	8,...,15
5	$1 \leq n \leq 16$	16,...,31



Rys. 5.4 Przykład kilku funkcji Haara.

Do zalet falki Haara zaliczyć należy przede wszystkim jej zwarty nośnik oraz ortogonalność. Dodatkowo, jako jedyna z istniejących rodzin falkowych, posiada oś antysymetrii, dzięki czemu odpowiadający jej filtr nie wprowadza nieliniowego przesunięcia pomiędzy sygnałem wejściowym a sygnałem wyjściowym. Główną wadą falek Haara jest jednak nieciągłość. Funkcje te bowiem przyjmują, poza skończonym przedziałem, wartości zerowe, a to w dużym stopniu utrudnia ich zastosowanie w praktyce.

### 5.3.2 Falki Daubechies

Analiza literatury naukowej związanej z teorią falek i jej zastosowaniami wskazuje jednoznacznie na fakt, iż najczęściej używaną rodziną falek są falki Daubechies. Wykorzystywane w tym przypadku filtry dolno- i górnoprzepustowe mają skończoną długość, co odróżnia te falki od pozostałych. Warto także zaznaczyć, iż falki Daubechies istnieją dla każdej parzystej długości filtrów. Mają zwarty nośnik o szerokości  $(2p-1)$ , a falka Haara jest najprostszym elementem należącym do rodziny falek Daubechies. Wraz ze wzrostem rzędu wzrasta gładkość tych falek Daubechies, co łatwo zauważyć na podstawie przykładowych wykresów tej rodziny falek i ich funkcji skalujących (Rys. 5.5).

Ich konstrukcja opiera się na stworzeniu odpowiedniego filtra dolnoprzepustowego  $\{h_m\}$ , spełniającego założenia wielorozdzielczej dekompozycji sygnału (algorytmu Mallata). Warto zaznaczyć, iż dla falek o zwartym nośniku, długość nośnika musi być liczbą nieparzystą. Weźmy zatem pod uwagę falkę Daubechies o długości nośnika 5 (Db3). Wówczas, zgodnie

z układem (5.26 – 5.27), możemy zapisać następujące równania określające współczynniki:

$$\begin{cases} h_0 + h_1 + h_2 + h_3 + h_4 + h_5 = \sqrt{2} \\ h_0^2 + h_1^2 + h_2^2 + h_3^2 + h_4^2 + h_5^2 = 1 \\ h_0h_2 + h_1h_3 + h_2h_4 + h_3h_5 = 0 \\ h_0h_4 + h_1h_5 = 0 \end{cases} \quad (5.45)$$

Otrzymaliśmy więc 4 równania z 6-cioma niewiadomymi i 2-ma stopniami swobody. Stosując zasadę odbicia, którą definiuje zależność (5.46), otrzymujemy dodatkowy zbiór wymagań w postaci (5.47).

$$g_n = (-1)^n h_{-n+1} \quad (5.46)$$


$$\sum_{n=0}^s (-1)^n h_{s-n} n^k \text{ dla } k = 1, 2, \dots \quad (5.47)$$

W wyniku tego, dla  $k=1,2$  otrzymujemy dwa brakujące (dodatkowe) równania w układzie (5.45).

$$\begin{cases} 0h_5 - 1h_4 + 2h_3 - 3h_2 + 4h_1 - 5h_0 = 0 & \text{dla } k = 1 \\ 0h_5 - 1h_4 + 4h_3 - 9h_2 + 16h_1 - 25h_0 = 0 & \text{dla } k = 2 \end{cases} \quad (5.48)$$

Rozwiązaniem równań (5.45), (5.48) są współczynniki odpowiedzi impulsowych filtrów generujących falkę Daubechies o długości nośnika 5 (db3). Przykładowe współczynniki  $\{h_n\}$  dla funkcji skalujących Daubechies podane są w Tabeli Nr 5.2, zaś w postaci numerycznej dla falek Daubechies rzędu  $p=4, \dots, 8$  w Tabeli Nr 5.3. Przykłady falek omawianej rodziny i ich funkcji skalujących zaprezentowano na Rys. 5.5.

Niestety wadą rodziny falek Daubechies jest wprowadzenie nieliniowego przesunięcia fazowego pomiędzy sygnałem wejściowym a sygnałem wyjściowym, co będzie pokazane, dla sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym, w następnym rozdziale niniejszej rozprawy, dotyczącym części eksperymentalnej przedstawianego algorytmu.



Rys. 5.5 Przykłady falek z rodziny Daubechies i funkcji skalujących. Kolejno db3, db5, db8, db20.

Tabela nr 5.2 Współczynniki  $\{h_n\}_{n=0}^{2p-1}$  dla funkcji skalujących Daubechies rzędu  $p=1,2,3$ .

$\{h_n\}$	Rząd		
	1	2	3
$h_0$	$\frac{1}{\sqrt{2}}$	$\frac{1 + \sqrt{3}}{4\sqrt{2}}$	$\frac{1 + \sqrt{10} + \sqrt{5 + 2\sqrt{10}}}{16\sqrt{2}}$
$h_1$	$\frac{1}{\sqrt{2}}$	$\frac{3 + \sqrt{3}}{4\sqrt{2}}$	$\frac{5 + \sqrt{10} + 3\sqrt{5 + 2\sqrt{10}}}{16\sqrt{2}}$
$h_2$		$\frac{3 - \sqrt{3}}{4\sqrt{2}}$	$\frac{10 - 2\sqrt{10} + 2\sqrt{5 + 2\sqrt{10}}}{16\sqrt{2}}$
$h_3$		$\frac{1 - \sqrt{3}}{4\sqrt{2}}$	$\frac{10 - 2\sqrt{10} - 2\sqrt{5 + 2\sqrt{10}}}{16\sqrt{2}}$
$h_4$			$\frac{5 + \sqrt{10} - 3\sqrt{5 + 2\sqrt{10}}}{16\sqrt{2}}$
$h_5$			$\frac{1 + \sqrt{10} - \sqrt{5 + 2\sqrt{10}}}{16\sqrt{2}}$

Tabela nr 5.3 Obliczone wartości współczynników  $\{h_n\}_{n=0}^{2p-1}$  dla funkcji skalujących falek Daubechies rzędu  $p=4, \dots, 8$ .

	4	5	6	7	8
$h_0$	0,230378	0,160102	0,111541	0,077852	0,0544158
$h_1$	0,714847	0,603829	0,494624	0,396539	0,3128715
$h_2$	0,630881	0,724309	0,751134	0,729132	0,6756307
$h_3$	-0,027983	0,138428	0,31525	0,469782	0,5853546
$h_4$	-0,187035	-0,242295	-0,226265	-0,143906	-0,0158291
$h_5$	0,030841	-0,032244	-0,129767	-0,224036	-0,2840155
$h_6$	0,032883	0,0775715	0,0975016	0,0713092	0,0004724
$h_7$	-0,010597	-0,0062414	0,0275229	0,0806126	0,1287474
$h_8$		-0,0125808	-0,031582	-0,0380299	-0,0173693
$h_9$		0,0033357	0,00055384	-0,0165745	-0,0440882
$h_{10}$			0,00477726	0,012551	0,0139810
$h_{11}$			-0,0010773	0,00042957	0,0087460
$h_{12}$				-0,00180164	-0,0048703
$h_{13}$				0,000353714	-0,0003917
$h_{14}$					0,0006754
$h_{15}$					-0,0001174

## 5.4 Sztuczne sieci neuronowe

Intensywny rozwój elektroniki, a przede wszystkim informatyki, w ostatniej dekadzie XX wieku doprowadził do bardzo dużego zainteresowania tematyką sztucznych sieci neuronowych, a w konsekwencji do ich burzliwego rozwoju. Za początek tej dyscypliny badawczej uznana została praca McCullocha, Pittsa z 1946 roku, w której opisano matematyczny model sztucznego neuronu. Kolejne ważne opracowania to:

- 1958 r. — rozwiązanie przez Rosenblatta oraz Wightmana problemu rozpoznawania znaków alfanumerycznych w wyniku zastosowania perceptronu i algorytmu uczenia ustalającego wartości wag połączeń sieci;
- 1960 r. — wprowadzenie przez Widrowa oraz Hoffa sieci ADALINE (ang. ADaptive LINear Element). Autorzy wykorzystali liniową funkcję jako funkcję aktywacji w modelu McCullocha – Pittsa, a przede wszystkim zastosowali nowy algorytm uczenia sieci neuronowej oparty na metodzie największego spadku gradientu, minimalizując błąd średniokwadratowy na wyjściu sieci neuronowej. Algorytm ten nazwany został LMS (ang. Least Mean Square). Niekiedy można spotkać się z określeniem pochodzącym od jego pomysłodawców – metoda Widrowa – Hoffa;
- 1969 r. – wykazanie przez Minsky’ a oraz Paperta, że istniejące sieci neuronowe nie rozwiązują prostych problemów, np. nie realizują funkcji logicznej XOR. Praca ta zahamowała badania z zakresu sieci neuronowych na ponad 10 lat;
- 1984 r. – prace Kohonnena nad samoorganizującymi się mapami cech oraz prace Hopfielda wykazujące zdolność do przetwarzania danych przez sieci neuronowe, przełamują napotkane w latach 70. bariery, co prowadzi do wznowienia zainteresowania tą dyscypliną badawczą.

Za prekursora polskich prac badawczych zajmujących się tą tematyką uważa się R. Tadeusiewicza z Akademii Górniczo – Hutniczej w Krakowie. Bardzo prężnie działają również ośrodki na Uniwersytecie Zielonogórskim pod kierunkiem J. Korbicza, na Uniwersytecie Mikołaja Kopernika w Toruniu pod kierunkiem W. Ducha a także na Politechnice Częstochowskiej pod kierunkiem L. Rutkowskiego. Historia badań nad sztucznymi sieciami neuronowymi jest szeroko omówiona między innymi w [260, 261, 136, 193].



Sieci neuronowe, których pierwowzorem jest ludzki mózg i układ nerwowy, wyróżniają się na tle innych metod (tzw. obliczeń inteligentnych) przede wszystkim:

- możliwością równoległego przetwarzania informacji,
- zdolnością nadzorowanego lub nie nadzorowanego uczenia się,
- umiejętnością abstrakcji, bowiem mogą uogólniać wiedzę zdobytą w procesie trenowania,
- odpornością na uszkodzenia, gdyż potrafią poprawnie działać nawet jeśli część elementów została uszkodzona (informacje zostały utracone).

W literaturze przedmiotu dokonuje się klasyfikacji sztucznych sieci neuronowych według kilku kryteriów, a mianowicie:

- a) według liczby warstw [262]:
  - jednowarstwowe,
  - dwuwarstwowe,
  - wielowarstwowe.
- b) ze względu na stosowaną funkcję aktywacji:
  - liniowe – neurony przetwarzają informację wejściową i przekazują ją na wyjście przy zastosowaniu progowej funkcji aktywacji
  - nieliniowe – każdy neuron przetwarza informacje według ściśle określonej funkcji ciągłej.
- c) Z uwagi na sposób łączenia neuronów [193,136]:
  - sieci jednokierunkowe,
  - sieci o radialnych funkcjach bazowych,
  - sieci rekurencyjne,
  - sieci komórkowe.

Obecnie odnaleźć można ogromną ilość publikacji dotyczących zarówno zagadnień teoretycznych, architektury sieci, algorytmów uczenia, jak również zastosowania sieci neuronowych w różnych dziedzinach nauki, szczególnie tam, gdzie nie można w prosty sposób zapisać matematycznie danego problemu (patrz np. [74]).


## 5.5 Wybrane typy sieci neuronowych i ich sposoby uczenia

### 5.5.1 Sieci jednokierunkowe wielowarstwowe

Jednokierunkowe sieci neuronowe wielowarstwowe, inaczej zwane wielowarstwowymi perceptronami (*ang. multi – layer perceptrons, feedforward neural networks*) (MLP), są jednymi z najczęściej wykorzystywanych architektur sieci neuronowych (patrz np. [107, 262, 187]). Na pojęcie architektury sieci neuronowej składa się:

- liczba warstw sieci  $L$  (warto podkreślić, iż warstwa wejściowa nie jest numerowana),
- liczba neuronów w poszczególnych warstwach,
- sposób połączenia neuronów,
- rodzaj stosowanej funkcji aktywacji.

Przykładową architekturę dwuwarstwowej sieci neuronowej przedstawiono na Rys. 5.6



Rys. 5.6 Schemat jednokierunkowej dwuwarstwowej sieci neuronowej.

Połączenia neuronów w sąsiednich warstwach mogą być realizowane na wiele sposobów. Jak podaje Tadeusiewicz [262], liczbę możliwych struktur sieci dla 20 neuronów szacuje się na  $10^{96}$  sposobów. W przypadku jednokierunkowej sieci neuronowej realizowane są połączenia tylko pomiędzy sąsiednimi warstwami, zgodnie z typem „każdy z każdym”, tzn. każdy neuron warstwy

poprzedniej ( $n-1$ ) łączy się ze wszystkimi neuronami warstwy następnej ( $n$ ). Można również mówić o tzw. „połączeniu kompletnym” [157].

Przyjmując następujące oznaczenia:  $L$  – liczba warstw, w każdej warstwie znajduje się  $N_k$  elementów (dla  $k=1,2,\dots, L$ ) nazywanych neuronami;  $x_i^k(t)$  – wartość neuronu  $i$ -tego wyjścia dla  $k$ -tej warstwy ukrytej (dla  $k = 1, 2, \dots, N_k$ );  $w_{ij}^{(k)}(t)$  jest wagą  $i$ -tego neuronu  $k$ -tej warstwy, możemy zdefiniować sygnał wyjściowy neuronu  $y_i^k$  ( $i$ -tego wyjścia  $k$ -tej warstwy) w postaci (5.49).

$$y_i^{(k)}(t) = f \left( \sum_{j=0}^{N_k-1} w_{ij}^{(k)}(t) x_j^{(k)}(t) \right) \quad (5.49)$$

Często stosowana jest także dodatkowa waga o stałym wejściu równym 1, określana jako tzw. bias. Wówczas równanie (5.49) opisane jest jako (5.50).


$$y_j = f_L \left( \sum_{k=0}^{K^L-1} w_{jk}^L x_k^{L-1} + b^L \right) \quad (5.50)$$

W literaturze przedmiotu można odnaleźć różne funkcje aktywacji  $f$ . Najczęściej wykorzystywana jest funkcja sigmoidalna określona zależnością (5.51), inaczej zwana funkcją unipolarną, przyjmująca dowolne wartości z przedziału  $(0,1)$  oraz funkcja tangesoidalna (5.52) – bipolarna, przyjmująca wartości z przedziału  $(-1,1)$ .

$$f_1(x) = \frac{1}{1 + e^{-\beta x}} \text{ dla } \beta > 0 \quad (5.51)$$

$$f_2(x) = \frac{1 - e^{-\beta x}}{1 + e^{-\beta x}} \text{ dla } \beta > 0 \quad (5.52)$$

Wykres powyższych funkcji aktywacji dla kilku przykładowych wartości parametru  $\beta$ , który pozwala dobrać odpowiedni kształt krzywej, przedstawiono na Rys. 5.7.



Rys. 5.7 Wykres funkcji aktywacji dla wartości parametru  $\beta=1, 5, 15, 25$ . a) funkcji sigmoidalnej b) funkcji tangesoidalnej.

### Algorytm uczenia z nauczycielem

W przypadku tzw. uczenia sieci neuronowej z nauczycielem, każdemu zestawowi danych wejściowych odpowiada przyporządkowany im wzorzec wyjściowy. Nauka sieci polega na modyfikacji połączeń wagowych w celu dopasowania poszczególnych składowych wejściowych do żądanych wzorców  $d_i$ . Adaptacja wag sprowadza się do znalezienia minimum funkcji celu, nazywanej funkcją błędu średniokwadratowego. Całkowity błąd średniokwadratowy zdefiniowany jest jako suma kwadratów błędów  $\varepsilon_i^{(k)}$  na wyjściach neuronów ostatniej warstwy  $L$  sieci neuronowej. Błąd ten opisuje zależność (5.53).

$$E(t) = \sum_{i=1}^{N_L} (\varepsilon_i^{(L)})^2 = \sum_{i=1}^{N_L} (d_i^{(L)}(t) - y_i^{(L)}(t))^2 \quad (5.53)$$

Proces minimalizacji funkcji błędu oparty na modyfikacjach wartości wektora wag najczęściej wykorzystuje tzw. metody gradientowe, dla których wektor gradientu wskazuje kierunek najszybszego spadku poprzez swoje składowe, będące pochodnymi cząstkowymi funkcji błędu po poszczególnych wagach sieci [251]. W literaturze przedmiotu odnaleźć można inne sposoby definiowania funkcji błędu (patrz np. [193, 187, 251]).

Najbardziej popularnym algorytmem gradientowego uczenia jednokierunkowych sieci neuronowych jest metoda wstecznej propagacji błędu (*ang. error back – propagation*) (BP) zaproponowana w 1974 roku przez Werbosa, a rozpowszechniona przez Rumelharta. Korekcja wag w przypadku

algorytmu BP rozpoczyna się od wyznaczenia błędu na podstawie sygnału wejściowego i sygnału wyjściowego dla ostatniej warstwy, a następnie wykonywane jest przesunięcie od warstwy poprzedzającej ( $L-1$ ) aż do warstwy wejściowej. Modyfikacja wartości wag przeprowadzana zgodnie z regułą najszybszego spadku, przyjmuje postać (5.54), co pozwala na wyznaczenie błędu  $\varepsilon_i^k$   $k$ -tej warstwy opisanej zależnością (5.55).

$$w_{ij}^{(k)}(t+1) = w_{ij}^{(k)}(t) + 2\mu\delta_i^{(k)}(t)x_j^{(k)}(t) \quad (5.54)$$

$$\varepsilon_i^{(k)}(t) = \begin{cases} (d_i^{(L)}(t) - y_i^{(L)}(t)) & \text{dla } k = L, \text{ czyli ostatniej warstwy} \\ \sum_{j=1}^{N_{k+1}} \delta_j^{(k+1)}(t)w_j^{(k+1)}(t) & \text{dla } k = 1, 2, \dots, L-1 \end{cases} \quad (5.55)$$

$$\delta_i^{(k)}(t) = \varepsilon_i^{(k)}(t)f'(y_i^{(k)}(t)) \quad (5.56)$$

Algorytm BP można zatem scharakteryzować układem zależności matematycznych (5.54) – (5.56), gdzie:  $k$  – numer warstwy,  $L$  – liczba warstw,  $i$  – numer neuronu w danej warstwie,  $j$  – indeks próbki sygnału wejściowego  $x$ ,  $N_k$  – liczba neuronów w  $k$ -tej warstwie,  $f$  – funkcja aktywacji,  $\mu$  – wielkość kroku korekcji wag tzw. współczynnik uczenia).

Proces uczenia sieci neuronowej algorytmem wstecznej propagacji błędu można określić jako zbyt wolno zbieżny, szczególnie dla małego współczynnika uczenia  $\mu$ . Dodatkowo może okazać się, iż proces uczenia zakończy się nie z chwilą odnalezienia minimum globalnego funkcji błędu, ale w jednym z minimów lokalnych. Bardzo duże znaczenia ma także wybór wartości początkowych wag.

Poprawy zbieżności algorytmu BP najczęściej dokonuje się poprzez wprowadzenie współczynnika  $\alpha$  zwanego współczynnikiem momentum. W wyniku tego (5.54) zapisujemy zależnością (5.57).

$$w_{ij}^{(k)}(t+1) = w_{ij}^{(k)}(t) + 2\mu\delta_i^{(k)}(t)x_j^{(k)}(t) + \alpha[w_{ij}^{(k)}(t) - w_{ij}^{(k)}(t-1)] \quad (5.57)$$

Wagi współczynnika momentum  $\alpha$  są niezależne od aktualnej wartości gradientu, dzięki temu dla  $\alpha \approx 1$  algorytm cechuje się dużą bezwładnością. Oznacza to, że wraz z pojawieniem się gradientu wymuszającego ruch w przeciwną lub inną stronę niż ruch aktualny, zmiana nie następuje natychmiast. Zmiana wag odbywa się więc w sposób bardziej płynny. Jak wykazuje wielu autorów, momentowa metoda wstecznej propagacji powoduje przyśpieszenie procesu uczenia. Aktualnie w literaturze przedmiotu można odnaleźć różne

modyfikacje metody wstecznej propagacji błędu. Szeroko ten problem poruszony jest np. w opracowaniu [251] (patrz także [193,195,175,262,261]).

