



Wojskowa  
Akademia  
Techniczna

Wydział  
Elektroniki



---

---

# ROZPRAWA DOKTORSKA

NOWATORSKA METODA DIAGNOSTYKI  
WYBRANYCH STANÓW PATOLOGII SERCA  
OPARTA NA CZASOWO-CZĘSTOTLIWOŚCIOWEJ ANALIZIE  
SYGNAŁÓW FONOKARDIOGRAFICZNYCH

**por. mgr inż. Wojciech Lejkowski**

Promotor

prof. dr hab. inż. Andrzej P. Dobrowolski

Drugi Promotor

dr hab. n. med. Robert Olszewski, prof. NIGRiR

WARSZAWA 2020

*Niniejszą rozprawę dedykuję mojej ukochanej Żonie Martynie,  
w podziękowaniu za nieocenione wsparcie i wyrozumiałość w niełatwym czasie pracy twórczej.*

## SPIS TREŚCI

<b>SPIS TREŚCI</b> .....	<b>3</b>
<b>STRESZCZENIE</b> .....	<b>5</b>
<b>ABSTRACT</b> .....	<b>6</b>
<b>WPROWADZENIE</b> .....	<b>7</b>
<b>1. FONOKARDIOGRAFIA „WCZORAJ I DZIŚ”</b> .....	<b>10</b>
1.1. Układ sercowo-naczyniowy .....	13
1.2. Osłuchiwanie mięśnia sercowego .....	14
1.3. Struktura systemu diagnostycznego opartego o analizę PCG .....	16
1.4. Podsumowanie.....	17

<b>2.</b>	<b>ŹRÓDŁO I CHARAKTERYSTYKA DANYCH DIAGNOSTYCZNYCH.....</b>	<b>18</b>
2.1.	Stetoskop.....	19
2.2.	Stetoskop elektroniczny JABES.....	20
2.3.	Proces przetwarzania analogowo-cyfrowego sygnału PCG.....	21
2.4.	Rejestrator fonokardiogramów – hardware.....	22
2.5.	Rejestrator fonokardiogramów – aplikacja.....	29
2.6.	Stetoskop cyfrowy Littmann 3200.....	31
2.7.	Baza danych.....	36
2.8.	Statystyka zebranych danych.....	39
2.9.	Podsumowanie.....	42
<b>3.</b>	<b>OCENA JAKOŚCI SYGNAŁÓW FONOKARDIOGRAFICZNYCH.....</b>	<b>43</b>
3.1.	Filtracja falkowa sygnału.....	45
3.2.	Parametry jakościowe.....	48
3.3.	Klasyfikator jakościowy.....	56
3.4.	Podsumowanie.....	64
<b>4.</b>	<b>GENERACJA CECH DYSTYNKTYWNYCH.....</b>	<b>65</b>
4.1.	Uśrednianie w dziedzinie częstotliwości.....	66
4.2.	Ekstrakcja cech.....	69
4.3.	Podsumowanie.....	78
<b>5.</b>	<b>SELEKCJA CECH DYSTYNKTYWNYCH.....</b>	<b>79</b>
5.1.	Selekcja cech osobniczych z wykorzystaniem metody Fishera.....	80
5.2.	Analiza składowych głównych.....	81
5.3.	Liniowa analiza dyskryminacyjna.....	82
5.4.	Ewolucyjna selekcja cech osobniczych.....	84
5.5.	Podsumowanie.....	88
<b>6.</b>	<b>KLASYFIKACJA SYGNAŁÓW FONOKARDIOGRAFICZNYCH.....</b>	<b>89</b>
6.1.	Wielokryterialna optymalizacja parametrów.....	90
6.2.	Klasyfikacja.....	90
6.2.1.	Zbiór uczący i testowy.....	91
6.2.2.	Miary oceny jakości klasyfikatorów.....	91
6.2.3.	Analiza składowych głównych.....	94
6.2.4.	Liniowa analiza dyskryminacyjna.....	94
6.2.5.	Sieć wektorów nośnych.....	95
6.3.	Podsumowanie.....	100
	<b>PODSUMOWANIE.....</b>	<b>102</b>
	<b>LITERATURA.....</b>	<b>104</b>
<b>Z.1.</b>	<b>DOKUMENTACJA REJESTRATORA FONOKARDIOGRAMÓW.....</b>	<b>110</b>
<b>Z.2.</b>	<b>REJESTRATOR FONOKARDIOGRAMÓW PODRĘCZNIK UŻYTKOWANIA.....</b>	<b>116</b>





Wojskowa  
Akademia  
Techniczna

Wydział  
Elektroniki



## **STRESZCZENIE**

### **Nowatorska metoda diagnostyki wybranych stanów patologii serca oparta na czasowo-częstotliwościowej analizie sygnałów fonokardiograficznych**

Autor: por. mgr inż. Wojciech Lejkowski  
Promotor: prof. dr hab. inż. Andrzej P. Dobrowolski  
Drugi Promotor: dr hab. n. med. Robert Olszewski, prof. NIGRiR

Celem niniejszej rozprawy było opracowanie metody diagnostyki wybranych stanów patologii serca opartej na czasowo-częstotliwościowej analizie sygnałów fonokardiograficznych możliwej do wykorzystania przez personel pielęgniarski. W rozprawie przedstawiono proces zbierania danych diagnostycznych, proces projektowania systemu oraz wyniki klasyfikacji sygnałów fonokardiograficznych.

Rozprawa składa się z trzech logicznych części prezentujących kolejne etapy realizowanych prac. W części pierwszej (rozdziały 1-2) przedstawiona została tematyka fonokardiografii, z którą ściśle związany jest sposób funkcjonowania układu sercowo-naczyniowego i mięśnia sercowego. W tej części autor zaprezentował również napotkane problemy związane z gromadzeniem i akwizycją danych diagnostycznych oraz sposoby ich rozwiązania.

Kolejna część (rozdział 3) prezentuje problem oceny zarejestrowanych danych pod kątem ich jakości. Wskazano problem pojawiania się sygnałów zakłócających, które negatywnie wpływają na działanie systemu. Opisano wektor cech oraz zaprojektowany klasyfikator służący do oceny jakości zarejestrowanych danych diagnostycznych.

Sposób doboru cech oraz porównanie wyników klasyfikacji zaprezentowane są w części trzeciej (rozdziały 4-6). Głównym celem tego etapu jest znalezienie optymalnych parametrów klasyfikatora, zapewniających jak najmniejsze błędy klasyfikacji, przy jednoczesnym zapewnieniu dobrych właściwości separujących.

Ostatnią część pracy stanowi podsumowanie, w którym na podstawie wcześniej zaprezentowanych badań udowodniona została teza niniejszej rozprawy, w brzmieniu: **możliwe jest opracowanie metody diagnostycznej przyporządkowującej zarejestrowane przypadki do klasy chory lub zdrowy z prawdopodobieństwem wystarczającym do współczesnych zastosowań medycznych, z wykorzystaniem sygnałów fonokardiograficznych rejestrowanych w typowych warunkach ambulatoryjnych**. W części tej przedstawiono także przewidywane dalsze obszary prac rozwojowych prezentowanego systemu.

**Słowa kluczowe:** fonokardiogram, analiza widmowa, sieć wektorów nośnych, algorytmy genetyczne, selekcja cech dystynktywnych.

Wojciech Lejkowski  
Warszawa, 30 czerwca 2020 r.



Military  
University  
of Technology

Faculty  
of Electronics



## ABSTRACT

### Innovative method of diagnostics of selected heart diseases based on time and frequency analysis of phonocardiographic signals

Author: Lt Wojciech Lejkowski MSc Eng.  
Supervisor: Prof. Andrzej P. Dobrowolski PhD Eng.  
Co-supervisor: Robert Olszewski PhD MD, Professor of National Institute of Geriatrics, Rheumatology and Rehabilitation

This dissertation aims at developing a method of diagnostics of selected heart diseases based on time-frequency analysis of phonocardiography signals, which can be used by nursing personnel. The dissertation presents the process of collecting diagnostic data, the process of system design and the results of phonocardiography signal classification.

The dissertation consists of three logical parts presenting subsequent stages of the work. The first part (chapters 1-2) presents the subject of phonocardiography, which is closely related to the way of functioning of the cardiovascular system and myocardium. In this part, the author also presents the problems encountered when collecting and acquiring diagnostic data and the methods of solving them.

The next part (chapter 3) presents the problem of evaluation of recorded data in terms of their quality. The author indicates the problem of interference signals, which negatively influence system operation. He describes the vector of features and the designed classifier used to evaluate the quality of the recorded diagnostic data.

The method of selection of features and comparison of classification results are presented in part 3 (Chapters 4-6). The main aim of this stage is finding optimal parameters of the classifier, ensuring the lowest possible classification errors, while delivering good separating properties.

The last part of the dissertation is a summary, proving the thesis of the dissertation on the basis of previously presented studies, as follows: ***it is possible to develop a diagnostic method, assigning recorded cases to a class of a healthy or ill patient, with probability sufficient for modern medical applications, using phonocardiography signals recorded in typical outpatient conditions.*** This section also presents the expected further areas of development of the presented system.

**Keywords:** phonocardiogram, spectral analysis, support vector network, genetic algorithms, selection of distinctive features.

Wojciech Lejkowski  
Warsaw, 30 June 2020

## WPROWADZENIE

Występowanie wad serca wzrasta wraz w populacji wraz z wiekiem. Są one istotnym czynnikiem rozwoju niewydolności serca, arytmii oraz ograniczają sprawność funkcjonalną organizmu. Wraz z wydłużeniem długości życia wczesna diagnostyka i nowoczesne sposoby leczenia mogą poprawić jakość życia oraz je wydłużyć [1], [2]. Choroby układu sercowo-naczyniowego dominują w statystykach Światowej Organizacji Zdrowia (WHO – ang. *World Health Organization*) jako główna przyczyna zgonów na świecie. Według danych Głównego Urzędu Statystycznego, w Polsce z przyczyn chorób serca umiera rocznie około 175 tysięcy osób, co stanowi 46% wszystkich zgonów. Problem jest na tyle poważany, iż Światowa Federacja Serca (WHF – ang. *World Heart Federation*) z udziałem WHO stworzyła Światowy Dzień Ochrony Serca obchodzony od 2000 roku w ostatnią niedzielę września, by alarmować i zwiększać świadomość społeczną dotyczącą chorób serca oraz promować zdrowy styl życia.

Niniejsza rozprawa doktorska dotyczy opracowania skutecznej automatycznej metody diagnostyki wybranych stanów patologii serca na podstawie analizy czasowo-częstotliwościowej sygnału fonokardiograficznego. Proponowane rozwiązanie ma na celu wspomóc subiektywną ocenę

słuchową dźwięków serca poprzez obiektywną analizę matematyczną charakterystycznych tonów serca, w celu wyprowadzenia jak najlepszej diagnozy bądź kwalifikacji do dalszych badań. Obecnie badanie osłuchowe wykonywane przy pomocy stetoskopu kardiologicznego jest jednym z pierwszych etapów badania diagnostycznego, niestety jest ono obarczone błędami związanymi z brakiem doświadczenia, rutyną czy naturalnymi ubytkami słuchu. W dobie wydajnych komputerów oraz z pomocą unikalnych algorytmów cyfrowego przetwarzania i sztucznej inteligencji możliwe jest opracowanie takiej aplikacji, która poprzez analizę matematyczną sygnału fonokardiograficznego, dokona klasyfikacji przypadku przyporządkowując go do grupy prawidłowej bądź patologicznej.

Z badań przeprowadzonych przez autora w zakresie tematyki pracy doktorskiej wynika teza rozprawy w brzmieniu, iż **„możliwe jest opracowanie metody diagnostycznej przyporządkowującej zarejestrowane przypadki do klasy chory lub zdrowy z prawdopodobieństwem wystarczającym do współczesnych zastosowań medycznych, z wykorzystaniem sygnałów fonokardiograficznych rejestrowanych w typowych warunkach ambulatoryjnych”**.

Wykazanie słuszności postawionej tezy opiera się na generacji cech dystynktywnych reprezentujących dany sygnał fonokardiograficzny, który rejestruje się za pomocą elektronicznego stetoskopu medycznego, a następnie w procesie ekstrakcji i selekcji wektora cech buduje się klasyfikator przypadków w oparciu o sieć wektorów nośnych (SVM – ang. *Support Vector Machine*).

Celem niniejszej rozprawy było znalezienie właściwych cech dystynktywnych wskazujących na przyporządkowanie danego sygnału fonokardiograficznego do danej grupy pacjentów, ich ekstrakcja i selekcja, oraz zbudowanie skutecznego klasyfikatora. Obecnie nie stosuje się żadnych metod oceny sygnałów fonokardiograficznych, jednak ograniczenia w dostępie do opieki zdrowotnej wskazują, że badania wykonywane za pomocą dedykowanego stetoskopu lub w przyszłości *smartfona* w domu przyczynią się znacznie do wcześniejszego wykrywania tego typu schorzeń. Do przeprowadzenia analiz wykorzystano sygnały fonokardiograficzne zarejestrowane wśród pacjentów Wojskowego Instytutu Medycznego w Warszawie oraz podchorążych Wojskowej Akademii Technicznej. Rejestracje wykonywał wykwalifikowany personel medyczny pod nadzorem dr. hab. n. med. Roberta Olszewskiego, profesora Narodowego Instytutu Geriatrii, Reumatologii i Rehabilitacji w Warszawie.

W skład rozprawy wchodzi trzy logicznie wyodrębnione części prezentujące kolejne etapy realizowanych prac. Pierwsza z nich (rozdziały 1-2) zapoznaje czytelnika z tematyką fonokardiografii, z którą ściśle związany jest sposób funkcjonowania układu sercowo-naczyniowego i serca. Na tym etapie zaprezentowano również problemy związane z gromadzeniem i akwizycją danych, jakie autor napotkał w trakcie budowania bazy danych oraz sposoby ich rozwiązania.

Kolejna, druga część (rozdział 3) opisuje problem oceny jakościowej zarejestrowanych danych. Wskazano problem pojawiania się sygnałów zakłócających, które mogą negatywnie wpływać na działanie systemu. Opisano zestaw cech oraz zaprojektowany klasyfikator służący do oceny jakości zarejestrowanych danych.

Odpowiednio przeprowadzona selekcja cech stanowi dobry punkt wyjściowy dla budowy klasyfikatorów. Sposób doboru cech oraz porównanie wyników klasyfikacji przedstawione są w części trzeciej (rozdziały 4-6). Głównym celem tego etapu jest dobranie optymalnych parametrów klasyfikatora, zapewniających minimalne błędy klasyfikacji, przy jednoczesnym zapewnieniu dobrych właściwości separujących. Autor wykazuje, iż spośród testowanych klasyfikatorów optymalne rozwiązania uzyskiwane są przy pomocy liniowej sieci wektorów nośnych (SVM).

Zwieńczenie włożonych przez autora wysiłków w przygotowanie niniejszej rozprawy stanowią wnioski końcowe, w których na podstawie wcześniej zaprezentowanych badań udowodniona została postawiona teza.

## **Podziękowania**

Kieruję wyrazy podziękowania do osób, bez których uprzejmości i wyrozumiałości, osiągnięcie wielu z wyznaczonych celów nie byłoby możliwe. W pierwszej kolejności chciałbym podziękować promotorowi, Panu prof. dr. hab. inż. Andrzejowi Dobrowolskiemu za nieocenioną pomoc i dyspozycyjność, którą służył bez względu na porę dnia. Niesamowite oddanie sprawie i pasja, którymi zaraża Pan profesor stanową, przykład do naśladowania dla młodych adeptów sztuki dydaktycznej i naukowej. Pan profesor wykazuje się znakomitą umiejętnością właściwego przewodzenia i motywowania do działania, bez którego osiągnięcie tak długodystansowego celu, jakim jest ukończenie przeze mnie rozprawy doktorskiej, nie byłoby możliwe. Ogromna wiedza i doświadczenie Pana profesora oraz jego umiejętności przywódcze przyczyniły się do mojego prywatnego sukcesu, którego finałem jest ta rozprawa.

Szczere podziękowania kieruję również w stronę drugiego promotora, Pana dr. hab. n. med. Roberta Olszewskiego, prof. NIGRiR, za jego oddanie oraz cenne uwagi z wyjątkowo trudnej dziedziny nauki – medycyny, a w szczególności kardiologii.

Podziękowania składam również na ręce Dyrektora Instytutu Systemów Elektronicznych Wydziału Elektroniki WAT dr. hab. inż. Zbigniewa Watrala oraz Kierownika Zakładu Eksploatacji Systemów Elektronicznych dr. inż. Wiktora Olchowika, za zapewnienie komfortowych warunków podczas studiów doktoranckich. Dziękuję także Panu mgr. inż. Jakubowi Kaźmierczakowi i dr. inż. Mariuszowi Wierzbowskiemu za wspólny czas spędzony podczas prowadzenia zajęć dydaktycznych, oraz panu dr. hab. inż. Jackowi Jakubowskiemu za cenne uwagi dotyczące klasyfikacji sygnałów.

Dziękuję również moim przyjaciołom: dr. inż. Kamilowi Kamińskiemu oraz dr inż. Ewelinie Majdzie-Zdancewicz za wsparcie merytoryczne w czasie wykonywania analiz oraz pisanie rozprawy.

Szczególne podziękowania składam również mojej ukochanej Żonie Martynie, bez której wsparcia i wyrozumiałości nie udało się ukończyć tej rozprawy.

Dziękuję również moim Rodzicom, Małgorzacie i Andrzejowi za ich trud, wyrzeczenia i przekazywane wartości, bez których na pewno nie byłbym dziś tym kim jestem.

Wojciech Lejkowski

Warszawa, 30 czerwca 2020 r.

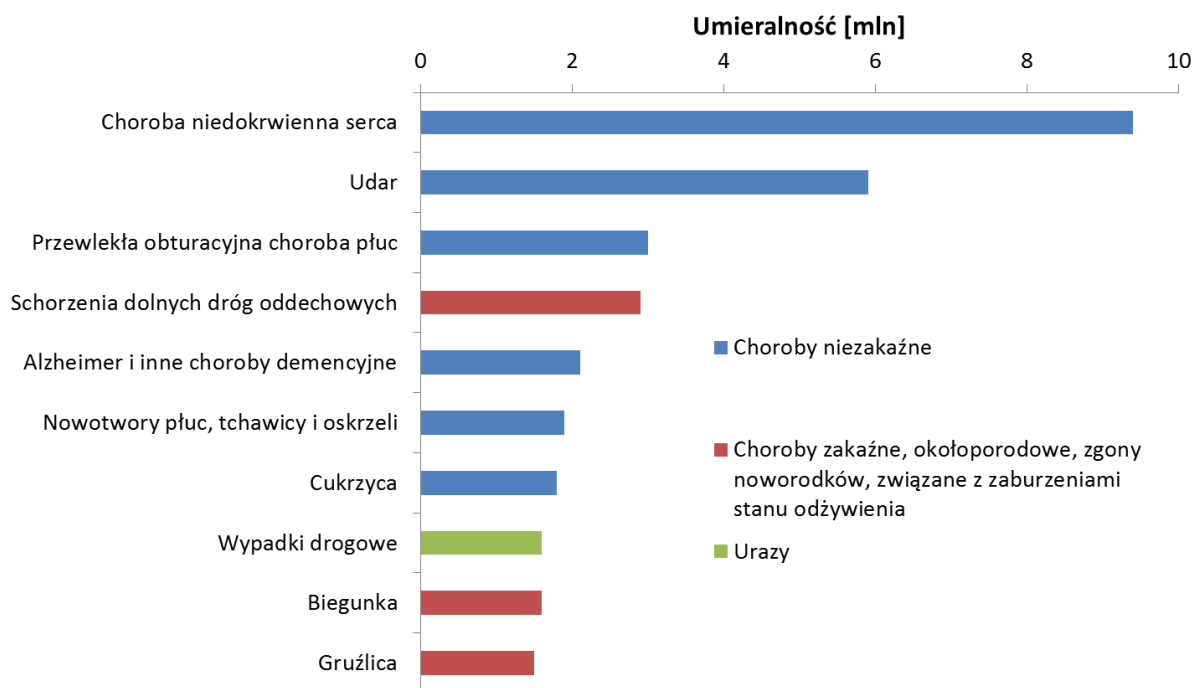
# 1

## FONOKARDIOGRAFIA „WCZORAJ I DZIŚ”

*Renee Laennec* (1781 – 1826) w 1816 r. wynalazł pierwszy stetoskop [3] – urządzenie, które do dziś jest podstawowym narzędziem pracy każdego lekarza rodzinnego, pielęgniarki, internisty czy kardiologa. Osłuchiwanie pracy mięśnia sercowego jest jednym z pierwszych i niezwykle ważnym etapem w diagnostyce lekarskiej stosowanej w kontekście wykrywania nieprawidłowości i chorób układu sercowo-naczyniowego. Osłuchiwanie stetoskopem jest powszechnie stosowane w szczególności u osób starszych, a główną zaletą takiej metody jest bardzo niski koszt badania. W przypadku wątpliwości personelu medycznego, zlecane są kolejne etapy badań, takie jak morfologia krwi, badanie elektrokardiograficzne (EKG), czy specjalistyczne badania obrazowe.

Fonokardiografia to diagnostyczna metoda badania pracy mięśnia sercowego, która polega na graficznym zapisie akustycznych efektów pracy serca. Zarejestrowany fonokardiogram pozwala na bardzo dokładną charakterystykę szmerów sercowych [4].


Niestety mimo szeroko dostępnych zaawansowanych metod obrazowania pracy układu krążenia, choroby serca nadal dominują w statystykach Światowej Organizacji Zdrowia (WHO) jako główna przyczyna zgonów na świecie [5]. Najnowsze dane statystyczne dotyczą roku 2016. Właśnie w tym roku z 56,9 mln zgonów, ponad 15 mln zgonów była spowodowana chorobą niedokrwienną serca i udarem. Choroby te pozostają głównymi przyczynami zgonów na całym świecie w ciągu ostatnich 15 lat [6]. Na chorobę niedokrwienną serca w 2016 r. zmarło ponad 9 mln osób co stanowi ponad 15% wszystkich zgonów zanotowanych na świecie (rys. 1.1).




Rys. 1.1. Dziesięć głównych przyczyn zgonów na świecie wg WHO [6]

Wzrost tempa życia społecznego, a przy tym malejąca aktywność fizyczna, niezdrowe odżywianie i stres psychospołeczny są głównymi odwracalnymi czynnikami utrzymującymi tak wysokie statystyki śmiertelności. Te czynniki powodują powstawania tzw. pokolenia „trzech krzeseł” – „krzesło w pracy, krzesło w samochodzie i krzesło w domu”, co istotnie naraża nasz układ krążenia na rozwój różnych procesów patologicznych. Opracowanie szybkiej i taniej metody wykrywającej choroby układu sercowo-naczyniowego pozwoli na wczesne wdrożenie leczenia i znacznie przyczyni się do zmniejszenia tak wysokiego współczynnika śmiertelności.

W 2014 roku Organizacja Współpracy Gospodarczej i Rozwoju (OECD – ang. *Organisation for Economic Co-operation and Development*) opublikowała najnowszy raport „Health at a Glance 2019” [7] w którym znajdują się dane dotyczące opieki medycznej w danym kraju. W Polsce na 1000 mieszkańców przypada 5,1 pielęgniarki oraz 2,4 lekarza, co jest wynikiem znacznie poniżej średniej na świecie. Według OECD średnio na 1000 mieszkańców przypada 8,8 pielęgniarki (rys. 1.2) oraz 3,5 lekarza (rys. 1.3). Jeżeli chodzi o ilość lekarzy jesteśmy na ostatnim miejscu w krajach europejskich, gorszą wydolność służby zdrowia pod tym kątem prezentują tylko takie kraje jak Meksyk, Chile, Kraje Południowej Afryki czy Indonezja [7].



Rys. 1.2. Ilość praktykujących pielęgniarek na 1000 mieszkańców wg kraju w 2017 r. [7]



Rys. 1.3. Ilość praktykujących lekarzy na 1000 mieszkańców wg kraju w 2017 r. [7]


Aby dogonić średnią europejską powinniśmy do czasu wykształcenia wystarczającej liczby personelu medycznego postawić na telemedycynę i konsultacje pielęgniarskie wspierane wysokospecjalizowanym sprzętem i innowacyjnymi metodami diagnostycznymi. Najnowsze publikacje Europejskiego Towarzystwa Kardiologicznego (ESC – ang. *European Society of Cardiology*) prezentują oszacowane współczynniki prawdopodobieństwa śmierci pacjentów hospitalizowanych ze względu na choroby układu sercowo-naczyniowego świadczą o wysokim poziomie jego istotności [8][9].



## 1.1. Układ sercowo-naczyniowy

Chcąc zrozumieć proces powstawania szmerów i zaburzeń akustycznych w pracy mięśnia sercowego, w pierwszej kolejności należy poznać budowę *układu krążenia* którego głównym „napędowym” elementem jest właśnie *serce*. Ze względu na techniczny charakter niniejszej pracy budowa tego układu zostanie przedstawiona w sposób uproszczony.