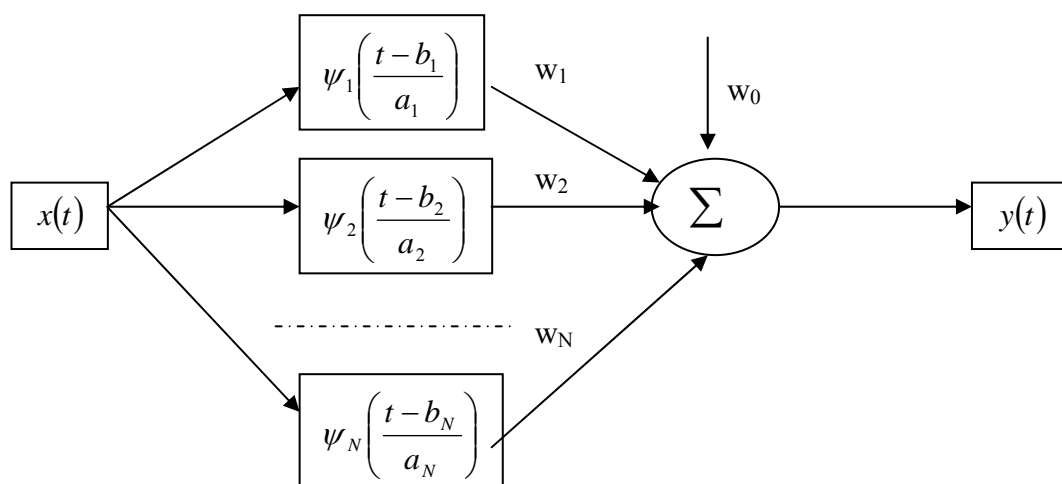
## 5.6 Sieć falkowo – neuronowa

### 5.6.1 Koncepcja klasyczna

Pod nazwą sieci falkowo – neuronowych (*ang. wavelet neural networks*) (WNN) w literaturze przedmiotu można spotkać dwie zasadnicze idee. Pierwsza z nich, to koncepcja klasyczna zaproponowana w 1992 roku przez Zhanga i Benveniste'a [294]. Autorzy połączyli zdolności aproksymacyjne sieci neuronowych z czasowo – częstotliwościową reprezentacją sygnału uzyskiwaną na podstawie przekształceń falkowych. Istota tej koncepcji polega na zastąpieniu funkcji aktywacji sieci neuronowych funkcjami falkowymi. Wyjście sieci falkowo – neuronowej, wyrażone zależnością (5.73), jest sumą ważoną wartości funkcji falkowych  $\psi_i$ , skalowanych i przesuwanych odpowiednimi parametrami  $a_j$ ,  $b_j$  dla określonego pobudzenia, zaś  $w_{ij}$  to współczynniki wagowe.

$$y(t) = \sum_{j=1}^p w_{ij} \psi \left( \frac{t - b_j}{a_j} \right) + w_0 \quad (5.58)$$

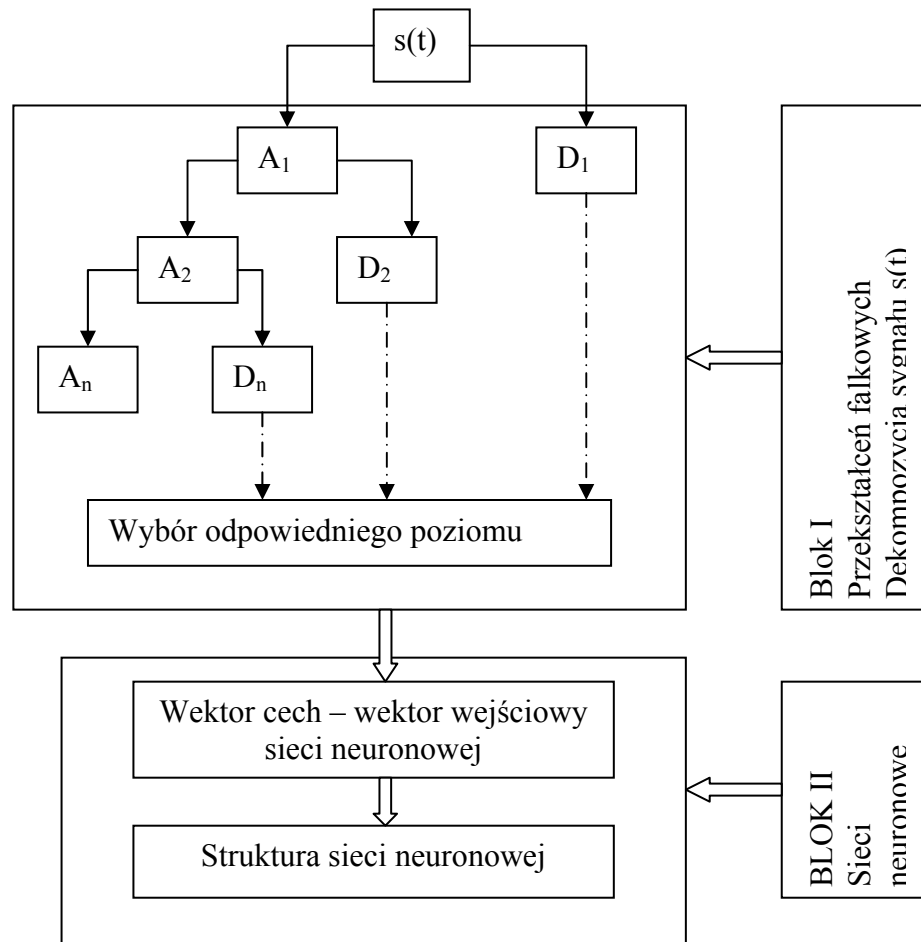
Zamiana funkcji aktywacji na podstawowe funkcje falkowe jest zastosowana analogicznie do sieci o radialnych funkcjach bazowych. W tym przypadku algorytm uczenia sprowadza się do uczenia parametrów przekształcenia falkowego – parametru skali  $a$  oraz parametru przesunięcia  $b$ . Wyjście jest wartością współczynnika dekompozycji przekształcenia falkowego. Strukturę zaproponowanej przez Zhanga i Benveniste sieci falkowo – neuronowej przedstawiono na Rys. 5.8.



Rys. 5.8 Struktura sieci falkowo – neuronowej. Źródło [ 294].

### 5.6.2 Koncepcja intuicyjna

Druga koncepcja sieci falkowo – neuronowych polega na wykonaniu wstępnego przetwarzania badanego sygnału za pomocą przekształceń falkowych. W wyniku analizy czasowo – częstotliwościowej uzyskuje się poszukiwane cechy charakterystyczne, które podlegają dalszej selekcji. Przygotowany wektor cech, powstały w efekcie zastosowanych przekształceń falkowych, stanowi optymalny wektor wejściowy dla odpowiednio dobranej struktury sieci neuronowej. Taką koncepcję można znaleźć w kilku pracach np. w pracy [238] opisaną także w rozdziale drugim niniejszej rozprawy. Rozwiązania te dotyczą wykrywania różnego rodzaju morfologii zespołu QRS dla standardowych sygnałów elektrokardiograficznych. Interesująca jest także praca Wrześniowskiego [286], dokładnie omawiająca klasyfikację ewolucji serca sygnałów EKG rejestrowanych metodą Holtera, przy zastosowaniu koncepcji intuicyjnej WNN. Należy podkreślić, iż w omawianym kontekście struktura sieci falkowo – neuronowej uwarunkowana jest zarówno sposobem wykorzystania przekształceń falkowych, jak i zastosowaną siecią neuronową. Z powyższych względów nie można podać jej konkretnej, a zarazem optymalnej struktury. Uproszczoną strukturę sieci WNN, dla tej grupy systemów, przedstawiono na Rys.5.9



Rys. 5.9 Uogólniona struktura sieci falkowo – neuronowej.

### 5.6.3 Rozwiązanie WNN przystosowane do zdefiniowanego w rozprawie problemu

Na potrzeby detekcji zespołu QRS oraz klasyfikacji rytmu endogenego pacjenta z wszczepionym układem stymulującym pracę serca, co jest przedmiotem prezentowanej rozprawy, zastosowano sieci falkowo – neuronowe należące do drugiego rodzaju omówionych powyżej sieci WNN, tzw. koncepcję intuicyjną systemu falkowo – neuronowego. Wybór takiego rozwiązania podyktowany jest przede wszystkim specyfiką omawianego w rozprawie problemu. Struktura systemu uwarunkowana jest odpowiednim doбором falki i sieci neuronowej, co będzie przedmiotem analizy w kolejnych podpunktach niniejszego rozdziału.



### 5.6.3.1 Blok I – Dekompozycja sygnału

Dobór falki podstawowej przeprowadzono intuicyjnie. W literaturze przedmiotu dotyczącej teorii falek nie można odnaleźć jednoznacznego algorytmu określającego sposób dobierania fali w celu rozwiązania zadanego problemu. Choć są proponowane rozwiązania ustalające stopień przydatności wybranej falki (np. metoda Grama – Schmidta, najmniejszych kwadratów), nie można wykorzystać ich do omawianej bazy sygnałów, gdyż nie odzwierciedlają charakteru przetwarzanego sygnału. Podczas doboru falki brano były pod uwagę następujące właściwości: ortogonalność i biortogonalność, symetria, regularność i gładkość oraz czas trwania. Własności dla kilku wybranych falek przedstawiono w Tabeli nr 5.4.

**Tabela nr 5.4 Własności przykładowych falek. Opracowano na podstawie [19].**

Własność	Morlet	Db 4	Bior 2.4
Ortogonalność	-	+	-
Biortogonalność	-	+	+
Ograniczony czas trwania	-	+	+
Symetria	+	-	+
Arbitralna regularność	-	+	+
Zapewnienie dokładnej rekonstrukcji	-	+	+

Należy również podkreślić, iż w przypadku niespełnienia podstawowej własności, jaką jest ortogonalność, błędy i zniekształcenia zawarte w sygnale byłyby powielane w kolejnych poziomach dekompozycji. Ortogonalność, zapewnia zatem stabilność obliczeń numerycznych [286]. Zachowanie symetrii nie powoduje wprowadzenia dodatkowych zniekształceń, a gładkość decyduje o stopniu rozdzielczości i lokalizacji sygnału w dziedzinie częstotliwości. Im większa gładkość, tym lepsza rozdzielczość.

Kolejną istotną kwestią jest to, iż żadna ze znanych falek nie spełnia wszystkich podanych wcześniej właściwości. I choć istnieje możliwość konstruowania własnych falek (sposób ich tworzenia podaje Augustyniak w [19]), to autorka rozprawy nie skorzystała z tego rozwiązania. Powodem takiej decyzji była zbyt duża różnorodność morfologiczna analizowanej grupy sygnałów oraz niemożność zapisania cech w postaci matematycznego opisu zjawiska.

Oprócz doboru fali podstawowej, należy także dobrać optymalną wartość parametru skali  $a$  oraz określić znaczącą ilość poziomów. W niniejszej rozprawie zastosowano tzw. kryterium istotności w postaci funkcji entropii zdefiniowanej worem (5.59). Jest to tzw. entropia Shannona.

$$E\{a_i\} = -\sum_i a_i^2 \log(a_i^2) \quad (5.59)$$

Warto zauważyć, iż funkcja entropii jest funkcją odwrotną w stosunku do funkcji koncentracji energii. Inne przykłady stosowanych w literaturze przedmiotu entropii podaje Augustyniak w [19]. Sposób minimalizacji entropii polega na obliczeniu sumy entropii składowej aproksymacji i składowej detali dla  $j$ -tego poziomu dekompozycji sygnału, zgodnie z algorytmem dekompozycji Mallata, i porównaniu z sumą entropii na wcześniejszym poziomie. Jeżeli wartość entropii na  $(j-1)$ -ym poziomie jest większa od wartości entropii na  $j$ -tym poziomie, to składowe entropii  $(j-1)$  poziomu są zastępowane przez szereg  $j$ -tego poziomu lub odwrotnie. Można także porównywać wyznaczoną entropię  $j$ -tego poziomu z założoną wartością progową entropii, dla której proces dekompozycji sygnału zostanie zakończony.

### 5.6.3.2 Blok II – Stosowane struktury sieci neuronowych

Realizacja celów niniejszej rozprawy opiera się na przetestowaniu kilku struktur jednokierunkowych sieci neuronowych tj. sieci jedno-, dwu-, trzy- czterowarstwowej o tangesoidalnej i sigmoidalnej funkcji aktywacji.

Istotną rolę w procesie uczenia sieci neuronowej odgrywa czas treningu. Duży wpływ na szybkość uczenia, a tym samym na minimalizację funkcji błędu, ma także odpowiedni dobór wag początkowych sieci. Zastosowano dwa sposoby tworzenia tablicy wag początkowych:

- a) tzw. inicjację losową – wagom przypisywane są losowe wartości z przedziału  $(-0,1;0,1)$ ,
- b) wagom, których wskaźnik  $i=j$  przypisujemy wartości  $+0,1$  zaś pozostałym wagom wartości  $0$  (patrz [281]).

Pierwszy sposób przyspiesza proces uczenia, drugi zapewnia jego powtarzalność. Niektórzy autorzy, w celu zakończenia treningu sieci neuronowej, zalecają

przerwanie uczenia po z góry wybranej iteracji (tzw. ilości epok). W przypadku analizowanej grupy sygnałów elektrokardiograficznych, wykorzystano metodę tzw. wcześniejszego zatrzymania (*ang. hold – out*), która za moment zatrzymania procesu uczenia uznaje minimum błędu testowego. W literaturze przedmiotu można odnaleźć zarówno negatywne [175], jak i pozytywne [193] opinie dotyczące tej metody.

Bardzo istotną sprawą jest także odpowiedni dobór wejściowego zbioru danych. Analiza literatury wskazuje na istnienie kilku metod dotyczących podziału tego zbioru danych na zbiór uczący i testowy. Są to m.in:

- a) podział losowy (*ang. split – sample*), najczęściej stosowany. Wadą tej metody jest jednak używanie tylko części przygotowanego zbioru. Warunki podziału określone zostały w pracy [127].
- b) metoda krzyżowa (*ang. cross – validation*), polegająca na podziale przygotowanego zbioru na prawie równolicznych  $k$  – podzbiorów, z których  $(k - 1)$  uczestniczy w procesie uczenia. W literaturze przedmiotu można odnaleźć wiele modyfikacji tej metody (np. *leave – v – out*, *bootstrapping*). Szerzej te zagadnienia poruszane są w [265].

Warto zaznaczyć, iż w przypadku systemów diagnostyki medycznej ważne jest, aby w procesie uczenia brała udział dobrze wyselekcjonowana część zbioru, zawierająca wszystkie charakterystyczne przypadki. Metody podziału zbioru, w sytuacji danych medycznych, opisuje [157] wykazując przy tym, iż najlepszym wyborem jest zastosowanie metody krzyżowej. Jak podaje autor, zbyt małe  $k$  prowadzi do zaniżonego oszacowania w wyniku dużej różnicy między liczebnością zbiorów uczących wykorzystywanych podczas oceny krzyżowej a liczebnością pełnej bazy danych.

Kolejnym istotnym problemem jest dobór właściwej architektury sieci neuronowej, który sprowadza się do określenia odpowiedniej liczby warstw ukrytych i ilość neuronów w nich zawartych. Wielkość warstw wejściowych i wyjściowych narzucona jest rozpatrywanym zadaniem. W literaturze przedmiotu można odnaleźć różne metody optymalizacji architektury sieci neuronowych. Wiele opracowań zawiera choćby jeden rozdział poświęcony temu zagadnieniu (patrz np. [107, 193, 195, 258, 261, 175, 136, 70]). Są to m.in.: metody wzrostu, redukcji czy też optymalizacji dyskretnej. W większości publikacji dotyczących

problemu optymalizacji sieci neuronowej brak jest konkretnego rozstrzygnięcia, który kierunek poszukiwań należy wybrać [193,195]. Jedyne autorzy prac [107,175] proponują zastosowanie kierunku w górę. Bardzo często w różnych opracowaniach prezentujących wyniki konkretnych zastosowań, szczególnie z zakresu medycyny, problem optymalizacji struktury stosowanej sieci neuronowej nie jest w ogóle poruszany. Autorzy ograniczają się jedynie do podania, z jakiej sieci korzystali. W niniejszej rozprawie kierowano się zdaniem Tadeusiewicza, który twierdzi w [262], iż „**każdy system zawierający sieć neuronową powinien być indywidualnie optymalizowany ze szczególnym uwzględnieniem specyfiki zastosowania**”. Ową indywidualną optymalizację, w przypadku badanej grupy sygnałów elektrokardiograficznych – stymulatorowych i zastosowanych sieci, potraktowano jako dostosowanie liczby warstw i neuronów ukrytych na drodze eksperymentalnej, sprawdzając działanie kilku wybranych sieci (typując kierunek poszukiwań w górę, czyli rozpoczynając od najmniejszej liczby warstw).

## 5.7 Podsumowanie rozdziału

Niniejszy rozdział zawiera charakterystykę algorytmu detekcji zespołu QRS i klasyfikacji rytmu endogennego pacjenta z wszczepionym układem stymulującym. Ze względu na połączenie dwóch dziedzin, a mianowicie przekształceń falkowych i sieci neuronowych, uzasadniony wydaje się fakt krótkiego ich scharakteryzowania w dwóch pierwszych podpunktach niniejszego rozdziału, o czym była mowa we wstępie. W celu realizacji założeń niniejszej rozprawy przetestowano tylko wybrane rodziny falek, a także tylko kilka struktur sieci neuronowych. Zastosowano również tylko jeden algorytm uczenia – algorytm wstecznej propagacji. Zarówno dla każdej wykorzystywanej falki, jak i zastosowanej sieci neuronowej wykonano szereg badań eksperymentalnych. Wyniki przedstawione są w kolejnym rozdziale pracy.

## Rozdział VI

### Wyniki badań

W rozdziale piątym rozprawy omówiono matematyczne podstawy wykorzystywanego algorytmu opartego na sieci falkowo – neuronowej. W tym rozdziale zostaną zaprezentowane wyniki badań dla zgromadzonej bazy sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca. Testowano 150 sygnałów o częstotliwości 128 Hz, udostępnionych przez Instytut Kardiologii w Warszawie oraz 21 sygnałów uzyskanych z firmy ASPEL z Krakowa. Charakterystyka zebranych sygnałów została omówiona w rozdziale czwartym. Rozdział niniejszy został podzielony na dwie części. Pierwsza, związana jest bezpośrednio z detekcją zespołu QRS. W tej części, uwagę skoncentrowano przede wszystkim na odpowiednim doborze poziomu dekompozycji, progu detekcyjnego, a także wyborze falki. Druga część rozdziału dotyczy zaś rozpoznania rytmu endogennego pacjenta.

#### 6.1 Dobór poziomu dekompozycji


Poziomy dekompozycji sygnału elektrokardiograficznego pochodzącego od pacjentów z wszczepionym układem stymulującym wyznaczono na podstawie kryterium istotności – entropii Shannona, określonej wzorem (5.59). W 132 przypadkach sygnałów drzewo dekompozycji ukształtowało się na poziomie czwartym. Poziom ten wydaje się stosunkowo niski, należy jednak zaznaczyć, że zgromadzona baza testowych sygnałów elektrokardiograficznych – stymulatorowych, zarejestrowana metodą Holtera, charakteryzuje się niską częstotliwością, tylko 128 Hz. W wyniku dekompozycji sygnału, częstotliwość na kolejnych poziomach wynosi: poziom pierwszy – 128 Hz, poziom drugi – 64 Hz, ..., poziom ósmy – 1 Hz.

Przykładowe wartości entropii Shannona dla kilku rodzin falek wykorzystywanych w badaniach w kolejnych poziomach dekompozycji sygnału przedstawia Tabela nr 6.1. Łatwo zauważyć, iż maksymalna wartość entropii, znajduje się na czwartym poziomie dekompozycji (wartości te zostały w tabeli oznaczone pogrubioną czcionką). Zmianę entropii Shannona na poszczególnych poziomach dekompozycji dla rodzin falek Daubechies, Coiflets,

Symlets oraz Biortogonalnych dla sześciu losowo wybranych sygnałów (stym12; stym33; stym67; stym78; stym105; stym115) przedstawiono na Rys. 6.1.

**Tabela nr 6.1 Przykład wartości entropii Shannona dla 8 poziomów z wykorzystaniem kilku rodzin falek.**


Poziom	Db3	Db6	Coif2	Coif3	Sym3	Sym7	Bior1.5	Bior2.6
1	2,022	2,188	2,161	2,274	1,886	1,971	2,043	2,239
2	2,941	3,255	3,054	3,144	2,622	2,721	2,821	3,02
3	3,827	4,477	3,941	4,002	3,401	3,727	3,755	3,878
4	<b>4,791</b>	<b>5,127</b>	<b>4,717</b>	<b>4,79</b>	<b>4,355</b>	<b>4,42</b>	<b>4,381</b>	<b>4,452</b>
5	4,55	4,55	4,564	4,513	4,092	3,817	3,804	3,481
6	3,556	3,304	3,397	3,455	3,09	3,054	3,437	3,073
7	2,506	1,977	2,214	1,979	2,074	1,906	2,549	1,446
8	0,991	0,98	0,963	0,989	0,987	0,987	1,367	0,963



**Rys. 6.1 Zmiana entropii Shannona na poziomach 1-8 dla rodzin falek Daubechies (kolor czarny), Biortogonalne (zielony), Symlet (czerwony), Coiflets (kolor niebieski).**


Dekompozycja sygnału wykonana przy zastosowaniu falki Haara oraz meksykańskiego kapelusza nie potwierdza czwartego poziomu. Maksimum entropii Shannona, w tych dwóch przypadkach falek, znajduje się na pierwszym

poziomie dekompozycji (patrz Rys. 6.2 dla falki Haara i meksykańskiego kapelusza).



**Rys. 6.2 Entropia Shannona na poziomach 1-8 dla falki Haara (czarny), Meksykański kapelusza (niebieski).**

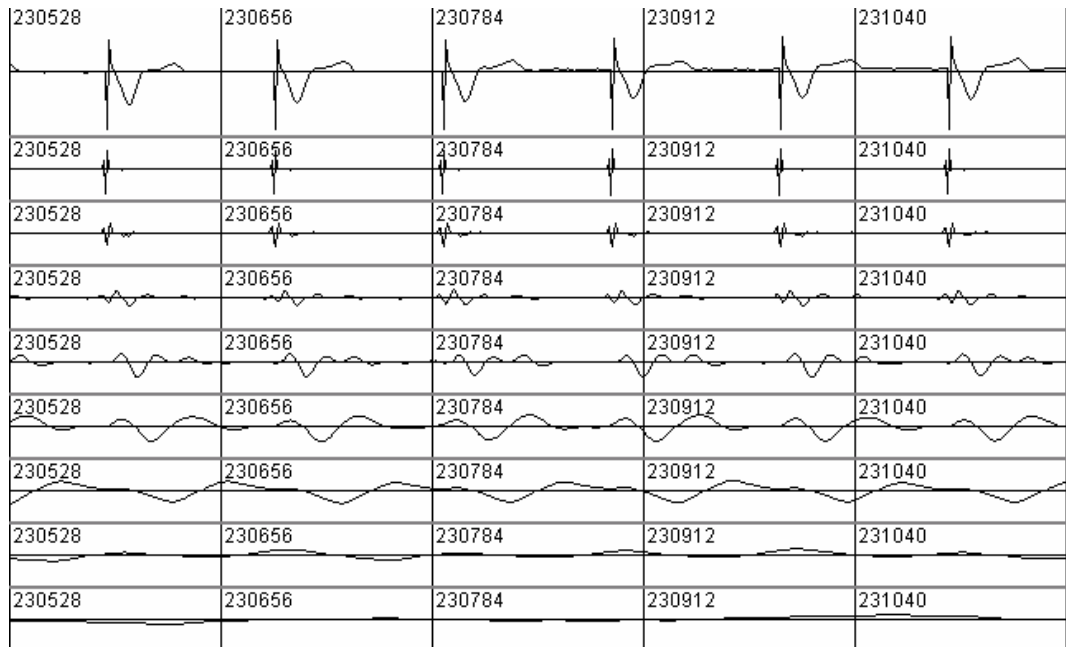
Ciekawą sytuację zauważono dla falki Morleta. Pojawia się bowiem nagły spadek entropii Shannona na drugim poziomie oraz łagodny spadek wartości począwszy od maksimum (od poziomu czwartego) (patrz Rys.6.3).



**Rys. 6.3 Entropia Shannona na poszczególnych poziomach dekompozycji dla falki Morlet.**


Przyczyna tego nagłego spadku wartości entropii Shannona na poziomie drugim dla falki Morleta jest trudna do interpretacji dla zastosowanej dyskretnej postaci. Możliwe jest, iż efekt ten zostałby wyjaśniony dla jej postaci ciągłej.

Przeprowadzone badania eksperymentalne również potwierdzają czwarty poziom dekompozycji. Rys. 6.4 – 6.6 przedstawiają 8 poziomów dekompozycji sygnału EKG z wykorzystaniem falek Daubechies, Coiflet, Symlet odpowiednio trzeciego, pierwszego i siódmego rzędu. Można zauważyć, iż zespół QRS gromadzi składowe wysokoczęstotliwościowe oraz średnie częstotliwości, zatem jego kontury są widoczne w każdym prezentowanym przypadku, aż do szóstego poziomu. Można także zaobserwować wzrost amplitudy w okolicach zespołu QRS na poziomach 2, 3, i 4, co odpowiada rozkładowi ilościowemu współczynników falkowych dla kolejnych poziomów.




**Rys. 6.4** Dekompozycja 8 poziomowa z wykorzystaniem falki db3. U góry jeden z kanałów sygnału rzeczywistego (stym036.dat), poniżej kolejne poziomy dekompozycji.





**Rys. 6.5** Dekompozycja 8-cio poziomowa wykorzystująca falkę *coif1*. U góry sygnał rzeczywisty (*stym036.dat*) oraz kolejne poziomy dekompozycji.



**Rys. 6.6** Dekompozycja 8-cio poziomowa wykorzystująca falkę *sym7*. U góry sygnał rzeczywisty (*stym036.dat*) oraz kolejne poziomy dekompozycji.


Należy podkreślić, iż pierwszy poziom dekompozycji sygnału, zgodnie z przyjmowanym w sposób niejawni założeniem, że dekompozycja na pierwszym poziomie jest sygnałem (aproksymacji) z nieistniejącego poziomu niższego, wygląda w ten sam sposób, co rzeczywisty sygnał. Oznacza to, że współczynniki

falkowe określające szczegóły pierwszego poziomu dekompozycji sygnału, są niezależne od poziomu dekompozycji.

Na podstawie zaprezentowanych wykresów (Rys. 6.4 – 6.6) dotyczących dekompozycji sygnału elektrokardiograficznego – stymulatorowego, można łatwo zauważyć, iż najkorzystniejsza jest dekompozycja czteropoziomowa. Na trzecim i czwartym poziomie następuje wzrost amplitudy w rejonie zespołu QRS. Na Rys. 6.7 pokazano tylko czwarty poziom dekompozycji sygnału przy zastosowaniu kilku wybranych falek.

Omawiając wybór poziomu dekompozycji należy zwrócić uwagę na miary, takie jak czułość oraz błąd detekcyjny zespołu QRS. Dla 150 badanych sygnałów największą czułość na poziomie czwartym uzyskano w 127 przypadkach, na poziomie piątym dla 15 sygnałów oraz dla 8 sygnałów na poziomie trzecim. Czułość maksymalna wynosiła na kolejnych poziomach:


- trzecim 96,86% (średnio 95,23%),
- czwartym 99,07% (średnio 97,36%),
- piątym 98,05% (średnio 96,04%).



**Rys. 6.7** Przykład informacji zawartej na czwartym poziomie dekompozycji sygnału EKG dla kilku wybranych falek. Kolejno od góry: db3, coif1, sym7, bior1.5.

Rozpatrując zastosowanie różnego rodzaju falek do omawianego problemu doboru poziomu dekompozycji okazuje się, iż dla większości wykorzystywanych rodzin falek czułość jest największa na poziomie czwartym. Dodatkowo, na tym poziomie nie zważono dużych różnic między wyznaczoną czułością w stosowanych falkach, co daje się szybko zauważyć np. dla poziomu piątego. Kolejny wykres (Rys. 6.8) ukazuje wartości miary czułości uzyskane dla poszczególnych rodzin falek w omawianych trzech poziomach dekompozycji sygnału.


### SE na poziomach dekompozycji



Rys. 6.8 Średnia czułość na 3, 4 oraz 5 poziomie dekompozycji.

Rozpatrując zaś natępną analizowaną miarę, którą stanowi błąd detekcyjny, okazuje się, iż jest on najmniejszy na 4 poziomie. Średni błąd wynosi 5,36%, 4,98%, 6,84% dla odpowiednio 3, 4 oraz 5 poziomu (patrz Rys. 6.9).

### BD na poziomach dekompozycji



Rys. 6.9 Średni błąd detekcyjny poszczególnych rodzin falek na 3, 4, 5 poziomie dekompozycji.

Biorąc pod uwagę wszystkie miary i zależności omawiane powyżej, wybór czwartego poziomu dekompozycji sygnału wydaje się być uzasadniony. Potwierdzają to zarówno rezultaty badań eksperymentalnych, jak i wyniki zastosowanego kryterium istotności w postaci entropii Shannona.

## 6.2 Dobór progu detekcyjnego

W przypadku sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca, rozpatrywano następujące wartości progowe: 0,45; 0,5; 0,55; 0,6; 0,65; 0,7. Rozważając dobór progu zwrócono uwagę na liczbę wykrytych zespołów QRS, detekcje fałszywie pozytywne i fałszywie negatywne oraz otrzymany błąd detekcyjny. Przykład liczby wykrytych zespołów QRS dla wymienionych powyżej progów podano w Tabeli nr 6.2.


Tabela nr 6.2 Wykryte zespoły QRS w zależności od wybranego progu.

próg syg	0,45	0,5	0,55	0,6	0,65	0,7
Stym001	2524	2445	2332	2210	2107	2026
Stym025	2187	2190	2180	2170	2154	2075
Stym037	2334	2331	2331	2331	2327	2322
Stym045	2205	2216	2281	2238	2204	2122
Stym94	2349	2508	2571	2605	2587	2500
Stym102	2630	2599	2547	2459	2316	2161

Na podstawie analizy zgromadzonych sygnałów, zaobserwowano dwie istotne zależności. A mianowicie:

- 1) liczba wykrytych zespołów QRS wzrasta do wartości progu 0,55 lub 0,6, a po niej maleje, przyjmując kształt zbliżony do paraboli funkcji kwadratowej o współczynniku kierunkowym  $a < 0$ ;
- 2) liczba wykrytych zespołów QRS maleje wraz ze wzrostem progu, przyjmując w przybliżeniu kształt malejącej funkcji liniowej lub kształt prawej strony paraboli z  $a < 0$ .

Powyższe zależności ilustruje Rys. 6.10.



**Rys. 6.10** Liczba wykrytych zespołów QRS w zależności od zmiany progu dla czterech sygnałów stymulatorowych (stym025 – kolor czerwony, stym037 – czarny, stym098 – niebieski, stym102 – zielony).

W pierwszym przypadku, maksimum przypada dla wartości progu 0,55 – 0,6 (linia czerwona i zielona na Rys. 6.10). Należy więc przypuszczać, że te dwa progi będą miały największe znaczenie i mogą być wybrane jako progi detekcyjne podczas detekcji zespołu QRS. W drugim przypadku (linia niebieska oraz czarna na Rys. 6.10), maksimum wykrytych zespołów QRS przypada na najmniejszy badany próg 0,45. Taki rezultat zaprzecza więc powyżej postawionemu wnioskowi, dotyczącemu wyboru progu o wartości 0,6. Należy jednak zauważyć, że liczba wykrytych zespołów QRS nie jest wystarczającym kryterium do tego, aby jednoznacznie stwierdzić, iż próg, dla którego otrzymano maksymalną liczbę wykrytych zespołów QRS jest ogólnie odpowiednim i prawidłowo dobranym progiem dla wszystkich sygnałów elektrokardiograficznych – stymulatorowych.

W związku z powyższym, przeprowadzono analizę detekcji fałszywie negatywnych oraz fałszywie pozytywnych. Rozpatrując w pierwszym rzędzie detekcje fałszywie negatywne należy zauważyć, iż największą liczbę FN otrzymujemy dla najmniejszego progu 0,45. Liczba FN maleje wraz ze wzrostem

progów, choć należy podkreślić, że najmniejszy spadek zaobserwowano pomiędzy progami 0,55 a 0,6 (patrz Rys. 6.11).

W przypadku detekcji fałszywie pozytywnej także należy zauważyć dwie możliwości zmian tych wartości, podobnie jak w opisanej powyżej sytuacji. Wraz ze wzrostem progów zwiększa się liczba detekcji FP. W pozostałych przypadkach obserwujemy maksimum FP na krańcach przedziału [0,45; 0,7], zaś minimum FP dla dwóch progów 0,55 lub 0,6. Należy wziąć pod uwagę, iż największa liczba detekcji FP przypadająca na skrajne wartości progowe związana jest z wykryciem szumu jako zespołu QRS (patrz Rys. 6.12).


Na podstawie powyższych wyników wydaje się, iż wybór progów 0,55 oraz 0,6 jest uzasadniony. W celu dodatkowego potwierdzenia powyżej postawionej tezy sprawdzono miary detekcyjne, tj. czułość oraz błąd detekcyjny.

Dla wszystkich 150 sygnałów analiza miary czułości wykazała, iż najlepsze rezultaty są osiągane w przypadku zastosowania progów 0,6. Biorąc zaś pod uwagę błąd detekcyjny, najmniejszy BD uzyskano w 89% sygnałów dla wartości progów 0,6, dla pozostałych 11% sygnałów wartość progów wyniosła 0,55. Najmniejszą czułość oraz największy błąd detekcyjny otrzymano dla pozostałych skrajnych dwóch progów, a mianowicie dla progów o wartościach 0,45 oraz 0,7. Przykładowe wartości błędów detekcyjnych przedstawione są w Tabeli nr 6.3


**Tabela nr 6.3 Maksymalny i minimalny błąd detekcyjny dla progów detekcyjnych 0,45 – 0,7.**

	0,45	0,5	0,55	0,6	0,65	0,7
max	9,76%	7,84%	6,79%	6,71%	7,63%	11,72%
min	6,31%	3,31%	2,00%	1,84%	2,28%	5,63%

Omówione powyżej wszystkie zależności, szczególnie błąd detekcyjny, czułość oraz liczba detekcji fałszywie pozytywnej oraz fałszywie negatywnej, wskazują że należy uznać próg 0,6 za najbardziej prawidłowy.



Rys. 6.11 Liczba detekcji fałszywie negatywnej w zależności od wybranego progu dla czterech sygnałów stymulatorowych (stym025 – kolor czerwony, stym037 – czarny, stym098 – niebieski, stym102 – zielony).



Rys. 6.12 Liczba detekcji FP w zależności od wybranego progu dla czterech sygnałów stymulatorowych (stym025 – kolor czerwony, stym037 – czarny, stym098 – niebieski, stym102 – zielony).

### 6.3 Dobór falki

Jak wspomniano w poprzednim rozdziale, w literaturze przedmiotu brak jest jakichkolwiek wskazówek dotyczących odpowiedniego doboru falki do różnych zagadnień wykorzystujących przekształcenia falkowe, w szczególności do problematyki będącej przedmiotem niniejszej rozprawy. Trudność ta spotęgowana jest przede wszystkim niemożliwością dokładnego opisu matematycznego badanego sygnału elektrokardiograficznego. W trakcie wielu analiz przeprowadzono szereg empirycznych doświadczeń. Brane były pod uwagę falki o różnych właściwościach.

Należy zauważyć, iż na pierwszym poziomie dekomponowanego sygnału mamy do czynienia z wysokimi częstotliwościami, zaś w każdym kolejnym kroku dekompozycji następuje rozszerzenie falki – dwukrotne zwiększenie obszaru oraz zmniejszenie częstotliwości sygnału. Łatwo można zaobserwować omawianą zależność na podstawie Rys. 6.4 – 6.6, przedstawionych w punkcie 6.1 niniejszego rozdziału pracy.

Analizując morfologię załamek QRS w zgromadzonej przez autorkę bazie sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym, trudno jest wyróżnić powtarzający się kształt, choćby dla tego samego typu stymulacji. Duże zróżnicowanie w morfologiach akcentowano już w rozdziale pierwszym niniejszej rozprawy. Tabela nr 6.4 przedstawia kilka różnych kształtów zespołu QRS.

Analizując kształty falek rodziny Daubechies, Symlet, Coiflets czy też falki biortogonalne można zaobserwować ich pewne podobieństwo do przedstawionych w Tabeli nr 6.4 morfologii zespołów QRS. W Tabeli nr 6.5 podano dwie wybrane falki o kształcie zbliżonym do powyższych zespołów QRS.


Jak wykazały przeprowadzone badania, dobór falki ma bardzo duże znaczenie w przypadku poprawnego wykrycia zespołu QRS. Wyniki przedstawione są w następnym punkcie niniejszego rozdziału.



**Tabela nr 6.4 Przykład różnorodności morfologicznej zespołu QRS. Po lewej stronie sztuczne zespoły QRS (stymulatorowe), po prawej rytm endogeny - własny pacjenta.**



**Tabela nr 6.5 Przykład podobieństwa dwóch wybranych falek sym7 oraz coif3 do morfologii zespołu QRS.**

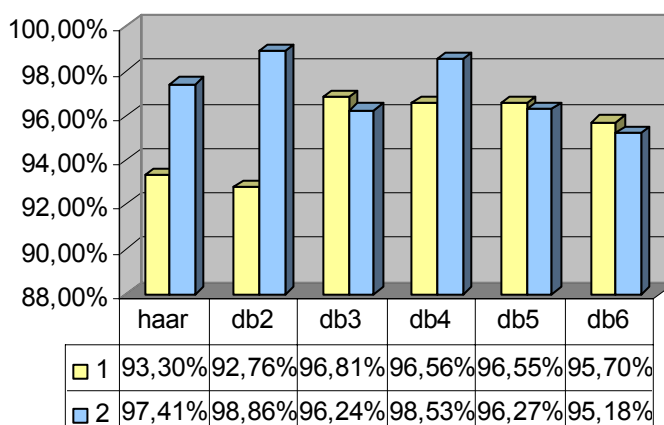


### 6.3.1 Detekcja zespołu QRS a dobór falki

Odpowiedni dobór falki ma ogromne znaczenie dla wykrycia zespołu QRS. W niniejszym punkcie zaprezentowano uzyskane wyniki dla analizowanych sygnałów elektrokardiograficznych – stymulatorowych w przypadku zastosowania falek z rodzin Daubechies, Coiflets, Symlet, Biortogonalnych oraz falek Morleta, Meyera i meksykańskiego kapelusza.

W przypadku rodziny falek Daubechies (Rys. 6.13), najgorsze wyniki otrzymywano dla falki Haara. Liczba wykryć fałszywie negatywnych, dla fragmentów 30 minutowych, średnio wynosiła 67. Dla 105 sygnałów przekraczała wartość  $FN > 100$ , co jest powodem uzyskania niskiej czułości detekcyjnej. Podobnie niskie wartości otrzymano dla 87 sygnałów stosując falki Daubechies drugiego rzędu (db2). Dla 15 sygnałów uzyskano niższe wyniki falki db2 niż w przypadku użycia falki Haara. Jeżeli z dalszej analizy wykluczy się falę Haara, pomimo iż należy ona do rodziny falek Daubechies, średnia czułość rozpatrywanej grupy falek wzrasta o 1,16% (z 95,53% do 96,69%).

**SE dla falek Daubechies**



**Rys. 6.13 Czułość dla falek rodziny Daubechies dla dwóch wybranych sygnałów. Oznaczenia 1- stym025; 2 – stym067.**


Przedstawiona na Rys. 6.13 średnia czułość kilku kolejnych falek rodziny Daubechies może sugerować, że wraz ze wzrostem rzędu falki (począwszy od db4) maleje czułość. Jak wykazały badania, falki Daubechies wyższych rzędów

uzyskują czułość podobną do falek rzędu czwartego, piątego i szóstego. Nie można zatem potwierdzić zaobserwowanej zależności.

Analizując detekcje fałszywie negatywne oraz fałszywie pozytywne dla rodziny falek Coiflets stwierdzono większą liczbę detekcji FN niż FP. Średnio dla 30 minutowego fragmentu sygnału, FN wynosi 90, zaś FP = 45. Największą czułość uzyskano dla falki Coiflets pierwszego rzędu (coif1), dla 37 sygnałów przekroczyła ona minimalnie 99,% (np. 99,05%), a dla 14 sygnałów przekroczyła tylko 92%. Ogólnie średnia czułość dla tej rodziny falek wynosi 96,40%. Przykład miary czułości dla trzech losowo wybranych sygnałów (stym25, stym67, stym99), charakteryzujących się różnym odsetkiem rytmu endogenego, dla kilku falek Coiflets ukazano na Rys. 6.14.


Biorąc pod uwagę rodzinę falek Szymlet, czułość (Rys.6.15) waha się od 89% - 99%. Dla 7 sygnałów, przy zastosowaniu falki Sym4, dla której czułość we wszystkich badanych sygnałach okazała się najniższa, uzyskano tylko 88,95%.

**SE - falki Coiflet**



**Rys. 6.14 Czułość dla falek rodziny Coiflets dla trzech wybranych sygnałów. Oznaczenia: 1- stym25, 2- stym67, 3-stym99.**


### SE-falki Symlet



**Rys. 6.15** Czulość dla falek rodziny Symlet dla trzech wybranych sygnałów. Oznaczenia: 1- stym25, 2- stym67, 3-stym99.


Gdy chodzi o rodzinę falek biortogonalnych, najmniejszą liczbę detekcji fałszywie negatywnej, (średnio dla 30 minutowego fragmentu sygnału FN=50), uzyskano dla falki bior3.3. Dla 132 badanych sygnałów, w przypadku użycia tej falki otrzymano największą czulość 98,28%. W sytuacji 14 sygnałów najmniejszą liczbę detekcji FN (FN=17), jak również największą liczbę detekcji FP (FP= 52), uzyskano dla falki bior2.2. Przykładowy wykres otrzymanych czulości zilustrowano na Rys. 6.16.

### SE - falki biortogonalne




**Rys. 6.16** Czulość dla rodziny falek biortogonalnych dla czterech wybranych sygnałów. Oznaczenia: 1- stym25, 2- stym67, 3-stym99, 4-stym126.

Analizując powyżej omówione rodziny falek pod względem uzyskiwanej miary czułości, najlepsze rezultaty otrzymujemy dla falek z rodziny biortogonalnych (średnio 97,11%), zaś najslabszą czułość dla rodziny coiflet (średnio 96,40%). Średnie wartości miar czułości dla poszczególnych analizowanych rodzin ukazano na Rys. 6.17.



**Rys. 6.17 Średnia czułość dla rodzin db, coif, sym, bior.**

Omawiana powyżej miara czułości została wyznaczona również dla innych falek (tj. meksykański kapelusz, falki Meyera oraz falki Morleta). Dla wskazanych tu falek, wartość tej miary nie przekracza 96,93%. Jest zatem porównywalna do średniej czułości rodzin falek Daubechies lub Coiflets w przypadku 67 sygnałów, dla pozostałych zaś wyniki są niższe od 2% do 4%.




**Rys. 6.18 Czułość falek Morleta, Meyera oraz meksykańskiego kapelusza dla trzech sygnałów (1-stym026; 2-stym059; 3 – stym101).**

W podobny sposób dokonano charakterystyki kolejnej miary, jaką jest błąd detekcyjny. Zestawienie wyników dotyczących uzyskiwanego BD, w przypadku analizowanej grupy sygnałów EKG, dla kilku falek, przedstawiono w Tabeli nr 6.6.

**Tabela nr 6.6 Błąd detekcyjny dla kilku wybranych sygnałów i kilku stosowanych falek.**


Nazwa falki	Stym12	Stym34	Stym55	Stym79	Stym91	Stym101	Stym143
db2	8,28%	8,81%	5,59%	0,90%	2,59%	5,00%	6,08%
db4	3,60%	5,07%	5,35%	3,11%	3,64%	3,01%	3,49%
coif2	4,12%	4,35%	5,36%	2,22%	2,22%	2,68%	2,77%
coif5	5,03%	4,21%	8,95%	2,08%	2,08%	3,40%	3,48%
sym3	4,60%	4,83%	4,60%	2,67%	2,67%	2,84%	2,92%
sym7	3,28%	3,52%	7,71%	3,11%	3,56%	2,93%	3,01%
bior1.5	3,73%	3,97%	6,86%	1,60%	1,60%	2,17%	2,25%
bior2.4	3,28%	3,52%	5,80%	1,76%	2,37%	2,80%	2,88%
Mexican Hat	<b>10,04%</b>	<b>8,67%</b>	<b>9,87%</b>	<b>9,01%</b>	<b>14,49%</b>	<b>2,55%</b>	<b>11,98%</b>
Meyer	9,98%	5,73%	6,28%	0,87%	7,51%	6,23%	9,82%
Molet	3,27%	3,30%	3,27%	0,67%	8,61%	1,67%	6,27%

Największy BD uzyskano dla meksykańskiego kapelusza. Dość duży BD otrzymano także dla falki Haara. Średni BD wynosił dla tych falek odpowiednio 9,26%, 8,89%. W przypadku 19 sygnałów, wyniósł on prawie 15% (np. 14,49%, 13,93%). W 11 sytuacjach uzyskano także wysoki – 10% błąd dla falki Coif1. Maksymalny błąd detekcyjny pozostałych grup falek należał do przedziału od 5% do 8%. Analizując błąd detekcyjny dla każdej rodziny falek osobno, można zauważyć, iż dla większości badanych sygnałów maksimum BD przypada na falki: db2, coif1, sym8, bior2.2. Minimalny zaś BD uzyskują db3, coif3, sym4, bior1.5. Biorąc pod uwagę wszystkie grupy falek najmniejszy błąd detekcyjny otrzymano dla falki symlet 4. Minimalny BD dla analizowanych falek zilustrowano na Rys. 6.19.