Głównym zadaniem całego układu sercowo-naczyniowego jest transport krwi do wszystkich organów w celu dostarczenia substancji odżywczych. Ruch krwi wywołany jest poprzez pracę skurczową serca i różnicę ciśnień pomiędzy układem *tętnicznym* i *żylnym*. Fizjologicznie ciśnienie krwi w aorcie ulega zmianie od około 120 mm Hg ponad ciśnienie atmosferyczne podczas skurczu do około 70 mm Hg podczas rozkurczu [10]. Na rys. 1.4 przedstawiono schemat układu krążenia, widać na nim, że układ obejmuje krążenie duże i małe, rozpoczynające się w sercu przedzielonym podłużną przegrodą na dwie czynnościowo odmienne połowy.



Rys. 1.4. Schemat układu krążenia [11]


Prawa komora tłoczy krew do krążenia małego zwanego płucnym, stamtąd krew napowietrzona wraca do lewej komory która przepompowuje ją do krążenia dużego zwanego układowym, w którym dociera do wszystkich organów.

Serce swoim działaniem przypomina pompę, która w kolejnych cyklach pracy przepompowuje płyn (krew). Przepływowi płynu przez serce w trakcie jego pracy towarzyszą zjawiska akustyczne, które mają charakter dźwięków o niejednorodnej i niskiej częstotliwości od pojedynczych herców do kilkuset herców. Duże znaczenie ma graficzna rejestracja z użyciem fonokardiogramu [12]. Praktycznie wyróżnia się tony serca występujące fizjologicznie oraz patologiczne szmery sercowe. Fonokardiogram umożliwia ustalenie czasowych zależności między tymi zjawiskami. **Pierwszy** ton serca (skurczowy, S1) charakteryzuje się niską częstotliwością (poniżej 45 Hz) i trwa około 200 ms. Dominującym czynnikiem powodującym jego powstawanie jest wibracja struktur sercowych (zastawek i ścian serca) na skutek nagłej zmiany ciśnienia wewnątrzsercowego. Jest on najlepiej słyszalny w koniuszku serca. **Drugi** ton serca (rozkurczowy, S2) charakteryzuje się wyższą częstotliwością (ok. 50 Hz) i trwa nieco krócej, około 120 ms. Jest on najlepiej słyszalny nad podstawą serca w rzucie zastawek półksiężycowych aorty. Jest on powodowany przez napięcie zamykających się zastawek półksiężycowych na początku rozkurczu komór. **Trzeci** ton serca (S3) jest niekiedy słyszalny u ludzi poniżej 30 roku życia, rzadko u ludzi starszych. Pojawia się w czasie rozkurczu w okresie wypełniania komór krwią napływającą z przedsionków i spowodowany jest przez wibracje krwi wypełniającej jamy komór sercowych. **Czwarty** ton serca (S4) jest czasem słyszalny u ludzi dorosłych, natomiast daje się go zarejestrować tylko fonokardiograficznie podczas skurczów przedsionków [10].

Czasami przepływ krwi w sercu może być zaburzony przez zwężenie ujścia albo np. niedomykanie zastawek. Takie akustyczne zaburzenia nazywamy szmerem. Zaburzenie laminarnego przepływu krwi (wiry) bądź przyspieszenie przepływu albo zarzucanie krwi z komór do przedsionków mogą być przyczyną powstawania szmerów.

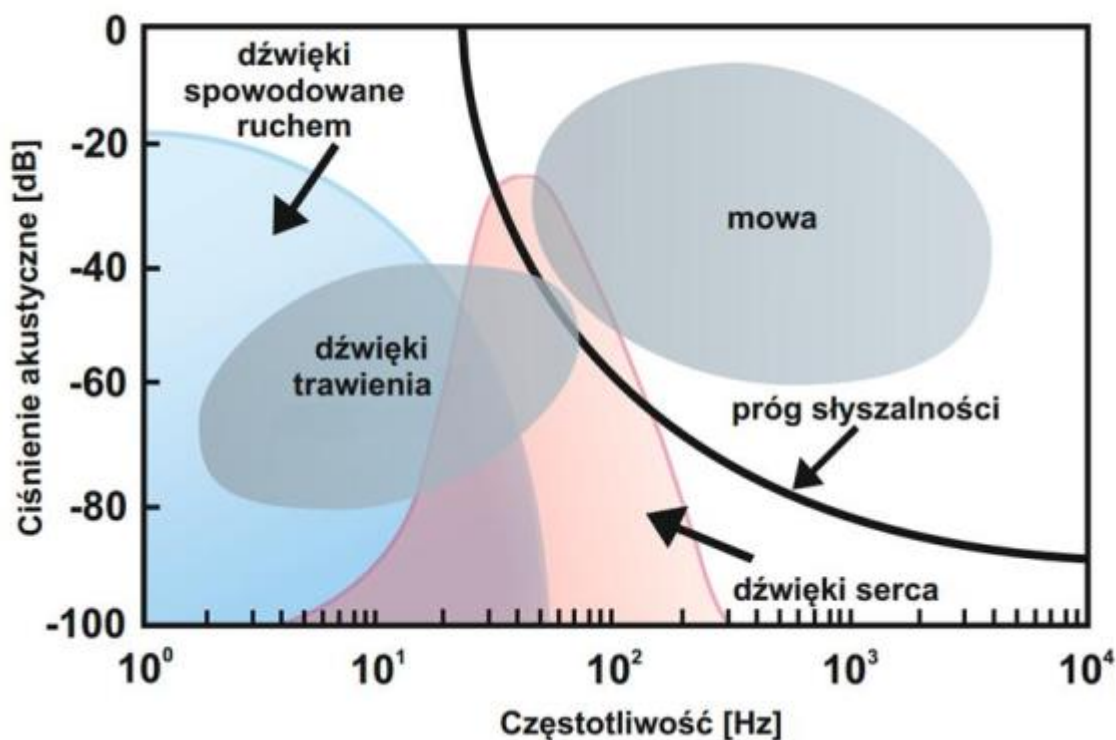
## 1.2. Osłuchiwanie mięśnia sercowego

Osłuchiwanie pracy serca (szmerów i tonów) bezpośrednio uchem (za pomocą stetoskopu) jest obecnie stosowane w pierwszym etapie diagnostyki chorób serca. Metoda ta ma pewne wady, po pierwsze aby była skuteczna, lekarz przeprowadzający osłuchiwanie musi być bardzo doświadczony i w dodatku musi dysponować odpowiednimi predyspozycjami dotyczącymi słuchu. Najgorszy w tym jest fakt, że w miarę jak przybywa doświadczenia, jednocześnie ze względu na wiek pogarsza się czułość słuchu, w wyniku czego doświadczony lekarz może już nie dosłyszeć szmerów. Czynnikiem utrudniającym osłuchiwanie jest fakt, że nie jest ono prowadzone w bezpośredniej bliskości źródła powstawania szmerów i tonów serca. Osłuchiwanie jest wykonywane poprzez tkanki klatki piersiowej, które nie są najlepszym przewodnikiem dźwięków, w efekcie do głowicy stetoskopu dociera stłumiony dźwięk. Tłumienie dźwięków wnoszone przez tkanki jest w przybliżeniu kwadratową funkcją częstotliwości, co oznacza, że dźwięki o wyższej częstotliwości są tłumione silniej, niż dźwięki o częstotliwości niższej [13]. Powyższą zależność pokazano na rys. 1.5.




Rys. 1.5. Tłumienie dźwięków serca przez tkanki klatki piersiowej [13]

Serce wytwarza dźwięki w zakresie częstotliwości od pojedynczych Hz do kilkuset Hz, a większość energii sygnału zawiera się poniżej progu słyszalności człowieka, co zilustrowano na rys. 1.6. W związku z powyższym należy spodziewać się, że znaczna część informacji diagnostycznej znajduje się w obszarze nieosiągalnym do percepcji przez ludzki narząd słuchu, nawet młodego i doświadczonego lekarza specjalisty [14].



Rys. 1.6. Charakterystyka dźwięków serca na tle progu słyszalności oraz sygnałów zakłócających [15]

Według najnowszego raportu przeprowadzonego w ramach Fundacji *Watch Health Care* – Barometr WHC [16] który ma na celu monitorowanie zmian w zakresie dostępu do gwarantowanych świadczeń zdrowotnych (NFZ) czas oczekiwania na wizytę u kardiologa wynosi ponad 2 miesiące, a u kardiologa dziecięcego prawie rok – rys. 1.7. Po wizycie u specjalisty, pacjent zazwyczaj otrzymuje skierowanie na bardziej specjalistyczne badania. Według Barometru WHC czas oczekiwania na badanie echokardiograficzne u dorosłego pacjenta czeka się ponad 2 miesiące, a u dziecka ponad 4 miesiące. Finalnie na wynik badań i opinię kardiologa prowadzącego w przypadku osób dorosłych czeka się około 5 miesięcy, w przypadku dzieci ponad rok. Tak długi czas oczekiwania bez leczenia może prowadzić do pogłębiania się chorób w układzie sercowo-naczyniowym co w skrajnym przypadku może nawet prowadzić do śmierci pacjenta. Dlatego tak niezmiernie ważne są badania przesiewowe wykonywane przez cały personel medyczny, a nie tylko przez lekarzy. Fonokardiografia cyfrowa z wykorzystaniem wyszukanych algorytmów analizujących dane fonokardiograficzne może w przeciągu kilku sekund wskazać nieprawidłowości pracy układu sercowo-naczyniowego, co może przełożyć się na skrócenie czasu oczekiwania do postawienia właściwego rozpoznania i wdrożenia leczenia .



Rys. 1.7. Średni czas oczekiwania na wizytę u specjalisty w grudniu 2019 podany w miesiącach [16]

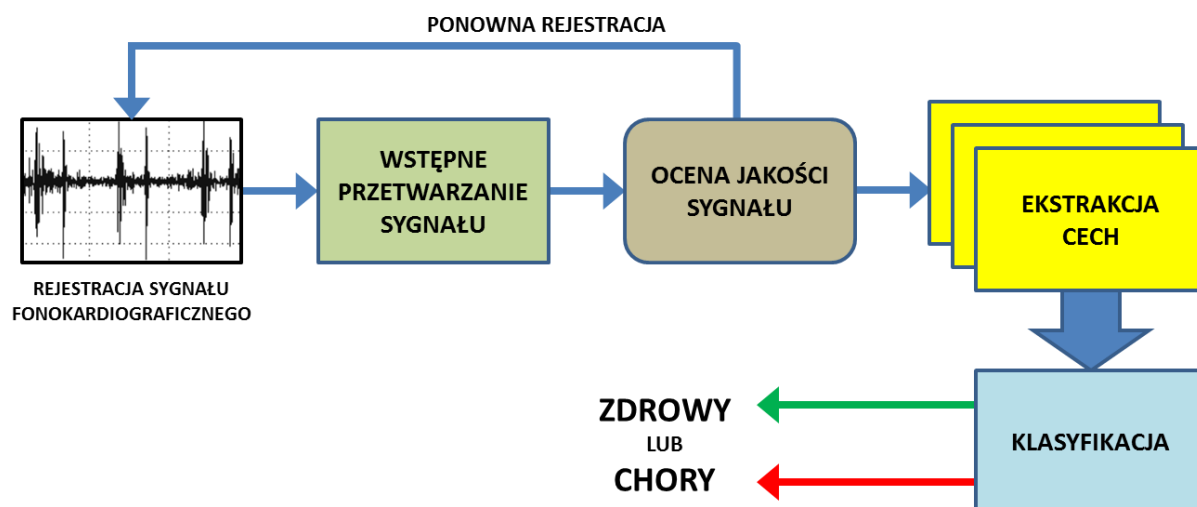
### 1.3. Struktura systemu diagnostycznego opartego o analizę PCG

Struktura systemu diagnostycznego opisanego w niniejszej pracy została przedstawiona na rysunku 1.8. Każdy z prezentowanych modułów systemu zostanie szerzej opisany w kolejnych rozdziałach pracy.

Pierwszy element stanowi akwizycja sygnałów fonokardiograficznych. Mowa tu o sygnałach rejestrowanych za pomocą cyfrowego stetoskopu. W etapie tym znaczenie ma jakość wykorzystywanego sprzętu rejestrującego, a także warunki w jakich zostały zarejestrowane sygnały fonokardiograficzne.

Kolejny etap związany jest oceną jakości zarejestrowanego sygnału. Ważne jest aby analizowany sygnał zawierał charakterystyczne tony serca i jak najmniejszą ilość dźwięków zakłócających. W tym celu został opracowany dedykowany klasyfikator jakościowy, który jest w stanie określić jakość sygnału fonokardiograficznego, a w efekcie jego przydatność do dalszej analizy. W przypadku gdy jakość sygnału jest niezadowolająca, lekarz wykonujący badanie może je powtórzyć.

Kluczowym etapem jest ekstrakcja cech dystynktywnych z sygnału fonokardiograficznego. Podczas tego etapu z zarejestrowanych rejestracji wydobywany jest zestaw cech, który powinien zapewniać rozróżnienie stanu zdrowia danego pacjenta. Ponadto, wobec cech stawiane jest wymaganie, aby nie wymagały dużej ilości obliczeń oraz były niezależne np. od wieku czy płci pacjenta.



Rys. 1.8. Struktura systemu diagnostycznego opartego o analizę sygnałów fonokardiograficznych

W niniejszej rozprawie zaproponowano zastosowanie klasycznej, fourierowskiej analizy widmowej, która pozwala na opis sygnału fonokardiograficznego w sposób parametryczny. Zastosowanie analizy spektralnej jest podyktowane fizjologią ludzkiego słuchu gdyż w procesie percepcji, przed etapem analizy dźwięku w sieciach neuronowych mózgu, następuje etap wydzielenia składowych o poszczególnych częstotliwościach przez wyspecjalizowane struktury ucha wewnętrznego. Zatem biologiczny odbiornik analizuje głównie widmo amplitudowe sygnału i już bardzo dawno stwierdzono, że ucho ludzkie jest bardzo czułym analizatorem częstotliwości. Ten niezmiernie istotny fakt (poparty milionami lat ewolucji) przemawia za stosowaniem metod częstotliwościowych do analizy sygnałów akustycznych [17].

W etapie klasyfikacji, wydobyte cechy są poddawane działaniu klasyfikatora, który przyporządkowuje przypadki do odpowiedniej grupy pacjentów – „chorzy” lub „zdrowi”.

## 1.4. Podsumowanie

W niniejszym rozdziale zaprezentowano zagadnienia związane z sygnałami fonokardiograficznymi w nawiązaniu do chorób układu sercowo-naczyniowego. W dużym uproszczeniu przedstawiono budowę układu krążenia człowieka oraz rolę mięśnia sercowego w całym procesie transportu krwi. Powiązano poszczególne tony serca z etapami pracy mięśnia sercowego oraz wskazano ich właściwości fizyczne takie jak częstotliwość podstawowa i czas trwania. Wskazano również problem dotyczący niedoskonałości ludzkiego narządu słuchu w kwestii osłuchiwania serca, oraz wskazano niezbyt optymistyczne statystyki dotyczące czasu oczekiwania pacjenta na pełną diagnostykę specjalistycznymi metodami lekarskimi. W ten sposób wyraźnie zaznaczono przydatność lekarską na zautomatyzowany system detekcji stanów patologii układu sercowo-naczyniowego we wczesnym etapie badań. W rozdziale zaprezentowano również strukturę systemu diagnostycznego, która szerzej została opisana w kolejnych rozdziałach.

# 2

## **ŹRÓDŁO I CHARAKTERYSTYKA DANYCH DIAGNOSTYCZNYCH**

Badania naukowe, szczególnie w dziedzinie elektroniki biomedycznej są ściśle powiązane z danymi. Żaden rezultat badania naukowego nie może być przedstawiony bez szczegółowego omówienia metodyki zbierania danych. Dzięki danym możliwe jest odkrywanie nowych zależności i precyzowanie już istniejących. Postęp wiedzy naukowej jest możliwy właśnie dzięki zbieraniu i przetwarzaniu danych. Właściwa rejestracja i interpretacja danych jest podstawą prowadzenia wszystkich badań naukowych.

W niniejszym rozdziale zostanie przedstawiony proces akwizycji i rejestracji danych diagnostycznych, którymi są dźwięki wytwarzane przez ludzkie serce. W trakcie nieustannego przepompowywania krwi serce generuje dźwięki w paśmie rozpoczynającym się w okolicy pojedynczych herców i kończącym się w obszarze 200-300 Hz [18]. Należy jednak zauważyć, że większość energii znajduje się poniżej progu słyszalności, co może być istotną przeszkodą w pełnej analizie dźwięku przez nawet bardzo doświadczonego lekarza.

## 2.1. Stetoskop

W celu osłuchania pacjenta, tj. percepcji dźwięków generowanych wewnątrz ludzkiego organizmu wykorzystuje się stetoskop. Jest to przyrząd wynaleziony przez francuskiego lekarza *René Laenneca* w 1816 r [3]. Budowa współczesnego stetoskopu została przedstawiona na rys 2.1 Składa się on z głowicy i zespołu liry z drenem.



Rys. 2.1. Budowa stetoskopu [19]

**Głowica** jest elementem stetoskopu przenoszącym drgania z wybranego fragmentu ciała do zespołu liry z drenem. Dren i lira tworzą falowód przekazujący zmiany ciśnienia akustycznego wprost do ucha wewnętrznego lekarza osłuchującego. Głowice wykonuje się ze stali nierdzewnej, mosiądzu z nałożoną powłoką galwaniczną lub z aluminium. Głowica może występować w formie jednostronnej lub dwustronnej (rys. 2.2).



Rys. 2.2. Głowica jednostronna i dwustronna [19]

Głowica dwustronna wyposażona jest w możliwość zmiany trybu pracy poprzez obrót korpusu wokół tłoczka. Głowica jednostronna pracuje tylko w trybie membrany, który umożliwia dobry osłuch w zakresie wysokich częstotliwości, natomiast głowice dwustronne mogą pracować w trybie membrany oraz lejka, który umożliwia lepszy osłuch w zakresie niskich częstotliwości.



**Membrana** jest elementem głowicy, który ma bezpośredni kontakt ciałem pacjenta. Wpływa ona na czułość stetoskopu, powtarzalność pomiarów i trwałość. W zależności od zastosowań membrany i lejki wykonuje się w różnych rozmiarach. W środowisku medycznym przyjęto, że dla stetoskopów kardiologicznych średnica membrany jest największa i wynosi od 45 do 50 mm, zaś średnica lejka wynosi od 25 do 30 mm.

**Lira** jest to zespół połączonych elementem sprężystym, metalowych, sztywnych ramion zakończonych **oliwkami**. Lirę wykonuje się również z wysokiej jakości materiałów, takich jak stal nierdzewna, chromowany mosiądz czy aluminium. Jakość wykonania liry wpływa w szczególności na trwałość i wpływ zakłóceń zewnętrznych na osłuchiwany sygnał. Lira zakończona jest oliwkami, czyli miękkimi nakładkami które wpasowują się szczelnie w ucho lekarza osłuchującego.

**Dren** łączy lirę z głowicą. Jest on falowodem akustycznym przenoszącym zmiany ciśnienia akustycznego wytworzone w głowicy do liry. Dren jest bardzo ważnym elementem stetoskopu, ponieważ jego budowa określa sposób transmisji dźwięku i poziom izolacji akustycznej od zewnętrznych zakłóceń. Jakość wykonania drenu determinuje mechaniczne i eksploatacyjne parametry stetoskopu oraz jego estetykę. W stetoskopach kardiologicznych używane są dreny dwukanałowe tzn. takie w których transmisja dźwięku od głowicy przebiega oddzielnym, niezależnym kanałem do każdego ucha. Ma to duży wpływ na izolację sygnałów od świata zewnętrznego.

## 2.2. Stetoskop elektroniczny JABES

Stetoskop elektroniczny składa się z funkcjonalnie takich samych elementów jak stetoskop akustyczny, przy czym dodatkowo wyposażony jest w wyjście sygnału elektrycznego *Audio* lub interfejs komunikacyjny umożliwiający cyfrową rejestrację i wstępne przetwarzanie sygnału audio. Do pierwszych prób rejestracji sygnałów fonokardiograficznych, wykonanych przez autora wykorzystano zaprezentowany na rys. 2.3 stetoskop elektroniczny JABES.



Rys. 2.3. Stetoskop elektroniczny JABES [20]

Stetoskop JABES wyposażony jest m.in. w dedykowane filtry częstotliwościowe do osłuchu różnych pasm częstotliwości. Podstawowe parametry zostały wyszczególnione w tabeli 2.1. Powyższe urządzenie posiada wyjście analogowe audio 3,5 mm typu *Jack*. W celu rejestracji sygnału fonokardiograficznego w formie cyfrowej należało sygnał analogowy stetoskopu poddać próbkowaniu i zarejestrować go w pamięci komputera. Istotę przetwarzania analogowo-cyfrowego przedstawiono w kolejnym podrozdziale.




Tabela 2.1. Dane techniczne stetoskopu elektronicznego JABES [20]

Lp.	Parametr	Opis
1	Skala akustyczna	7
2	Wykończenie głowicy	Stal nierdzewna
3	Wykonanie membrany	Epoksydowa / włókno szklane
4	Wykonanie liry	Anodowane aluminium
5	Waga	170 g
6	Zakres częstotliwości	Lejek (BELL MODE) (20 – 200)Hz, Membrana (DIAPHRAGM MODE) (200 – 500)Hz, Szerszy zakres (WIDE MODE) (20 – 1000)Hz
7	Regulacja głośności	10 poziomowa
8	Poziom sygnału na wyjściu	$2 V_{p-p}$
9	THD (Total Harmonic Distortion)	0,04%
10	SNR (Signal Noise Ratio)	101 dB
11	Maksymalny poziom dźwięku	32 dB
12	Minimalny poziom dźwięku	6 dB
13	Zasilanie	2 x 1,5V AAA

### 2.3. Proces przetwarzania analogowo-cyfrowego sygnału PCG

Przetwarzanie analogowo-cyfrowe, potocznie zwane próbkowaniem sygnału, to zamiana ciągłego w czasie i wartości przebiegu napięcia na odpowiadający mu dyskretny ciąg wartości podawanych z określonym, najczęściej stałym odstępem czasowym (tzw. próbkowanie równomierne). Podczas przetwarzania sygnału do postaci cyfrowej następuje dyskretyzacja sygnału zarówno w dziedzinie czasu (próbkowanie), jak i w dziedzinie wartości sygnału (kwantyzacja) [21]. Istotę przetwarzania analogowo-cyfrowego (A/C) przedstawiono na rys. 2.4. Podstawowym wnioskiem jaki nasuwa się podczas analizy procesu przetwarzania analogowo-cyfrowego jest fakt, że sygnały analogowe mogą być reprezentowane przez ich cyfrowe odpowiedniki ze skończoną dokładnością. Dokładność ta jest determinowana zarówno przez częstotliwość próbkowania sygnału – odstępy czasowe akwizycji próbek, jak i rozdzielczość przetwornika analogowo-cyfrowego – liczba poziomów kwantyzacji (bezpośrednio skorelowana z liczbą bitów). Poprzez odpowiednie dobranie częstotliwości próbkowania oraz liczby bitów przetwornika A/C można uzyskać wymaganą dokładność reprezentacji sygnału analogowego w jego formie cyfrowej. Należy pamiętać, że wzrost częstotliwości próbkowania i/lub wzrost liczby poziomów kwantyzacji wpływa na złożoność systemu i czas obliczeń matematycznych wykonywanych na sygnale.



Rys. 2.4. Porównanie sygnału analogowego (czarna linia), dyskretnego (niebieskie punkty) i cyfrowego (czarna kropka)

Stetoskop cyfrowy JABES wyposażony jest w trzy dedykowane filtry cyfrowe. Filtr o najszerszym paśmie (*wide mode*) pracuje w zakresie częstotliwości do 1 kHz. Zgodnie z *twierdzeniem o próbkowaniu*, częstotliwość próbkowania sygnału powinna być co najmniej dwukrotnie większa od maksymalnej składowej częstotliwości sygnału próbkowanego. W omówionym w dalszej części *rejestratorze fonokardiogramów* przyjęto nadmiarowo częstotliwość próbkowania równą 10 kHz czyli pięciokrotnie więcej niż wymagana minimalna częstotliwość próbkowania.

## 2.4. Rejestrator fonokardiogramów – hardware


Urządzeniem próbkującym sygnał wyjściowy ze stetoskopu cyfrowego JABES jest opracowany i wykonany przez autora *rejestrator fonokardiogramów* [22][23][24]. Jest to w pełni funkcjonalne urządzenie, które zostało wykonane w celu rejestracji fonokardiogramów przez personel medyczny. Urządzenie zostało zaprojektowane tak, aby możliwa była akwizycja analogowego sygnału akustycznego *PCG* (ang. *Phonocardiogram*) i jego konwersja do postaci cyfrowej z jednoczesną rejestracją sygnału *EKG* badanego pacjenta. Transmisja danych z urządzenia do komputera odbywa się poprzez interfejs USB. Dodatkowo należało zapewnić wysoką jakość napięcia zasilania przy jednoczesnym spełnieniu warunku zasilania z portu USB komputera [25]. Jednym z warunków **bezpiecznej** pracy urządzenia było zapewnienie separacji galwanicznej układu zasilania i toru pomiarowego. W tej części pracy przedstawiono i omówiono tylko istotne fragmenty schematów urządzenia. Pełna dokumentacja dostępna jest w załączniku nr 1 (Z.1).