**Rys. 6.19 Minimalny błąd detekcyjny dla wybranych falek. Oznaczenia: db – rodzina falek Daubechies, coif – rodzina falek Coiflets, sym – rodzina falek Symlets, bior – rodzina falek biortogonalnych, mh – falka meksykański kapelus, meyr- falka Meyera, morl – falka Morleta.**

Biorąc pod uwagę średni błąd detekcyjny (Rys.6.20), najlepsze rezultaty dla większości badanych sygnałów daje rodzina falek biortogonalnych, najgorsze zaś meksykański kapelusz.



**Rys. 6.20 Średni błąd detekcyjny.** Oznaczenia: db – rodzina falek Daubechies, coif – rodzina falek Coiflets, sym – rodzina falek Symlets, bior – rodzina falek biortogonalnych, mh – falka meksykański kapelusz, meyr- falka Meyera, morl – falka Moleta.

Podsumowując dwie analizowane miary – czułość i błąd detekcyjny, w przypadku badanych sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym, najlepszą czułość i zarazem najmniejszy błąd detekcyjny uzyskano dla rodziny falek biortogonalnych. Należy zaznaczyć, iż często detekcje fałszywie pozytywne oraz fałszywie negatywne były spowodowane licznymi artefaktami w sygnale i wpływały na wyniki poszczególnych miar (patrz np. Rys. 6.22).



**Rys. 6.21 Przykład detekcji fałszywie negatywnej wynikającej z licznymi artefaktów zawartych w sygnale stymulatorowym stym056.** Kropki oznaczają wykryty zespół QRS.

## 6.4 Rozpoznanie rytmu endogennego

### 6.4.1 Dobór zbioru uczącego

Próby trenowania sieci neuronowej wykonywano dla kilku zbiorów. Dla dwóch zbiorów rozłącznych (zb\_qrs\_e; zb\_qrs\_s), gdzie pierwszy zbiór zawierał tylko QRS-y rytmu własnego, drugi zaś tylko QRS-y rozrusznikowe oraz trzeciego zbioru (zb\_qrs\_es) obejmującego mieszaną liczbę QRS endogennych i stymulacyjnych. Rezultaty trenowania określonej struktury sieci neuronowej poszczególnymi zbiorami treningowymi były bardzo podobne (mieściły się w granicach błędu  $E=0,001$ ). Nie można więc mówić o jakiegokolwiek zależności pomiędzy przygotowanymi zbiorami uczącymi a wynikami sieci. Zauważono jednak, iż bardzo istotna jest liczebność zbioru. Badania symulacyjne rozpoczęto od zbioru o liczebności 5000 QRS-ów. Każdy z trzech zbiorów zwiększano stopniowo o 1000 QRS-ów i wykonywano eksperymenty. Proces zwiększania zbioru ukończono na liczebności 12000. Z obserwacji wynika, iż wraz z liczebnością zbioru treningowego wzrasta dokładność klasyfikacji, zgodnie z Rys. 6.23.


W przypadku podziału zbioru danych na zbiór uczący i zbiór testowy zastosowano dwie metody:

- podział losowy
- podział krzyżowy – (cross validation),

opisane krótko w rozdziale piątym niniejszej rozprawy.

Dla przygotowanych dwóch zbiorów zawierających tylko QRS-y endogenne lub QRS-y stymulatorowe, nie zauważono różnic w dokładności klasyfikacji pomiędzy powyżej wymienionymi metodami podziału zbioru.





**Rys. 6.22 Zależność dokładności klasyfikacji od liczebności zbioru testowego.**

Dla trzeciego zbioru (zb\_qrs\_es) obejmującego mieszaną liczbę QRS (zarówno QRS endogenne, jak i QRS stymulatorowe), uzyskano lepsze wyniki przy zastosowaniu metody krzyżowej. Średnia różnica między metodami podziału zbioru wynosi 0,37%. Przykładowe wyniki podano w Tabeli nr 6.7

**Tabela nr 6.7 Średnia dokładność dla różnego podziału zbioru danych.**

Metoda podziału zbioru danych	Średnia dokładność [%]
Podział losowy	97,45
Podział krzyżowy	97,82

## 6.4.2 Dobór architektury sieci neuronowej

W wielu opracowaniach naukowych dotyczących bezpośrednio klasyfikacji danych medycznych bardzo rzadko omawiane są problemy związane z doбором optymalnej architektury sieci neuronowej. W większości prac dokonywana jest optymalizacja medycznych danych (np. pacjenta) i podana jest konkretna struktura sieci neuronowej, dla której uzyskano najlepsze rozwiązanie. W niniejszej rozprawie podjęto próbę wyznaczenia optymalnej architektury sieci neuronowej do zadania klasyfikacyjnego rytmu endogenego.

W opracowaniu przeprowadzono badania określające wpływ zastosowanej architektury sieci neuronowej na dokładność wykrycia rytmu własnego. Obserwacji dokonano dla sieci neuronowych, od jednej do czterech warstw ukrytych. Dla każdej struktury zmieniano liczbę neuronów ukrytych, zgodnie z następującym wektorem  $nu=[10, 20, 30, 40, 50, 60, 70]$ . Dodatkowo, przyjęto zasadę, iż dla sieci o  $n$  warstwach ukrytych, jeśli pierwsza warstwa zbudowana jest z  $N$  neuronów, to druga będzie ulegać zmianie odpowiednio według sekwencji 5, 10, ...,  $N$ . Dla każdego rodzaju sieci stosowano dwa sposoby wyznaczania wag początkowych, a mianowicie:

- wyznaczanie losowe wag początkowych,
- Wyznaczanie według Weymaere'a, czyli przypisanie wartości +0,1 dla wag  $i=j$ , zaś pozostałym wagom wartości 0.

Każdy rodzaj sieci trenowano do niemal idealnego rozpoznania zbioru uczącego, czyli do uzyskania błędu treningowego  $E=10^{-3}$ . W procesie uczenia stosowano algorytm wstecznej propagacji błędu, krótko opisany w rozdziale piątym niniejszej rozprawy.

Ustalenie architektury sieci odbywało się etapowo, poprzez zwiększanie liczby neuronów w warstwie ukrytej, kolejno dla każdego rodzaju sieci. Okazało się, iż minimalny błąd treningowy  $E=0,001$  nie został osiągnięty dla sieci dwuwarstwowej o minimalnej liczbie neuronów równej 10 w warstwie ukrytej. Należy zauważyć, iż w przypadku sygnałów elektrokardiograficznych zawierających bardzo dużą liczbę QRS stymulatorowych, w porównaniu do QRS endogennych (lub odwrotnie), każdy rodzaj sieci, oprócz wyżej wymienionej struktury dwuwarstwowej o 10 neuronach w warstwie ukrytej, klasyfikował QRS w 100%. Inne rezultaty uzyskano dla sygnałów o zróżnicowanej liczbie QRS stymulatorowych i endogennych. Przykładowe wyniki dla czterech sygnałów o zawartości rytmu endogennego odpowiednio 74% (stym032), 58% (stym121), 45% (stym037), 32% (stym095), ukazano w Tabeli nr 6.8.

**Tabela nr 6.8 Średni procent poprawnej klasyfikacji rytmu endogenego, dla sygnałów o zróżnicowanej liczbie QRS własnych i stymulatorowych dla sieci neuronowych od 1 do 4 warstw ukrytych.**


Nr sygnału	Prawidłowa liczba QRS endogennych	% poprawnej wykrywalności QRSów w sieciach neuronowych z liczbą warstw ukrytych			
		1	2	3	4
Stym032	60121	96,95	98,99	98,98	98,99
Stym037	46620	97,99	98,95	98,68	97,97
Stym095	30982	96,94	98,97	97,37	98,99
Stym121	57356	96,95	98,98	98,56	99,98

Biorąc pod uwagę cztery rodzaje sieci neuronowych, najlepsze rezultaty, w większości sygnałów otrzymano dla struktury o dwóch warstwach ukrytych. Jednak analizując dokładnie powyższe wyniki należy zauważyć, iż zależność pomiędzy wykryciem rytmu własnego a stosowaną architekturą sieci nie jest duża. Nie można więc jednoznacznie stwierdzić, że trójwarstwowa sieć o  $n$  neuronach ukrytych najlepiej wykrywa QRS-y endogenne. W wynikach brakuje systematyczności, która potwierdzałaby taką tezę. Istniejące różnice w poprawnej klasyfikacji rytmu endogenego, w zależności od liczby warstw, wynoszą maksymalnie 0,97%.

Trudno jest również ustalić optymalną liczbę neuronów w warstwach ukrytych sieci neuronowych. Z przeprowadzonych analiz wynika, iż w przypadku:

- 105 badanych sygnałów najlepsze wyniki uzyskuje się dla 30 (53 sygnałów) i 40 (52 sygnałów) neuronów w warstwach ukrytych;
- Dla 33 sygnałów optymalną liczbą neuronów ukrytych okazała się liczba 20 neuronów w warstwie ukrytej;
- Dla 12 badanych sygnałów wyniki działania sieci, dla różnej liczby neuronów w warstwach ukrytych, były identyczne (różnice wynosiły 0,01%).

Wyniki dotyczące zależności pomiędzy liczbą neuronów ukrytych a poprawną klasyfikacją rytmu endogenego ukazano na Rys. 6.23.



**Rys. 6.23 Dokładność klasyfikacji rytmu endogennego w zależności od liczby neuronów w poszczególnych warstwach ukrytych sieci neuronowych.**


Badania nie potwierdziły jednak funkcjonującego w literaturze przedmiotu poglądu o lepszej zdolności uogólniania sieci z mniejszą ilością neuronów. Liczba 40 neuronów stanowi środkową wartość rozpatrywanego wektora  $nu$ . Na Rys. 6.23 nie zaprezentowano rezultatów dla 50 neuronów w warstwie ukrytej ze względu na minimalną różnicę, jaką uzyskano w wynikach pomiędzy 50 a 60 neuronami. Różnica ta wynosiła zaledwie 0,01%.

### 6.4.3 Dokładność sieci neuronowych w zależności od stosowanej funkcji aktywacji

Dobór odpowiedniej architektury sieci neuronowej związany jest także z wyborem funkcji aktywacji. Jak zaprezentowano w rozdziale piątym niniejszej rozprawy, w badaniach wykorzystano dwie funkcje aktywacji: sigmoidalną oraz tangesoidalną, opisane wzorami odpowiednio (5.51) i (5.52). Wykresy funkcji aktywacji dla różnej wartości parametru zamieszczono w rozdziale piątym (Rys. 5.7).

Każdy rodzaj sieci (od dwuwarstwowej do pięciwarstwowej) został poddany analizie dla powyżej wymienionych dwóch funkcji aktywacji. W badaniach zmianie podlegała również wartość parametru  $\beta = \{1,5,15,25\}$ .

Zauważono, iż dla badanych sieci neuronowych, przy obu stosowanych funkcjach aktywacji najslabsze rezultaty (na poziomie 89% poprawnej klasyfikacji) uzyskuje się dla wartości parametru  $\beta = 1$ . Zmiana parametru  $\beta = 5$  umożliwia rozpoznanie rytmu endogenego już na poziomie ponad 96%. Uśrednione wyniki poszczególnych rodzajów sieci neuronowej dla sigmoidalnej i tangesoidalnej funkcji aktywacji przy wartości parametru  $\beta = 15$  zilustrowano na Rys. 6.24.



**Rys. 6.24 Dokładność klasyfikacji rytmu endogenego w zależności od wyboru funkcji aktywacji dla sieci neuronowych od 1 do 4 warstw ukrytych.**

Na podstawie powyższego wykresu (Rys.6.24) można zauważyć, iż sigmoidalna funkcja aktywacji wykazuje większy procent dokładności dla sieci neuronowych o jednej oraz dwóch warstwach ukrytych. Dla sieci o trzech oraz czterech warstwach ukrytych uzyskane wyniki sugerują, iż użycie tangesoidalnej funkcji aktywacji jest bardziej uzasadnione. Różnice pomiędzy badanymi dokładnościami sieci, w zależności od użytej funkcji aktywacji, są stosunkowo nieduże. W Tabeli nr 6.9 przedstawiono obliczone odchylenie standardowe dla analizowanych sieci neuronowych pomiędzy dokładnością klasyfikacji uzależnioną od wybranej funkcji aktywacji.

**Tabela nr 6.9 Odchylenie standardowe pomiędzy funkcjami aktywacji sigmoidalną i tangesoidalną dla sieci neuronowych od 1 do 4 warstw ukrytych.**

Liczba warstw ukrytych	Odchylenie standardowe
1	0,077
2	0,049
3	0,035
4	0,007

Należy zauważyć, iż odchylenie standardowe maleje wraz ze wzrostem warstw ukrytych. Można więc przypuszczać, iż znaczenie doboru funkcji aktywacji nie będzie miało znaczenia dla sieci neuronowych z większą niż 4 liczbą warstw ukrytych.

## 6.5 Podsumowanie rozdziału – wnioski

Porównanie algorytmów różnych grup zaprezentowane w rozdziale trzecim niniejszej rozprawy dowodzi, iż przekształcenia falkowe są skutecznym narzędziem analizy sygnałów elektrokardiograficznych, zaś sieci neuronowe ich dobrym klasyfikatorem.

Przeprowadzone badania wskazują, że zgromadzona baza sygnałów jest niewystarczająca, aby zdecydowanie stwierdzić, iż dokładność sieci trzywarstwowej o 30 (40) neuronach, dla której uzyskano średnio najlepszą dokładność klasyfikującą QRS endogenne, można byłoby uznać za optymalną. Różnice w otrzymanych wynikach dla poszczególnych struktur sieci neuronowych są bardzo niewielkie i jedynie zwracają uwagę na pewne prawidłowości. Mają bardziej znaczenie poznawcze niż kliniczne.

Na tle metod informatycznych stosowanych w diagnostyce kardiologicznej (podanych w rozdziale drugim i trzecim), wydaje się, iż sieci falkowo – neuronowe wypadają korzystnie. Dokładne porównanie uzyskanych wyników nie jest w pełni precyzyjne, gdyż w literaturze przedmiotu, według wiedzy autorki rozprawy, mamy do czynienia z brakiem badań dotyczących sygnałów elektrokardiograficznych – stymulatorowych. Zestawiając jednak wyniki niniejszego rozdziału z uzyskanymi w rozdziale III (patrz np. Tabela nr 3.3), można stwierdzić, iż choć w przypadku sygnałów stymulatorowych otrzymano niższą wartość miary czułości i wyższy błąd detekcyjny, to sygnały stymulatorowe zawierają znacznie większą ilość szumu niż sygnały pochodzące z bazy MIT-BIH. Jeżeli weźmiemy pod uwagę zdanie Augustyniaka, który w [18] podaje, iż dla sygnałów o wysokim poziomie szumu odsetek poprawnej detekcji nie powinien być mniejszy niż 92%, to uzyskany wynik średniej wartości  $R=97,23\%$ , w przypadku sygnałów EKG – stymulatorowych, można uznać za dobry. Z tego względu należy również stwierdzić, że wyniki SE i BD są porównywalne do proponowanych w literaturze metod sprawdzających swoje

działanie na podstawie ogólnodostępnych internetowych baz sygnałów EKG (np. bazy MIT-BIH). Zestawiając wyniki niniejszego rozdziału z otrzymanymi w rozdziale IV (patrz np. Rys. 4.20 oraz Rys. 4.21) należy uznać zdecydowaną wyższość sieci falkowo – neuronowych nad algorytmami Friesena działającymi w dziedzinie czasu. Celem uargumentowania powyżej wysuniętych wniosków przygotowano Tabelę nr 6.10, zestawiającą otrzymane wyniki w III, IV oraz VI rozdziale niniejszej rozprawy.

**Tabela nr 6.10 Średnie wartości miar SE, BD, +P, R dla trzech grup algorytmów (T-dziedzina czasu, T-F dziedzina czasowo-częstotliwościowa, SN- sieci neuronowe) sygnałów pochodzących z bazy MIT-BIH w porównaniu do wyników uzyskanych przez zastosowane algorytmy Friesena oraz sieci falkowo-neuronowe dla sygnałów elektrokardiograficznych - stymulatorowych.**

Średnie miary detekcyjne	MIT-BIH				Sygnały EKG stymulatorowe	
	T	T-F	SN	WNN [77]	Friesen	Sieci falkowo – neuronowe
SE	98,60	99,48	99,53	98,99	82,72	97,12
BD	4,70	1,10	0,97	1,14	13,21	2,17
+P	96,67	99,51	99,42	99,12	80,86	96,98
R	91,66	97,76	97,86	97,62	79,98	95,77

Co do otrzymanych wyników detekcji zespołu QRS dla sygnałów EKG pochodzących z bazy MIT-BIH opublikowanych w pracy [77], rezultaty te wydają się być niższe, choć porównywalne do stosowanych w literaturze metod opierających się na przekształceniach falkowych czy też sieciach neuronowych. Wykorzystane zaś połączenie przekształceń falkowych z radialną siecią neuronową w pracy [78], dla sygnałów EKG pochodzących z bazy MIT-BIH oraz sygnałów EKG – stymulatorowych, nie polepszyło wykazanych wyżej wyników.

Wykorzystany system oparty o sieć falkowo – neuronową, stosowany do detekcji zespołu QRS i klasyfikacji rytmu endogennego dla sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca, wydaje się być zatem uzasadniony. Inwencja badacza jest praktycznie nieograniczona.

## Zakończenie

Istotą prowadzonych badań było zaproponowanie **algorytmu wykrywającego zespół QRS z jednoczesną klasyfikacją rytmu endogennego w sygnałach elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca.**

Chronologia rozdziałów niniejszej rozprawy odpowiada wykonywanym pracom badawczym. Rozdział I ma charakter wprowadzający w tematykę rozprawy i podkreśla jej interdyscyplinarność. Analiza poglądów spotykanych w literaturze, wyodrębniająca trzy grupy metod detekcyjnych zespołu QRS, wydaje się mało wnikliwa, dlatego też w rozdziale II podsumowano aktualny stan wiedzy z wyselekcjonowaniem pięciu grup algorytmów (algorytmów działających w dziedzinie czasu, dziedzinie częstotliwościowej, dziedzinie czasowo – częstotliwościowej, opartych na sztucznej inteligencji oraz innych rozwiązaniach algorytmicznych).

Wykonywane badania prowadzono w kilku etapach, które koncentrowały się odpowiednio na:

- dokonaniu analizy i porównaniu wybranych algorytmów dla sygnałów elektrokardiograficznych pochodzących z bazy MIT – BIH (Rozdział III niniejszej rozprawy). Należy podkreślić, iż w literaturze przedmiotu brak jest kompleksowego opracowania przeprowadzającego taką analizę;
- dokonaniu oceny działania algorytmów Friesena dla sygnałów elektrokardiograficznych – stymulatorowych, (Rozdział IV niniejszej rozprawy);
- opracowaniu, w sposób analityczny oraz praktyczny, algorytmu detekcji zespołu QRS i klasyfikacji rytmu endogennego dla sygnałów elektrokardiograficznych – stymulatorowych. Rozważania dotyczące proponowanej metody sieci falkowo – neuronowej są zawarte w rozdziale V niniejszej rozprawy. Wyniki prac badawczych odnoszące się do jej skuteczności i efektywności podano w rozdziale VI.



Należy podkreślić, iż ocenę wyników powyżej wymienionych etapów prac badawczych przeprowadzono na podstawie omówionych w rozdziale III miar. Eksperymenty zaś wykonywano dla zgromadzonych 150 przebiegów stymulatorowych z różnymi „zakłóceniami” i niejednorodnościami, wpływającymi niekorzystnie na wykrycie zespołu QRS. Charakterystyka zgromadzonych i wykorzystanych sygnałów została opisana w rozdziale IV.

Przeprowadzone badania pozwalają na sformułowanie następujących wniosków:

- 1. Metody detekcji oparte na sieciach neuronowych oraz przekształceniach falkowych mogą być użyte z dobrym skutkiem jako algorytmy detekcji zespołu QRS w sygnałach elektrokardiograficznych pochodzących z bazy MIT-BIH.**

Powyższy wniosek wykazano w rozdziale III niniejszej rozprawy.

- 2. Algorytmy Friesena działające w dziedzinie czasu, jako detektory zespołu QRS zastosowane do sygnałów elektrokardiograficznych – stymulatorowych, generują dużą liczbę detekcji fałszywie pozytywnej oraz detekcji fałszywie negatywnej.**

Powyższy wniosek wykazano w rozdziale IV niniejszej rozprawy.

- 3. Algorytmy Friesena działające w dziedzinie czasu, jako detektory zespołu QRS, uzyskują niską ocenę działania w przypadku sygnałów elektrokardiograficznych – stymulatorowych, prowadzą do dużego błędu detekcyjnego oraz niskiej czułości detekcyjnej.**

Powyższy wniosek wykazano w rozdziale IV niniejszej rozprawy.

- 4. Algorytmy Friesena nie powinny być stosowane w rzeczywistych systemach analizy sygnałów elektrokardiograficznych – stymulatorowych.**

Powyższy wniosek wykazano w rozdziale IV niniejszej rozprawy (na podstawie wniosków 2 i 3).

5. **W przypadku proponowanej metody sieci falkowo–neuronowej, dla sygnałów elektrokardiograficznych – stymulatorowych, zgromadzonych na potrzeby realizacji niniejszej rozprawy, za prawidłowy należy uznać czwarty poziom dekompozycji sygnału oraz próg detekcyjny 0,6.**

Powyższy wniosek wykazano w rozdziale VI niniejszej rozprawy.