Jednym z podstawowych elementów rejestratora fonokardiogramów jest układ przetwarzania A/C. Przy wyborze odpowiedniego przetwornika A/C kierowano się m.in. takimi parametrami jak:

- rozdzielczość przetwornika,
- możliwie niski współczynnik zawartości harmonicznych THD,
- niski błąd nieliniowości różniczkowej (DNL),
- niski błąd nieliniowości całkowitej (INL).


Ostatecznie wybór padł na przetwornik *ADS8866* wyprodukowany przez firmę *Texas Instruments*. Układ ten to przetwornik z aproksymacją postępującą (*SAR* – ang. *Successive Aproximation Register*) [26], charakteryzujący się rozdzielczością 16 bitową, co daje  $2^{16}$  poziomów kwantyzacji.

Nieliniowość różniczkowa (DNL – ang. *Differential NonLinearity*) charakteryzuje lokalne odchylenia charakterystyki przetwarzania przetwornika od linii prostej [23]. Na rys. 2.5 po lewej stronie przedstawiono charakterystykę przetwarzania przetwornika A/C który charakteryzuje się współczynnikiem  $|DNL| < 1LSB$ , natomiast po prawej stronie można zauważyć pominięty kod, co wskazuje na większy od  $1LSB$  współczynnik DNL. Przetwornik *ADS8866* posiada współczynnik DNL na poziomie  $\pm 1,0LSB$  [26].



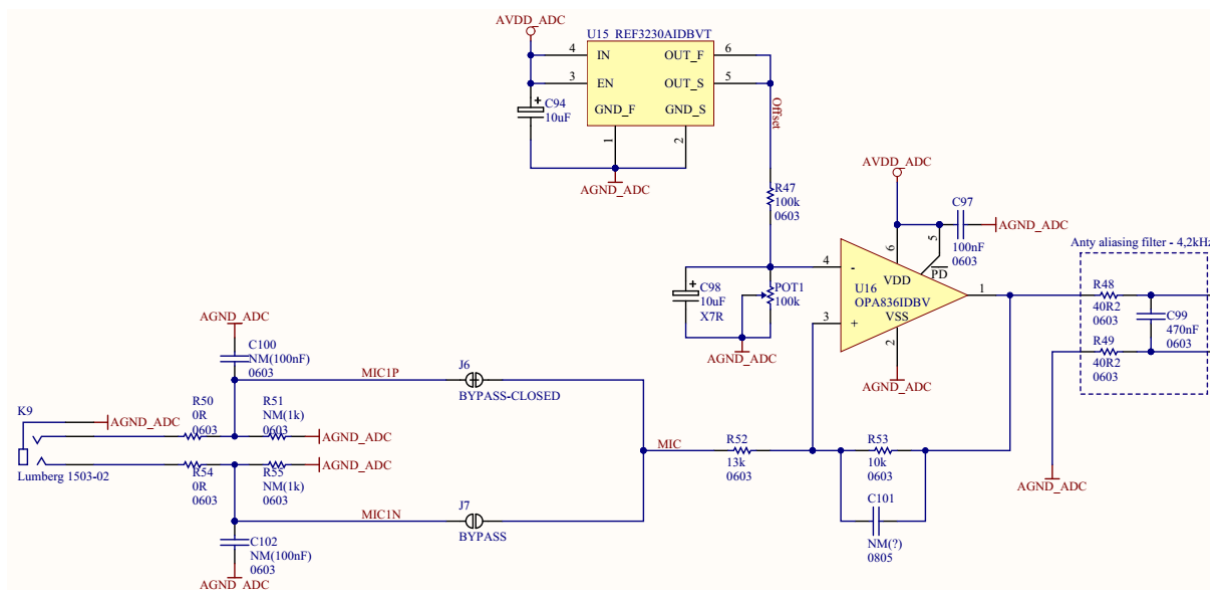
Rys. 2.5. Interpretacja graficzna nieliniowości różniczkowej dla przetwornika A/C

Nieliniowość całkowita (*INL* – ang. *Integral NonLinearity*) charakteryzuje największe odchylenie rzeczywistej charakterystyki przetwarzania od linii prostej, dla przetwornika *ADS8866* wynosi on  $\pm 1,0LSB$  [26], a jego interpretacja graficzna została przedstawiona na rys. 2.6.



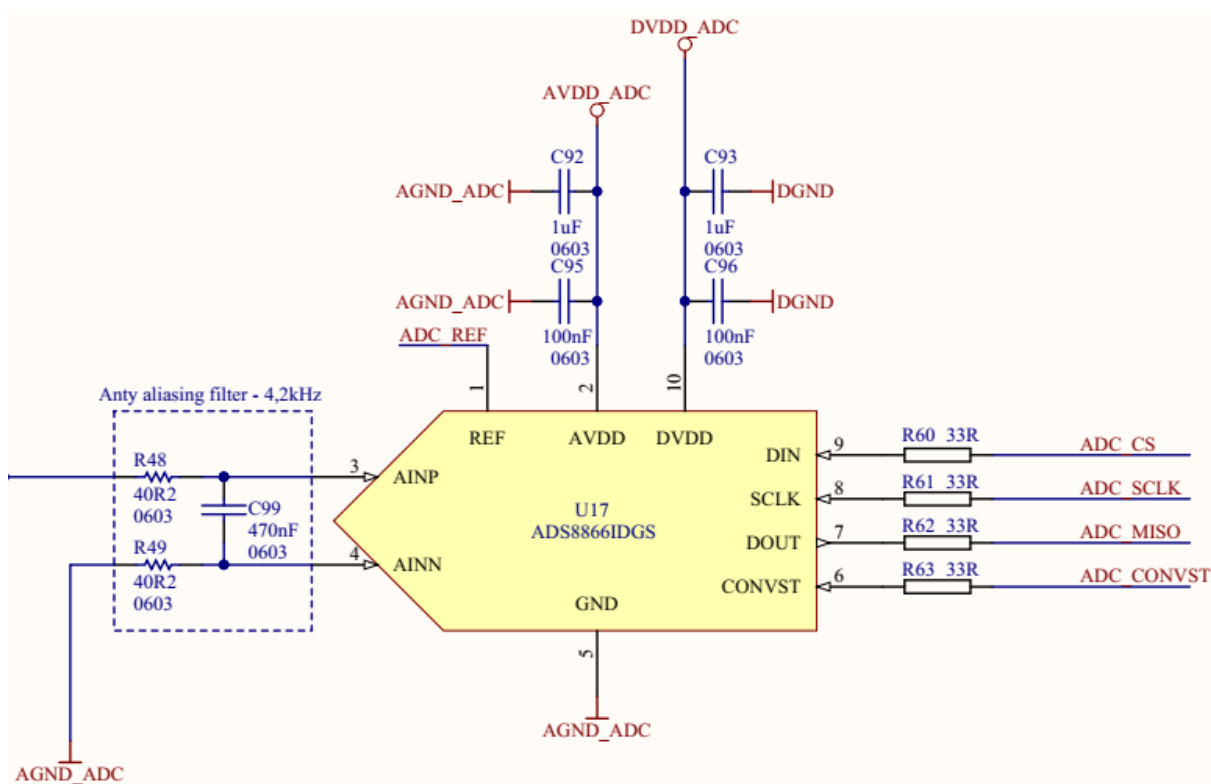
Rys. 2.6. Interpretacja graficzna nieliniowości całkowitej

Przetwornik *ADS8866* w rejestratorze pomiarowym pełni główną funkcję – realizuje przetwarzanie analogowo-cyfrowe sygnału wyjściowego ze stetoskopu cyfrowego *JABES*. Przed przetwornikiem zaprojektowano układ kondycjonujący sygnał wejściowy dostosowany do parametrów wejściowych przetwornika A/C [27]. Schemat ideowy układu wejściowego został zaprezentowany na rys. 2.7.



Rys. 2.7. Schemat układu wejściowego przetwornika A/C

Sygnał analogowy ze stetoskopu cyfrowego jest dostarczany do układu przez gniazdo *K9*. W zależności od zamkniętego obwodu *J6* lub *J7*, sygnał dociera na wejście nieodwracające wzmacniacza operacyjnego *U16 OPA836* typu *rail-to-rail*, który wraz z źródłem napięcia odniesienia *U15 REF3230* tworzy wzmacniacz nieodwracający z dodatkową składową stałą, który dopasowuje amplitudę sygnału wejściowego do obwodów wejściowych przetwornika A/C. Między wyjściem wzmacniacza operacyjnego *U16* a wejściem przetwornika A/C znajduje się filtr antyaliasingowy złożony z elementów *R48*, *R49* oraz *C99*. Na rys. 2.8 przedstawiono schemat podłączenia przetwornika wraz filtrem antyaliasingowym.




Rys. 2.8. Schemat podłączenia przetwornika ADS8866

Do wejścia napięcia referencyjnego (REF) przetwornika podłączone jest wysokostabilne źródło napięcia referencyjnego 3,0 V *REF3230*, które charakteryzuje się dokładnością 0,01% i dryftem napięcia na poziomie 4 ppm/°C [28].

Rezystory R48 i R49 oraz kondensator C99 tworzą antyaliasingowy filtr dolnoprzepustowy o górnej częstotliwości granicznej określonej wzorem [29] (2.1)

$$f_{-3dB} = \frac{1}{2\pi \cdot (R48 + R49) \cdot C99} = \frac{1}{2\pi \cdot (40,2 + 40,2) \cdot 470 \cdot 10^{-9}} \approx 4,21 \text{ kHz} \quad (2.1)$$

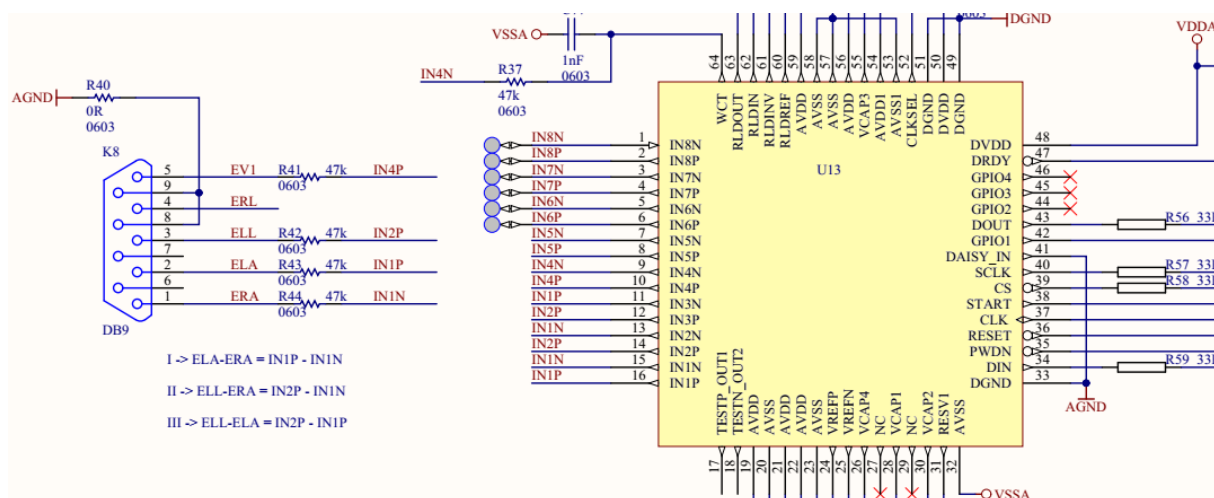
Na rys. 2.9 przedstawiono wyznaczoną symulacyjnie charakterystykę filtra antyaliasingowego – spadek amplitudy o 3 dB i przesunięcie fazy sygnału o  $-44,88^\circ$ , występuje na częstotliwości 4,19 kHz.



Rys. 2.9. Charakterystyka częstotliwościowa filtra antyaliasingowego

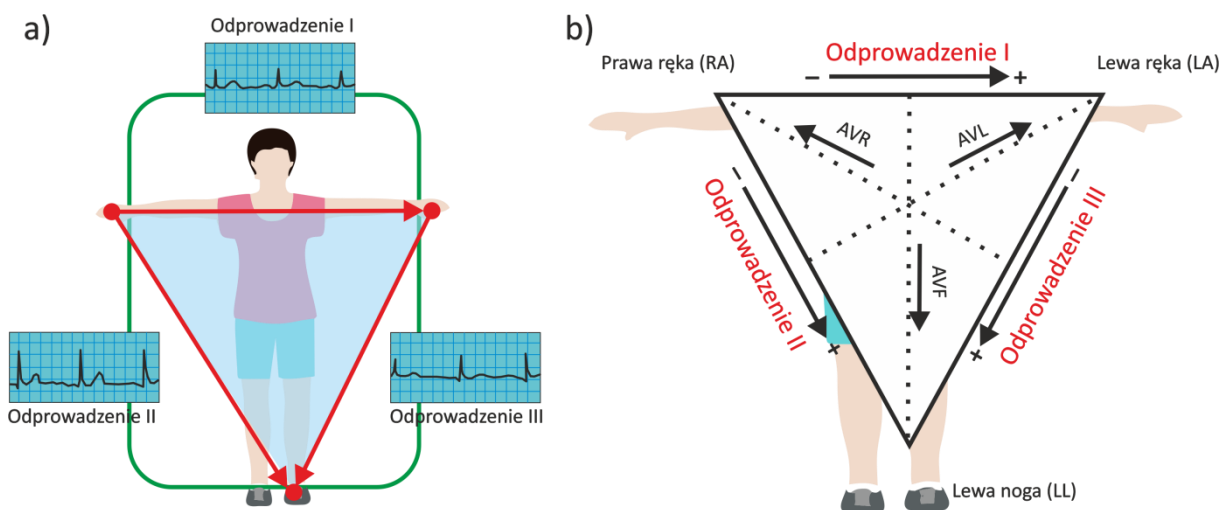
W celu akwizycji sygnału EKG pacjenta wykorzystano oddzielny tor pomiarowy, którego celem jest rejestracja sygnału EKG synchronicznie z sygnałem PCG. Sygnał EKG w odniesieniu do sygnału PCG jest sygnałem dolnopasmowym o małej amplitudzie i niskiej częstotliwości górnej. Do rejestracji tego sygnału zastosowano przetwornik *ADS1296*, jest to sześciokanałowy, 24 bitowy przetwornik typu Sigma-Delta, który dedykowany jest do współpracy z sygnałami EKG, EEG i EMG. Każdy kanał wyposażony jest w filtr *EMI* (ang. *ElectroMagnetic Interference*) oraz układ wzmacniaczy pozwalający na dostosowanie wzmocnienia każdego z kanałów. Przetwornik, ze względu na pracę z sygnałami symetrycznymi, został zasilony napięciem symetrycznym, co nieco skomplikowało budowę układu zasilania.

Na rys. 2.10 przedstawiono fragment toru pomiarowego sygnału EKG. Układ U13 to omawiany wyżej przetwornik *ADS1296*. Pełny schemat toru pomiarowego EKG został zamieszczony w załączniku 1 (Z.1). Obsługiwane wejścia przetwornika zostały podłączone do gniazda DB9. Jak można zauważyć na podstawie schematu zastosowano tutaj pomiar 3 odprowadzeniowego EKG.



Rys. 2.10. Fragment toru pomiarowego EKG

Elektrody podłączono zgodnie ze schematem wskazanym na rys. 2.11.



Rys. 2.11. Schemat podłączenia 3 odprowadzeniowego EKG

- Elektroda I – pomiar między lewym i prawym ramieniem (ELA – ERA: Left Arm – Right Arm).
- Elektroda II – pomiar między lewą nogą i prawym ramieniem (ELL – ERA: Left Leg – Right Arm).
- Elektroda III – pomiar między lewą nogą i lewym ramieniem (ELL – ELA: Left Leg – Left Arm).

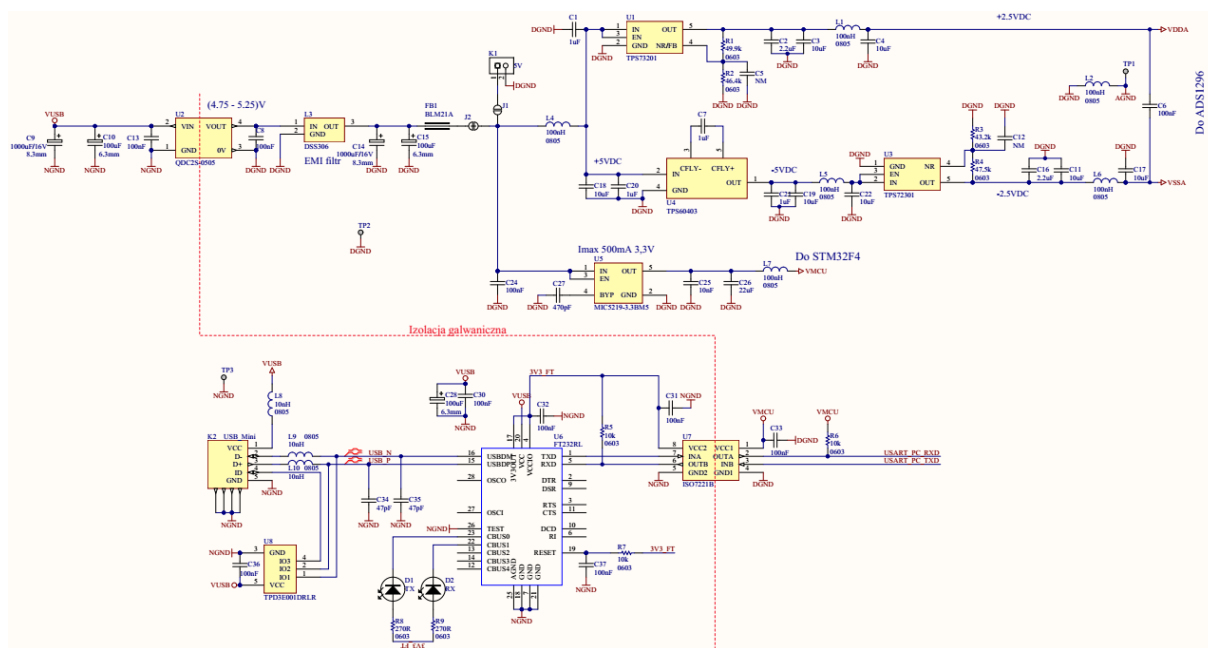
Oba toru pomiarowe (PCG i EKG) rejestratora fonokardiogramów zarządzane są poprzez 32 bitowy mikrokontroler o architekturze RISC z rdzeniem ARM Cortex-M4: *STM32F437* [23]. Program procesora został napisany w języku C w standardzie C99 (ISO/IEC 9989:1999). Po włączeniu zasilania, w pierwszej kolejności odbywa się inicjalizacja systemu zegarowego. Procesor jest „rozpędzany” do częstotliwości 180 MHz. Następnie następuje inicjalizacja komunikacji USB, konfiguracja przetwornika EKG (*ADS1296*) oraz PCG (*ADS8866*). Rejestrator fonokardiogramów współpracuje z dedykowaną aplikacją zainstalowaną na komputerze PC. Opis tej aplikacji został zamieszczony w podrozdziale 2.6. W stanie bezczynności rejestrator fonokardiogramów czeka na polecenia z aplikacji sterującej.

Omawiany rejestrator fonokardiogramów dodatkowo został wyposażony w slot karty pamięci (*microSD*), na której zapisywane są próbki zarejestrowanych sygnałów wraz z parametrami pomiaru. Ponadto urządzenie wyposażono w moduły *Bluetooth* oraz *Wi-Fi* służące do zdalnej transmisji danych na serwer zewnętrzny lub telefon komórkowy.

Najtrudniejszą do zaprojektowania i wykonania częścią rejestratora był układ zasilania. Na samym wstępie założono, że jedynym źródłem zasilania urządzenia ma być port USB komputera, który

jednocześnie zapewnia transmisję danych. Systemy rozdzielające zasilanie na porty USB w komputerach nie zapewniają wysokiej jakości zasilania. Według specyfikacji napięcie zasilające dla standardu USB 1.1/2.0 może wahać się między 4,75 V i 5,25 V, natomiast dla standardu USB 3.0 zakres ten jest szerszy i wynosi 4,45-5,25 V. Maksymalna wydajność prądowa dla standardu USB 1.1/2.0 to 500 mA, a dla USB 3.0 – 900 mA [30].

Rejestrator fonokardiogramów wyposażony jest w dwa analogowe torry pomiarowe, których czułość jest ograniczona m.in. przez szumy własne będące pochodną szumów zasilania. Im gorsza jakość układu zasilania (większe szumy i tętnienia) tym mniejsza efektywność bitowa przy przetwarzaniu A/C oraz większy udział szumu w rejestrowanym sygnale. Ponadto urządzenie służące do wykonywania pomiarów EKG, ze względów bezpieczeństwa pacjenta powinno posiadać separację galwaniczną układu zasilania. Standard USB zapewnia zasilanie niesymetryczne +5 V, a przetwornik EKG wymaga zasilania symetrycznego  $\pm 2,5$  V. Potrzeba wytworzenia ujemnego napięcia zasilającego  $-2,5$  V dodatkowo rozbudowała układ zasilania, którego schemat przedstawiono na rys. 2.12.




Rys. 2.12. Schemat układu zasilania rejestratora fonokardiogramów

W pierwszej kolejności napięcie zasilające z portu USB poprzez baterię kondensatorów trafia na przetwornicę DC/DC, która zapewnia separację galwaniczną. Kolejnym elementem jest scalony filtr EMI, którego częstotliwość rezonansowa wynosi około 100 MHz. Następnie za filtrem złożonym z kondensatora i dławika następuje rozdzielenie napięcia na poszczególne segmenty zasilające.

Procesor zarządzający oraz moduły komunikacyjne zasilane są przez stabilizator LDO (ang. *Low-Dropout*) *MIC5219*, na którego wyjściu uzyskujemy zasilanie cyfrowe *VMCU* o wartości 3,3 V. Maksymalna wydajność powyższego stabilizatora to 500 mA. Kolejnym elementem w innej gałęzi jest stabilizator LDO *TPS73201* dostarczający napięcia dodatniego 2,5 V. Inwerter *TPS60403* i stabilizator napięcia ujemnego *TPS72301*, przekształcają napięcie wejściowe na  $-2,5$  V i zasilają część analogową urządzenia. Masa analogowa jest odseparowana od cyfrowej cewką L2. W dolnej części schematu znajduje się moduł komunikacyjny wraz z układem *ISO7221B* który zapewnia izolację galwaniczną szyny komunikacyjnej. Układ ten może przesyłać dane z maksymalną szybkością 5 Mb/s.


W celu sprawdzenia jakości napięcia zasilającego wykonano pomiary oscyloskopowe poszczególnych fragmentów układu zasilania. Pomiary wykonano oscyloskopem *LeCroy-9361*. Na rys. 2.13 przedstawiono przebieg czasowy napięcia zasilania na złączu USB. Pomiar wykonano przy odchyłaniu pionowym 20 mV/dz. Na przebiegu widoczne są silne szpilki zakłócające o amplitudzie około 50 mV i częstotliwości około 200 MHz. Są to prawdopodobnie momenty przełączania cewki przetwornicy

USB. Tak silne zakłócenia mogłyby wpłynąć negatywnie na pracę przetworników EKG i PCG. Zasilanie tych układów bezpośrednio ze złącza USB byłoby niedopuszczalne.



Rys. 2.13. Oscylogram napięcia zasilającego na wyjściu portu USB


Na rys. 2.14 przedstawiono przebieg czasowy napięcia zasilającego część cyfrową czyli procesor sterujący wraz z układami komunikacyjnymi. Pomiar wykonano przy odchyłaniu pionowym 5 mV/dz. Nadal można zauważyć szpilki zakłócające pojawiające się co około 5  $\mu$ s o amplitudzie około 5 mV. Filtry w części zasilającej zredukowały amplitudy zakłóceń około czterokrotnie.



Rys. 2.14. Oscylogram napięcia zasilającego część cyfrową


Na 2.15 przedstawiono przebieg czasowy napięcia zasilającego część analogową. Można zaobserwować szpilki o małej amplitudzie. W porównaniu do napięcia zasilającego z portu USB znacząco poprawiono jakość zasilania sekcji analogowej. Widać zmniejszenie tętnień i wygładzenie napięcia zasilającego. Bez wątpienia ma to ogromny wpływ na jakość pracy urządzenia.





Rys. 2.15. Oscylogram napięcia zasilającego część analogową

Na rys. 2.16 przedstawiono fotografię zaprojektowanego i wykonanego urządzenia, które spełnia wszystkie założenia projektowe i osiągnęło pełną funkcjonalność. W dalszej części pracy omówiono aplikacje do zarządzania rejestratorem.

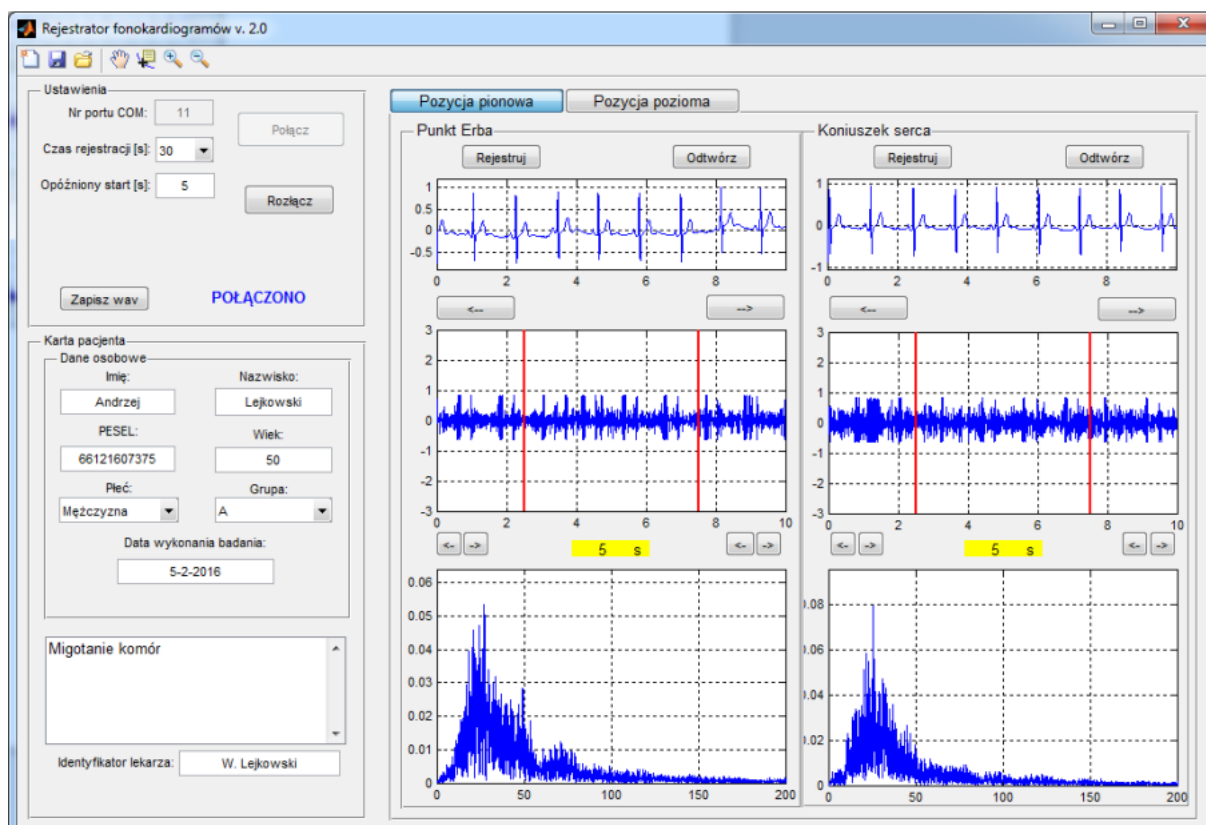


Rys. 2.16. Fotografia wykonanego rejestratora fonokardiogramów

## 2.5. Rejestrator fonokardiogramów – aplikacja

Sterowaniem i akwizycją danych za pomocą omawianego wcześniej rejestratora fonokardiogramów zajmuje się autorska aplikacja, która została napisana w środowisku *Matlab*. Dzięki niej współpracujący personel medyczny mógł zebrać odpowiednią ilość danych niezbędnych do utworzenia wymaganej bazy danych. Za pośrednictwem aplikacji próbki sygnałów PCG i EKG są strumieniowo przesyłane z urządzenia do pamięci komputera z prędkością 1Mb/s i zapisywane na

dysku twardym komputera w formie plików \*.mat. Okno główne aplikacji zostało zaprezentowane na rys. 2.17.



Rys. 2.17. Okno główne aplikacji sterującej rejestratorem fonokardiogramów

Personel medyczny wykonujący rejestrację (lekarz lub pielęgniarka) przy pomocy aplikacji może ustawić czas rejestracji w sekundach (od 1 do 30 s). Dodatkowo pomocna jest opcja opóźnionego startu, która domyślnie ustawiona jest na 5 s. Opcja ta daje odpowiedni czas osobie wykonującej rejestrację na kliknięcie przycisku „Rejestruj” i odpowiednie przyłożenie stetoskopu do ciała badanego pacjenta. Rejestracja rozpoczyna się po określonym czasie (opóźniony start) i zostaje potwierdzona krótkim sygnałem dźwiękowym. Po lewej stronie znajduje się karta pacjenta w której personel wykonujący rejestrację wpisuje takie dane jak: imię i nazwisko, numer PESEL, wiek pacjenta oraz płeć. **Jeżeli pacjent nie chce podać danych osobowych, personel ma obowiązek wpisać tylko wiek oraz płeć.**

Ponadto lekarz lub pielęgniarka przypisuje pacjenta do jednej z grup chorobowych. Robi to na podstawie wcześniejszych badań lekarskich oraz historii choroby pacjenta. Na potrzeby niniejszych badań, po szerokich konsultacjach lekarskich, wyszczególniono:

- A – nadciśnienie tętnicze samoistne bez chorób towarzyszących,
- B – nadciśnienie tętnicze powikłane przerostem mięśnia lewej komory,
- C – nadciśnienie tętnicze powikłane przerostem lewej komory oraz niewydolnością krążenia,
- Z – zdrowy,
- K1 – pacjent po urazach kończyn bez chorób przewlekłych i nie przyjmujący leków na stałe,
- K2 – pacjent po urazach kończyn, z nadciśnieniem tętniczym krwi, innymi chorobami przewlekłymi oraz mogący przyjmować leki na stałe,
- K3 – pacjent po endoprotezoplastyce stawu biodrowego,
- K4 – pacjent po endoprotezoplastyce stawu kolanowego.

Na karcie pacjenta jest dodatkowe miejsce na opis oraz spostrzeżenia rejestrującego na temat danego pacjenta. Taka obszerna ilość informacji pozwala na bardzo dobre udokumentowanie każdego przypadku, co w efekcie daje podstawy do dalszej analizy zebranych danych.

W środkowej części okna aplikacji widoczne są dwie zakładki: *Pozycja pionowa i pozioma* (pozycja stojąca lub leżąca). Na każdej zakładce znajdują się dwa punkty pomiarowe: *Punkt Erba i Koniuszek serca* [31]. Dla każdego pacjenta przewidziane są łącznie cztery rejestracje: gdy pacjent stoi, pierwszą w punkcie Erba i drugą w koniuszku serca oraz drugą parę badań w tych samych punktach, gdy pacjent leży. Podczas opracowywania założeń rejestracji danych przyjęto, że każda rejestracja powinna trwać co najmniej 30 s.

Po synchronicznym zarejestrowaniu sygnałów są one wyświetlane na wykresach. W aplikacji zaimplementowano tzw. kursory (pionowe czerwone linie), które za pomocą dedykowanych przycisków można przesuwac (osobno lub jednocześnie) w prawo lub w lewo zmieniając zakres sygnału pomiędzy kursorami. W dolnym oknie wyświetlone jest aktualnie wyznaczone widmo amplitudowe z sygnału zawartego między kursorami. Dzięki takiemu rozwiązaniu osoba rejestrująca już na początkowym etapie może ocenić skład widmowy zarejestrowanego sygnału fonokardiograficznego. W przypadku zarejestrowania zakłóceń, np. w postaci sygnału mowy, pojawią się w widmie składowe wysokoczęstotliwościowe. Taka informacja może być przydatna w celu podjęcia ewentualnej decyzji o ponownej rejestracji sygnału. Aplikacja posiada możliwość wczytania wcześniej zarejestrowanych danych, odsłuchu każdego z zarejestrowanych przebiegów oraz zapisania ich w postaci pliku audio z rozszerzeniem \*.wav.

Pełny opis aplikacji został umieszczony w załączniku 2 (Z.2) – *Podręcznik użytkownika*.

## 2.6. Stetoskop cyfrowy Littmann 3200

Stetoskop Littmann 3200 to elektroniczny stetoskop cyfrowy wyprodukowany przez amerykańską firmę *Littmann*<sup>®</sup>. Urządzenie to jest wyposażone w interfejs *Bluetooth 4.0*, który umożliwia transmisję zarejestrowanego sygnału do dedykowanej aplikacji *StethAssist*. Na rys. 2.18 przedstawiono fotografię stetoskopu Littmann 3200.



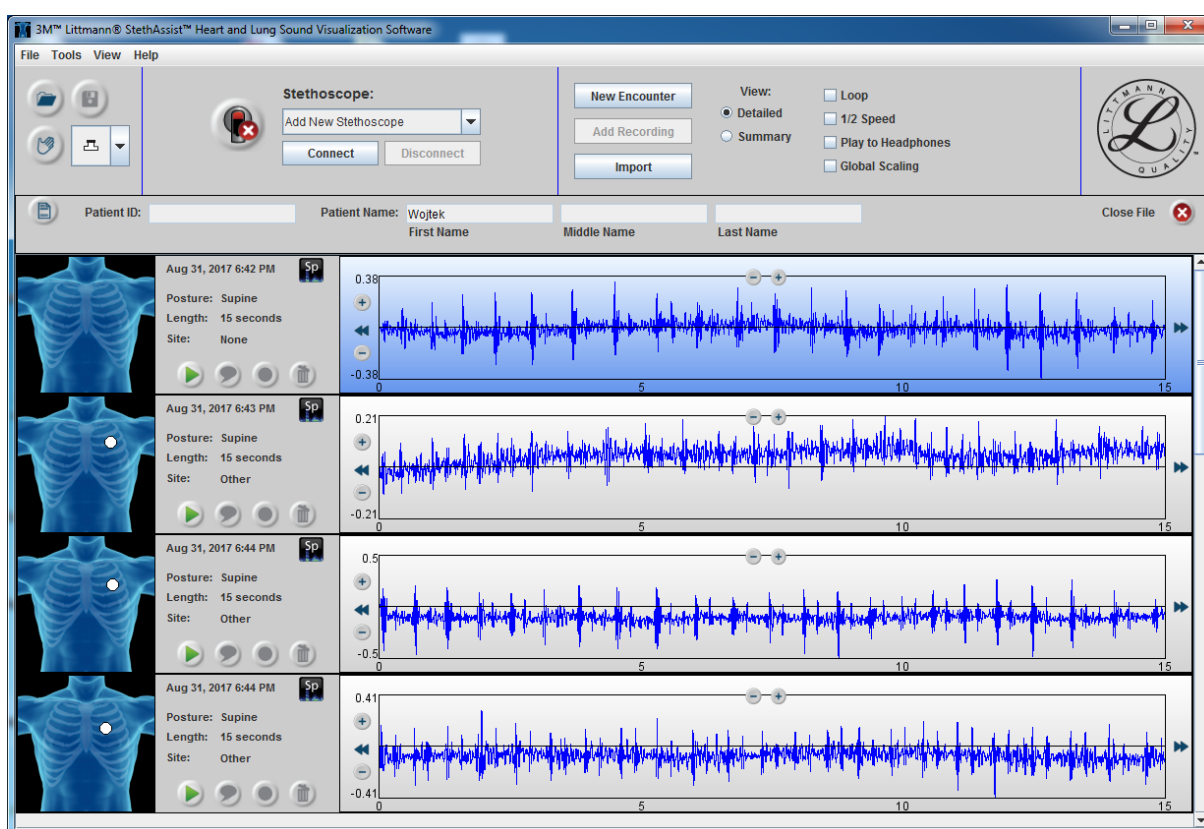
Rys. 2.18. Stetoskop elektroniczny Littmann 3200 [32]

Według producenta stetoskop wyposażony jest w innowacyjną, opatentowaną technologię redukcji szumów otoczenia eliminującą do 85% sygnałów zakłócających pochodzących z otoczenia [32]. Stetoskop umożliwia 24-krotne wzmocnienie dźwięku serca w tym również możliwość nagrywania i zapamiętywania do dwunastu 30-sekundowych rejestracji w pamięci urządzenia. Urządzenie może również odtwarzać zarejestrowane dźwięki w normalnym oraz w zwolnionym tempie. Podczas rejestracji należy wybrać jeden z trzech filtrów:

- *Lejek (ang. Bellmode)* – 20 Hz ÷ 1000 Hz, wzmocnienie w zakresie (20 – 200) Hz,
- *Membrana (ang. Diaphragm)* – 20 Hz ÷ 2000 Hz, wzmocnienie w zakresie (100 – 500) Hz,
- *Rozszerzony (ang. Extended)* – 20 Hz ÷ 2000 Hz, wzmocnienie w zakresie (50 – 500) Hz.

Poziom wzmocnienia można regulować w 8-stopniowym zakresie, od poziomu 1 do poziomu 9. Poziom 9 odpowiada 24-krotnemu wzmocnieniu sygnału docierającego do głowicy stetoskopu.

Stetoskop współpracuje z dedykowaną aplikacją *StethAssist*, której okno główne zostało przedstawione na rys. 2.19.



Rys. 2.19. Okno główne programu Littmann StethAssist


Program umożliwia wprowadzenie danych pacjenta, opis medyczny, oraz rejestrację dowolnej liczby sygnałów w różnych pozycjach pacjenta i różnych punktach. Możliwy jest eksport do pliku dźwiękowego z rozszerzeniem \*.wav oraz zapis całego badania w pliku zewnętrznym. Możliwe jest odsłuchanie wcześniej zarejestrowanego sygnału oraz sterowanie ustawieniami stetoskopu z poziomu aplikacji.

Po przeprowadzeniu rejestracji pilotażowych w Wojskowym Instytucie Medycznym w Warszawie wykonanych rejestratorem fonokardiogramów, w tabeli 2.2 przedstawiono porównanie najważniejszych parametrów stetoskopów JABES i Littmann 3200.


Tabela 2.2. Porównanie wybranych parametrów technicznych stetoskopów JABES i Littmann 3200

Lp.	Parametr	JABES	Littmann 3200
1	BellMode	(20 – 200)Hz	(20 – 200)Hz
2	DiaphragmMode	(200 – 500)Hz	(100 – 500)Hz
3	WideMode	(20 – 1000)Hz	(50 – 500)Hz
4	Regulacja głośności	10 poziomowa	8 poziomowa
5	Sygnal wyjściowy	Sygnal analogowy $2 V_{p-p}$	Sygnal cyfrowy przesyłany przez Bluetooth 4.0

W 2019 r. zespół złożony m.in. z pracowników Akademii Medycznej na Florydzie (USA) [33] dokonał porównania wydajności i parametrów technicznych stetoskopów cyfrowych przy użyciu technik inżynierii akustycznej w warunkach studyjnych. Badano m.in. takie parametry jak czułość detekcji dźwięków serca (tony S1 – S4) z zakresu od 22 Hz do 281 Hz (rys. 2.20) oraz tłumienie szumu (rys. 2.21).



Rys. 2.20. Czułość poszczególnych stetoskopów na dźwięki serca (22 – 281) Hz przedstawione w LUFS (ang. *Loudness Unit Full Scale*) [33]




Rys. 2.21. Tłumienie szumu poszczególnych stetoskopów w zakresie (22 – 281) Hz przedstawione w LUFs (ang. *Loudness Unit Full Scale*) [33]


Wyniki badań przedstawione na rys. 2.20 i 2.21 ewidentnie wskazują jako faworyta stetoskop Littmann 3200 pracujący w trybie lejka (ang. *Bell*). Największą różnicę między tymi stetoskopami widać porównując tłumienie szumu, co ma znaczący wpływ na jakość rejestrowanych sygnałów. Im większe tłumienie artefaktów zewnętrznych takich jak mowa, czy szum urządzeń elektrycznych w gabinecie lekarskim tym lepsza jakość rejestracji, a w efekcie większa skuteczność detekcji schorzeń.

Kolejny ważny zestaw badań (rys. 2.22 i 2.23) dotyczył czułości i tłumienia szumu w zakresie częstotliwości od 205 Hz do 705 Hz, zakres częstotliwości charakterystyczny dla takich schorzeń jak ubytek przegrody międzykomorowej VSD (ang. *Ventricular Septal Defect*), ubytek przegrody międzyprzedsionkowej ASD (ang. *Atrial Septal Defect*) oraz zwężenia drogi odpływu prawej komory PS (ang. *Pulmonic stenosis*).





Rys. 2.22. Czułość poszczególnych steteskopów na dźwięki serca (205 – 705) Hz przedstawione w LUFS (ang. *Loudness Unit Full Scale*) [33]



Rys. 2.23. Tłumienie szumu poszczególnych steteskopów w zakresie (205 – 705) Hz przedstawione w LUFS (ang. *Loudness Unit Full Scale*) [33]

Spośród badanych steteskopów elektronicznych, JABES pracujący w trybie membrany (ang. *Diaphragm*) wykazał się największą czułością na dźwięki patologii serca takie jak VSD, ASD, AS i PS. Porównywalny był również Littmann 3200 pracujący w trybie membrany. Najgorzej wypadł tryb lejka w steteskopie Littmann 3200, czego powodem jest charakterystyka tego trybu pracy – dokumentacja tego steteskopu wskazuje, że wzmocnienie w tym trybie jest realizowane tylko w zakresie


częstotliwości od 20 Hz do 200 Hz, czyli poniżej badanego zakresu. Natomiast tłumienie szumów w tym zakresie jest efektywniejsze niż w przypadku stetoskopu JABES.

Przewaga stetoskopu Littmann 3200 nad stetoskopem JABES wynika najprawdopodobniej z lepszej jakości wykonania. Doświadczenie w budowie tego typu urządzeń jest również kluczowe, a firma Littmann istnieje na światowym rynku od 1967 r. Dobór lepszej jakości materiałów również znacząco wpływa na jakość rejestrowanych sygnałów.

## 2.7. Baza danych

W początkowym etapie prac wykonano trzy identyczne egzemplarze rejestratorów fonokardiogramów współpracujące z trzema stetoskopami JABES. Niestety w trakcie rejestracji pilotażowych wykonywanych przez niezależny personel zauważono znaczny rozrzut jakości rejestracji zależny od konkretnego egzemplarza stetoskopu. W jednym ze stetoskopów odnotowano niepokojące przesłuchy w trakcie rejestracji. Ponadto regulacja wzmacnienia nie działała w sposób zadowalający. Efektem były znaczne różnice jakościowe w rejestracjach sygnałów.


Poniżej zaprezentowano dwa przykładowe sygnały zarejestrowane za pomocą stetoskopu JABES, na których widać zniekształcenia oraz efekty źle pracującego układu wzmacnienia. Na rys. 2.24 można zauważyć przykład nieprawidłowo działającego toru wzmacnienia stetoskopu JABES. Jak wynika z rys. 2.8, który przedstawia schemat podłączenia przetwornika A/C przetwarzającego sygnał PCG, napięcie referencyjne przetwornika jest równe 3,0 V. Oznacza to, że zakres przetwarzania przetwornika wynosi od 0 V do około 3 V. Amplituda sygnału z powyższego rysunku nie przekracza 1 V, co oznacza, że przesterowanie następuje już wewnątrz stetoskopu. Zarejestrowany sygnał przypomina sygnał prostokątny, jego szczyty są ograniczone możliwościami stetoskopu. Widmo amplitudowe takiego przebiegu jest zbyt zniekształcone aby wykorzystać je do analizy sygnałów PCG pod kątem detekcji schorzeń.



Rys. 2.24. Zarejestrowany sygnał PCG z widocznym przesterowaniem


Na rys. 2.25 przedstawiono rejestrację sytuacji odwrotnej niż poprzednio. Sygnał ten został zarejestrowany u tego samego pacjenta, w tej samej pozycji, ale innym stetoskopem JABES. Można zauważyć brak wzmacnienia sygnału mimo ustawienia największego wzmacnienia stetoskopu. Brak wystarczającej dynamiki sygnału również może przeszkadzać w analizie sygnału PCG. Kłopotliwa może być detekcja tonów S1 – S4.





Rys. 2.25. Sygnał PCG o niskiej amplitudzie

Z kolei na rys. 2.26 zaprezentowano przykładowy sygnał zarejestrowany stetoskopem Littmann 3200 przy pomocy aplikacji *StethAssist*. W sygnale można wyraźnie zauważyć ton S1 serca. Dynamika sygnału jest odpowiednia i nie występują przesterowania sygnału mogące zakłócać dalszą analizę.



Rys. 2.26. Sygnał PCG zarejestrowany stetoskopem Littmann 3200

Ostatecznie, po przeprowadzeniu badań pilotażowych, dalsze prace prowadzono z wykorzystaniem stetoskopu Littmann 3200 i dedykowanej aplikacji *StethAssist*.

Łącznie przebadano 231 osób, co dało 921 sygnałów fonokardiograficznych. U jednego z pacjentów zarejestrowano tylko jeden sygnał PCG. Wszystkie te sygnały zarejestrowano stetoskopami Littmann 3200 współpracującymi z aplikacją *StethAssist*. W celu odpowiedniej identyfikacji zarejestrowanych przypadków wyróżniono następujące klasy:

- **ZS** – zdrowy,
- **MC** – przypadek wieloklasowy, tj. pacjent cierpiący na więcej niż jedno schorzenie (ang. *MultiClass*),
- **CHW** – choroba wieńcowa,
- **HF** – niewydolność serca (ang. *Heart Failure*),
- **MI** – zawał mięśnia sercowego (ang. *Myocardial Infarction*),
- **MP** – migotanie przedsionków,
- **NT** – nadciśnienie tętnicze.

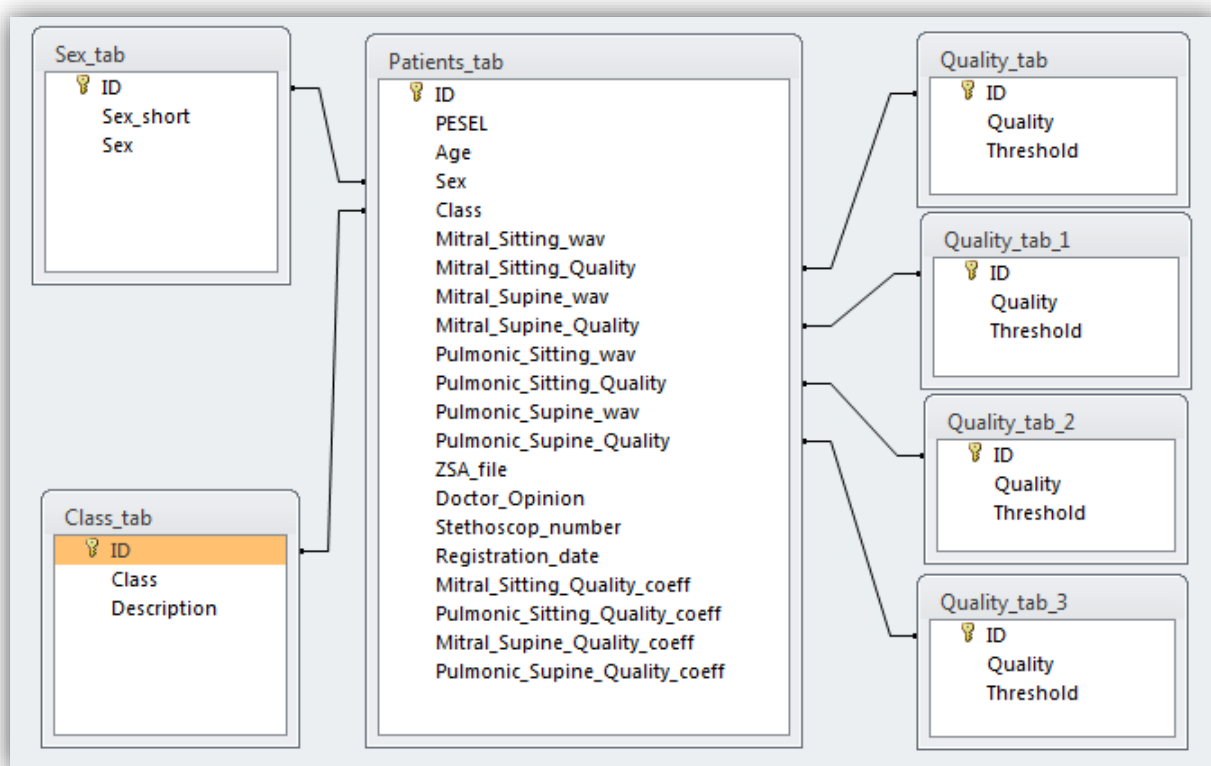
Ponadto zaproponowano system nazywania plików z zarejestrowanymi przypadkami tak, aby każda z osób wykonujących rejestrację postępowała według identycznego schematu. Dzięki temu nie ma rozbieżności na etapie analizy danych. Przyjęto, że plik wynikowy rejestracji ma następującą nazwę:

**HF\_90071602858\_20171107T081457.zsa**

Poniżej wyjaśniono poszczególne składniki nazwy pliku:

- **HF** – klasa do której przyporządkowano pacjenta, na podstawie historii medycznej i innych badań lekarskich, w tym przypadku zdiagnozowano niewydolność serca;
- **90071602858** – nr PESEL pacjenta (lub jego początek w przypadku braku wyrażenia zgody) pozwalający na identyfikację wieku pacjenta, w tym przypadku pacjent urodzony 16 lipca 1990 r.;
- **20171107** – data wykonania badania w formacie RRRRMMDD, w tym przypadku badanie wykonano 7 listopada 2017 r.;
- **T081457** – Przybliżony czas wykonania badania w formacie THMMSS, w tym przypadku badanie wykonano około 8:14:57;
- **.zsa** – rozszerzenie pliku.