6. **W przypadku proponowanej metody sieci falkowo–neuronowej, dla sygnałów elektrokardiograficznych – stymulatorowych, zgromadzonych na potrzeby realizacji niniejszej rozprawy, najlepszą czułość i zarazem najmniejszy błąd detekcyjny, uzyskano dla rodziny falek biortogonalnych.**

Powyższy wniosek udowodniono w rozdziale VI niniejszej rozprawy.

7. **W świetle proponowanej metody sieci falkowo–neuronowej, dla sygnałów elektrokardiograficznych – stymulatorowych zgromadzonych na potrzeby realizacji niniejszej rozprawy, uzasadniony wydaje się podział zbioru danych sieci neuronowej metodą krzyżową.**

Powyższy wniosek udowodniono w rozdziale VI niniejszej rozprawy.

8. **W świetle proponowanej metody sieci falkowo–neuronowej, dla sygnałów elektrokardiograficznych – stymulatorowych zgromadzonych na potrzeby realizacji niniejszej rozprawy, korzystne jest wykorzystanie liczby 30 neuronów w warstwach ukrytych.** Wskazana powyżej liczba, będąca środkową wartością rozpatrywanego wektora *nu* wszystkich wykorzystanych neuronów ukrytych, nie potwierdza funkcjonującego w literaturze przedmiotu poglądu o lepszej zdolności uogólniania sieci z mniejszą liczbą neuronów. Powyższy wniosek udowodniono w rozdziale VI niniejszej rozprawy.

## **Konfirmacja tezy pracy**

Na podstawie podanych powyżej wniosków należy stwierdzić, iż możliwa jest detekcja zespołu QRS i klasyfikacja rytmu endogenego w sygnałach elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym pracę serca, przy wykorzystaniu sieci falkowo – neuronowej. Wyniki zaprezentowane w rozdziale VI są porównywalne, w sensie dokładności rozpoznawania i klasyfikacji, z zamieszczonymi w rozdziale III wynikami analizującymi metody detekcji zespołu QRS dla sygnałów elektrokardiograficznych pochodzących z bazy MIT-BIH. Uzyskana na przykład miara czułości dla WNN=97,12%, w przypadku sygnałów EKG – stymulatorowych, jest niższa od otrzymanej czułości w przypadku metod opierających się na przekształceniach falkowych (99,48%) czy też sieciach neuronowych (99,53%) tylko o 2,36% w stosunku do WT, a o 2,41% dla SN. Podkreślić należy jednak fakt dużo wyższego zaszumienia sygnału EKG – stymulatorowego, niż ma to miejsce w przypadku sygnałów EKG pochodzących z bazy MIT-BIH. Wyniki przedstawione w rozdziale VI niniejszej rozprawy są zaś lepsze, w kontekście dokładności rozpoznawania i klasyfikacji, od zamieszczonych w rozdziale IV wyników detekcji zespołu QRS algorytmów Friesena dla sygnałów elektrokardiograficznych – stymulatorowych. Porównanie wyników prezentowanych w rozdziale III, IV, oraz VI zamieszczono w podsumowaniu rozdziału VI (patrz np. Tabela nr 6.10). **Główna teza rozprawy została udowodniona.**

Na podstawie wniosków podanych powyżej można stwierdzić, iż algorytmy Friesena działające w dziedzinie czasu, generują dużą liczbę detekcji fałszywie pozytywnej oraz fałszywie negatywnej, w przypadku sygnałów elektrokardiograficznych pochodzących od pacjentów z wszczepionym układem stymulującym. Uzyskana miara czułości wynosząca 82,78% oraz wysoki błąd detekcyjny o wartości 13,21%, zdecydowanie potwierdzają i jednocześnie udowadniają drugą tezę niniejszej rozprawy. Dla sygnałów elektrokardiograficznych zawierających wysoki poziom szumu, odsetek poprawnej detekcji nie powinien być mniejszy niż 92%. Natomiast w przypadku

algorytmów Friesena uzyskano jedynie 79,98%. **Pomocnicza teza rozprawy została udowodniona.**

Należy podkreślić, że wprowadzone ograniczenia prac badawczych, wymienione we wstępie do niniejszej rozprawy, mogą mieć wpływ na wyniki detekcji zespołu QRS. Analiza tego wpływu wymagałaby jednak przeprowadzenia znacznie szerszych badań. Proponowana metoda detekcji ma charakter poznawczy i może być wykorzystana w przyszłości jako element wprowadzający rozbudowanego systemu oceny działania pracy stymulatorów.

Oryginalnymi osiągnięciami niniejszej rozprawy są:

1. Krytyczna analiza komparatystyczna metod detekcji i klasyfikacji sygnałów EKG w warunkach normalnych, ze szczególnym uwzględnieniem algorytmu falkowo – neuronowego.
2. Zbadanie algorytmów Friesena w aspekcie ich efektywności wobec sygnałów elektrokardiograficznych – stymulatorowych.
3. Opracowanie i implementacja algorytmu wykorzystującego sieć falkowo – neuronową do sygnałów elektrokardiograficznych – stymulatorowych.
4. Przetestowanie algorytmu opartego na sieci falkowo – neuronowej z wykorzystaniem rzeczywistych przebiegów EKG – stymulatorowych.
5. Optymalizacja opracowanego algorytmu w aspekcie dopasowania odpowiedniej struktury sieci falkowo – neuronowej.

## Literatura

- [1] ACC/AHA Guidelines for ambulatory electrocardiography: Executive summary and recommendations. A report of American College of Cardiology/ American Heart Association Task Force on Practice Guidelines (Committee to Revise the Guidelines for Ambulatory Electrocardiography) Development in collaboration with the North American Society for Pacing and Electrophysiology, *Circulation* 1999, No. 100, pp. 886 – 893.
- [2] Acharya R., Kumar A., Bhat P.S., Lim C.M., Iyengar S.S., Kannathal N., Krishnan S.M., Classification of cardiac abnormalities using heart rate signals, *Medical and Biology Engineering and Computing*, Vol. 42, 2004, pp. 288 – 293.
- [3] Acharya R., Bhat P.S., Iyengar S.S., Rao A., Dua S., Classification of heart rate data using artificial neural network and fuzzy equivalence relation, *Pattern Recognition*, Vol. 36, 2003, pp. 61 – 68.
- [4] Addison P.S., Watson J.N., Clegg G.R., Holzer M., Sterz F., Robertson C.E., Evaluating arrhythmias in ECG signals using wavelet transforms, *IEEE Engineering in Medicine and Biology*, Vol. 19, No. 5, September – October 2000, pp. 104 – 109.
- [5] Addison P.S., *The illustrated wavelet transform handbook. Introductory theory and applications in science, engineering, medicine and finance*, Institute of Physics Publishing, Bristol and Philadelphia 2002.
- [6] Addison P.S., *Wavelet transforms and the ECG: A review*, Institute of Physics Publishing *Physiological Measurement*, *Physiological Measurement*, Vol. 26, 2005, R155 – R199.
- [7] Afonso V. X., Tompkins W. J., ECG Beat Detection Using Filter Banks, *IEEE Transaction Biomedical Engineering*, Vol. 46, No. 2, 1999, pp. 192 – 202.
- [8] Afonso V.X., Tompkins W.J., Nquyen T., Michler K., Luo S., Comparing stress ECG enhancement algorithms: With an introduction to a filter bank based approach, *IEEE Engineering in Medicine and Biology Magazine*, May – June 1996, Vol. 15, Issue 3, pp. 37 – 44.
- [9] Agante P.W., de Sa J.P., ECG noise filtering using wavelets with softthresholding methods, *Computer in Cardiology*, Vol. 26, 1999, pp. 535 – 538.
- [10] Ahlstrom M.I., Tompkins W.J., Automated high-speed analysis of holter tapes with microcomputers, *IEEE Transaction BioMedical Engineering*, Vol. 30, October 1983, pp. 651-657.
- [11] Akazawa K., Motoda K., Sasamori A., Ishizawa T., Harasawa E., Adaptive threshold QRS detection algorithm for ambulatory ECG, *Computers in Cardiology*, 23-26 September 1991, pp. 445 – 448.
- [12] Akhtar M., Williams S., Achord J., Reynolds W., Fisch Ch., Friesinger G., Klocke F., Ryan T., Schlant R., Clinical competence in invasive cardiac electrophysiological studies, *Circulation* 1994, Vol. 84, pp. 1917 – 1920.
- [13] Albanesi M.G., Ferretti M., Giancane A., Time-frequency decomposition for analysis and retrieval of 1-D signals, *IEEE International Conference on Multimedia Computing and Systems*, 1999, Vol. 2, pp. 974 – 978.

- [14] Aleksandrow D., Wyszacka - Aleksandrow W., Czaplicki S., Diagnostyka elektrokardiograficzna, Wyd. 5, Państwowy Zakład Wydawnictw Lekarskich, Warszawa 1983.
- [15] Al-Fahour A.S., Howitt I., Combine wavelet transform and radial basic neural networks for classifying life – threatening cardiac arrhythmias, Medical and Biological Engineering Computational, Vol. 37, 1999, pp. 566 – 573.
- [16] Almenar V., Albion A., A new adaptive scheme for ECG enhancement, Signal Processing, 1999, Vol. 75, Issue 3, pp. 253 – 263.
- [17] Anand R.S., Kumar V., Efficient and reliable detection of QRS-segment in ECG signals, Engineering in Medicine and Biology Society, 14th Conference of the Biomedical Engineering Society of India. An International Meeting, Proceedings of the First Regional Conference, 15-18 February 1995, pp. 2/56 - 2/57.
- [18] Augustyniak P., Przetwarzanie sygnałów elektrodiagnostycznych, AGH Uczelniane Wydawnictwo Naukowo – Dydaktyczne, Kraków 2001.
- [19] Augustyniak P., Transformacje falkowe w zastosowaniach elektrodiagnostycznych, AGH Uczelniane Wydawnictwa Naukowo – Dydaktyczne, Kraków 2003.
- [20] Augustyniak P., Adaptacyjna dyskretna reprezentacja elektrokardiogramu, Rozprawy Monografie, Uczelniane Wydawnictwo Naukowo – Dydaktyczne AGH, Kraków 2003.
- [21] Augustyniak P., Wrześniowski A., Adaptive Channels Weighting for the QRS Detection in Long-Term Electrocardiograms [w:] Materiały VI International Conference SYMBIOSIS 2001, Szczyrk 11-13.09.2001, str. 27-32.
- [22] Augustyniak P., [www.agh.edu.pl/~august](http://www.agh.edu.pl/~august)
- [23] Bahoura M., Hassani M., Hubin M., DSP implementation of wavelet transform for real time ECG wave forms detection and heart rate analysis, Computers Methods and Programs in Biomedicine, No. 52, 1999, pp. 35 – 44.
- [24] Baig M.H., Rasool A., Bhatti M.I., Classification of electrocardiogram using SOM, LVQ and beat detection methods in localization of cardiac arrhythmias, Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Vol. 2, 25-28 October 2001, pp. 1684 – 1687
- [25] Bargieł D., Implementacja algorytmu genetycznego w C++, [w:] Software 2.0, Nr 2 (86), 2002, pp. 40 – 45.
- [26] Baxt W.G., The role of the artificial neural network the charakterisation of complex systems and the prediction of disease, [in:] Artificial Neural Networks in Biomedicine, Lisboa P.J.G., Ifeachor C., Szczepaniak P.S. (Eds.), Springer – Verlag London Berlin Heidelberg, 2000, Chapter 2, pp. 25 – 38.
- [27] Baxt W.G., Use of artificial neural network for the diagnosis of myocardial infarction, Annals of Internal Medicine, Vol. 115, 1991, pp. 843 – 848.
- [28] Beauchamp K.G., Przetwarzanie sygnałów metodami analogowymi i cyfrowymi, Wydawnictwo Naukowo - Techniczne, Warszawa 1978.

- [29] Benitez D.S, Gaydeckia P.A., Zaidib A., Fitzpatrick A.P., The use of the Hilbert transform in ECG signal analysis, *Computers in Biology and Medicine*, Vol. 31, 2001, pp. 399 – 406.
- [30] Benitez D.S., Gaydecki P.A., Zaidi A., Fitzpatrick, A.P., A new QRS detection algorithm based on the Hilbert transform, *Computers in Cardiology* 2000, pp. 379 - 382
- [31] Białasiewicz J.T., *Falki i aproksymacje*, WNT, Warszawa 2000.
- [32] Bieniaszewski L., *Cyfrowe przetwarzanie sygnałów [w:] Zmienność rytmu serca*, Piotrowicz R. (red.), Wydawnictwo Medyczne Via Medica, Gdańsk 1995.
- [33] Bishop C.M., *Neural networks for pattern recognition*. Oxford: Oxford University Press, 1995.
- [34] Bolton R.J., Westphal L.C., ECG display and QRS detection using the Hilbert Transform, *Computers in Cardiology*, IEEE Computer Society, Washington, DC, 1985, pp. 463 – 466.
- [35] Bolton R.J., Westphal L.C., On the use of the Hilbert Transform for ECG waveform processing, in: *Computers in Cardiology*, IEEE Computer Society, Silver Spring, MD, 1984, pp. 533 – 536.
- [36] Borna Ayad, *Optimisation du pretraitement des electrocardiogrammes algorithmes et methodes*, Diplome de Docteur – Ingenieur, France, Annee 1987.
- [37] Borodziewicz W., Jaszczak K., *Cyfrowe przetwarzanie sygnałów*, Wydawnictwa Naukowo - Techniczne, Warszawa 1987.
- [38] Boser B. E., Gyuon I. M., Vapnik V.N., A training algorithm for optimal margin classifier, *Fifth Annual Workshop on Computational Learning Theory*, Pittsburg 1993, pp. 144 – 152.
- [39] Boston, J.R., Akyol, G., Using an uncertainty measure in a fuzzy QRS detector, *Engineering in Medicine and Biology*, 21st Annual Conf. and the 1999 Annual Fall Meeting of the Biomedical Engineering Soc., BMES/EMBS Conference, 1999. *Proceedings of the First Joint Vol. 2*, 13 – 16 October 1999, pp. 916.
- [40] Box G.E.P., Jenkins G.M., *Analiza szeregów czasowych – prognozowanie i sterowanie*, Państwowe Wydawnictwo Naukowe, Warszawa 1983.
- [41] Bracewell R. N., *Przekształcenie Fouriera i jego zastosowania*, Warszawa 1968.
- [42] Buchner T., Cytowski J., Kępski R., *Filtracja adaptacyjna w dynamicznym sygnale EKG o wysokiej rozdzielczości*, Prace IPI PAN, Warszawa 1998, 859, str. 5 – 40.
- [43] Carrault G., Cordier M.-O., Quiniou R., Wang F., Temporal abstraction and inductive logic programming for arrhythmia recognition from electrocardiograms, *Artificial Intelligence in Medicine*, Vol. 28, 2003, pp. 231–263.
- [44] Castellano G., Fanelli A. M., Fuzzy Inference and Rule Extraction Using A Neural Network, *Neural Networks World Journal*, Vol. 3, July 2000, pp. 361 – 371.
- [45] Castellano G., Fanelli A. M., A Self-Organizing Neural Fuzzy Inference Network, [In:] *Proceeding of IEEE International Join Conference on Neural Networks (IJCNN2000)*, Vol. 5, Como Italy 2000, pp. 14 – 19.
- [46] Celler B.G., de Chazal P., Low computational cost classifiers for ECG diagnosis using neural networks, [in:] *Proceedings Annual International*

- Cong. IEEE Engineering in Medicine and Biology Society, 1998, pp. 1337 – 1340.
- [47] Chang Ch.-L., Lin K.-P., Tao T.-H., Kao T., Chang W.H., Validation of automated arrhythmia detection for Holter ECG, Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE 29 October-1 November 1998, pp. 101 – 103.
- [48] Chang W. H., Lin K. P., Tseng S. Y., ECG analysis based on Hilbert transform descriptor, IEEE Engineering Medical and Biology Society, 10th Annual International Conference, 1988, pp. 36-37.
- [49] de Chazal P., Reilly R.B., A Comparison of the Use of Different Wavelet Coefficients for the Classification of the Electrocardiogram, Proceedings of the 14th International Conference on Pattern Recognition, September 2000.
- [50] Christov I.I., Real time electrocardiogram QRS detection using combined adaptive threshold, BioMedical Engineering OnLine 2004, pp. 3 – 28.
- [51] Chui C.K., An introduction to wavelets; Wavelets – a tutorial in theory and applications, Academic Press, San Diego 1992.
- [52] Coast D.A., Segmentation of high-resolution ECGs using hidden Markov models, Acoustics, Speech, and Signal Processing, 1993. ICASSP-93, 1993 IEEE International Conference on Vol. 1, 27-30 April 1993, pp. 67 – 70.
- [53] Cohen, K.P., Tompkins, W.J., Djohan, A., Webster, J.G., Hu, Y.H., QRS detection using a fuzzy neural network, Engineering in Medicine and Biology Society, IEEE 17th Annual Conference 1995, Vol. 1, 20-23 September 1995, pp. 189 – 190.
- [54] Compton A.J., Bolouri H., Nathan A.W., Arrhythmia recognition strategies and hardware decision for the implantable cardioverter-defibrillator – a review, Medical Engineering Physics, Vol. 17, No. 2, 1995, pp. 96 – 105
- [55] Cost A.A., Cano G.G., QRS detection based on hidden Markov modeling, Engineering in Medicine and Biology Society, 1989. Images of the Twenty-First Century. Proceedings of the Annual International Conference of the IEEE Engineering in 9-12 November 1989, pp. 34 - 35
- [56] Couderc J.-P., Fareh S., Chevalier P., Fayn J., Kirkorian G., Rubel P., Touboul P., Stratification of time–frequency abnormalities in the signal averaged high-resolution ECG in postinfarction patients with and without ventricular tachycardia and congenital long QT syndrome, Journal of Electrocardiology, Vol. 29, Supplement, 1996, pp. 180 – 188
- [57] Couderc J.-P., Chevalier P., Fayn J., Rubel P., Touboul P., Identification of post-myocardial infarction patients prone to ventricular tachycardia using time–frequency analysis of QRS and ST segments, Europace (2000), Vol. 2, pp. 141–153.
- [58] Craig M., Ewers G., Zarys cyfrowego przetwarzania sygnałów, Wydawnictwo Komunikacji i Łączności, Warszawa 1999.
- [59] Cristianini N., Shaw-Taylor J., Support Vector and Kernel Method, [in:] Intelligent Data Analysis. An introduction, Berthold M., Hand D.J. (Eds.), Springer – Verlag, Berlin 2003.
- [60] Cytowski J., Metody i algorytmy sztucznej inteligencji w cyfrowym przetwarzaniu sygnałów, Akademicka Oficyna Wydawnicza PLJ, 1999.



- [61] Czogała E., Łęski J., Entropy and energy measures of fuzziness in ECG signal processing, [in:] Fuzzy systems in medicine, Szczepaniak P.S., Lisboa P.J.G., Tsumoto S. (Eds.), Heidelberg: Springer, 2000, pp. 227 – 245.
- [62] Dąbrowska B., Dąbrowski A., Elektrokardiografia holterowska, Oxford – Polska, Wydawnictwo Medyczne, Warszawa 1994.
- [63] Dąbrowska B., Dąbrowski A., Podręcznik elektrokardiografii, PZWL Warszawa 1993.
- [64] Daskalov I.K., Christov I.I., Electrocardiogram signal preprocessing for automatic detection of QRS boundaries, Medical Engineering and Physics, Vol. 21, 1999, pp. 37 – 44.
- [65] Dassen W.R., Seft-learning neural networks in electrocardiography, Journal of Electrocardiology, No. 23, Supplement, 1990, pp. 200 – 202.
- [66] Daubechies I., Ten lectures on wavelet, SIAM, Philadelphia, 1992.
- [67] Daubechies I., The wavelet transform, time-frequency localizations and signal analysis, IEEE Transaction on Information Theory, Vol. 35, No. 5, 1990, pp. 961-1005.
- [68] Delgado F.M., Ameneiro S.B., MART: A multichannel ART-based neural network, IEEE Transaction on Neural Networks, Vol. 9, 1988, pp. 139-150.
- [69] Dinh H.A.N., Kumar D.K., Pah N.D., Burton P., Wavelets for QRS detection, Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE Vol. 2, 25-28 October 2001, pp. 1883 – 1887.
- [70] Doering A., Galicki M., Witte H., Structure optimization of neural networks with the A\* - algorithm, IEEE Transaction on Neural Networks, 1997, Vol. 8, No. 6, pp. 1434 – 1445.
- [71] Dokur Z., Ölmez T., ECG beat classification by a novel hybrid neural network, Computer Methods and Programs in Biomedicine, Vol. 6, 2001, pp. 167 – 181.
- [72] Dokur Z., Ölmez T., Yazgan E., Comparison of discrete wavelet and Fourier transforms for ECG beat classification, Electronics Letters, Vol. 35, Issue 18, 2 September 1999, pp. 1502 – 1504.
- [73] Dokur Z., Ölmez T., Yazgan E., Ersoy O.E., Detection of ECG waveforms by neural networks, Medical Engineering Physics, Vol. 19, No 8, 1997, pp. 738 – 741.
- [74] Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R., Biocybernetyka i inżynieria biomedyczna, Tom 6, Sieci neuronowe, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
- [75] Dunajski Z., Biomagnetyzm, Wydawnictwo Komunikacji i Łączności, Warszawa 1990.
- [76] Duraj A., Krawczyk A., Koźluk E., Kumor M., Sadowiski J., The application of Wavelet Transforms to Detection and Identification of QRS, Folia Cardiologica, tom 12, Supplement D, 2005, pp. 390 – 393.
- [77] Duraj A., Krawczyk A., Zastosowanie sieci falkowo – neuronowej do detekcji zespołu QRS, Materiały XIV Krajowej Konferencji Naukowej Biocybernetyka i Inżynieria Biomedyczna, Tom II, 2005, str. 947 – 953.