Wszystkie rejestracje umieszczono w relacyjnej bazie danych. Struktura bazy została przedstawiona na rys. 2.27.



Rys. 2.27. Struktura bazy danych przechowującej zarejestrowane sygnały

Baza danych składa się z 4 tabel. Największa i główna tabela to *Patients\_tab*. Zawiera ona wszystkie niezbędne informacje na temat danej rejestracji. Kolejną tabelą jest *Sex\_tab*, Zawiera ona definicje płci pacjenta, która została zadeklarowana w programie *StethAssist* podczas rejestracji. Następną tabelą jest *Class\_tab*, która zawiera opis klas, do których można przyporządkować danego pacjenta. Ostatnią tabelą jest *Quality\_tab* zawierająca możliwe do przyporządkowania współczynniki jakości danego sygnału. Na rys. 2.27 widać cztery relacje między tabelą *Quality\_tab* a *Patients\_tab*. Jest to spowodowane tym, że jakość sygnału jest przyporządkowana do każdej z rejestracji, a wykonywane są cztery rejestracje dla każdego pacjenta.


Struktura poszczególnych tabel została zaprezentowana w tabeli 2.3.

Tabela 2.3. Struktura tabel bazy danych przechowującej rejestrację

<b>Patients_tab</b>		
1	ID	Numer identyfikacyjny (klucz tabeli)
2	PESEL	Numer PESEL pacjenta
3	Age	Wiek pacjenta
4	Sex	Płeć pacjenta - Relacja do tabeli Sex_tab
5	Class	Klasa chorobowa - Relacja do tabeli Class_tab
6	Mitral_Sitting_wav	Nazwa pliku WAV (koniuszek serca - pozycja siedząca)
7	Mitral_Sitting_Quality	Jakość pliku WAV (koniuszek serca - pozycja siedząca)
8	Mitral_Supine_wav	Nazwa pliku WAV (koniuszek serca - pozycja stojąca)
9	Mitral_Supine_Quality	Jakość pliku WAV (koniuszek serca - pozycja stojąca)
10	Pulmonic_Sitting_wav	Nazwa pliku WAV (punkt Erba - pozycja siedząca)
11	Pulmonic_Sitting_Quality	Jakość pliku WAV (punkt Erba - pozycja siedząca)
12	Pulmonic_Supine_wav	Nazwa pliku WAV (punkt Erba - pozycja stojąca)
13	Pulmonic_Supine_Quality	Jakość pliku WAV (punkt Erba - pozycja stojąca)
14	ZSA_file	Nazwa pliku *.zsa zawierającego plik z rejestracją
15	Doctor_Opinion	Uwagi lekarza dokonującego rejestracji
16	Stethoscop_number	Numer identyfikujący stetoskop
17	Registration_date	Data rejestracji
18	Mitral_Sitting_Quality_coeff	Wyznaczony współczynnik jakości
19	Pulmonic_Sitting_Quality_coeff	Wyznaczony współczynnik jakości
20	Mitral_Supine_Quality_coeff	Wyznaczony współczynnik jakości
21	Pulmonic_Supine_Quality_coeff	Wyznaczony współczynnik jakości
<b>Class_tab</b>		
1	ID	Numer identyfikacyjny (klucz tabeli)
2	Class	Klasa – skrót, np. ZS
3	Description	Opis klasy
<b>Sex_tab</b>		
1	ID	Numer identyfikacyjny (klucz tabeli)
2	Sex_short	Skrót płci (M lub K)
3	Sex	Opis pełny (Mężczyzna lub Kobieta)
<b>Quality_tab</b>		
1	ID	Numer identyfikacyjny (klucz tabeli)
2	Quality	Współczynnik jakości (np. Bardzo dobry)
3	Threshold	Próg dla danego współczynnika (od -100 do 100)


## 2.8. Statystyka zebranych danych

Dzięki zaangażowaniu personelu Wojskowego Instytutu Medycznego w Warszawie udało się zarejestrować 921 sygnałów PCG u łącznie 231 osób. Na rys. 2.28 przedstawiono podział populacji badanych ze względu na płeć – zarejestrowano sygnały fonokardiograficzne od 119 mężczyzn i 112 kobiet, co odpowiada stosunkowi 48% do 52%.



Rys. 2.28. Podział badanych ze względu na płeć


Na rys. 2.29 zaprezentowano podział populacji badanych ze względu na przyporządkowaną klasę chorobową. Najwięcej, bo aż 41% pacjentów (94 przypadki) to pacjenci zdrowi, bez chorób układu sercowo-naczyniowego. Największą liczbę chorych pacjentów stanowią pacjenci z rozpoznaniem nadciśnieniem tętniczym (NT), stanowią aż 21% całej populacji. Trzecią pod względem wielkości grupą są osoby po przebytych zawałach mięśnia sercowego – 12% populacji.



Rys. 2.29. Podział badanych ze względu na klasę chorobową


Na rys. 2.30 zaprezentowano porównanie rozkładu przypisanych klas chorobowych kobiet i mężczyzn w całej populacji badanych. Największa dysproporcja prezentuje się w klasie „zdrowy”. Kobiety w tej grupie stanowią tylko 30%. Duża dysproporcja występuje również u pacjentów z klasy NT

(nadciśnienie tętnicze), gdzie sytuacja jest odwrotna. Mężczyźni stanowią tutaj zaledwie 26%. Klasy MI, HF oraz CHW cechują się najmniejszą dysproporcją płciową, nie przekraczającą 15%. Duża różnica w liczbie przebadanych mężczyzn i kobiet w klasie „zdrowy” wynika z pochodzenia populacji. Pacjentów chorych, czyli wszystkich poza klasą ZS pozyskano z Wojskowego Instytutu Medycznego. Natomiast zdrowych ochotników pozyskano z grupy studentów wojskowych I roku Wojskowej Akademii Technicznej. Po konsultacjach z zespołem WIM stwierdzono, że studenci I roku studiów wojskowych są po gruntownych badaniach lekarskich kwalifikujących na tego typu studia, więc można założyć, że są zdrowi kardiologicznie. W tak zdefiniowanej grupie znaczącą większość stanowią mężczyźni, stąd dysproporcje.



Rys. 2.30. Porównanie rozkładu klas chorobowych kobiet i mężczyzn w populacji badanych

Na rys. 2.31 przedstawiono podział populacji badanych ze względu na przedział wiekowy. Można zauważyć, że największy odsetek mężczyzn znajduje się w przedziale wiekowym między 20 a 24 rokiem życia. Jak wspomniano wcześniej, są to studenci I roku studiów wojskowych.



Rys. 2.31. Podział populacji badanych ze względu na wiek

## 2.9. Podsumowanie

W rozdziale drugim opisane zostały poszczególne etapy prowadzące do zebrania wystarczającej ilości danych niezbędnych do dalszej analizy. W pierwszym etapie wybrano stetoskop cyfrowy JABES. Zaprojektowano i zbudowano dedykowane urządzenie zwane rejestratorem fonokardiogramów, które dzięki współpracy ze stetoskopem JABES oraz komputerem PC pozwalało na jednoczesną akwizycję sygnałów PCG i EKG pacjenta. Opisano proces przetwarzania analogowo-cyfrowego sygnału wraz z etapami projektowania rejestratora fonokardiogramów. Po wstępnych badaniach pilotażowych stwierdzono zbyt duży rozrzut w jakości rejestrowanych sygnałów, który ściśle zależał od stosowanego egzemplarza stetoskopu JABES. Ostatecznie zrezygnowano z rejestracji przy pomocy tego stetoskopu i wybrano stetoskop Littmann 3200. W efekcie zarejestrowano niemal 1000 sygnałów fonokardiograficznych wzbogaconych o profesjonalny lekarski opis poszczególnych przypadków [34]. Wszystkie sygnały zgromadzono w relacyjnej bazie danych, dzięki czemu zapewniono ich uporządkowanie oraz łatwość dostępu. Zebrane dane w dalszym etapie posłużą do wstępnej oceny jakości, a następnie do analizy pod kątem obecności artefaktów związanych ze schorzeniami układu sercowo naczyniowego.

# 3


## OCENA JAKOŚCI SYGNAŁÓW FONOKARDIOGRAFICZNYCH

Według Platona „*jakość konkretnych rzeczy to stopień osiągniętych przez nie doskonałości*” [35]. Sygnał fonokardiograficzny zawiera komplet informacji dotyczących pracy serca. Wszystkie szmery dodatkowe świadczące o nieprawidłowościach pracy serca są w nim zawarte. Niestety sposób rejestracji sygnału fonokardiograficznego bywa bardzo niedoskonały, co prowadzi do jego zniekształcenia artefaktami zewnętrznymi. Sygnał PCG jest dźwiękiem, czyli zaburzeniem gęstości i ciśnienia, które rozchodzi się w ośrodku w postaci fali podłużnej, dlatego sygnał fonokardiograficzny zawsze rejestrowany jest za pomocą mikrofonu, którego pasmo musi być co najmniej takie jak pasmo akustyczne pracy serca lub szersze. Pasma akustyczne serca pokrywa się w znacznej części z pasmem innych zakłócających dźwięków słyszalnych przez człowieka, często o znacznie większej energii i niezależnie od tego jakie filtry zastosujemy i jaką technologię przetwarzania cyfrowego wybierzemy, rejestrując sygnał fonokardiograficzny zawsze zarejestrujemy również dźwięki niepożądane, takie jak


mowa, szum klimatyzatora w pomieszczeniu czy inne dźwięki generowane wewnątrz organizmu. Im więcej tego typu dodatkowych dźwięków tym większa degradacja właściwego sygnału PCG, a w efekcie niższa jakość rejestracji [36].

W ciągu trzech pierwszych miesięcy badań medycznych<sup>1</sup> udało się zarejestrować około 400 sygnałów fonokardiograficznych. W czasie odsłuchiwania rejestracji zauważono, że niektóre z nich zawierają niestety dodatkowe artefakty niezwiązane z dźwiękami kardiologicznymi, które można traktować jako zakłócenia sygnału, mające wpływ na wartości cech dystynktywnych wskazujących na schorzenie kardiologiczne. Silne zakłócenia mogą zaburzyć wartości cech dystynktywnych na tyle, że prawidłowa klasyfikacja nie będzie możliwa [36][37]. W związku z tym na etapie przygotowania danych do dalszej analizy, dokonano klasyfikacji jakościowej, która już bezpośrednio po rejestracji umożliwia odrzucenie sygnałów silnie zakłóconych i ewentualne powtórzenie rejestracji.

Na rys. 3.1 zaprezentowano sygnał o dobrej jakości. Wyraźnie da się zauważyć okresowość sygnału, można również wyróżnić tony S1 i S2. Poziom szum jest znikomy, da się dość precyzyjnie określić rytm serca. Odsłuchując ten sygnał wyraźnie słychać bicie serca, brak jest również zewnętrznych sygnałów zakłócających.



Rys. 3.1. Przykład sygnału o względnie dobrej jakości



Rys. 3.2. Przykład sygnału o względnie niskiej jakości

---

<sup>1</sup> Rejestracje na potrzeby niniejszej rozprawy prowadził zespół w składzie: autor rozprawy por. W. Lejkowski, por. lek. med. Bartłomiej Gawron z Oddziału Zabezpieczenia Dowództwa Garnizonu Warszawa, dr n. med. Tomasz Grycewicz oraz p. Katarzyna Majka z Wojskowego Instytutu Medycznego.



Na rys. 3.2 przedstawiono sygnał fonokardiograficzny o niskiej jakości. Występuje w nim bardzo duży poziom szumu który praktycznie przysłania użyteczną część sygnału. Sygnał jest również niemożliwy do wzrokowej i słuchowej oceny kardiologicznej. Z tak zakłóconego sygnału nie można ekstrahować skutecznych cech dystynktywnych.

W niniejszym rozdziale opisano klasyfikator jakościowy, który został zastosowany w pierwszym etapie działania systemu diagnozującego wybrane patologie serca. Dzięki niemu możliwa jest automatyczna analiza danych pod kątem ich dalszej użyteczności i ewentualne poinformowanie osoby wykonującej rejestrację o konieczności jej powtórzenia ze względu na obecność zakłóceń.

### 3.1. Filtracja falkowa sygnału

Każdy zarejestrowany sygnał ma czas trwania 30 s, a częstotliwość próbkowania stetoskopu Littmann 3200 wynosi 4 kHz. W efekcie dysponujemy sygnałem cyfrowym o długości 120 000 próbek:

$$N = T_c \cdot Fs = 30s \cdot 4000Hz = 120\ 000 \quad (3.1)$$

gdzie:  $N$  – liczba próbek sygnału;  
 $T_c$  – czas trwania sygnału w sekundach;  
 $Fs$  – częstotliwość próbkowania sygnału.

W pierwszej kolejności z sygnału usuwana jest składowa stała (3.2), następnie sygnał jest normalizowany (3.3):

$$y_i = y_i - \bar{y} \quad (3.2)$$

gdzie:  $y_i$  – próbka sygnału po odjęciu średniej ze wszystkich próbek;  
 $\bar{y}$  – wartość średnia sygnału;

$$\hat{y}_i = \frac{y_i}{\max(|\vec{y}|)} \quad (3.3)$$

gdzie:  $\hat{y}_i$  – próbka znormalizowana sygnału;  
 $|\vec{y}|$  – moduł wartości chwilowej sygnału;

Tak przygotowany sygnał poddawany jest filtracji z wykorzystaniem dyskretnej transformacji falkowej (*DWT* – ang. *Discrete Wavelet Transform*). Transformacja falkowa ma szerokie zastosowanie w obszarze przetwarzania sygnałów, w szczególności może być z sukcesem wykorzystywana do estymacji i usuwania trendu oraz usuwania szumu z sygnału. Jest to metoda czasowo-częstotliwościowa zapewniająca dobrą rozdzielczość zarówno w dziedzinie czasu, jak i częstotliwości.

Podstawową różnicą między transformacją falkową a Fouriera jest funkcja jądra, która w przypadku transformacji falkowej jest zbiorem funkcji otrzymanych poprzez skalowanie i przesuwanie tzw. *falki podstawowej* (*falki matki*)  $\psi(t) \in L^2(\mathbf{R})$ , zdefiniowanej w taki sposób aby jej energia była jednostkowa i spełniała warunek dopuszczalności [38] [39]:

$$\int_0^{+\infty} \frac{|\Psi(\omega)|^2}{\omega} d\omega < \infty \quad (3.4)$$

gdzie  $\Psi(\omega)$  to transformata Fouriera funkcji  $\psi(t)$ .


Powyższe równanie (3.4) należy interpretować jako wymaganie, aby wraz z wzrostem pulsacji kwadrat modułu widma dążył do zera szybciej niż odwrotność pulsacji, co oznacza skoncentrowanie widma falki matki. Ponadto z warunku dopuszczalności wynika, że falka nie może zawierać składowej

stałej. Dzięki użyciu operacji skalowania oraz przesunięcia w dziedzinie czasu, można utworzyć rodzinę funkcji bazowych na podstawie falki podstawowej:

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right), s, \tau \in R, s > 0 \quad (3.5)$$

gdzie:  $\psi_{s,\tau}(t)$  – przekształcona falka z parametrami  $s$  i  $\tau$ ;  
 $s$  – skala;  
 $\tau$  – przesunięcie w czasie.

Na rys. 3.3 przedstawiono sposób skalowania falki wykorzystując operację skalowania i przesunięcia, za pomocą którego tworzy się rodzinę falek.



Rys. 3.3. Ilustracja przesuwania i skalowania falki matki na przykładzie falki *Symlet* IV rzędu [38]

Zgodnie z [40][41] falka jest funkcją rzeczywistą, która charakteryzuje się zerową wartością średnią, znormalizowaną oraz scentrowaną w sąsiedztwie  $t = \tau$ .

Ciągła transformata falkowa (CWT – ang. *Continuous Wavelet Transform*) sygnału  $x(t)$  zaproponowana przez *Marlet'a-Grossman'a* [42] w 1984 r. zdefiniowana jest następująco:


$$CWT_x(s, \tau) = \frac{1}{\sqrt{s}} \int_{-\infty}^{+\infty} x(t) \psi^* \left( \frac{t - \tau}{s} \right) dt \quad (3.6)$$

Zastosowanie transformacji falkowej pozwala na prezentację sygnału w dziedzinie czas – skala dzięki zastosowaniu współczynników falkowych. Współczynniki te są odzwierciedleniem korelacji pomiędzy zastosowaną bazą falkową a transformowanym sygnałem. Falka  $\psi_{s,\tau}(t)$  jest funkcją parametrów  $s$  (skala – decyduje o właściwościach częstotliwościowych) oraz  $\tau$  (przesunięcie – określa położenie falki). Dla  $s = 1$  i  $\tau = 0$  dana falka jest wersją podstawową. Należy zauważyć, że transformacja falkowa, podobnie jak transformacja Fouriera jest operacją odwracalną, ale odpowiedni dobór falki podstawowej powinien umożliwić rekonstrukcję sygnału z użyciem minimalnej liczby współczynników falkowych.

Podobnie jak w przypadku ciągłej transformacji Fouriera, transformatę falkową również możemy zdyskretyzować w dziedzinie częstotliwości, próbując w odpowiedni sposób wartości przesunięcia i skali [38]. W praktyce wyznacza się dyskretną transformatę falkową DWT, która jest określona dla wartości parametrów  $s = 2^j$  oraz  $\tau = 2^j k$ , gdzie  $j$  – to poziom, a  $k$  – przesunięcie dyskretne. Dzięki zastosowaniu takich warunków jądro falkowe przyjmuje następującą postać:

$$\psi_{j,k}(t) = 2^{-\frac{j}{2}} \psi(2^{-j}t - k) \quad (3.7)$$

Przy zmianie poziomu z  $j$  na poziom  $j+1$  skala ulega dwukrotnemu powiększeniu (falka rozszerza się, co powoduje, że rozdzielczość w dziedzinie czasu dwukrotnie maleje) i jednocześnie skok przesunięcia również zwiększa się dwukrotnie, dzięki czemu zapewniona jest ortogonalność falek w dziedzinie czasu. DWT można wyznaczyć za pomocą iteracyjnego algorytmu *Mallata* [43][44][45], który stanowi szybkie i proste rozwiązanie dekompozycji sygnału na aproksymacje (składowe niskoczęstotliwościowe) oraz detale (składowe wysokoczęstotliwościowe) z wykorzystaniem filtrów cyfrowych. Schemat blokowy wyznaczenia aproksymacji i detali przedstawiono na rys. 3.4.



Rys. 3.4. Wyznaczenie DWT za pomocą algorytmu *Mallata*  
(FDP – filtr dolnoprzepustowy, FGP – filtr górnoprzepustowy, ↓2 – dwukrotna decymacja)

Kaskadowe połączenie zaprezentowanego bloku, dla  $j \in \{-J, -1\}$  pozwala na wyznaczenie falkowej reprezentacji sygnału na  $J$  poziomach [44]. Wynikiem działania jest zbiór współczynników wielopoziomowego przekształcenia DWT, które zlokalizowane są w przestrzeni czas – skala. W teorii liczba detali sygnału analogowego jest nieskończenie duża, natomiast w przypadku sygnałów cyfrowych istnieje maksymalna wartość rozdzielczości, która jest określona przez próbki sygnału. Jeżeli przyjmiemy umownie poziom określony przez surowe próbki za zerowy, to możemy stwierdzić,

że przetwarzany sygnał jest tożsamy z aproksymacją na poziomie zero i sygnał  $x(t)$  można przedstawić w następujący sposób:

$$x(t) = A_0(t) = A_1(t) + D_1(t) = A_2(t) + D_2(t) + D_1(t) = A_3(t) + D_3(t) + D_2(t) + D_1(t) = \dots \quad (3.8)$$

Jak można zauważyć, wraz z wzrostem poziomu rośnie udział sumy detali. Proces dekompozycji musi zakończyć się na poziomie, na którym długość sygnału jest jeszcze większa od długości falki.

Ogromną zaletą algorytmu *Mallata* jest prostota implementacji, gdyż opiera się on głównie na filtracji dolnoprzepustowej i górnoprzepustowej dla danego poziomu dekompozycji. Matematycznie ogranicza się to do wykonania operacji splotu współczynników z sygnałem wejściowym, a następnie wykonanie decymacji. Dekompozycja falkowa w niniejszej pracy została wykorzystana do filtracji z wykorzystaniem falki *Daubechies* X rzędu. Sygnał po filtracji jest prezentowany jako suma detali z poziomów od 5 do 8. Taka filtracja pozwala na usunięcie niestacjonarnej składowej wolnozmiennnej, pochodzącej np. od ruchu klatki piersiowej pacjenta, oraz składowej szybkozmiennnej, powyżej akustycznego zakresu pracy serca. Operacja filtracji falkowej w środowisku *Matlab* została przedstawiona na listingu 3.1.

Listing 3.1.

```
wavelet = 'db10';      % Falka Daubechies X rzędu
[C,L] = wavedec(SignalOriginal,8,wavelet);
D5 = wrcoef('d',C,L,wavelet,5);
D6 = wrcoef('d',C,L,wavelet,6);
D7 = wrcoef('d',C,L,wavelet,7);
D8 = wrcoef('d',C,L,wavelet,8);
SignalFiltered = D5 + D6 + D7 + D8;
```

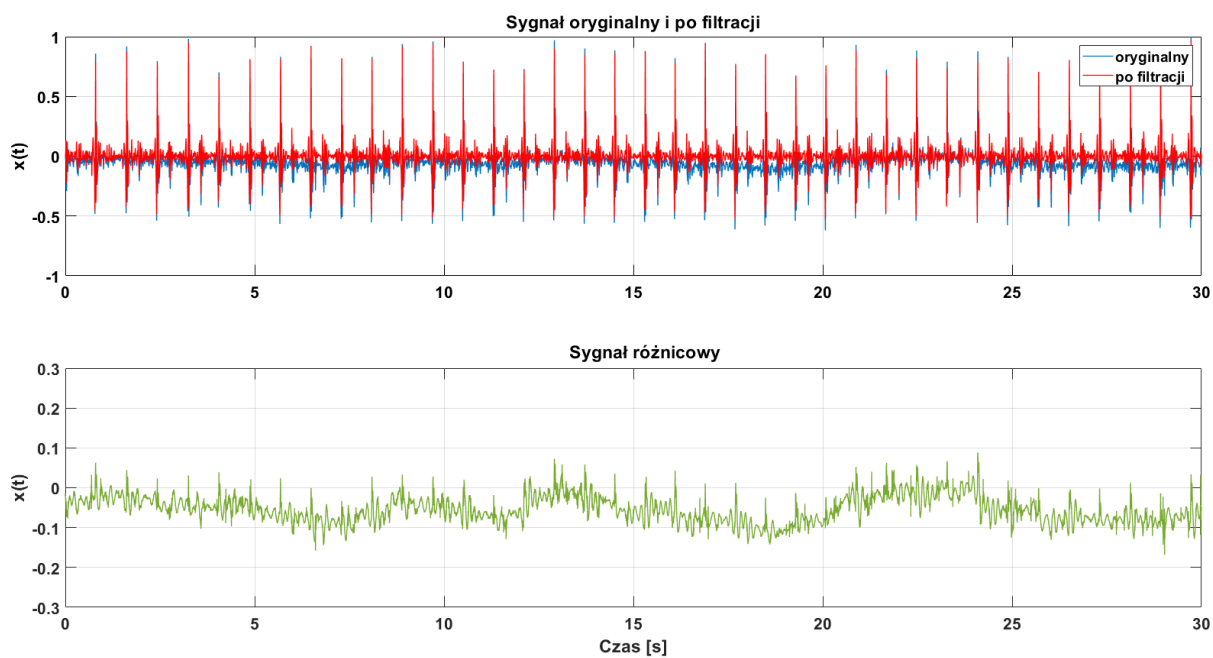
## 3.2. Parametry jakościowe

Parametry wykorzystywane do oceny jakości sygnału fonokardiograficznego są wyznaczane z sygnału po filtracji falkowej [46]. Pierwszym parametrem jest stosunek energii sygnału po filtracji falkowej do energii sygnału pierwotnego, określony wzorem (3.9).


$$p_1 = 10 \cdot \log_{10} \left( \frac{y_{f\_rms}^2}{y_{rms}^2} \right) \quad (3.9)$$

gdzie:  $y_{f\_rms}$  – wartość skuteczna sygnału po filtracji falkowej;  
 $y_{rms}$  – wartość skuteczna sygnału oryginalnego;


Jak wspomniano w podrozdziale 3.1 filtracja falkowa usuwa wolno i szybkozmiennie składowe sygnału nie pochodzące od serca pacjenta [46]. Na rys. 3.5 przedstawiono wpływ filtracji falką *Daubechies* X rzędu na sygnał PCG o dobrej jakości, na rys. 3.6 powiększenie fragmentu wykresu z rys. 3.5, natomiast na rys. 3.7 wpływ filtracji na sygnał charakteryzujący się niską jakością. Niebieskim kolorem oznaczono sygnał oryginalny, czerwonym sygnał po filtracji, a zielonym sygnał różnicowy.