- [78] Duraj A., Krawczyk A., Kumor M., Detekcja zespołu QRS przy zastosowaniu sieci falkowo – neuronowych, *Przegląd Elektrotechniczny*, nr 12, 2005, str. 98 - 100.
- [79] Einthoven W., The string galvanometer and the measurement of the action currents of the heart, Nobel Lecture, December 11, 1925.
- [80] Engin M., ECG beat classification using neuro-fuzzy network, *Pattern Recognition Letters*, Vol. 25, 2004, pp. 1715–1722.
- [81] Feliks J., Elektryczna, magnetyczna i mechaniczna aktywność serca. Metody badawcze. [w:] ... frag od prof. AK
- [82] Ferdi Y., Herbeuval J.P., Charef A., Boucheham B., R wave detection using fractional digital differentiation, *ITBM-RBM (RBM)*, Vol. 24, No.5, December 2003, pp. 273-280.
- [83] Foo S.Y., Stuart G., Harvey B., Meyer-Baese A., Neural network-based EKG pattern recognition, *Engineering Applications of Artificial Intelligence*, Vol. 15, 2002, pp. 253 – 260.
- [84] Friesen G.M., Jannett T.C., Djadallah M.A., Yates S.L., Quint S.R., Nagle H.T, A comparison of the noise sensitivity of nine QRS detection algorithms, *IEEE Transaction on Biomedical Engineering*, Vol. 37, No. 1, January 1990, pp. 85-98.
- [85] Froelicher V., *Podręcznik testów wysiłkowych*, Belcorp, Warszawa 1999.
- [86] Gacek A., Pedrycz W., A Genetic segmentation of ECG signals, *IEEE Transaction on Biomedical Engineering*, Vol. 50, No. 10, October 2003, pp. 1203 – 1208.
- [87] Gałęcka J., Prochaczek F., Gacek A., Kargul W., Wojciechowski D., Diagnostyczna i terapeutyczna elektrostymulacja oraz defibrylacja serca [w:] *Biocybernetyka i inżynieria biomedyczna 2000*, Tom 2, Rozdział 20, *Biopomiary*, (red.) Nałęcz Maciej, EXIT 2000, str. 403 – 441.
- [88] Geddes I.A., Historical highlights in cardiac pacing, *IEEE Engineering in Medicine and Biology*, 1990, June, pp. 12 – 18.
- [89] Glisson T.H., *Introduction to system analysis*, McGraw – Hill Book, New York 1985.
- [90] Goldberger D., *Algorytmy genetyczne i ich zastosowania*, WNT, Warszawa 1996.
- [91] Górczyńska K., Darowski M., Pałko T., Wojciechowski D., Pęczalski K., Sionek P., Kowalewski M., Religa G., Wspomaganie układu krążenia w sposób mechaniczny [w:] Nałęcz M. (red.), *Biocybernetyka i inżynieria biomedyczna*, Tom 3, *Sztuczne narządy*, WNT, Warszawa 2000, str. 76 – 97.
- [92] Grauel A., Fuzzy logic system for ECG interpretation, [in:] *Fuzzy system in medicine*, (Eds.) Szczepaniak P., Physica – Verlag 2004, pp. 246 – 260.
- [93] Gregoratos G., Cheitlin M.D., Conill A., Epstein A.E., Fellows Ch., Ferguson T.B., Freedman R.A., Hlatky M.A., Naccarelli G.V., Saksena S., Schlant R.C., Silka M.J., ACC/AHA Guidelines for implantation of cardiac pacemakers and antiarrhythmia devices: executive summary, *Circulation*, 1998, No. 97, pp. 1325 – 1335.
- [94] Grossman A., Morlet J., Decomposition of Hardy function into square integrable wavelets of constant shape, *SIAM Journal on Mathematical Analysis*, 1984, No. 15, pp.723 – 736.

- [95] Grzymkowski R., Zielonka A., Zastosowanie teorii falek w zagadnieniach brzegowych. Wykład z modelowania matematycznego, Wydawnictwo Pracowni Komputerowej Jacka Skalmierskiego, Gliwice 2004.
- [96] Guć M., System akwizycji i przetwarzania sygnałów [w:] Informatyka medyczna, Rudowski R. (red.), PWN, Warszawa 2003, str. 49 – 74.
- [97] Hagen M.T., Menhaj M.B., Training feedforward networks with the Marquardt algorithm, *IEEE Transaction on Neural Networks*, Vol. 5, 1994, pp. 989 – 993.
- [98] Ham F.M., Soowhan H., Classification of cardiac arrhythmias using fuzzy ARTMAP, *IEEE Transactions on Biomedical Engineering*, Vol. 43, Issue 4, April 1996, pp. 425 – 429.
- [99] Hamilton P.S., Tompkins W.J., Quantitative Investigation of QRS detection rules using the MIT/BIH Arrhythmia database, *IEEE Transaction on Biomedical Engineering*, Vol. BME-33, No. 12, December 1986, pp. 1157 - 1165.
- [100] Hamilton, P.S., Tompkins, W.J., Adaptive matched filtering for QRS detection, *Engineering in Medicine and Biology Society*, 1988. Proceedings of the Annual International Conference of the IEEE 4-7 November 1988, pp. 147 – 148.
- [101] Haraldsson H., Edenbrandt L., Ohlsson M., Detecting acute myocardial infarction in the 12-lead ECG using Hermite expansions and neural networks, *Artificial Intelligence in Medicine*, Vol. 32, 2004, pp. 127—136.
- [102] Harrison R.F., Marshall S.J., Kennedy R.L., The early diagnosis of heart attacks: A neurocomputational approach, *Proceedings of the International Joint Conference on Neural Networks*, Seattle, Vol. 1, 1991, pp. 1 – 5.
- [103] Hasiewicz Z., Śliwiński P., Falki ortogonalne o zwartym nośniku. Zastosowanie do nieparametrycznej identyfikacji systemów, *Akademicka Oficyna Wydawnicza EXIT*, Warszawa 2005.
- [104] Hassani M., Fachrudin I., Hubin M., Pattern recognition of ECG waves forms using wavelet transform: experimental results in the sudden infant death syndrome monitoring, *MPBE 94 Conference 2*, 1994, pp. 212 – 216.
- [105] Hernández A.I, Carrault G, Mora F, Thoraval L, Passariello G, Schleich JM., Multisensor fusion for atrial and ventricular activity detection in coronary care monitoring, *IEEE Transaction on Biomedical Engineering*, Vol. 46, 1999, pp. 1186 – 1190.
- [106] Hernández A.I., Carrault G., Mora F., Bardou A., Model-based interpretation of cardiac beats by evolutionary algorithms: signal and model interaction, *Artificial Intelligence in Medicine*, Vol. 26, 2002, pp. 211 – 235.
- [107] Hertz J., Krogh A., Palmer R., *Wstęp do teorii obliczeń neuronowych*, WNT, Warszawa 1995.
- [108] Hsiung, H.-S.H., Cheng, C.-K., Jan, G.-J., A real-time QRS detection and delineation algorithm based on the inflection angle of the ECG waveform, *Engineering in Medicine and Biology Society*, 1989. Images of the Twenty-First Century. Proceedings of the Annual International Conference of the IEEE Engineering in 9-12 November 1989, pp. 138 – 139
- [109] Hu Y. H., Palreddy S., Tompkins W. J., A patient-adaptable ECG beat classifier using a mixture of experts approach, *IEEE Transaction on Biomedical Engineering*, Vol. 44, September 1997, pp. 891–900.

- [110] Hu Y.H., Tompkins W.J., Urrusti J.L., Afonso V.X., Application of Artificial Neural Networks for ECG signal detection and classification, *Journal of Electrocardiology*, Vol. 26, Supplement, 1993, pp. 66 - 73.
- [111] Huck M.P., Leder U., Haueisen J., Pohl H.P., Nowak H., Muller S., Comparison of Simson-method and Daubechies wavelet method in the detection of late fields, *Engineering in Medicine and Biology Society, 1996. Bridging Disciplines for Biomedicine. Proceedings of the 18th Annual International Conference of the IEEE* Vol. 5, 31 October – 3 November 1996, pp. 2295 – 2296.
- [112] Hunter J, Kirby I, Gotts N., Using quantitative and qualitative constraints in models of cardiac electrophysiology, *Artificial Intelligence in Medicine*, Vol. 3, 1991, pp. 41–61.
- [113] Istepanian R.S.H., Hadjileontiadis L.J., Panas S.M., ECG data compression using wavelet and higher order statistic methods, *IEEE Transactions on Information Technology in Biomedicine*, Vol. 5, No. 2, June 2001, pp. 108 – 115.
- [114] Itchaporla D., Artificial neural networks: current status in cardiovascular medicine, *Journal of the American College of Cardiology*, August 1996, Vol. 28, No. 2, pp. 515 – 521.
- [115] Ivaylo I.Ch., Real time electrocardiogram QRS detection using combined adaptive threshold, *BioMedical Engineering OnLine*, 2004, pp. 3 – 28.
- [116] Izydorczyk J., Płonka G., Tyma G., *Teoria sygnałów. Wstęp.*, Helion 1999.
- [117] Jankowski N., *Ontogeniczne sieci neuronowe. O sieciach zmieniających swoją strukturę*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2003.
- [118] Jankowski S., Oreziak A., Learning system for computer-aided ECG analysis based on support vector machines, *International Journal of Bioelectromagnetism*, 2003, Vol. 5, No. 1, pp. 175 – 177
- [119] Jankowski S., Tijink J., Vumbaca G., Balsi M., Karpiński G., Support Vector Machine for the recognition of atrial and ventricular depolarization in Holter ECG recording, *International Journal of Bioelectromagnetism*, Vol. 4, No. 2, 2002, pp. 343 - 344.
- [120] Jeongwhan Lee, Keesam Jeong, Jiyoung Yoon, Myoungcho Lee, A simple real-time QRS detection algorithm, *Engineering in Medicine and Biology Society, 1996. Bridging Disciplines for Biomedicine. Proceedings of the 18th Annual International Conference of the IEEE* Vol. 4, 31 October-3 November 1996, pp. 1396 – 1398.
- [121] Jeżewski J., Horoba K., Wrobel J., Gacek A., Inconsistency in evaluation of clinical patterns in fetal heart rate waveforms, *Journal of Medical Informatics and Technologies*, Vol.4, 2002, pp. 27-35.
- [122] Jones N.B., Wang J.T., Sehmi A.S., de Bono D.P., Knowledge - based systems and neural networks for clinical decision making, *Control Engineering Practice*, Vol. 3, No. 7, 1995, pp. 967 - 975.
- [123] Kadambe S., Murray R., Boudreaux – Bartels G.F., Wavelet Transform - based QRS complex detector, *IEEE Transaction on Biomedical Engineering*, Vol. 46, No. 7, July 1999, pp. 838 - 848.
- [124] Karczmarewicz S., *Elementarne podstawy stałej elektrostymulacji serca*, *Kardiologia Polska* 2000, Nr 52, Str. 136 – 139.

- [125] Karlik B., The Effects of Fuzzy Clustering on The Back-Propagation Algorithm, Proceeding of Int. Conference on Computational and Applied Mathematics, 9-10 September, Kiev, Ukraine, 2002.
- [126] Karlik, B., Özbay, Y., A new approach for arrhythmia classification, Engineering in Medicine and Biology Society, 1996. Proceedings of the 18th Annual International Conference of the IEEE, Vol. 4, 31 October – 3 November 1996, pp. 1646 – 1647.
- [127] Kearns M., A bound of terror of cross – validation Rusing the approximation and estimation ratek, with consequences for the training – test split, Neural Computation, 1997, Vol. 9, pp. 1143 – 1161.
- [128] Kępski R., Buchner T., Cytowski J., Zastosowanie filtracji adaptacyjnej do EKG o wysokiej rozdzielczości, Prace Instytutu Podstaw Informatyki PAN, Warszawa 1995, Nr 787, str. 5 – 27.
- [129] Kępski R., Cytowski J., Her P.R, Buchner T., Wybrane procedury przetwarzania sygnałów elektrokardiograficznych [w:] Biocybernetyka i inżynieria biomedyczna 2000, Tom 2, Rozdział 19, Biopomiary, Nałęcz M. (red.), EXIT 2000, str. 377 – 402.
- [130] Kępski R., Cytowski J., Małecka L., Walczak F., Koźluk E., Szumowski Ł., Szufładowicz E., Masiak H., Buchner T, Her P., Rejestracja zmiennego dynamicznie elektrokardiogramu wysiłkowego, przy zastosowaniu filtracji adaptacyjnej, Polski Przegląd Kardiologiczny 2001, Nr 3 (2), str.109 – 117.
- [131] Kestler H.A., Hoher M., Palm G., Schwenker F., Kochs M., Hombach V., Time domain variability of high resolution beat-to-beat recordings classified by neural networks, Computers in Cardiology, 8-11 September 1996, pp. 317 – 320.
- [132] Kestler H.A., Hoher M., Schwenker F., Hombach V., Filtering beat-to-beat recordings of the high resolution electrocardiogram, Computers in Cardiology, 8-11 September 1996, pp. 461 - 464.
- [133] Kestler H.A., Muller A., Hombach V., Wohrle J., Grebe O., Palm G., Moher M., Schwenker F., Decision fusion of micro-variability and signal averaged ECG parameters from the QRS complex with RBF networks, Computers in Cardiology, 2002, 22-25 September 2002, pp. 297 - 300
- [134] Köhler B.-U., Henning C., Orglmeister R., The Principles of Software QRS Detection, IEEE Engineering in Medicine and Biology, Vol. 21, No. 1, pp. 42-54, 2002.
- [135] Kopczyński P., Algorytmy genetyczne – elementy składowe, [w:] Software 2.0, Nr 2 (74), 2001, pp. 32 – 38.
- [136] Korbicz J., Obuchowicz A., Uciski D., Sztuczne sieci neuronowe. Podstawy i zastosowania, Warszawa 1994
- [137] Koski A., Juhola M., Meriste M., Syntactic recognition of ECG signals by attributed finite automata, Pattern Recognition, Vol. 28, Issue 12, December 1995, pp. 1927 – 1940.
- [138] Koski A., Modelling ECG signals with hidden Markov models, Artificial Intelligence in Medicine, No. 8, 1996, pp. 453 – 471.
- [139] Kośmicki M., Elektrokardiograficzne próby wysiłkowe u pacjentów z chorobą niedokrwienną serca, Postępy Nauk Medycznych, Nr 1, 2002.

- [140] Kowalski H., Skorupski A., Wielokanałowa rejestracja sygnałów EKG, Materiały VIII Krajowej Konferencji Metrologii, Tom 2, 1995, str. 242 – 249.
- [141] Krawczyk A., Pławiak – Mowna A., Kardiostymulatory w polu elektromagnetycznym emitowanym przez telefony, Przegląd Elektrotechniczny, nr 78, 2002, str. 230 – 235.
- [142] Krawczyk A., Pławiak – Mowna A., Wpływ pola elektromagnetycznego na implanty kardiologiczne – dane literaturowe, [w:] Bioelektromagnetyzm, Krawczyk A. (red.), Instytut Naukowo – Badawczy ZTUREK Polskie Towarzystwo Zastosowań Elektromagnetyzmu, Warszawa 2002, str. 143 – 161.
- [143] Krul I., Wywiad miesiąca ze Zbigniewem Michalewiczem, Software 2.0, Nr 2, (86), 2002, pp. 56 – 57.
- [144] Kubacki R., Sobiech J., Zyss T., Pławiak – Mowna A., Krawczyk A., Zaburzenia pracy kardiointerferentów w polach impulsowych mikrofalowych stacji bazowych telefonii komórkowej, [w:] Elektromagnetyzm w medycynie i biologii, Kubacki R., Krawczyk A. (red.), Instytut Naukowo – Badawczy ZTUREK Polskie Towarzystwo Zastosowań Elektromagnetyzmu, Warszawa 2004, str. 31 – 38.
- [145] Kucharski A., Stymulacja dwuprzedsionkowa, Folia Cardiologica 2000, Tom 7, Nr 4, str. 281 - 295.
- [146] Kucharski A., Wskazania do stałej stymulacji serca u progu nowego tysiąclecia, Kardiologia Polska 2000, Nr 54, str. 140 – 141.
- [147] Kumor M., Baranowski R., Rydlewska – Sadowska W., Wpływ korzystania z telefonu komórkowego na zapis EKG rejestrowany metodą Holtera, Folia Cardiologica 2000, Tom 7, Nr 4, str. 321 – 326.
- [148] Kumor M., Ocena wartości klinicznej programów diagnostycznych stymulatorów serca, Rozprawa doktorska, Warszawa 2003.
- [149] Kunzmann U., von Wagner G., Schöchlin J., Bolz A., Parameter extraction of ECG signals in real – time, Biomedical Technology, No. 47, 2002, Supplement 1, Pt 2, pp. 875 – 878.
- [150] Kurzyński M., Rozpoznawanie obiektów: metody statystyczne, Wydawnictwo Politechniki Wrocławskiej, Wrocław 1997.
- [151] Kutarski A., Zastosowania stałej stymulacji serca u progu nowego tysiąclecia, Folia Cardiologica 1999, Tom 6, Nr 2, str. 148 – 155.
- [152] Kwiatkowski W., Wstęp do cyfrowego przetwarzania sygnałów, Wydawnictwo Wojskowej Akademii Technicznej, Warszawa 2003.
- [153] Laguna, P., Jané, R., Caminal, P., Adaptive feature extraction for QRS classification and ectopic beat detection, Computers in Cardiology 1991. Proceedings 23-26 September 1991, pp. 613 – 616.
- [154] Laguna, P., Vigo, D., Jané, R., Caminal, P., Automatic wave onset and offset determination in ECG signals: Validation with the CSE database, Computers in Cardiology 1992, 11 – 14 October 1992, pp. 167 – 170.
- [155] Laguna P., Jané R., Olmos S., Thakor N.V., Rix H., Kaminal P., Adaptive estimation of QRS complex wave features of ECG signal by the Hermite model, Medical and Biology Engineering and Computing, No. 34, 1996, pp. 58-68.
- [156] Leder U., Huck M.P., Haueisen J., Pohl H.P., Nowak H., Muller S., Detection of very high frequency magnetocardiographic signals within the

- QRS complex using discrete Daubechies wavelet transformation, Engineering in Medicine and Biology Society, 1996. Bridging Disciplines for Biomedicine. Proceedings of the 18th Annual International Conference of the IEEE Vol. 2, 31 Oct.-3 Nov. 1996, pp. 806 – 807.
- [157] Lewenstein K., Modele sztucznych sieci neuronowych do oceny testów wysiłkowych stosowanych w diagnostyce choroby wieńcowej, Oficyna Wydawnicza Politechniki Warszawskiej, Prace Naukowe, Elektronika, z. 140, Warszawa 2002.
- [158] Li C., Zheng C., Detection of ECG characteristic points using wavelet transforms, IEEE Transaction on Biomedical Engineering, Vol. 42, January 1995, pp. 21–28.
- [159] Lin K.-P., Chang W.H., A technique for automated arrhythmia detection of Holter ECG, Engineering in Medicine and Biology Society, 1995. IEEE 17th Annual Conference, Vol. 1, 20-23 September 1995, pp. 183 - 184.
- [160] Lin K.-P., Chang W.H., Classification of QRS pattern by an associative memory model, Engineering in Medicine and Biology Society, 1989. Images of the Twenty-First Century. Proceedings of the Annual International Conference of the IEEE Engineering in 9-12 November 1989, pp. 2017 – 2018.
- [161] Lipiński S., Trohman R.G., Interference in Implanted Cardiac Devices, Part II, Pacing and Clinical Electrophysiology, Vol. 25, Issue 10, October 2002, pp. 1496.
- [162] Lux R.L., Karhunen – Loeve representation of ECG data, Journal of Electrocardiology, Vol. 25, 1992, pp. 195 – 198.
- [163] Lyons R.G., Wprowadzenie do cyfrowego przetwarzania sygnałów, Wydawnictwa Komunikacji i Łączności, Warszawa 2000.
- [164] Łęski J., Nowe możliwości nieinwazyjnej diagnostyki elektrokardiologicznej, Zeszyty Naukowe Nr 1233, Elektronika Z.2, Gliwice 1994.
- [165] Łęski, J., Henzel, N., A fuzzy method for ECG feature extraction, [Engineering in Medicine and Biology, 1999. 21st Annual Conf. and the 1999 Annual Fall Meeting of the Biomedical Engineering Soc.] BMES/EMBS Conference, 1999. Proceedings of the First Joint Vol. 2, 13-16 October 1999, pp. 930.
- [166] Machejek J., Lelakowski J., Bednarek J., Majewski J., Pierwsze lata elektrostymulacji serca w Polsce, Polski Przegląd Kardiologiczny 2000, Tom 2, Nr 4, str. 361-365.
- [167] Machejek J., Lelakowski J., Czunko A., Majewski J., Lata 1952-62: Rewolucyjna dekada w dziejach elektrostymulacji serca, Folia Cardiologica, 2001, Tom 8, Nr 1, pp. 1 – 4.
- [168] Maglaveras N., Stamkopoulos T., Diamantaras K., Pappas C., Strintzis M., ECG pattern recognition and classification using non-linear transformations and neural networks: A review, International Journal of Medical Informatics, Vol. 52, 1998, pp. 191–208.
- [169] Mallat S., Hwang W.L., Singular detection and processing with wavelets, IEEE Transaction on Information Theory, Vol. 38, 1992, pp. 6.
- [170] Mallat S.G., A theory for multiresolution signal decomposition: the wavelet representation, IEEE Transaction on Pattern Analysis, 1989, Vol. 7, No. 11, pp. 674-693.