Rys. 3.5. Wpływ filtracji falkowej na przebieg czasowy sygnału fonokardiograficznego o dobrej jakości



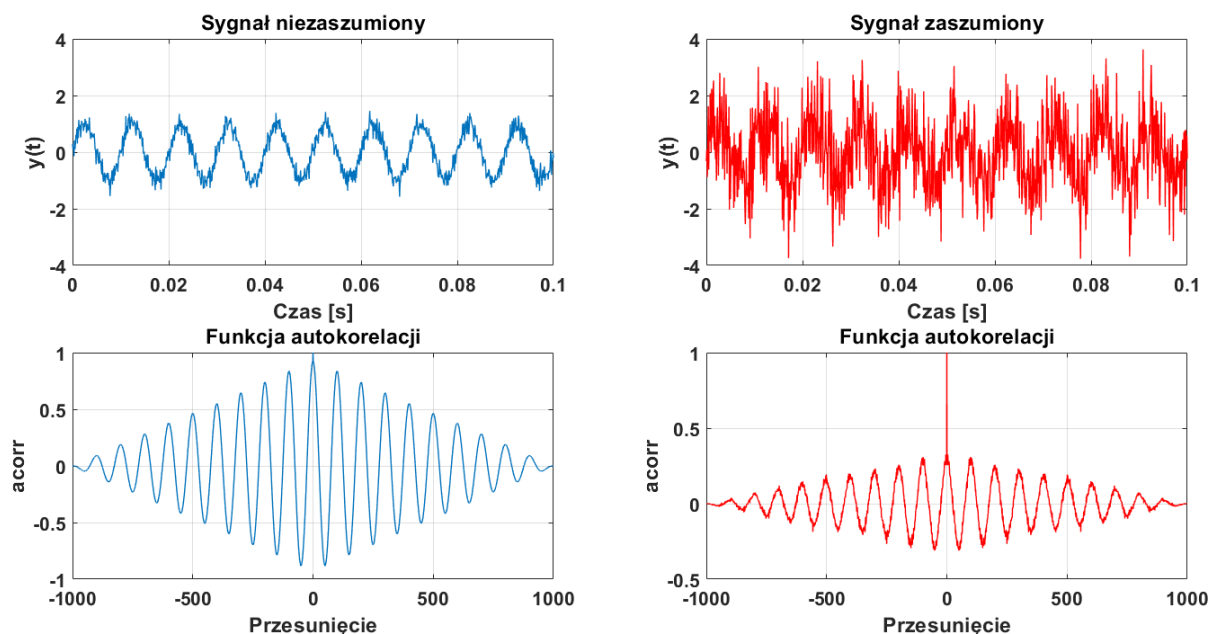
Rys. 3.6. Wpływ filtracji falkowej na przebieg czasowy sygnału fonokardiograficznego - zbliżenie



Rys. 3.7. Wpływ filtracji falkowej na przebieg czasowy sygnału fonokardiograficznego o złej jakości

Dla sygnału przedstawionego na rys. 3.5 wartość parametru  $p_1$  wynosi 9,31 dB, co oznacza dobry stosunek sygnał/szum. Sygnał różnicowy jest sygnałem o niskiej amplitudzie. Kształt sygnału różnicowego wskazuje również, że w tym przypadku filtracja falkowa jest głównie filtracją górnoprzepustową, która usuwa z sygnału składową wolnozmienną pochodzącą między innymi od ruchu klatki piersiowej pacjenta. W przypadku sygnału przedstawionego na rys. 3.7, parametr  $p_1$  wynosi 12,92 dB, co wskazuje na wyższy poziom szumu w sygnale.

W celu wyznaczenia drugiego parametru zastosowano normalizację okienkową sygnału [46]. Poddano normalizacji sygnał w oknie o czasie trwania 1,5 s. Cały sygnał został podzielony na 20 takich okien i każde z nich poddano normalizacji. Z tak przetworzonego sygnału wyznaczono funkcję autokorelacji, i przyjęto, że stosunek amplitudy głównego (zerowego) maksimum funkcji autokorelacji do wartości kolejnego maksimum zawiera informację o poziomie szumu w sygnale. Dla sygnałów z niską zawartością szumu i wyraźną okresowością stosunek ten jest wyższy niż dla sygnałów silnie zaszumionych, w których bezpośrednio trudno dostrzec cechy okresowości. Omawianą właściwość zobrazowano na rys. 3.8. Kolorem niebieskim oznaczono przykładowy sygnał z niską zawartością szumu. Funkcja autokorelacji wygląda „podręcznikowo”, stosunek amplitudy głównego maksimum do kolejnego jest mały. Natomiast w przypadku sygnału z dużą zawartością szumu (kolor czerwony) stosunek tych maksimum jest bardzo duży.




Rys. 3.8. Przebieg sygnału z małą i dużą zawartością szumu oraz odpowiadająca mu funkcja autokorelacji

Podobnie jest z sygnałem fonokardiograficznym. W przypadku „czystej” rejestracji widać wyraźne cechy okresowości, dlatego jego funkcja autokorelacji przypomina kształtem niebieską funkcję z rys. 3.8. Wykorzystując powyższą właściwość, wyznaczono drugi parametr opisany wzorem (3.10). Im większa wartość parametru  $p_2$  tym większa jest zawartość szumu w sygnale.

$$p_2 = \frac{\max(f_{acorr})_0}{\max(f_{acorr})_1} \quad (3.10)$$


gdzie:  $\max(f_{acorr})_0$  – amplituda głównego maksimum funkcji autokorelacji,  
 $\max(f_{acorr})_1$  – amplituda kolejnego maksimum funkcji autokorelacji.

Na rys. 3.9 – niebieskim kolorem zaprezentowano funkcję autokorelacji sygnału charakteryzującego się wysoką jakością, natomiast czerwonym funkcję autokorelacji sygnału o złej jakości. Parametr  $p_2$  dla sygnału z lewej strony wynosi 0,59, natomiast dla sygnału z prawej strony 0,73.



Rys. 3.9. Funkcja autokorelacji sygnału o wysokiej jakości (niebieski) i niskiej jakości (czerwony)

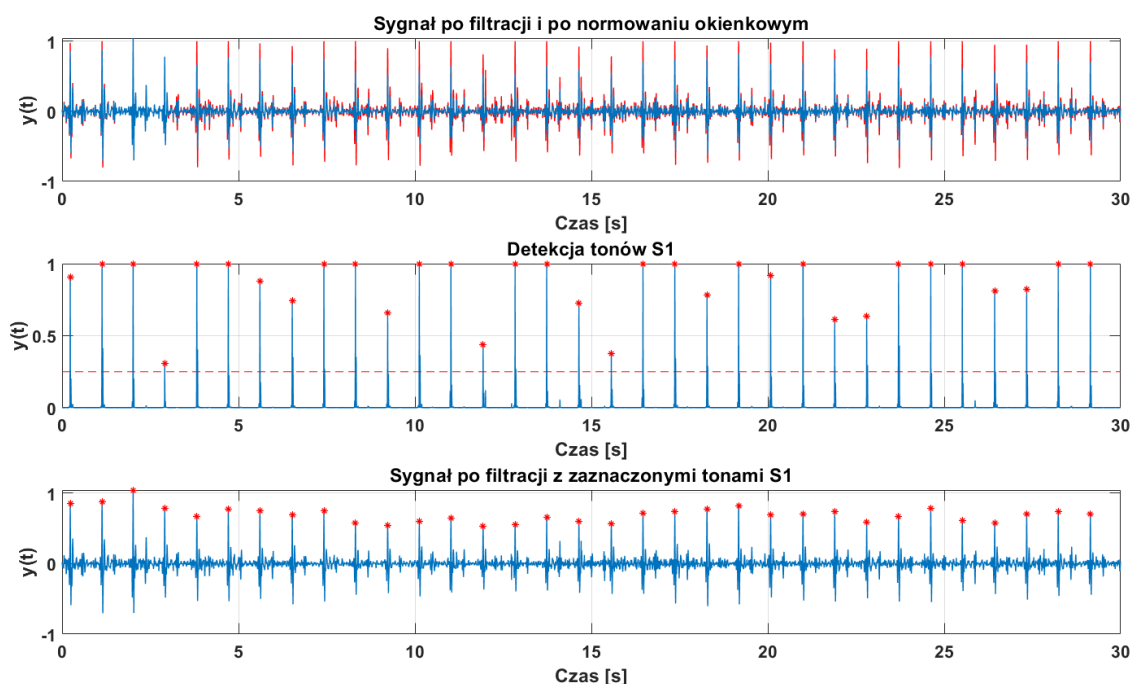
Następnym pomysłem, wprowadzonym w celu określenia położenia charakterystycznych tonów serca, tj. tonów S1, było podniesienie okienkowo unormowanego sygnału do potęgi 4, a następnie ponowne unormowanie. Na rys. 3.10 przedstawiono wykres funkcji stopnia 4. Funkcja tego typu charakteryzuje się tym, że mocno „tłumi” małe wartości (widać do na wykresie w zakresie  $x \in (-0,4; 0,4)$ ), i silnie „wzmacnia” wysokie wartości ( $x \in (-1; 0,4) \cap (0,4; 1)$ ).



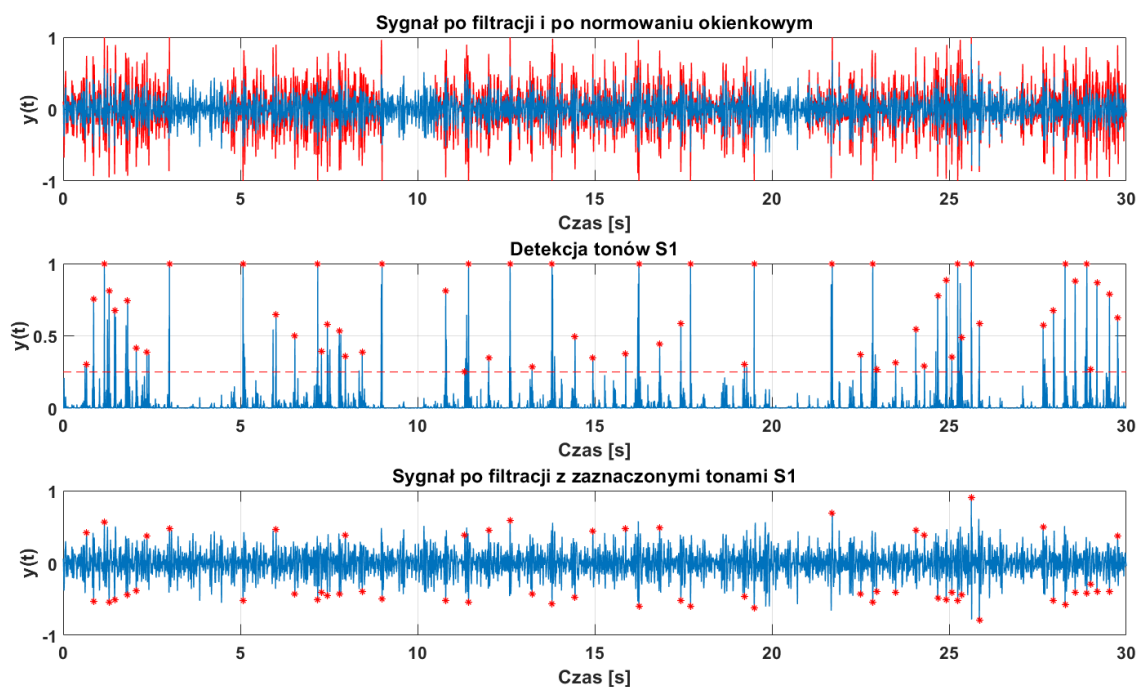
Rys. 3.10. Przebieg funkcji stopnia czwartego

Omawiana wyżej właściwość jest prostym sposobem służącym do wyznaczenia tonów charakterystycznych w sygnale PCG z niską zawartością szumu. Wynik tej operacji przedstawiono na rys. 3.11 (dla sygnału o dobrej jakości) oraz na rys. 3.12 (dla sygnału o złej jakości). W górnej części rysunków zaprezentowano sygnał po normalizacji okienkowej (czerwony) i po filtracji falkowej (niebieski). Poniżej przedstawiono sygnał po przemnożeniu przez funkcje stopnia czwartego. Czerwonymi punktami oznaczono wszystkie znalezione szczyty powyżej progu określonego na

poziomie 25% (czerwona pozioma przerywana linia). Na samym dole zaprezentowano sygnał po filtracji falkowej z naniesionymi tonami S1.



Rys. 3.11. Detekcja tonów charakterystycznych w sygnale o dobrej jakości



Rys. 3.12. Detekcja tonów charakterystycznych w sygnale o złej jakości

Detekcja tonów S1 pozwala na wyznaczenie kolejnych parametrów jakościowych. Parametr trzeci zdefiniowany wzorem (3.11) określa stosunek liczby wykrytych tonów S1 do liczby tonów estymowanych przy pomocy funkcji autokorelacji.

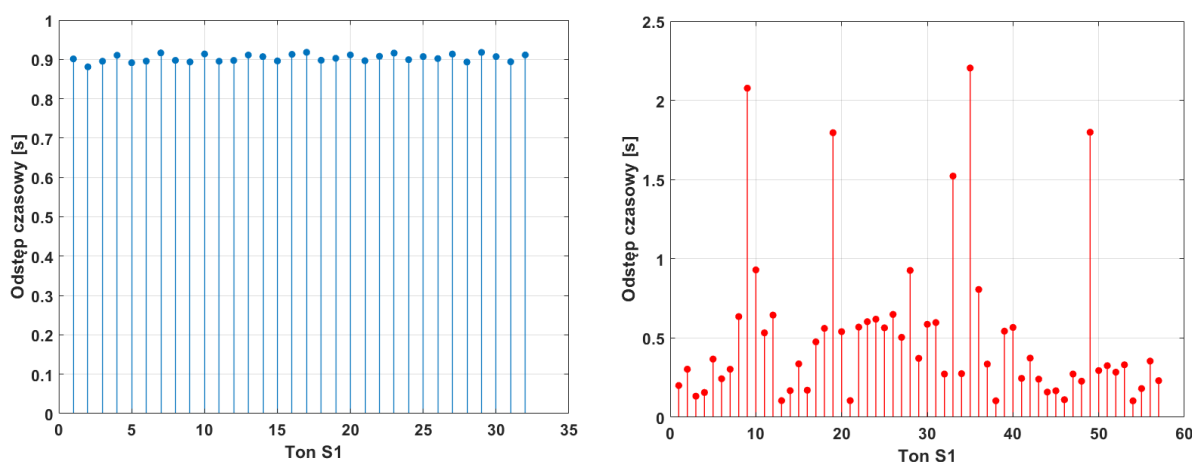


$$p_3 = \frac{\sum_{i=1}^n S1_i}{T \cdot F_{acorr}} \quad (3.11)$$

gdzie:  $S1_i$  – wykryty ton S1,  
 $T$  – czas trwania sygnału (30 s),  
 $F_{acorr}$  – częstotliwość podstawowa wyznaczona z funkcji autokorelacji.

Założono tu, że sygnał fonokardiograficzny jest sygnałem quasiokresowym zawierającym jedno uderzenie serca w czasie trwania pojedynczego okresu. Parametr  $p_3$  będzie bliski jedności jeżeli wszystkie tony zostaną zdetekowane poprawnie, a sygnał nie będzie zawierał niepożądanych zakłóceń. Parametr  $p_3$  dla sygnału o dobrej jakości wynosi 1,00. Częstotliwość rytmu serca określona na podstawie funkcji autokorelacji wynosi 1,106 Hz, a powyższy algorytm wykrył 33 tony S1. Natomiast w przypadku sygnału o złej jakości parametr trzeci ma wartość 0,52 przy częstotliwości rytmu serca 0,998 Hz i 58 wykrytych tonach S1.

W następnym kroku wyznaczono interwały czasowe pomiędzy kolejnymi wykrytymi tonami S1, a następnie średnią wartość odstępu występującego w sygnale. Parametr  $p_4$  określa procentowy stosunek liczby wykrytych tonów S1 do liczby tonów estymowanych za pomocą średniego czasu interwału. Na rys. 3.13 przedstawiono kolejne odstępy czasowe między kolejnymi tonami S1 występującymi w sygnale.



Rys. 3.13. Odstępy czasowe między poszczególnymi tonami S1 dla sygnału o dobrej jakości (niebieski) i złej jakości (czerwony)

Parametr  $p_4$  został zdefiniowany za pomocą wzoru (3.12).

$$p_4 = \frac{T}{\overline{dS1} \cdot nS1} \quad (3.12)$$

gdzie:  $T$  – czas trwania sygnału (30 s),  
 $\overline{dS1}$  – średni czas interwałów między tonami S1,  
 $nS1$  – liczba wykrytych tonów S1.

Parametr  $p_4$  dla obu powyższych sygnałów jest bliski jedności. Związane jest to z faktem, że średnia odległość czasowa między tonami S1, w stosunku do liczby wykrytych tonów zawsze jest bliska jedności. W dalszej analizie stwierdzono, że parametr ten nie może różnicować sygnałów ze względu na ich jakość.

Parametr piąty jest również powiązany z interwałami czasowymi tonów S1. Jest on określony jako odchylenie standardowe interwałów odniesione do ich wartości średniej, zgodnie z wzorem (3.13).

$$p_5 = \frac{\sqrt{\frac{1}{N-1} \sum_{i=1}^N (\overline{dS1} - dS1_i)^2}}{\overline{dS1}} \quad (3.13)$$

Należy zauważyć, że dla sygnałów charakteryzujących się złą jakością, parametr  $p_5$  będzie przyjmował duże wartości. Dla sygnału o dobrej jakości parametr ten przyjmuje wartość 0,01, natomiast dla sygnału o złej jakości wynosi 0,94. Wartości tych parametrów zostały odniesione do wartości średniej odstępu tonów S1. Parametr ten określa rozrzut interwałów czasowych.

Z interwałami czasowymi poszczególnych tonów związany jest również kolejny parametr  $p_6$  – jest to pierwiastek kwadratowy ze średniej kwadratów różnic pomiędzy kolejnymi dwoma interwałami  $dS1$  odniesiony do ich wartości średniej RMSSD (ang. *root mean square of successive differences*) wyrażony wzorem (3.14).

$$p_6 = \frac{\sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (dS1_{i+1} - dS1_i)^2}}{\overline{dS1}} \quad (3.14)$$

Podobnie jak parametr piąty, dla sygnałów o niskiej jakości rejestracji parametr  $p_6$  będzie przyjmował duże wartości, dlatego dla sygnału charakteryzującego się niską jakością wynosi on 1,25, natomiast dla sygnału o dobrej jakości 0,01.

Kolejny zaproponowany przez autora parametr niesie informację o poprawnej liczbie tonów S1 w określonym oknie czasowym. Na przebieg czasowy sygnału PCG po filtracji falkowej, z wyznaczonymi tonami S1 nałożono okno czasowe o czasie trwania 2,2 s, które przesuwano wzdłuż osi czasu z 25% zakładką. Za każdym razem wyznaczono liczbę wykrytych tonów S1. Jeżeli liczba tonów S1 w danym oknie zawierała się w przedziale od 2 do 4, to oznaczano je jako 1, w innym przypadku oznaczano je jako 0 [47]. Parametr  $p_7$  definiuje procentowy udział liczby okien zawierających od 2 do 4 uderzeń serca w stosunku do całkowitej liczby okien, zgodnie z wzorem (3.15).

$$p_7 = \frac{w(1)}{w(1) + w(0)} \quad (3.15)$$

gdzie:  $w(1)$  – liczba okien czasowych oznaczonych jako 1,  
 $w(0)$  – liczba okien czasowych oznaczonych jako 0.

Parametr ten jest również powiązany częściowo z regularnością występowania tonów S1, ale sprawdza również ich poprawną liczbę w sygnale. Dla sygnału o dobrej jakości parametr ten wynosi 0,95 co oznacza że prawie wszystkie okna zawierają wykryte tony S1 w liczbie od 2 do 4. Natomiast dla sygnału o niskiej jakości parametr ten przyjmuje wartość 0,53, co oznacza, że tylko połowa okien zawierała wymaganą liczbę tonów S1.


Ósmy parametr jakościowy definiuje procentowy stosunek całkowitego czasu występowania sygnału powyżej 40% amplitudy sygnału do całkowitego czasu trwania sygnału, zgodnie z wzorem (3.16).

$$p_8 = \frac{t_{y(f)>40\%}}{T} \quad (3.16)$$


gdzie:  $t_{y(f)>40\%}$  – całkowity czas trwania sygnału powyżej 40% amplitudy sygnału,  
 $T$  – całkowity czas trwania sygnału (30 s).

W sygnale PCG o niskim poziomie zakłóceń czas trwania powyżej 40% amplitudy będzie bardzo mały, ponieważ znajdują się tam tylko szczyty tonów S1. Natomiast w przypadku występowania szumu, lub zakłóceń np. sygnałem mowy, czas ten znacząco się wydłuży, ze względu na dużo większą energię sygnału mowy w stosunku do sygnału PCG. Dla sygnału o złej jakości parametr wynosi 0,14, natomiast dla sygnału o dobrej jakości 0,03.

Ostatni parametr, tj.  $p_9$ , jest zbliżony do parametru  $p_8$ . Określa on procent całkowitego czasu występowania modułu sygnału powyżej kwantyla rzędu 0,85. W sygnale silnie zaszumionym, energia sygnału w przedziale poniżej kwantyla rzędu 0,85 będzie większością całkowitej energii sygnału. Na rys. 3.14 pokazano sygnał silnie zaszumiony wraz z poziomem kwantyla rzędu 0,85, natomiast na rys. 3.15 – sygnał niezaszumiony. Analizując omawiane rysunki można stwierdzić, że w sygnałach z wysokim udziałem szumu szerokość przedziału między czerwonymi liniami jest większa niż w sygnałach z niskim poziomem szumu. Dla sygnałów, w których są wyraźne tony S1, wartość parametru  $p_9$  będzie niższa niż w przypadku sygnałów zaszumionych.



Rys. 3.14. Sygnał PCG z dużym udziałem szumu, z zaznaczonym przedziałem kwantyla rzędu 0,85



Rys. 3.15. Sygnał PCG z małym udziałem szumu, z zaznaczonym przedziałem kwantyla rzędu 0,85

W tabeli 3.1, przedstawiono wartości zdefiniowanych wyżej parametrów dla sygnałów o wysokiej i niskiej jakości.

Tabela 3.1. Zestawienie wartości parametrów jakościowych dla dwóch przykładowych sygnałów z grupy referencyjnej.

Parametr	Dobra jakość	Zła jakość
$\rho_1$	9,31 dB	12,92 dB
$\rho_2$	0,59	0,73
$\rho_3$	1,00	0,52
$\rho_4$	1,00	1,01
$\rho_5$	0,01	0,94
$\rho_6$	0,01	1,25
$\rho_7$	0,95	0,53
$\rho_8$	0,03	0,14
$\rho_9$	0,59	0,68

Na podstawie powyższej tabeli można zauważyć duże i bardzo duże różnice między wszystkimi parametrami, za wyjątkiem parametru  $\rho_4$ , co mogłoby wskazywać, że do oceny jakości wystarczy wykorzystać jeden lub najwyżej kilka z nich. Należy jednak zauważyć, że do wyboru i porównania proponowanych parametrów różnicujących wybrano sygnały, które różniły się znacząco jakością rejestracji.

### 3.3. Klasyfikator jakościowy

Wszystkie dziewięć parametrów zostało wyznaczonych w grupie 52 przypadków zawierających 27 sygnałów charakteryzujących się względnie niską jakością i 25 sygnałów o jakości umożliwiającej dalszą analizę. Jakość tych sygnałów została oceniona subiektywnie we współpracy z kardiologami dokonującymi rejestracji. Przed przystąpieniem do dalszych analiz i po wstępnych próbach

pilotażowych, zdecydowano się wszystkie zebrane parametry poddać procesowi standaryzacji określonej wzorem (3.17).

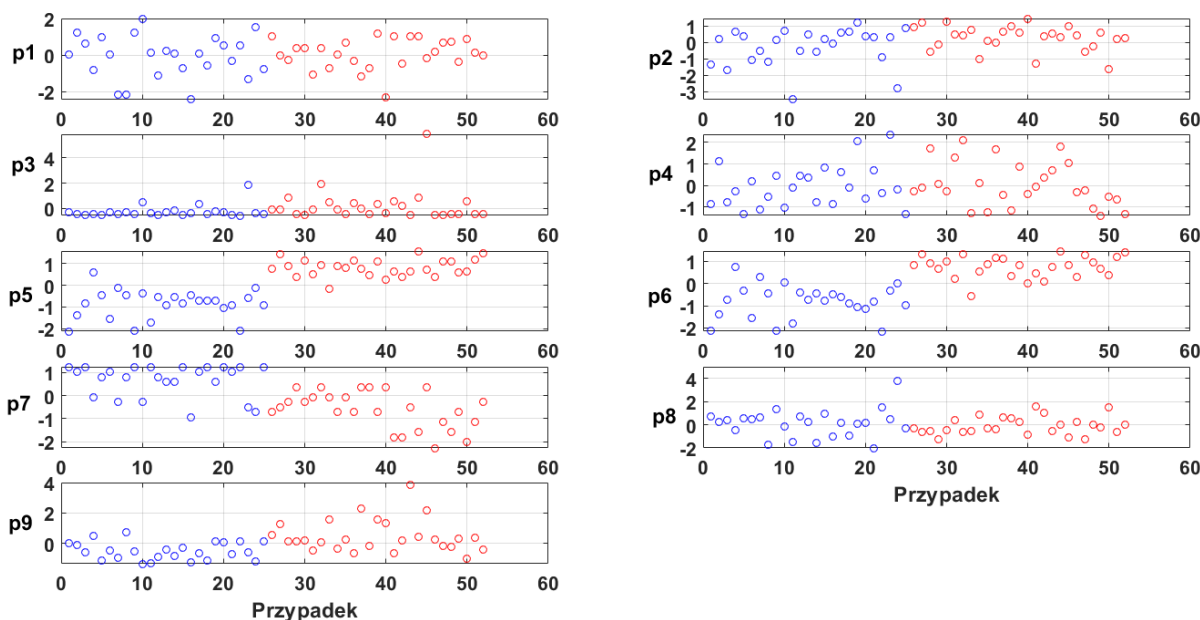
$$P_i = \frac{p_i - m}{\sigma} \quad (3.17)$$

gdzie:  $P_i$  – wartość parametru  $p_i$  po standaryzacji,  
 $p_i$  – pierwotna wartość parametru,  
 $m$  – wartość średnia z populacji parametru  $p_i$ ,  
 $\sigma$  – odchylenie standardowe z populacji parametru  $p_i$ .

Na rys. 3.16 przedstawiono ustandaryzowane parametry jakościowe wyznaczone w grupie wszystkich przypadków referencyjnych. Niebieskim kolorem oznaczono sygnały charakteryzujące się dobrą jakością, a czerwonym – złą. Aby określić jakość dyskryminacyjną poszczególnych parametrów posłużono się współczynnikiem istotności Fishera  $\gamma$ , który jest zdefiniowany jako odległość między wartościami średnimi danego parametru dla obu klas, odniesiona do podwojonej sumy odpowiednich odchyłeń standardowych. Im większa wartość współczynnika  $\gamma$  tym większa zdolność dyskryminacyjna rozpatrywanego parametru. Współczynnik istotności  $\gamma$  zdefiniowany jest wzorem (3.18).

$$\gamma = \frac{|\mu_p - \mu_f|}{2(\sigma_p + \sigma_f)} \quad (3.18)$$

gdzie:  $\mu_p, \mu_f$  – wartości średnie parametru dla sygnału o dobrej i złej jakości,  
 $\sigma_p, \sigma_f$  – odchylenia standardowe parametru dla sygnału o dobrej i złej jakości.




Rys. 3.16. Rozkład dziewięciu parametrów jakościowych (kolor niebieski – „dobra” jakość, kolor czerwony – „zła” jakość)

Jeżeli średnie arytmetyczne zbiorów  $\mu_p, \mu_f$  czyli centra tych zbiorów będą maksymalnie od siebie oddalone i jeśli jednocześnie mianownik wyrażenia (3.14) będzie jak najmniejszy, co oznacza maksymalne skupienie wartości parametrów wokół ich centrów, wtedy wartość współczynnika będzie największa. Metoda zakłada, że duża wartość sumarycznego współczynnika istotności Fishera

oznacza dobrą zdolność dyskryminacyjną cechy, a mała, że wartości cechy należące do obu klas są rozproszone i potencjalnie przemieszane ze sobą, co dyskwalifikuje ją jako cechę dystynktywną, przy czym od tej drugiej konkluzji są wyjątki [48][49]. Dokładniejszy opis metody współczynników Fishera umieszczono w podrozdziale 5.1.

Na rys. 3.17 zaprezentowano wartości współczynników Fishera dla wszystkich dziewięciu parametrów jakościowych wyznaczonych w grupie sygnałów referencyjnych.




Rys. 3.17. Wartości współczynników istotności Fishera dla dziewięciu parametrów p

W podrozdziale 3.2. wspomniano, że parametr  $p_4$  będzie miał znikomą zdolność dyskryminacyjną, co potwierdza powyższy rysunek. Największą zdolność dyskryminacyjną mają parametry  $p_5$ ,  $p_6$  i  $p_7$  oraz ewentualnie  $p_9$ , na nich postanowiono więc skupić uwagę tworząc klasyfikator jakościowy. Wybrane parametry to:


- $p_5$  - odchylenie standardowe z wyznaczonych interwałów odniesione do ich wartości średniej,
- $p_6$  - pierwiastek kwadratowy ze średniej kwadratów różnic pomiędzy kolejnymi dwoma interwałami dS1 odniesiony do ich wartości średniej,
- $p_7$  - stosunek liczby okien o czasie trwania 2,2 s zawierających od 2 do 4 tonów S1 do całkowitej liczby okien,
- $p_9$  - stosunek całkowitego czasu występowania sygnału powyżej kwantyla rzędu 0,85.

Po wyborze parametrów pozwalających na potencjalnie najlepszą klasyfikację jest wybór metody klasyfikacyjnej pozwalającej na utworzenie hiperpłaszczyzny rozdzielającej oba zbiory danych. Pierwszym wyborem była analiza składowych głównych PCA (ang. *Principal Component Analysis*). Matematyczny opis tej metody zostanie przedstawiony w rozdziale 5.2. Na rys. 3.18 przedstawiono wynik analizy PCA wykorzystującej wszystkie 9 parametrów. Analiza PCA ograniczyła się tylko do dwóch pierwszych składowych głównych. Używając 9 parametrów dwa przypadki o dobrej jakości zostały zakwalifikowane do grupy sygnałów o złej jakości.



Rys. 3.18. Wynik analizy PCA z wykorzystaniem wszystkich 9 parametrów

Na rys. 3.19 zaprezentowano wynik analizy PCA z wykorzystaniem 4 najlepszych parametrów. W tym wariancie tylko jeden przypadek charakteryzujący się dobrą jakością został zakwalifikowany do grupy złej.



Rys. 3.19. Wynik analizy PCA z wykorzystaniem 4 najlepszych parametrów

Wyniki klasyfikacji PCA przedstawiono w tabeli 3.2. PCA dla 4 cech osiągnęło wyższą dokładność (ang. *Accuracy*) – 98,08 %, w przeciwieństwie do PCA dla wszystkich cech – 96,15%. Mniejsza liczba

parametrów wpłynęła również na większą czułość, oraz na złożoność obliczeniową wykorzystania takiego klasyfikatora. Wszystkie parametry ujęte w tabeli 3.2 opisano w podrozdziale 6.2.2.


Tabela 3.2. Wyniki i parametry klasyfikacji PCA

	PCA 9 cech		PCA 4 cechy	
	dobry	zły	dobry	zły
Dobry	23	0	24	0
Zły	2	27	1	27

Czułość	92,00 %	96,00 %
Specyficzność	100,00 %	100,00 %
PPV	100,00 %	100,00 %
NPV	93,10 %	96,43 %
Dokładność	96,15 %	98,08 %


Kolejną metodą wykorzystaną do klasyfikacji powyższych sygnałów jest LDA (ang. *Linear Discriminant Analysis*). Metoda ta jest używana do znalezienia liniowej kombinacji cech, które najlepiej rozróżniają dwie lub więcej klas. Istota tej metody zostanie przedstawiona w podrozdziale 5.3. Wykorzystując LDA również zdecydowano się porównać wyniki dla wszystkich 9 parametrów oraz dla 4 najlepszych. Wynik klasyfikacji LDA dla wszystkich parametrów przedstawiono na rys. 3.20, w tym przypadku jeden sygnał o dobrej jakości został zakwalifikowany jako zły.



Rys. 3.20. Wynik analizy LDA z wykorzystaniem wszystkich 9 parametrów

Na rys. 3.21 zaprezentowano wynik analizy LDA dla 4 najlepszych parametrów. Można zauważyć, że w tym przypadku liczba parametrów nie wpłynęła na ostateczny wynik, aczkolwiek należy zauważyć, że im większa liczba cech tym większa złożoność obliczeniowa, dlatego klasyfikator z mniejszą liczbą cech jest lepszy od klasyfikatora opierającego się na wszystkich dziewięciu cechach. Wyniki i parametry klasyfikacji LDA zaprezentowano w tabeli 3.3.






Rys. 3.21. Wynik analizy LDA z wykorzystaniem 4 najlepszych parametrów

Tabela 3.3. Wyniki i parametry klasyfikacji LDA

	LDA 9 cech		LDA 4 cechy	
	dobry	zły	dobry	zły
Dobry	24	0	24	0
Zły	1	27	1	27


Czułość	96,00 %	96,00 %
Specyficzność	100,00 %	100,00 %
PPV	100,00 %	100,00 %
NPV	96,43 %	96,43 %
Dokładność	98,08 %	98,08 %

Ostatnią wykorzystaną metodą klasyfikacji jest sieć *SVM* (ang. *Support Vector Machine*), która została opracowana przez Vapnika w latach siedemdziesiątych XX wieku [50]. Opis tej metody został przedstawiony w podrozdziale 6.2.5. Na rys. 3.22 zaprezentowano wynik uczenia sieci SVM na płaszczyźnie wektorów  $p_2$  i  $p_5$ . Wektory nośne zaznaczono czarnym konturem.



Rys. 3.22. Wizualizacja sygnałów na płaszczyźnie  $(p_2, p_5)$  – wektory nośne wyróżniono czarnym konturem

Wartości  $\beta_i$  związane z poszczególnymi parametrami  $p_i$ , otrzymane w procesie uczenia sieci i przedstawione na rys. 3.23, określają ich „wagę” w procesie klasyfikacji.




Rys. 3.23. Parametry przekształcenia SVM  $\beta_i$  dla parametrów  $p_i$

Wszystkie dziewięć parametrów może zostać przetransformowane do wyjścia sieci SVM zgodnie z wzorem (3.19).

$$y = X_p \cdot \beta + b \quad (3.19)$$


gdzie:  $y$  – wektor odpowiedzi sieci SVM,  
 $X_p$  – macierz wartości dziewięciu parametrów  $p$ ,  
 $\beta$  – wektor parametrów  $\beta_i$  przekształcenia SVM,  
 $b$  – składowa stała przekształcenia (dla powyższego modelu  $b = 125,5$ ).

Na rys. 3.24 zaprezentowano wyniki klasyfikacji przez sieć SVM uczoną z uwzględnieniem wszystkich 9 parametrów. Kolorem niebieskim oznaczono sygnały charakteryzujące się wysoką jakością rejestracji, natomiast czerwonym złą jakością. Fioletowa przerywana linia na poziomie 0 określa próg separacji. Wartości na osi rzędnych uzyskane z wzoru (3.15) świadczą o przynależności danego sygnału do konkretnej klasy. Jeśli wartość wyznaczonego parametru jest mniejsza od 0, to przypadek jest klasyfikowany jako sygnał o złej jakości, w przeciwnym przypadku jako sygnał o dobrej jakości. Wyniki klasyfikacji przedstawione na poniższym rysunku wskazują, że nie występuje ani jeden błąd klasyfikacji, czyli skuteczność klasyfikatora SVM w grupie uczącej okazała się stuprocentowa. Oznacza, to że spośród zastosowanych metod klasyfikator SVM uzyskał najlepsze wyniki.



Rys. 3.24. Odpowiedź sieci SVM przy użyciu wszystkich dziewięciu parametrów

Na rys. 3.25 przedstawiono zestawienie jakościowe wszystkich pozostałych sygnałów. Z grupy 921 zarejestrowanych sygnałów wyłączono grupę referencyjną - 52 sygnały wybrane do wyznaczenia klasyfikatora, co w rezultacie daje 869 pozostałych sygnałów. Z każdego sygnału wyekstrahowano dziewięć parametrów jakościowych, a następnie wykorzystano nauczonego klasyfikatora SVM do określenia współczynnika jakości danego sygnału. Omawiany rysunek prezentuje kolorem czerwonym sygnały zakwalifikowane jako sygnały o złej jakości, natomiast niebieskim sygnały charakteryzujące się względnie dobrą jakością. Im dalej od punktu 0 na osi rzędnych tym sygnał jest lepszy, bądź gorszy pod względem jakościowym. Uznano, że sygnały zawierające się w granicy między fioletowymi poziomymi liniami  $(-0,2; 0,2)$  są średniej jakości. Do dalszych analiz uwzględniono tylko sygnały o dobrej jakości znajdujące się poniżej wartości  $-0,2$ .



Rys. 3.25. Zestawienie jakości pozostałych zarejestrowanych sygnałów

Z 869 analizowanych sygnałów, 293 sygnały zostały zakwalifikowane jako sygnały o złej jakości, i 576 sygnały określono jako sygnały o dobrej jakości.

### 3.4. Podsumowanie

W rozdziale trzecim zaprezentowano kompletny proces analizy i klasyfikacji sygnałów fonokardiograficznych pod kątem jakości rejestracji sygnału. Zdefiniowano i opisano dziewięć parametrów, które w sposób pośredni charakteryzują jakość sygnału. Przedstawiono proces przygotowania zarejestrowanego sygnału cyfrowego do wyznaczenia parametrów jakościowych. Przedstawiono wartości współczynników Fishera oraz wybrano najlepsze parametry, przeprowadzono analizę składowych głównych (PCA), liniową analizę dyskryminacyjną (LDA) oraz wykorzystano sieć wektorów nośnych (SVM). Ze wszystkich trzech metod wybrano najlepszą pod kątem skuteczności, czyli SVM, której dokładność wynosiła 100% w grupie uczącej. Omówiony klasyfikator umożliwił zaprojektowanie skutecznego automatycznego systemu analizy jakości zarejestrowanego sygnału fonokardiograficznego, dzięki któremu bezpośrednio po rejestracji możliwa jest ocena sygnału i ewentualne powtórzenie osłuchiwania przez przeszkolony personel medyczny.

Analiza jakościowa przedstawiona w rozdziale trzecim jest niezbędnym elementem w procesie znalezienia cech wskazujących na obecność stanów patologii układu sercowo naczyniowego. Dzięki odpowiedniej ocenie jakości, jesteśmy pewni, że analizowany sygnał jest sygnałem fonokardiograficznym i nie zawiera artefaktów nie związanych z pracą serca, które mogą negatywnie wpłynąć na ocenę zdrowia pacjenta.

# 4

## GENERACJA CECH DYSTYNKTYWNYCH

W rozdziale trzecim przedstawiono kompletny proces analizy jakościowej sygnałów fonokardiograficznych. Spośród wszystkich zarejestrowanych 869 sygnałów, wybrano 576 charakteryzujących się dobrą jakością rejestracji. Tylko sygnały spełniające odpowiednie kryteria jakościowe mogą być poddawane dalszym analizom mającym na celu detekcję schorzeń układu sercowo-naczyniowego. Etap generacji parametrów (deskryptorów numerycznych) reprezentujących poszczególne sygnały fonokardiograficzne, zwany też parametryzacją sygnału jest bardzo istotny. Odpowiedni dobór parametrów i metod ich wyznaczania rzutuje na jakość systemu i jego skuteczność. Celem parametryzacji jest przekształcenie zarejestrowanego sygnału fonokardiograficznego na zestaw parametrów charakteryzujących dany sygnał i pozwalających na wykrycie obecności schorzenia kardiologicznego.

Na poziomie  $-0,2$  ustalono próg rozróżnialności między sygnałami dobrymi a bardzo dobrymi, natomiast na poziomie  $+0,2$  próg rozróżnialności między sygnałami złymi a bardzo złymi. Omawiane progi zostały zaprezentowane na rys. 3.25 jako przerywane linie na poziomie  $\pm 0,2$ . W tabeli 4.1

przedstawiono zestawienie ilościowe sygnałów fonokardiograficznych ze względu na jakość rejestracji. Im wartość współczynnika jakościowego jest niższa tym sygnał jest jakościowo lepszy.


Tabela 4.1. Zestawienie ilościowe sygnałów fonokardiograficznych ze względu na jakość rejestracji.

Klasa jakościowa	Przedział wartości	Liczba
Bardzo zła	$\langle 0,2; +\infty \rangle$	155
Zła	$\langle 0; 0,2 \rangle$	138
Dobra	$\langle -0,2; 0 \rangle$	186
Bardzo dobra	$\langle -\infty; -0,2 \rangle$	390

Do dalszych badań wykorzystano sygnały o jakości bardzo dobrej, czyli 390 sygnałów.

## 4.1. Uśrednianie w dziedzinie częstotliwości

W celu określenia przydatności analizy widmowej wykonano analizę czasowo-częstotliwościową zebranych danych. Wyznaczony spektrogram obrazuje czasowo-częstotliwościowy charakter badanych sygnałów, co pozwala wstępnie ocenić pozytywnie przydatność analizy widmowej dla tego typu sygnałów. Na rys. 4.1 przedstawiono spektrogramy dwóch wybranych sygnałów pochodzących od pacjenta zdrowego i chorego [51].

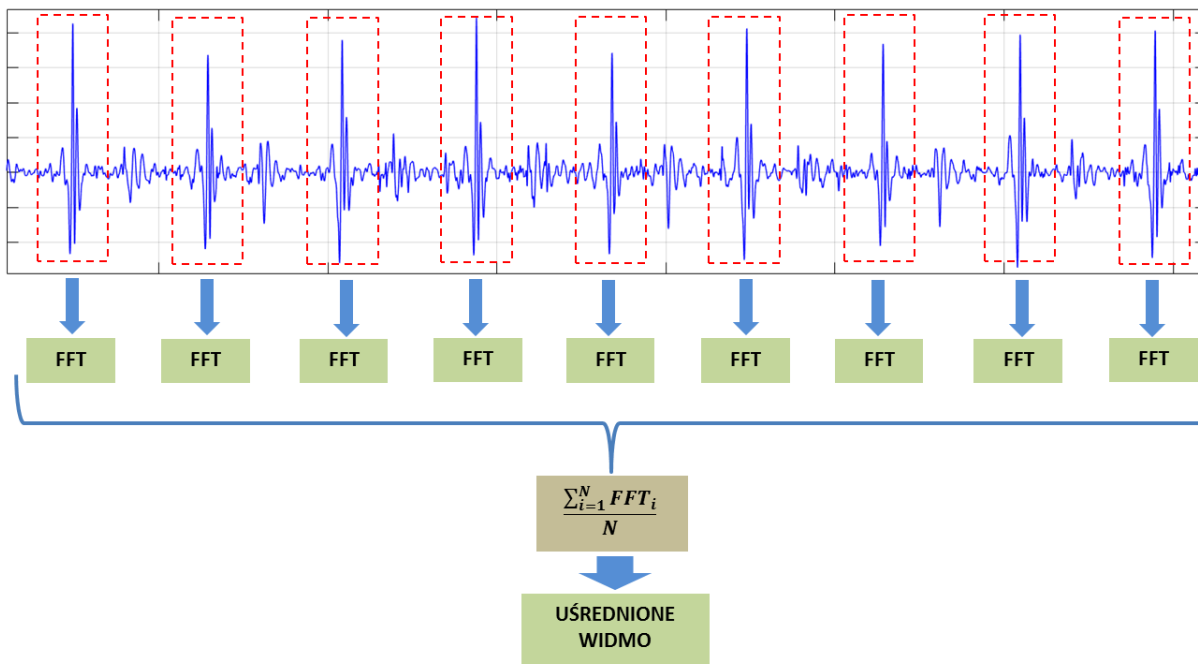


Rys. 4.1. Przykładowy spektrogram pacjenta zdrowego (lewy) i chorego (prawy).


Analizując powyższy rysunek, widać znaczące różnice między sygnałami. Spektrogram pacjenta chorego cechuje się znacząco większymi różnicami w amplitudach poszczególnych tonów. Na obu rysunkach widać efekt działania filtra dolnoprzepustowego o częstotliwości granicznej 1 kHz, zaimplementowanego w stetoskopie Littmann 3200.

Zarejestrowany sygnał fonokardiograficzny to sygnał w dziedzinie czasu zawierający od kilku do kilkunastu uderzeń serca, czyli par tonów S1 (tony systoliczne) i S2 (tony diastoliczne). Szmer charakterystyczny dla schorzeń układu sercowo-naczyniowego obecne są w każdym powtarzającym się tonie. Sygnały PCG są często zakłócone sygnałami pochodzącymi z wnętrza organizmu, dlatego zastosowano nowatorską metodę uśredniania widm poszczególnych tonów uwzględniającą od kilku do kilkunastu kolejnych uderzeń serca. W efekcie otrzymano uśrednione widma tonów S1 i S2 [51].

Na rys. 4.2 zaprezentowano poglądowy proces przedstawiający uśrednianie poszczególnych tonów. W pierwszym etapie wyodrębniono tony S1 i S2 z każdego zarejestrowanego sygnału fonokardiograficznego, które następnie poddano okienkowaniu. Zastosowanie okna pozwoliło na minimalizację przecieku widma. Finalnie użyto okna *Hamminga*, którego kształt oraz widmo przedstawiono na rys. 4.3.



Rys. 4.2. Nowatorska metoda uśredniania tonów


Rys. 4.3. Funkcja okna *Hamminga* w dziedzinie czasu (w próbkach) oraz w dziedzinie częstotliwości

Okno *Hamminga* jest zmodyfikowaną wersją okna *Hanninga*. Kształt tego okna jest określany jako podniesiony kosinus. Jest on zdefiniowany wzorem (4.1).

$$\omega(n) = 0,54 - 0,46 \cdot \cos\left(\frac{2\pi n}{M-1}\right) \quad 0 \leq n \leq M-1 \quad (4.1)$$

gdzie:  $\omega(n)$  – funkcja okna,  
 $M$  – długość okna.

Podstawowa różnica między tymi oknami, jest taka, że w dziedzinie czasu okno *Hamminga* przy krawędziach nie jest równe zero. Dobór okna oraz czas trwania tonów został zoptymalizowany pod kątem skuteczności klasyfikatora. Wyniki optymalizacji przedstawiono w dalszej części rozprawy. Przykładowe przebiegi czasowe tonów skurczowych (S1) i rozkurczowych (S2) przedstawiono na rys. 4.4.


Rys. 4.4. Przykładowe przebiegi czasowe tonów S1 i S2 po zastosowaniu okna *Hamminga*

Po wyodrębnieniu i odpowiednim przygotowaniu tonów serca wyznaczono widmo każdego z nich. W tym celu zastosowano algorytm dyskretnej transformaty Fouriera określony równaniem (4.2), a następnie wyznaczono widmo mocy określone zależnością (4.3) [52].

$$X(m) = \frac{2}{N} \sum_{n=0}^{N-1} x(n) e^{-j2\pi \frac{mn}{N}} \quad (4.2)$$


$$P(m) = |X(m)|^2 \quad (4.3)$$

Ostatnim etapem było uśrednienie otrzymanych widm mocy poszczególnych tonów oraz poddanie ich normalizacji. Na rys. 4.5 i 4.6 przedstawiono uśrednione widma poszczególnych przypadków w skali decybelowej i liniowej w określonej grupie przypadków [53].



Rys. 4.5. Uśrednione widma w skali liniowej (czerwone – przypadki patologiczne, niebieskie – przypadki fizjologiczne)






Rys. 4.6. Uśrednione widma w decybelach (czerwone – przypadki patologiczne, niebieskie – przypadki fizjologiczne)

## 4.2. Ekstrakcja cech

Po badaniach wstępnych i konsultacjach medycznych autor zdecydował się ostatecznie na poszukiwanie cech diagnostycznych tylko w tonie skurczowym (S1). Ton S1 ma większą energię w porównaniu do tonu S2, dlatego skuteczniej można go wyizolować z całego często zakłóconego sygnału fonokardiograficznego [54]. W celu odpowiedniej klasyfikacji uzyskanych widm do grupy przypadków fizjologicznych lub patologicznych wykonana została ekstrakcja 33 cech widmowych [52]. W niniejszym podrozdziale każda z cech zostanie zdefiniowana i opisana. Na rys 4.7 przedstawiono uśrednione widmo amplitudowe jednego z zarejestrowanych przypadków.



Rys. 4.7. Uśrednione widmo amplitudowe wybranego przypadku

Widmo zostało ograniczone częstotliwościowo do 200 Hz ze względu na brak informacji diagnostycznych powyżej tej częstotliwości. Widmo zostało również unormowane, dlatego wartość maksymalna widma jest równa 1,0.

Pierwszy parametr opisujący właściwości widma amplitudowego to moc maksymalna, określana zgodnie z równaniem (4.4).

$$c_1 = P_{max} = \max \{P_n\} \quad (4.4)$$


gdzie:  $P_n$  – moc  $n$ -tej składowej.