- [171] Mallat S.G., Multiresolution approximation and wavelets, Tech. Rep. Dep. Comput. Inform. Sci., University Pennsylvania, Philadelphia, PA, September 1987.
- [172] Mamcarz A., Testy wysiłkowe w rozpoznawaniu choroby niedokrwiennej serca. Co lekarz powinien wiedzieć o chorobie niedokrwiennej serca?, Warszawa 1993, str. 21 – 31.
- [173] Maniewski R., Lewandowski P., Mroczka T., Opolski G., Pomiar i analiza sygnałów EKG o wysokiej rozdzielczości [w:] Biocybernetyka i inżynieria biomedyczna 2000, Tom 2, Rozdział 18, Biopomiary, Nałęcz M. (red.), EXIT 2000, str. 333 – 375.
- [174] Martínez J.-P., Almeida R., Olmos S., Rocha A.P., Laguna P., A Wavelet-Based ECG Delineator: Evaluation on Standard Databases, IEEE Transaction on Biomedical engineering, Vol. 51, No. 4, April 2004, pp. 570 – 581.
- [175] Master T., Sieci neuronowe w praktyce. Programowanie w języku C++, Warszawa 1996.
- [176] Meste O., Rix H., Casminal P., Thakor N. V., Ventricular late potentials characterization in time–frequency domain by means of a wavelet transform IEEE Transaction on Biomedical Engineering, Vol. 41, 1994, pp. 625 – 634.
- [177] Miaou S.-G., Chao S.-N., Wavelet – Based Lossy – to – Lossless ECG Compression in a Unified Vector Quantization Framework, IEEE Transaction on Biomedical Engineering, Vol. 52, No. 3, March 2005, pp. 539 – 542.
- [178] Michalewicz Z., Algorytmy genetyczne + struktury danych = programy ewolucyjne, WNT, Warszawa 1996.
- [179] Miller A.S., Blott B.H., Hames T.K., Review of neural network applications in medical imaging and signal processing, Medical and Biological Engineering Computational, Vol. 30, 1992, pp. 449–464.
- [180] Moczko J., Kramer L., Cyfrowe metody przetwarzania sygnałów biomedycznych, Wydawnictwo Naukowe Uniwersytetu im. Adama Mickiewicza, Poznań 2001.
- [181] Moczko J., Kramer L., Cyfrowe metody przetwarzania sygnałów biomedycznych – zadania, Wydawnictwo Naukowe Uniwersytetu im. Adama Mickiewicza, Poznań 2001.
- [182] Mohsin S., Kurimoto Y., Suzuki Y., Maeda J., Extraction of the QRS wave in an electrocardiogram by fusion of dynamic programming matching and neural network, T.IEE Japan, Vol. 122-C, No. 10, 2002, pp. 1734 – 1741.
- [183] Momot A, Momot M., Owczarek A., Zastosowanie transformaty falkowej w klasyfikacji sygnałów EKG, Studia Informatica, Vol. 24, No. 3 (55), 2003.
- [184] Morabito M., Macerata A., Taddei A., Marchesi C., Computers in Cardiology 1991, 23-26 September 1991, pp.181 – 184.
- [185] Moraes, J.C.T.B., Freitas, M.M., Vilani, F.N., Costa, E.V., A QRS complex detection algorithm using electrocardiogram leads, Computers in Cardiology, 2002, 22-25 September 2002, pp. 205 – 208.
- [186] Nagin V.A., Selishchev S.V., Implementation of algorithms for identification of QRS – complexes in real – time ECG systems, IEEE



- Transaction on Biomedical Engineering, Vol. 35, No. 6, 2001, pp. 304 – 309.
- [187] Nałęcz M., Torbicz W., Filipczyński L., Maniewski R., Stolarski E., Biocybernetyka i inżynieria biomedyczna 2000, Tom 2, Biopomiary, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
- [188] Norma branżowa „Elektrokardiografy, ogólne wymagania i badania”, BN – 89/5963 – 02.
- [189] Okajima K., The Gabor function extracts the maximum information from input local signals input local signals, Neural Networks, Vol. 11, 1998, pp. 435–439.
- [190] Ölmez T., Dokur Z., Yazgan E., Classification of ECG waveforms by using genetic algorithms, Engineering in Medicine and Biology Society, 1997. Proceedings of the 19th Annual International Conference of the IEEE, Vol. 1, 30 October - 2 November 1997, pp. 92 – 94.
- [191] Oppenheim A.V., Schafer R.W., Cyfrowe przetwarzanie sygnałów, Wydawnictwa Komunikacji i Łączności, Warszawa 1979.
- [192] Oppenheim A.V., Sygnały cyfrowe. Przetwarzanie i zastosowania, Wydawnictwa Naukowo – Techniczne, Warszawa 1982.
- [193] Osowski S., Sieci neuronowe w ujęciu algorytmicznym, Wydawnictwo Naukowo Techniczne Warszawa 1996.
- [194] Osowski S., Moszczyński L., Tran Hoai L., Higher order statistic and neurofuzzy networks in ECG rhythm recognition and classification, Ukrainian-Polish Workshop, Solina 2000, pp. 142-146
- [195] Osowski S., Sieci neuronowe do przetwarzania informacji, Oficyna Wydawnicza PW, 2000.
- [196] Osowski S., Linh Toan Hoin, Fuzzy clustering neural network for classification of ECG beats, Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks (IJCNN'00), 2000.
- [197] Osowski S. , Linh T. H., ECG Beat Recognition Using Fuzzy Hybrid Neural Network, IEEE Transactions on Biomedical Engineering, Vol. 48, November 2001, pp. 1265-1271.
- [198] Osowski S., Sieci neuronowe wykorzystujące systemy wnioskowania rozmytego, Software 2.0, Vol. 74, Nr 2, Luty 2001, str. 18 – 22.
- [199] Osowski S., Sieci neuronowe typu SVM w zastosowaniu do klasyfikacji wzorców, Przegląd Elektrotechniczny, Nr 2, 2002, str. 29 – 36.
- [200] Osowski S., Tran Hoai L., Rozpoznawanie i klasyfikacja rytmów serca przy użyciu sieci neuronowych rozmytych, Software 2.0, Nr 2 (86), Luty 2002, str. 20 – 23.
- [201] Osowski S., Tran Hoai L., Markiewicz T., Support Vector Machine – Based Expert System for reliable heartbeat recognition, IEEE Transaction on Biomedical Engineering, Vol. 51, No. 4, April 2004, pp. 582 – 589 .
- [202] Özbay, Y., Karlik, B., A recognition of ECG arrhythmias using artificial neural networks, Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE, Vol. 2, 25 – 28 October 2001, pp. 1680 – 1683.
- [203] Ozimek E., Podstawy teoretyczne analizy widmowej sygnałów, Państwowe Wydawnictwo Naukowe, Warszawa – Poznań 1985.
- [204] Pałko T., Automatyczna analiza rytmu serca, Materiały Konferencyjne „Człowiek a komputer – medycyna”, Warszawa 1995, str. 677 – 682.

- [205] Pałko T., Wojciechowski D., Stymulatory serca [w:] Biocybernetyka i inżynieria biomedyczna, Darowski M., Orłowski T., Weryński A., Wójcicki J.M. (red.), Tom 3, Sztuczne narządy, Akademicka Oficyna wydawnicza EXIT, Warszawa 2001, str. 77 – 80.
- [206] Pan J., Tompkins W.J., A real – time QRS detection algorithm, IEEE Transaction on Biomedical Engineering, Vol. 32, No. 3, March 1985, pp. 230 – 236.
- [207] Pander T., Prosty, adaptacyjny M – filtr w tłumieniu zakłóceń impulsowych sygnałów biomedycznych, [w:] XIV Krajowa Konferencja Naukowa, Biocybernetyka i Inżynieria Biomedyczna, Rutkowski L. (red.), Tom II, Biopomiary, Częstochowa 21 – 23 wrzesień 2005, str.1035 – 1041.
- [208] Pander T., Zastosowanie adaptacyjnych filtrów miriadowych w tłumieniu zakłóceń impulsowych sygnałów biomedycznych [w:] XIV Krajowa Konferencja Naukowa, Biocybernetyka i Inżynieria Biomedyczna, Rutkowski L. (red.), Tom II, Biopomiary, Częstochowa 21 – 23 wrzesień 2005, str. 1042 – 1048.
- [209] Panoulas, K.I., Hadjileontiadis, L.J., Panas, S.M., Enhancement of R-wave detection in ECG data analysis using higher-order statistics, Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE Vol. 1, 25-28 October 2001, pp. 344 – 347.
- [210] Papaloukas C., Fotiadis D.I., Likas A., Michalis L.K., An ischemia detection method based on artificial neural networks, Artificial Intelligence in Medicine, Vol. 24, 2002, pp. 167 – 178.
- [211] Pasko M., Walczak J., Teoria sygnałów, Wydawnictwo Politechniki Śląskiej, Gliwice 1999.
- [212] Pektatlı R., Özbay Y., Ceylan M., Karlik B., Classification of ECG signals using fuzzy clustering neural networks (FCNN), International XII Turkish Symposium on Artificial Intelligence and Neural Networks – TAINN 2003.
- [213] Peña-Reyes C.A., Sipper M., Evolutionary computation in medicine: an overview, Artificial Intelligence in Medicine, Vol. 19, 2000, pp. 1–23.
- [214] Piotrowicz R. (red.), Zmienność rytmu serca, Wydawnictwo Medyczne Via Medica, Gdańsk 1995.
- [215] Pławiak – Mowna A., Interferencje elektromagnetyczne w kardiostymulatorach, Rozprawa doktorska, Warszawa 2005.
- [216] Pławiak – Mowna A., Krawczyk A., Zyss T., Koźluk E., Kompatybilność kardiostymulatorów w środowisku elektromagnetycznym, [w:] Kompatybilność elektromagnetyczna w biologii i medycynie, Krawczyk A, Pławiak – Mowna A. (red.), Instytut Naukowo – Badawczy ZTUREK Polskie Towarzystwo Zastosowań Elektromagnetyzmu, Warszawa 2003, str. 30 – 44.
- [217] Poli R., Cagnoli S., Genetic design of optimum linear and non-linear QRS detection, IEEE Translation Biomedical Engineering, Vol. 42, 1995, pp. 1137 – 1141.
- [218] Prochaczek P., Gałęcki J., Skowronek A., Machalski M., Przydatność nowego analogowego systemu eliminacji zakłóceń od impulsów z zapisu

- EKG w czasie nieinwazyjnej stymulacji serca., *Folia Cardiologica*, Tom 6, Nr 4, 1999.
- [219] Prochaczek P., Gibiński P., Gałecki J., Znaczenie układu tłumienia artefaktu impulsu stymulatora w cyfrowym rejestratorze EKG dla jakości zapisu nieinwazyjnego badania elektrofizjologicznego serca, *Folia Cardiologica*, Tom 4, Nr 1, 1997.
- [220] Przybylski A., Kurowski A., Lewandowski M., Sterliński M., Pytkowski M., Szwed H., Rola implantowanych kardiowerterów-defibrylatorów w leczeniu komorowych zaburzeń rytmu serca, *Postępy Nauk Medycznych*, Nr 1, 2002.
- [221] Ranjith P., Baby P.C., Joseph P., ECG analysis using wavelet transform: application to myocardial ischemia detection, *ITBM-RBM* 24, 2003, pp. 44 – 47.
- [222] Risk, M.R., Sobh, J.F., Saul, J.P., Beat detection and classification of ECG using self organizing maps, *Engineering in Medicine and Biology society, 1997. Proceedings of the 19th Annual International Conference of the IEEE Vol. 1, 30 October – 2 November 1997*, pp. 89 – 91.
- [223] Romaniuk P., Zastosowanie filtracji nieliniowej w dziedzinie transformaty falkowej do redukcji zakłóceń mięśniowych w sygnale elektrokardiograficznym, *Rozprawa Doktorska, Instytut Elektroniki, Politechnika Łódzka, Łódź 2002*.
- [224] Rubel P., Hamidi S., Behloul H., Couderc J.-P., Fayn J., Forlini M.-C., Maison-Blanche P., Miquel M., Coumel P., Touboul P., Are serial Holter QT, late potential and wavelet measurement clinically useful?, *Journal of Electrocardiology*, Vol. 29, Supplement, 1996, pp. 52 – 61.
- [225] Rudowski R., *Informatyka medyczna*, PWN, Warszawa 2003, str.49 – 74.
- [226] Rutkowska D., *Inteligentne systemy obliczeniowe i sztuczna inteligencja [w:] Nałęcz M. (red.), Biocybernetyka i inżynieria biomedyczna, Tom 6, Sieci neuronowe, Rozdział 24, WNT, Warszawa 2000*, str. 765 – 783.
- [227] Rutkowska D., Rutkowski L., Pliński M., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN Warszawa – Łódź, 1997.
- [228] Rutkowski L., *Filtry adaptacyjne i adaptacyjne przetwarzanie sygnałów*, Wydawnictwa Naukowo - Techniczne, Warszawa 1994.
- [229] Rutkowski L., *Metody i techniki sztucznej inteligencji*, PWN, Warszawa 2005.
- [230] Rydlewska - Sadowska W., Sadowski Z., *Zaburzenia rytmu serca*, Państwowy Zakład Wydawnictw Lekarskich, Warszawa 1985.
- [231] Sahambi J.S., Tandon S.N., Bhatt R.K.P., Using wavelet transforms for ECG characterization. An on-line digital signal processing system, *IEEE Engineering in Medicine and Biology Magazine*, Vol. 16, Issue 1, January - February 1997, pp. 77 – 83.
- [232] Sahambi J. S., Tandon S. M., Bhatt R. K. P., Quantitative analysis of errors due to power-line interference and base-line drift in detection of onsets and offsets in ECG using wavelets, *IEEE Engineering in Medicine and Biology Comput.*, Vol. 35, 1997, pp. 747–751.
- [233] Sahambi J. S., Tandon S. M., Bhatt R. K. P., Wavelet base ST-segment analysis, *IEEE Engineering on Medicine and Biology Comput.*, Vol. 36, 1998, pp. 568–572.

- [234] Schölkopf B., Burges C. J. C., Smola A. J. (eds.), *Advances in Kernel Methods - Support Vector Learning*, MIT Press, 1999.
- [235] Schuck A.Jr., Wisbeck J.O., QRS detector pre-processing using the complex wavelet transform, *Engineering in Medicine and Biology Society*, 2003. Proceedings of the 25th Annual International Conference of the IEEE Vol. 3, 17-21 September 2003, pp. 2590 – 2593.
- [236] Selesnick I.W., Hilbert Transform Pairs of Wavelet Bases, *IEEE Signal Processing Letters*, Vol. 8, No. 6, June 2001, pp. 170 – 173.
- [237] Senhadji L., Carrault G., Bellanger J.J., Passariello G., Comparing wavelet transforms for recognizing cardiac patterns, *IEEE Transaction on Medical and Biology*, Vol. 13, 1995, pp. 167 – 173.
- [238] Shyu L.-Y., Wu Y.-H., Hu W., Using wavelet transform and fuzzy neural networks for VPC detection from the Holter ECG, *IEEE Transaction on Biomedical Engineering*, Vol. 51, No. 7, July 2004, pp. 1269 – 1273.
- [239] Silipo R, Bortolan G., Neural and Traditional Techniques in Diagnostic ECG Classification, Proceedings of the 1997 IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP '97), IEEE Computer Society 1997.
- [240] Simelius, K., Reinhardt, L., Nenonen, J., Tierala, I., Toivonen, L., Katila, T., Self-organizing maps in arrhythmia localization from body surface potential mapping, *Engineering in Medicine and Biology society*, 1997. Proceedings of the 19th Annual International Conference of the IEEE Volume 1, 30 October – 2 November 1997, pp. 62 - 64.
- [241] Sivannarayana N., Reddy D.C., Biorthogonal wavelet transforms for ECG parameters estimation, *Medical Engineering and Physics*, Vol. 21, 1999, pp. 167 – 174.
- [242] Skordalaskis E., Syntactic ECG processing: A Review, *Pattern Recognition*, Vol. 19, Issue 4, 1986, pp. 305 – 313.
- [243] Stein E.M., Shakarchi R., *Fourier analysis: an introduction*, Princeton, Oxford 2003.
- [244] Sternickel K., Automatic pattern recognition in ECG time series, *Computer Methods and Programs in Biomedicine*, Vol. 68, 2002, pp. 109–115.
- [245] Strang G.: Wavelet Transforms versus Fourier Transforms, *Bulletin of The American Mathematical Society*, 1993, Vol. 28, No. 2, pp. 288-305.
- [246] Stranneby D., *Cyfrowe przetwarzanie sygnałów. Metody Algorytmu Zastosowania*, Wydawnictwo BTC, Warszawa 2004.
- [247] Stridh M., Sornmo L., Meurling C.J., Olsson B.S., Sequential characterization of atrial tachyarrhythmias based on ECG time – frequency analysis, *IEEE Transaction on Biomedical Engineering*, Vol. 51, No. 1, January 2004, pp. 100 – 113.
- [248] Strumiłło P., Modelowanie i analiza sygnału elektrokardiograficznego z zastosowaniem układów i przekształceń liniowych, *Zeszyty Naukowe Politechniki Łódzkiej*, nr 906, 2002.
- [249] Suppappola S., Sun Y., "Nonlinear transforms of ECG signals for digital QRS detection: A quantitative analysis," *IEEE Trans. BioMedical Engineering*, Vol. 41, 1994, pp. 397 – 400.
- [250] Suzuki Y., Self-organizing QRS-wave recognition in ECG using neural networks, *IEEE Transactions on Neural Networks*, Vol. 6, Issue 6, November 1995, pp. 1469 – 1477.

- [251] Świąc A., Bilski J., Metoda wstecznej propagacji błędów i jej modyfikacje [w:] Nałęcz M. (red.), Biocybernetyka i inżynieria biomedyczna, Tom 6, Sieci neuronowe, Rozdział 3, WNT, Warszawa 2000, str. 73 – 110.
- [252] Świątecka G., Standardy postępowania w elektroterapii serca, Folia Cardiologica 1999, Nr 6, Suplement 1, pp. 30 – 40.
- [253] Świątecka G., Nowe wskazania do elektrostymulacji serca, *Elektrofizjologia i stymulacja serca*, Tom 1, Nr 1, 1994, pp. 1 – 6.
- [254] Świątecka G., Interferencje elektromagnetyczne u osób ze stymulatorem serca, Folia Cardiologica, No. 6, Supplement 1, 1999, str. 40 – 46.
- [255] Szczepaniak P., Obliczenia inteligentne, szybkie przekształcenia i klasyfikatory, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2004
- [256] Szilagyi, L., Benyo, Z., Szilagyi, S.M., Szlavecz, A., Nagy, L., On-line QRS complex detection using wavelet filtering, Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE Volume 2, 25-28 Oct. 2001, pp. 1872 – 1874.
- [257] Szilagyi, L., Wavelet-transform-based QRS complex detection in on-line Holter systems, Engineering in Medicine and Biology, 1999. 21st Annual Conf. and the 1999 Annual Fall Meeting of the Biomedical Engineering Soc. BMES/EMBS Conference, 1999. Proceedings of the First Joint Volume 1, 13-16 Oct. 1999, pp. 271.
- [258] Tadeusiewicz R., Elementarne wprowadzenie do sieci neuronowych z przykładowymi programami, Akademicka Oficyna Wydawnicza, Warszawa 1998.
- [259] Tadeusiewicz R., Flasiński M., Rozpoznawanie obrazów, PWN, Warszawa 1991.
- [260] Tadeusiewicz R., Problemy biocybernetyki, Wydawnictwo Akademii Górniczo – Hutniczej, Kraków 1991.
- [261] Tadeusiewicz R., Sieci neuronowe, Akademicka Oficyna Wydawnicza, Warszawa 1993.
- [262] Tadeusiewicz R., Wstęp do informatyki, Wydawnictwo Poldex, Kraków 1997.
- [263] Tadeusiewicz R., Wybrane obszary biomedycznych zastosowań sieci neuronowych, [w:] Nałęcz M. (red.), Biocybernetyka i inżynieria biomedyczna, Tom 6, Sieci neuronowe, Rozdział 15, WNT, Warszawa 2000, str. 494 – 519.
- [264] Thakor N., Yi – Sheng Zhu, Applications of adaptive filtering to ECG analysis. Noise cancellation and arrhythmia detection, IEEE Transaction on Biomedical Engineering, August 1991, Vol. 38, Issue 8, pp. 785 – 794.
- [265] Tibishirani R., A comparison of some error estimates for neural network models, Neural Computation, 1996, Vol. 8, pp. 152 – 163.
- [266] Tkacz E., Nowe możliwości diagnostyczne analizy zmienności rytmu serca (HRV), Prace Instytutu Biocybernetyki i Inżynierii biomedycznej PAN, Nr 45, Warszawa 1996.
- [267] Traczyk W. Z., Fizjologia człowieka w zarysie, wyd. VI, Wydawnictwo Lekarskie PZWL, Warszawa 1972.
- [268] Traczyk W. Z., Fizjologia człowieka z elementami fizjologii stosowanej i klinicznej, Państwowy Zakład Wydawnictw Lekarskich, Warszawa 1989.
- [269] Trahanias P., Skordalakis E., Syntactic pattern recognition of the ECG, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 12, Issue 7, July 1990, pp. 648 – 657.

- [270] Trahanias P.E., An approach to QRS complex detection using mathematical morphology, *IEEE Transaction on Biomedical Engineering*, Vol. 40, No. 2, 1993, pp. 201-205.
- [271] Tran H.L., Sieci neuronowe rozmyte w zadaniach klasyfikacji i estymacji, *Rozprawa Doktorska*, Politechnika Warszawska, 2000.
- [272] Tran H.L., Współczesne generacje sztucznych sieci neuronowych i ich zastosowania, *Elektronika z.130*, Oficyna Wydawnicza Politechniki Warszawskiej, 2004.
- [273] Tsipouras M.G., Fotiadis D.I., Sideris D., An arrhythmia classification system based on the RR-interval signal, *Artificial Intelligence in Medicine*, Vol. 33, 2005, pp. 237 – 250.
- [274] Tu C.Y., Zeng Y.J., Ren X.Y., Wu S.C., Yang X.C., Hybrid processing and time-frequency analysis of ECG signal, *Engineering in Medicine and Biology Society*, 2004. EMBC 2004. Conference Proceedings. 26th Annual International Conference of the 2004, Vol. 1, 2004, pp. 361 – 364.
- [275] Valev V., Radeva P., Construction of Boolean decision rules for ECG recognition by non-reducible descriptors, *Pattern Recognition 1996*, Proceedings of the 13th International Conference on Volume 2, 25-29 Aug. 1996, pp. 111 – 115.
- [276] Vapnik V. N. , *Statistical Learning Theory*, Wiley, New York, 1998.
- [277] Varanini M., Emdin M., Conforti F., Marchesi C., A two – channel adaptive filtering approach for recognition of the QRS morphology, *Computers in Cardiology 1992*, 23-26 September 1992, pp. 141 – 144.
- [278] Walczak F., Baranowski R., *Podstawy EKG u pacjenta ze stymulatorem serca*, VIA MEDICA, Gdańsk 2003.
- [279] Walczak F., Baranowski R., Wskazania do 24-godzinnej rejestracji EKG u pacjenta z wszczepionym stymulatorem – zalecenia, *Sekcji Elektrokardiologii Nieinwazyjnej PTK oraz aktualne stanowisko ACC/AHA. Komentarz*, *Folia Cardiologica*, 2000; Nr 8, Supplement A, A3-A5.
- [280] Walczak F., Kępski R., *Stymulator przyjaciel twojego serca. Zarys wiedzy dla pacjenta i jego lekarza*, Wydawnictwo Lekarskie PZWL, Warszawa 1995.
- [281] Weymaere N., Martens J., On the initialization and optimization of multilayer perceptron, *IEEE Transaction on Neural Network*, 1994, Vol. 5, pp. 738 – 751.
- [282] Widman LE, Tong DA., Validation of the EINTHOVEN model-based computerized electrocardiogram rhythm analysis system with three classes of clinical arrhythmias, *The American Journal of Cardiology*, Vol. 78, 1996, pp. 927–931.
- [283] Widrow B., Stearns S.D., *Adaptive Signal processing*, Prentice Hall, 1986.
- [284] Wnuk P., *Algorytmy optymalizacji struktury rozmytych modeli dynamicznych*, *Rozprawa Doktorska*, Politechnika Warszawska, 2004.
- [285] Wojtaszczyk P., *Teoria falek*, Wydawnictwo naukowe PWN, Warszawa 2000.
- [286] Wrześniowski A., *Nowa metoda klasyfikacji ewolucji serca dla potrzeb badań holterowskich*, *Rozprawa Doktorska*, Politechnika Śląska w Gliwicach, Wydział Automatyki, Elektroniki i Informatyki, Gliwice 2002.

- [287] Xue, Q., Hu Y.H., Tompkins W.J., Artificial neural network for ECG arrhythmia monitoring, International Joint Conference on Neural Networks, 7-11 June 1992, Vol. 2, 1992, pp. 987 – 992.
- [288] Xue, Q., Hu Y.H., Tompkins W.J., Neural-network-based adaptive matched filtering for QRS detection, IEEE Transactions on Biomedical Engineering, Vol. 39, Issue 4, April 1992, pp. 317 – 329.
- [289] Yimman S., Hinjit W., Desyoo P., Bholsithi W., Dejhan K., Wavelet packet transform applications on QRS detection, Signal Processing and Information Technology, 2004. Proceedings of the Fourth IEEE International Symposium on 18-21 Dec. 2004, pp. 445 – 448.
- [290] Yu B.C., Liu S., Lee M., Chen C.Y., Chiang B.N., A nonlinear digital filter for cardiac QRS complex detection, Journal of Clinical Engineering, Vol. 10, 1985, pp. 193-201.
- [291] Zahan S., A fuzzy approach to computer-assisted myocardial ischemia diagnosis, Artificial Intelligence in Medicine, Vol. 21, 2001, pp. 271 – 275.
- [292] Zahan S., Michael C., Fuzzy inference systems based on Takagi – Sugeno fuzzy consequent rules, Proceedings of the EUFIT'96, Aachen 1996, pp. 563 – 567.
- [293] Zhang Q., Kandel A., Compensatory Neuro-Fuzzy Systems with Fast Learning Algorithms, IEEE Transactions on Neural Networks, Vol. 9, January 1998, pp. 83 – 105.
- [294] Zhang Q., Benveniste A., Wavelet Networks, IEEE Transaction on Neural Networks, Vol. 3, No. 6, November 1992, pp. 889 – 898.
- [295] Ziółko M., Modelowanie zjawisk falowych, Uczelniane Wydawnictwa Naukowo – dydaktyczne AGH, Kraków 2000.
- [296] Zyss T., Krawczyk A., Koźluk E., Roman A., Pławiak – Mowna A., Stymulatory serca a zmienne pole magnetyczne (0,01 – 1T) generowane przez urządzenia elektromedyczne – pośrednie pomiary pola magnetycznego, [w:] Zastosowanie elektromagnetyzmu w nowoczesnych technikach i informatyce, Krawczyk A. (red.), Polskie Towarzystwo Zastosowań Elektromagnetyzmu, Warszawa 2000, str. 89 – 90.
- [297] Zyss T., Krawczyk A., Koźluk E., Roman A., Pławiak – Mowna A., Stymulatory serca w zmiennym polu magnetycznym generowanym przez urządzenia elektromedyczne, Przegląd elektrotechniczny, Nr 78, 2002, str. 332 – 335.
- [298] Zyss T., Krawczyk A., Pławiak – Mowna A., Koźluk E., Czy pacjenci z wszczepionymi kardiostymulatorami mają unikać rozmów przez telefony komórkowe? – badania in vitro i na fantomie, Materiały Konferencyjne „Warsztaty Polskiego Towarzystwa Zastosowań Elektromagnetyzmu, Dychowo 2002, str. 30 –32.
- [299] Zyss T., Krawczyk A., Roman A., Koźluk E., Pławiak – Mowna A., Zagrożenia ze strony wybranych źródeł generujących pole elektromagnetyczne dla osób mających wszczepione stymulatory serca, [w:] Kompatybilność elektromagnetyczna w biologii i medycynie, Krawczyk A., Pławiak – Mowna A. (red.), Instytut Naukowo – Badawczy ZTUREK Polskie Towarzystwo Zastosowań Elektromagnetyzmu, Warszawa 2003, str. 45 – 55.
- [300] Żuranda J., Barski M., Jędruch W., Sztuczne sieci neuronowe, PWN 1996.

## Spis tabel

Tabela nr 1.1	Dane techniczne przykładowych stymulatorów.	19
Tabela nr 1.2	Kody stymulacji. Opracowane na podstawie [187].	21
Tabela nr 3.1	Przykładowe wyniki detekcji zespołu QRS dla kilku wybranych autorów. Maksymalna czułość (SE) uzyskana przez nich dla różnych baz sygnałów elektrokardiograficznych tj. MIT-BIH, AHA oraz zbiorów własnych sygnałów.	51
Tabela nr 3.2	Różne przypadki wykrycia zespołu QRS.	52
Tabela nr 3.3	Miary SE, +P, R dla sygnału 105, 108 w poszczególnych kategoriach.	62
Tabela nr 4.1	Liczba zgromadzonych sygnałów dla poszczególnych rozruszników firmy Biotronik.	70
Tabela nr 4.2	Liczba sygnałów dla określonego trybu stymulacji.	71
Tabela nr 4.3	Zawartość rytmu endogennego i stymulatorowego wyrażona w procentach dla kilku wybranych sygnałów.	72
Tabela nr 4.4	Źródło pochodzenia algorytmów Friesena.	74
Tabela nr 4.5	Przykład prawidłowych detekcji zespołu QRS (TP) dla kilku sygnałów EKG w zależności od górnego progu P2FS dla P1FS=0,05.	82
Tabela nr 5.1	Zależności między porządkującymi indeksami dla funkcji Haara.	103
Tabela nr 5.2	Współczynniki $\{h_n\}_{n=0}^{2p-1}$ dla funkcji skalujących Daubechies rzędu $p=1,2,3$ .	107
Tabela nr 5.3	Obliczone wartości współczynników $\{h_n\}_{n=0}^{2p-1}$ dla funkcji skalujących falek Daubechies rzędu $p=4, \dots, 8$ .	107
Tabela nr 5.4	Własności przykładowych falek. Opracowano na podstawie [19].	117
Tabela nr 6.1	Przykład wartości entropii Shannona dla 8 poziomów z wykorzystaniem kilku rodzin falek.	122
Tabela nr 6.2	Wykryte zespoły QRS w zależności od wybranego progu.	128
Tabela nr 6.3	Maksymalny i minimalny błąd detekcyjny dla progów detekcyjnych 0,45 – 0,7.	130
Tabela nr 6.4	Przykład różnorodności morfologicznej zespołu QRS. Po lewej stronie sztuczne zespoły QRS (stymulatorowe), po prawej rytm endogeny - własny pacjenta.	133
Tabela nr 6.5	Przykład podobieństwa dwóch wybranych falek sym7 oraz coif3 do morfologii zespołu QRS.	133
Tabela nr 6.6	Błąd detekcyjny dla kilku wybranych sygnałów i kilku stosowanych falek.	138
Tabela nr 6.7	Średnia dokładność dla różnego podziału zbioru danych.	141



Tabela nr 6.8	Średni procent poprawnej klasyfikacji rytmu endogenego, dla sygnałów o zróżnicowanej liczbie QRS własnych i stymulatorowych dla sieci neuronowych od 1 do 4 warstw ukrytych.	143
Tabela nr 6.9	Odchylenie standardowe pomiędzy funkcjami aktywacji sigmoidalna i tangesoidalną dla sieci neuronowych od 1 do 4 warstw ukrytych.	145
Tabela nr 6.10	Średnie wartości miar SE, BD, +P, R dla trzech grup algorytmów (T-dziedzina czasu, T-F dziedzina czasowo-częstotliwościowa, SN- sieci neuronowe) sygnałów pochodzących z bazy MIT-BIH w porównaniu do wyników uzyskanych przez zastosowane algorytmy Friesena oraz sieci falkowo-neuronowe dla sygnałów elektrokardiograficznych - stymulatorowych.	147

## Spis rysunków

Rys. 1.1	Sygnal elektrokardiograficzny z zaznaczonymi załamkami.	16
Rys. 1.2	Układ stymulujący.	18
Rys. 3.1	Fragmety zapisów sygnałów elektrokardiograficznych z bazy MIT – BIH omawianych w niniejszym rozdziale pracy (a) sygnał 105 (b) sygnał 108 (c) sygnał 203 (d) sygnał 222.	55
Rys. 3.2	Błąd detekcyjny dla sygnału 105 dla przykładowych algorytmów. Kolor żółty – metody czasowe, zielony – metody częstotliwościowe, niebieski – metody czasowo – częstotliwościowe, czerwony – sztuczna inteligencja.	57
Rys. 3.3	Średnia liczba detekcji FP i FN dla sygnału 105 dla trzech kategorii: T – dziedzina czasu, T-F – dziedzina czasowo – częstotliwościowa, SN – sieci neuronowe.	58
Rys. 3.4	Dodatnia wartość prognostyczna (+P) oraz odsetek poprawnych detekcji (R) dla sygnału 105 w poszczególnych grupach.	59
Rys. 3.5	Błąd detekcyjny. Kolor żółty – metody czasowe, zielony – metoda częstotliwościowa oparta o przekształcenia Hilberta, niebieski – metody czasowo – częstotliwościowe, czerwony – sieci neuronowe i algorytm genetyczny.	60
Rys. 3.6	Średnia ilość detekcji zespołu QRS fałszywie pozytywnej (kolor niebieski) oraz fałszywie negatywnej (kolor czerwony) w sygnale 108 dla trzech grup algorytmów (T- dziedzina czasu, T-F dziedzina czasowo – częstotliwościowa, AI – sztuczna inteligencja, SN – sieci neuronowe).	61
Rys. 3.7	Średni błąd detekcji zespołu QRS dla sygnałów 105 i 108 w kategoriach T- metod czasowych, T-F – metod czasowo – częstotliwościowych, AI – sztucznej inteligencji, SN – sieci neuronowych. (Kolor zielony – błąd detekcyjny sygnału 105, kolor żółty – sygnał 108).	62
Rys. 3.8	Średni błąd detekcji zespołu QRS dla sygnałów 105, 108, 203, 222 w zależności od kategorii T – dziedzina czasu, T-F dziedzina czasowo – częstotliwościowa, AI – sztuczna inteligencja, SN – sieci neuronowe.	63
Rys. 3.9	Czułość dla poszczególnych kategorii metod dla czterech sygnałów elektrokardiograficznych 105, 108, 203, 222.	64
Rys. 3.10	Dodatnia wartość prognostyczna (+P) w omawianych kategoriach (T, T-F, AI, SN) dla czterech wybranych sygnałów elektrokardiograficznych (105, 108, 203, 222).	64
Rys. 3.11	Odsetek poprawnych detekcji zespołu QRS dla poszczególnych grup algorytmów w sygnałach 105, 108, 203, 222.	65
Rys. 3.12	Średni wzrost miar SE, +P oraz R pomiędzy algorytmami z dziedziny czasu a algorytmami z dziedziny czasowo – częstotliwościowej i sieciami neuronowymi.	66
Rys. 4.1	Rozmieszczenie elektrod na klatce piersiowej pacjenta z wszczepionym rozrusznikiem.	70

Rys. 4.2	Liczna sygnałów o podanych rozpoznaniu klinicznym. W legendzie wykorzystano standardowe kody chorób używane w prezentowanych stymulatorach. B2 - choroba układu przewodzącego; C1+C2 - choroba wieńcowa lub zawał; D1 – patologia wrodzona; E1 – powikłania chirurgiczne; E3 – ablacja; G1 – kardiomopatia; G3 – wada zastawkowa; NZ – brak danych.	71
Rys. 4.3	Przykładowe sygnały elektrokardiograficzne – stymulatorowe a) stym005; b) stym014; c) stym025 d) stym037; e) stym052; f) stym103 g) stym145.	72
Rys. 4.4	Zależność wykrycia detekcji prawdziwie pozytywnej (TP) od wybranego progu z przedziału [0,05; 0,3] dla algorytmów AF1- kolor czerwony, AF2 – kolor czarny, AF3 – kolor niebieski.	75
Rys. 4.5	Liczba detekcji FN dla algorytmów AF1-AF3 w zależności od wybranego progu detekcyjnego. (AF1- kolor czerwony, AF2 – kolor czarny, AF3 – kolor niebieski).	75
Rys. 4.6	Liczba detekcji FP dla algorytmów AF1(kolor czerwony), AF2(czarny), AF3(niebieski) w zależności od progu.	76
Rys. 4.7	Średnia czułość dla algorytmów AF1-AF3.	77
Rys. 4.8	Średni błąd detekcyjny algorytmów AF1 – AF3.	77
Rys. 4.9	Liczba poprawnie wykrytych zespołów QRS (TP). Dla algorytmu FD1 (linia czerwona), FD2 (linia niebieska).	78
Rys. 4.10	Liczba detekcji FN dla algorytmu FD1 (linia czerwona), FD2 (linia niebieska).	78
Rys. 4.11	Liczba detekcji FP zespołów QRS. Dla algorytmu FD1 (czerwona), FD2 (niebieska).	79
Rys. 4.12	Czułość algorytmów FD1, FD2 dla trzech sygnałów.	80
Rys. 4.13	Błąd detekcyjny dla sygnałów stym005, stym037 algorytmów FD1, FD2.	81
Rys. 4.14	Procent detekcji TP w kolejnych progach P2FS = [0,4; 0,45; 0,5; 0,55; 0,6; 0,65], dla sygnałów stym005, stym014, stym037, stym103.	83
Rys. 4.15	Liczba detekcji fałszywie negatywnej (krzywa niebieska) oraz fałszywie pozytywnej (krzywa czerwona) w zależności od zmiany górnego progu algorytmów FS.	83
Rys. 4.16	Przykładowe wartości miary czułości w przypadku algorytmów FS1 oraz FS2 dla kilku sygnałów EKG.	84
Rys. 4.17	Najmniejszy błąd detekcyjny otrzymany dla algorytmów FS1, FS2 dla sygnałów.	85
Rys. 4.18	Średnia czułość algorytmów DF1 oraz DF2.	86
Rys. 4.19	Średni błąd detekcyjny algorytmów DF1 oraz DF2.	86
Rys. 4.20	Średnia miara czułości dla poszczególnych algorytmów Friesena. Kolejno kolorami zaznaczono algorytmy oparte: kolor żółty – o amplitudę i pierwszą pochodną; kolor niebieski – o pierwszą pochodną; kolor czerwony – o pierwszą i drugą pochodną; kolor zielony – o filtry cyfrowe.	87

Rys. 4.21	Średni błąd detekcyjny dla poszczególnych algorytmów Friesena. Kolejno kolorami zaznaczono algorytmy oparte: kolor żółty – o amplitudę i pierwszą pochodną; kolor niebieski – o pierwszą pochodną; kolor czerwony – o pierwszą i drugą pochodną; kolor zielony – o filtry cyfrowe.	88
Rys. 5.1	Wpływ parametrów przesunięcia i skalowania na lokalizację funkcji bazowej. Funkcja $\psi_1$ jest rezultatem przesunięcia w czasie o $\tau$ , $\psi_2$ to wynik modulacji częstotliwościowej o $\omega_0$ , zaś $\psi_3$ jest wynikiem skalowania.	91
Rys. 5.2	Drzewo 3 poziomowej dekompozycji sygnału.	101
Rys. 5.3	Podział pasma częstotliwościowego w wyniku dekompozycji sygnału.	102
Rys. 5.4	Przykład kilku funkcji Haara.	104
Rys. 5.5	Przykłady falek z rodziny Daubechies i funkcji skalujących. Kolejno db3, db5, db8, db20.	106
Rys. 5.6	Schemat jednokierunkowej dwuwarstwowej sieci neuronowej.	110
Rys. 5.7	Wykres funkcji aktywacji dla wartości parametru $\beta=1, 5, 15, 25$ . a) funkcji sigmoidalnej b) funkcji tangesoidalnej.	112
Rys. 5.8	Struktura sieci falkowo – neuronowej. Źródło [ 294].	115
Rys. 5.9	Uogólniona struktura sieci falkowo – neuronowej.	116
Rys. 6.1	Zmiana entropii Shannona na poziomach 1-8 dla rodzin falek Daubechies (kolor czarny), Biortogonalne (zielony), Symlet (czerwony), Coiflets (kolor niebieski).	122
Rys. 6.2	Entropia Shannona na poziomach 1-8 dla falki Haara (czarny), Mexican Hat(niebieski).	123
Rys. 6.3	Entropia Shannona na poszczególnych poziomach dekompozycji dla falki Molet.	123
Rys. 6.4	Dekompozycja 8 poziomowa z wykorzystaniem falki db3. U góry jeden z kanałów sygnału rzeczywistego (stym036.dat), poniżej kolejne poziomy dekompozycji.	124
Rys. 6.5	Dekompozycja 8-cio poziomowa wykorzystująca falę coif1. U góry sygnał rzeczywisty (stym036.dat) oraz kolejne poziomy dekompozycji.	125
Rys. 6.6	Dekompozycja 8-cio poziomowa wykorzystująca falę sym7. U góry sygnał rzeczywisty (stym036.dat) oraz kolejne poziomy dekompozycji.	125
Rys. 6.7	Przykład informacji zawartej na czwartym poziomie dekompozycji sygnału EKG dla kilku wybranych falek. Kolejno od góry: db3, coif1, sym7, bior1.5.	126
Rys. 6.8	Średnia czułość na 3, 4 oraz 5 poziomie dekompozycji.	127
Rys. 6.9	Średni błąd detekcyjny poszczególnych rodzin falek na 3, 4, 5 poziomie dekompozycji.	127
Rys. 6.10	Liczba wykrytych zespołów QRS w zależności od zmiany progu dla czterech sygnałów stymulatorowych (stym025 – kolor czerwony, stym037 – czarny, stym098 – niebieski, stym102 – zielony).	129
Rys. 6.11	Liczba detekcji fałszywie negatywnej w zależności od	131

	wybranego progu dla czterech sygnałów stymulatorowych (stym025 – kolor czerwony, stym037 – czarny, stym098 – niebieski, stym102 – zielony).	
Rys. 6.12	Liczba detekcji FP w zależności od wybranego progu dla czterech sygnałów stymulatorowych (stym025 – kolor czerwony, stym037 – czarny, stym098 – niebieski, stym102 – zielony).	131
Rys. 6.13	Czułość dla falek rodziny Daubechies dla dwóch wybranych sygnałów. Oznaczenia 1- stym025; 2 – stym067.	134
Rys. 6.14	Czułość dla falek rodziny Coiflets dla trzech wybranych sygnałów. Oznaczenia: 1- stym25, 2- stym67, 3-stym99.	135
Rys. 6.15	Czułość dla falek rodziny Symlet dla trzech wybranych sygnałów. Oznaczenia: 1- stym25, 2- stym67, 3-stym99.	136
Rys. 6.16	Czułość dla rodziny falek biortogonalnych dla czterech wybranych sygnałów. Oznaczenia: 1- stym25, 2- stym67, 3- stym99, 6-stym126.	136
Rys. 6.17	Średnia czułość dla rodzin db, coif, sym, bior.	137
Rys. 6.18	Czułość falek Mexican Hat, Meyer, Morlet dla trzech sygnałów (stym026, stym059, stym101).	137
Rys. 6.19	Minimalny błąd detekcyjny dla wybranych falek. Oznaczenia: db – rodzina falek Daubechies, coif – rodzina falek Coiflets, sym – rodzina falek Symlets, bior – rodzina falek biortogonalnych, mh – falka meksykański kapelusz, meyr- falka Meyera, morl – falka Moleta.	139
Rys. 6.20	Średni błąd detekcyjny. Oznaczenia: db – rodzina falek Daubechies, coif – rodzina falek Coiflets, sym – rodzina falek Symlets, bior – rodzina falek biortogonalnych, mh – falka meksykański kapelusz, meyr- falka Meyera, morl – falka Moleta.	139
Rys. 6.21	Przykład detekcji fałszywie negatywnej wynikającej z licznych artefaktów zawartych w sygnale stymulatorowym a) stym056; b) stym077. Czerwone kropki oznaczają wykryty zespół QRS.	140
Rys. 6.22	Zależność dokładności klasyfikacji od liczebności zbioru testowego.	141
Rys. 6.23	Dokładność klasyfikacji rytmu endogennego w zależności od liczby neuronów w poszczególnych warstwach ukrytych sieci neuronowych.	144
Rys. 6.24	Dokładność klasyfikacji rytmu endogennego w zależności od wyboru funkcji aktywacji dla sieci neuronowych od 1 do 6 warstw ukrytych.	145