Dla widm znormalizowanych ten parametr zawsze będzie równy 1 co oznacza, że nie wnosi żadnej informacji diagnostycznej. Kolejny parametr to częstotliwość, na której występuje maksimum mocy. Parametr ten jest opisany równaniem (4.5).

$$c_2 = f_m = n_{fmax} \Delta f \quad (4.5)$$

gdzie:  $\Delta f$  – ziarnistość widma,  
 $n_{fmax}$  – numer składowej częstotliwości dla której występuje maksimum mocy  $P_{max}$

Oba te parametry zostały zilustrowane graficznie na rys. 4.8.



Rys. 4.8. Interpretacja graficzna cechy 1 i cechy 2

Parametr trzeci to moc średnia widma która jest określona równaniem (4.6).

$$c_3 = P_{sr} = \frac{\sum_{n=1}^N P_n}{N} \quad (4.6)$$

gdzie:  $N$  – liczba składowych częstotliwości widma.

Parametr czwarty to środek ciężkości widma; jest to sposób opisu kształtu widma mocy. Wskazuje on czy widmo jest zdominowane przez niskie czy wysokie częstotliwości i dodatkowo jest powiązany

z głównym wymiarem barwy dźwięku, czyli z ostrością [55]. Wyznaczenie parametru  $c_4$  odbywa się zgodnie z zależnością (4.7).

$$c_4 = f_c = n_c \Delta f \quad (4.7)$$

gdzie:  $n_c = \sum_{n=1}^N n P'_n$ ,


$P'_n = \frac{P_n}{P_c}$  – moc jednostkowa n-tej składowej częstotliwościowej

Parametr piąty to dyspersja mocy wokół środka ciężkości, jest miarą kształtu widma mocy. Wskazuje on czy widmo jest skupione w pobliżu środka ciężkości, czy jest rozrzucone po całym zakresie częstotliwości. W skrajnym przypadku, cecha ta umożliwiła rozróżnianie sygnałów zawierających jedną częstotliwość (jak ton) od sygnałów o składowych równomiernie rozłożonych w całym widmie (jak szum). Ogólnie umożliwia charakterystykę wszystkich przypadków pośrednich. Dyspersja jest określona zgodnie z wzorem (4.8).

$$c_5 = f_d = n_d \Delta f \quad (4.8)$$

gdzie:  $n_d^2 = \sum_{n=1}^N (n - n_c)^2 P'_n$


Kolejny parametr jest związany ze stromością widma w dolnym zakresie częstotliwości. Określa on szybkość narastania widma amplitudowego od 3 Hz do częstotliwości, dla której występuje maksimum mocy  $f_m$ . Interpretacja tego parametru jest przedstawiona na rys. 4.9, a określona zależnością (4.9).



Rys. 4.9. Interpretacja cechy numer 6

$$c_6 = \frac{P_{max} - P_{3Hz}}{f_m - 3Hz} \quad (4.9)$$

Parametr siódmy wiąże się z szerokością widma na poziomie 70% wartości maksymalnej. Interpretacja graficzna została przedstawiona na rys 4.10, a zależność matematyczną definiującą tę cechę przedstawia równanie (4.10).




Rys. 4.10. Szerokość widma na poziomie 70% wartości maksymalnej

$$c_7 = f_{0,7m+} - f_{0,7m-} \quad (4.10)$$

gdzie:  $f_{0,7m+}$  – częstotliwość dla 70% mocy powyżej częstotliwości maksimum mocy,

$f_{0,7m-}$  – częstotliwość dla 70% mocy poniżej częstotliwości maksimum mocy.

Parametr ósmy jest bardzo zbliżony do parametru siódmego, jednak dotyczy on szerokości widma na poziomie 35% wartości maksymalnej, interpretację graficzną przedstawiono na rys. 4.11.



Rys. 4.11. Szerokość widma na poziomie 35% wartości maksymalnej


Równanie (4.11) przedstawia zależność matematyczną definiującą cechę numer osiem.

$$c_8 = f_{0,35m+} - f_{0,35m-} \quad (4.11)$$

gdzie:  $f_{0,35m+}$  – częstotliwość dla 35% mocy powyżej częstotliwości maksimum mocy,

$f_{0,35m-}$  – częstotliwość dla 35% mocy poniżej częstotliwości maksimum mocy.

Kolejne cechy dotyczą mocy widma w poszczególnych podpasmach. Podzielono widmo na 13 kolejnych podpasma i w każdym wyznaczono maksymalny poziom mocy. Na rys. 4.12 przedstawiono podział widma na niektóre z podpasma. Moc w kolejnym podpaśmie to kolejna cecha; cechy są numerowane od 9 do 21.




Rys. 4.12. Podział widma na podpasma

W pierwszym etapie wyszczególniono następujące podpasma, dla których wyznaczono moc maksymalną w podpaśmie:

- $c_9 = 5 \text{ Hz} - 15 \text{ Hz}$ ;
- $c_{10} = 15 \text{ Hz} - 20 \text{ Hz}$ ;
- $c_{11} = 16 \text{ Hz} - 27 \text{ Hz}$
- $c_{12} = 20 \text{ Hz} - 25 \text{ Hz}$ ;
- $c_{13} = 25 \text{ Hz} - 30 \text{ Hz}$ ;
- $c_{14} = 30 \text{ Hz} - 40 \text{ Hz}$ ;
- $c_{15} = 40 \text{ Hz} - 60 \text{ Hz}$ ;
- $c_{16} = 60 \text{ Hz} - 100 \text{ Hz}$ ;
- $c_{17} = 70 \text{ Hz} - 120 \text{ Hz}$ ;
- $c_{18} = 100 \text{ Hz} - 120 \text{ Hz}$ ;
- $c_{19} = 280 \text{ Hz} - 710 \text{ Hz}$ ;
- $c_{20} = 300 \text{ Hz} - 400 \text{ Hz}$ ;
- $c_{21} = 600 \text{ Hz} - 700 \text{ Hz}$ ;

W kolejnym etapie dostrojono te pasma w celu uzyskania najlepszej skuteczności. Zagadnienie dostrajania pasm przedstawiono wraz z zagadnieniem dostrajania szerokości analizowanego tonu w podrozdziale 6.1.

Widmo tonu S1 charakteryzuje się występowaniem siodła w zakresie częstotliwości od 20 do 40 Hz. Uwzględniono jego obecność w dobieraniu parametrów widmowych. Cecha 22 określa amplitudę minimum lokalnego przed siodłem, a cecha 23 częstotliwość, na której ono występuje – rys. 4.13.



Rys. 4.13. Interpretacja lokalizacji punktu przegięcia

Równania (4.12) i (4.13) przedstawiają omawiane powyżej cechy.

$$c_{22} = P_{infl} \quad (4.12)$$

gdzie:  $P_{infl}$  – amplituda minimum lokalnego występującego przed siodłem.


$$c_{23} = f_{infl} \quad (4.13)$$

gdzie:  $f_{infl}$  – częstotliwość występowania tego minimum.

Parametr kolejny jest również związany z punktem siodłowym. Jest to szerokość widma na poziomie określonym przez minimum lokalne. Na rys. 4.14 przedstawiono, w którym miejscu widma wyznaczana jest omawiana cecha. Równanie (4.14) przedstawia interpretację matematyczną:


$$c_{24} = f_{infl} - f_{P(infl)m-} \quad (4.14)$$

gdzie:  $f_{P(infl)m-}$  – częstotliwość punktu na poziomie minimum lokalnego występującego poniżej częstotliwości maksimum mocy.



Rys. 4.14. Szerokość widma w minimum lokalnym


Kolejna cecha związana jest również z występowaniem minimum lokalnego, jest to szybkość opadania widma od maksimum do minimum lokalnego. Cechę tę zilustrowano na rys. 4.15, a równanie (4.15) przedstawia jej reprezentację matematyczną.



Rys. 4.15. Szybkość opadania

$$c_{25} = \frac{P_{max} - P_{infl}}{f_m - f_{infl}} \quad (4.15)$$

Równanie (4.15) jest bardzo zbliżone do równania (4.9). Oba te równania wskazują średnią szybkość narastania lub opadania obwiedni widma w jednostkach amplitudy / Hz. Następne dwa parametry definiują parametry szczytu siodła (maksimum lokalnego występującego po minimum lokalnym), takie jak amplitudę i częstotliwość.



Rys. 4.16. Amplituda i częstotliwość szczytu siodła

Na rys. 4.16 wskazano punkt widma określony szczytem siodła. Cechy 26 i 27 określają amplitudę tego szczytu oraz częstotliwość, na której występuje. Równania (4.16) i (4.17) przedstawiają omawiane powyżej cechy.

$$c_{26} = P_{saddle} \quad (4.16)$$


gdzie:  $P_{saddle}$  – amplituda szczytu siodła.

$$c_{27} = f_{saddle} \quad (4.17)$$

gdzie:  $f_{saddle}$  – częstotliwość występowania szczytu siodła.

Cecha 28 to liczba ekstremów lokalnych widma. Informacja o liczbie ekstremów może być istotna jeśli chodzi o wykrywanie nietypowych składowych częstotliwościowych. Dlatego kolejna cecha (29) to liczba ekstremów po lewej stronie od szczytu widma, a cecha 30 to liczba ekstremów po prawej stronie (w kierunku wyższych częstotliwości). Wyznaczone ekstrema zaznaczone są na rys. 4.17.





Rys. 4.17. Ekstrema funkcji widma amplitudowego

Dodatkowo wyznaczono takie parametry jak różnica amplitudy pomiędzy punktem siodłowym a amplitudą maksymalną widma, różnica pomiędzy punktem siodłowym a minimum lokalnym oraz różnica częstotliwości między punktem siodłowym a minimum lokalnym. Wszystkie cechy opisujące widmo zostały zebrane w tabeli 4.2.

Tabela 4.2. Zestawienie parametrów opisujących uśrednione widmo tonu S1.

Cecha	Opis
$C_1$	Wartość maksymalna mocy widma amplitudowego
$C_2$	Częstotliwość dla której występuje maksimum mocy
$C_3$	Moc średnia
$C_4$	Środek ciężkości widma
$C_5$	Dyspersja mocy wokół środka ciężkości widma
$C_6$	Szybkość narastania widma amplitudowego od 3 Hz do częstotliwości dla której występuje maksimum mocy
$C_7$	Szerokość widma na poziomie 70% amplitudy maksymalnej
$C_8$	Szerokość widma na poziomie 35% amplitudy maksymalnej
$C_9$	Moc maksymalna w paśmie (5 – 15) Hz
$C_{10}$	Moc maksymalna w paśmie (15 – 20) Hz
$C_{11}$	Moc maksymalna w paśmie (16 – 27) Hz
$C_{12}$	Moc maksymalna w paśmie (20 – 25) Hz
$C_{13}$	Moc maksymalna w paśmie (25 – 30) Hz
$C_{14}$	Moc maksymalna w paśmie (30 – 40) Hz
$C_{15}$	Moc maksymalna w paśmie (40 – 60) Hz
$C_{16}$	Moc maksymalna w paśmie (60 – 100) Hz
$C_{17}$	Moc maksymalna w paśmie (70 – 120) Hz
$C_{18}$	Moc maksymalna w paśmie (100 – 120) Hz
$C_{19}$	Moc maksymalna w paśmie (280 – 710) Hz
$C_{20}$	Moc maksymalna w paśmie (300 – 400) Hz
$C_{21}$	Moc maksymalna w paśmie (600 – 700) Hz
$C_{22}$	Amplituda punktu przegięcia
$C_{23}$	Częstotliwość występowania punktu przegięcia
$C_{24}$	Szerokość widma w punkcie przegięcia
$C_{25}$	Szybkość opadania widma od maksimum mocy do punktu przegięcia

C <sub>26</sub>	Amplituda siodła
C <sub>27</sub>	Częstotliwość występowania szczytu siodła
C <sub>28</sub>	Liczba ekstremów lokalnych
C <sub>29</sub>	Liczba ekstremów lokalnych poniżej częstotliwości dla której występuje maksimum mocy
C <sub>30</sub>	Liczba ekstremów lokalnych powyżej częstotliwości dla której występuje maksimum mocy
C <sub>31</sub>	Amplituda pomiędzy szczytem siodła a amplitudą maksymalną widma
C <sub>32</sub>	Różnica między amplitudą siodła a głównym punktem przegięcia
C <sub>33</sub>	Różnica częstotliwości między szczytem siodła a głównym punktem przegięcia

### 4.3. Podsumowanie

W niniejszym rozdziale przedstawiono definicje i interpretacje cech dystynktywnych określonych na uśrednionym widmie tonu S1. W pierwszej kolejności używając spektrogramu dokonano weryfikacji użyteczności analizy widmowej do oceny przypadków pod kątem występowania patologii układu sercowo-naczyniowego. Widmo sygnału po okienkowaniu posłużyło do ekstrakcji cech osobniczych. Wstępnie wybrano 33 cechy, które opisują kształt i najważniejsze właściwości widma amplitudowego [52]. Jednakże tak liczny zbiór cech jest nadmiarowy i może zawierać cechy silnie wzajemnie skorelowane, co jest wysoce niepożądane, dlatego wymaga umiejętnej selekcji, co może znacząco wpłynąć na skuteczność detekcji schorzeń układu sercowo-naczyniowego i zwiększyć szybkość działania finalnego systemu. Selekcja cech jest kwintesencją kolejnego rozdziału, w którym autor przeprowadził wielokrotną selekcję cech osobniczych z zastosowaniem różnych metod selekcji.

# 5

## SELEKCJA CECH DYSTYNKTYWNYCH

W rozdziale czwartym przedstawiono sposób ekstrakcji maksymalnie licznego zbioru cech dystynktywnych, które mogą posłużyć do detekcji patologii układu sercowo-naczyniowego. Wyekstrahowano łącznie 33 cechy widmowe charakteryzujące uśrednione widmo amplitudowe tonu skurczowego S1. Liczne badania dowodzą, że użycie pełnego zestawu cech często nie prowadzi do uzyskania najlepszych wyników [48][56][57][58]. Część cech w początkowym zbiorze może mieć charakter szumu pomiarowego, co może spowodować zmniejszenie dokładności klasyfikatora. Niektóre cechy mogą być ze sobą silnie skorelowane, co powoduje ich dominację nad pozostałą częścią zbioru i również wpływa niekorzystnie na jakość klasyfikacji. Ponadto zmniejszenie liczby cech pozwala na skrócenie czasu niezbędnego na wykonanie obliczeń oraz uproszczenie klasyfikatora. Selekcja cech, która została opisana w niniejszym rozdziale umożliwiła ograniczenie zbioru cech z jednoczesnym poprawieniem dokładności klasyfikatora.

Selekcji cech osobniczych można dokonać na wiele różnych sposobów, jest to jeden z najważniejszych etapów budowy klasyfikatora gdyż bezpośrednio wpływa na jego finalny „kształt”. Metod selekcji jest wiele, od szybkich metod rankingowych do długotrwałych, zawierających złożone klasyfikatory.

Najbardziej rozpowszechnione miary jakości i metody selekcji to: *współczynnik Fishera, t-statystyki, korelacja wzajemna, sekwencyjna selekcja w przód, algorytmy genetyczne, liniowa analiza dyskryminacyjna* [59]. Niniejszy rozdział opisuje wybrane metody, które zostały wykorzystane do budowy klasyfikatora.

## 5.1. Selekcja cech osobniczych z wykorzystaniem metody Fishera


Ocena cechy dystynktywnej w oparciu o metodę Fishera polega na wyznaczeniu tzw. *współczynnika istotności Fishera (miary Fishera)* zdefiniowanego zależnością

$$\gamma = \frac{|\mu_i - \mu_j|}{2(\sigma_i + \sigma_j)} \quad (5.1)$$

Wspomniany współczynnik określa odległość między wartościami średnimi danej cechy dla obu klas, odniesioną do podwojonej sumy odpowiednich odchyłeń standardowych. Im współczynnik większy tym separowalność klas na podstawie danej cechy większa. W zależności (5.1)  $\mu_i$ ,  $\mu_j$  oznaczają wartości średnie  $i$ -tej i  $j$ -tej klasy dla danej cechy, natomiast  $\sigma_i$  oraz  $\sigma_j$  są odpowiednimi odchyleniami standardowymi[54].

Dana cecha charakteryzuje się dużą zdolnością dyskryminacyjną, jeżeli licznik wyrażenia (5.1) osiąga wartość maksymalną, co wskazuje, że średnia arytmetyczna (centrum)  $\mu_i$  wartości cechy dla  $i$ -tej klasy jest silnie oddalona od centrum klasy  $\mu_j$ , i jednocześnie mianownik osiąga wartości możliwie najmniejsze, co wskazuje, że punkty są mocno skupione wokół centrów danych klas. Zgodnie z założeniami metody, jeżeli cecha charakteryzuje się wysoką wartością współczynnika, oznacza to, że posiada dobrą zdolność dyskryminacyjną, w przeciwnym przypadku, gdy współczynnik ma niską wartość, cecha jest rozproszona w rozpatrywanych klasach, co dyskwalifikuje ją jako cechę dystynktywną [48][49], choć od tej reguły istnieją wyjątki.

Na rys. 5.1 zobrazowano dwie klasy (niebieską i czerwoną) charakteryzowane przez dwie cechy. Dla obu przypadków odległość centrów klas jest taka sama, natomiast każda klasa charakteryzuje się innym skupieniem wokół swojego centrum. Już na pierwszy rzut oka widać, że cecha po prawej stronie pozwala na pełną separowalność klas, współczynnik Fishera wynosi tutaj 2,5, natomiast dla cechy po lewej stronie klasy mieszają się ze sobą, a współczynnik Fishera wynosi jedynie 0,5.



Rys. 5.1. Zobrazowanie metody Fishera – mały współczynnik istotności po lewej i duży po prawej.

Kryterium Fishera może być zastosowane z powodzeniem do problemów dwuklasowych (takich, w których próbuje się odseparować tylko dwie klasy), natomiast w przypadku większej liczby klas, konieczne jest zastosowanie podejścia *każdej klasy przeciw wszystkim innym* (ang. *one vs. rest*). Dzięki temu uzyskuje się zestaw współczynników dla każdej z klas, który następnie sumuje się w celu uzyskania docelowej wartości współczynnika Fishera [60].

Stosując metodę Fishera, po wykonaniu obliczeń poszczególne cechy należy posortować w kolejności malejącej wartości miary Fishera. Konsekwencją takiego działania jest uzyskanie zbioru cech nazywanego *rankingiem*. Selekcja polega na wyborze najlepszych (tych o największych wartościach), a odrzuceniu najgorszych (tych o najmniejszych wartościach). Niestety nie zawsze udaje się w łatwy sposób określić miejsce odcięcia cech najlepszych, dlatego czasem konieczny jest dodatkowy parametr. Nie zawsze bowiem ustalanie optymalnej liczby cech opisujących dany model jest oczywiste. Metoda współczynników Fishera jest niejednokrotnie jedyną metodą, pozwalającą na wykonanie obliczeń w dużym zbiorze danych w założonym krótkim czasie.

## 5.2. Analiza składowych głównych

Oprócz metody współczynników Fishera można wykorzystać również *analizę składowych głównych* (ang. *Principal Component Analysis – PCA*), która jest jedną z podstawowych metod stosowanych do wizualnej oceny zależności między danymi. Analiza ta jest również nazywana *Dyskretną Transformacją Karhunen-Loevego*. Autorem metody jest *Pearson*, który zaproponował jej stosowanie w 1901 roku [61], rozwinął ją *Hotelling* w roku 1933. PCA zakłada, że analizowany zbiór danych zawiera cechy, które nie są od siebie niezależne. Wynika z tego fakt, że tylko niewielka część informacji każdej cechy jest unikatowa, a reszta jest skorelowana z informacjami z innych cech. Dzięki takiemu założeniu możliwe jest przekształcenie zbioru cech w nowe, które są wzajemnie ortogonalne i nazywane są *składowymi głównymi*.

Analiza składowych głównych jest metodą statystyczną wykorzystującą przekształcenie liniowe  $\mathbf{y} = \mathbf{W}\mathbf{x}$ , które transformuje opis stacjonarnego procesu stochastycznego występującego w postaci wektora  $\mathbf{x} \in R^N$  w wektor  $\mathbf{y} \in R^K$ , wykorzystując macierz  $\mathbf{W} \in R^{K \times N}$ , gdzie  $K \ll N$ . Dzięki takiemu przekształceniu przestrzeń wyjściowa posiada zredukowany wymiar, nie tracąc przy tym najważniejszych informacji. Zredukowanie wymiaru osiąga się dzięki odrzuceniu składowych głównych które wykazują niewielką wariancję oraz pozostawieniu wyłącznie pewnej liczby pierwszych, czyli największych składowych.

Jeżeli założymy istnienie wektora  $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$  o zerowej wartości średniej, a przez  $\mathbf{R}_{xx}$  wartość oczekiwaną macierzy autokorelacji

$$\mathbf{R}_{xx} = E[\mathbf{x}\mathbf{x}^T] = \langle \mathbf{x}\mathbf{x}^T \rangle \quad (5.2)$$

to oznaczając przez  $\lambda_i$  wartości własne macierzy autokorelacji  $\mathbf{R}_{xx}$  a przez  $\mathbf{w}_i$  odpowiadające im ortogonalne wektory własne, wartości i wektory własne można powiązać zależnością

$$\mathbf{R}_{xx}\mathbf{w}_i = \lambda_i\mathbf{w}_i \quad (5.3)$$

Wartości własne dodatniej, symetrycznej macierzy  $\mathbf{R}_{xx}$  są dodatnie i rzeczywiste. Podczas gdy uszeregujemy wartości własne i wektory własne w kolejności od największej do najmniejszej, oraz ograniczymy się do  $K$  największych wartości własnych, macierz  $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_K]^T$  przekształcenia PCA definiuje się w postaci zawierającej  $K$  wierszy  $N$ -elementowych, która określa transformację PCA jako przekształcenie liniowe

$$\mathbf{y} = \mathbf{W}\mathbf{x} \quad (5.4)$$

Otrzymany w ten sposób wektor  $\mathbf{y}$  stanowi wektor głównych składników PCA, które mają największy wpływ na rekonstrukcję oryginalnego wektora danych. Transformacja danych PCA uwzględnia jedynie powiązania liniowe między wektorami danych. Macierz korelacji można również przedstawić w postaci zdekomponowanej, oznaczając przez  $\mathbf{L}$  macierz diagonalną utworzoną z wartości własnych  $\lambda_i$ .

$$\mathbf{R}_{xx} = \mathbf{W}^T \mathbf{L} \mathbf{W} \quad (5.5)$$

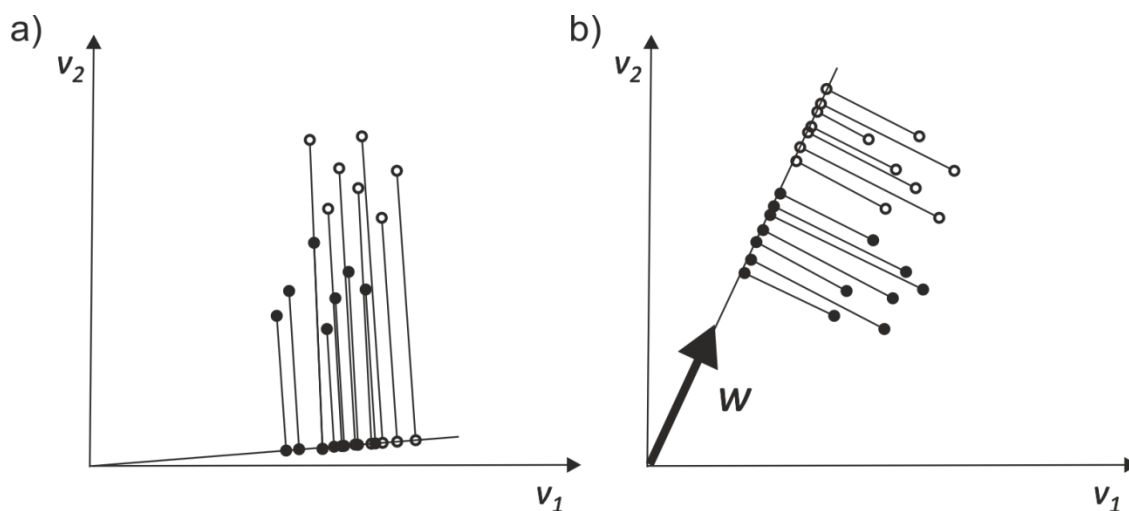
Zasadniczym celem transformacji PCA jest określenie kierunków głównych transformacji, w taki sposób, aby osiągnąć maksymalną wartość iloczynu skalarnego dla kolejnych wartości, przy jednoczesnym spełnieniu warunku wzajemnej ortogonalności kolejnych wektorów  $\mathbf{w}$ . Spełnienie tego warunku powoduje, że otrzymane dane wyjściowe są nieskorelowane.

Transformacja PCA pozwala na kompresję wektora cech przy jednoczesnym zachowaniu maksymalnej porcji informacji występującej w zbiorze danych wejściowych. Największy składnik główny, który powiązany jest z  $\lambda_1$  poprzez swój wektor własny  $\mathbf{w}_1$  - wyznacza kierunek w przestrzeni, dla którego wariancja danych jest maksymalna. Ostatni składnik charakteryzuje się najmniejszą wariancją co oznacza, że ma on najmniejszy wpływ na rekonstrukcję danych wejściowych i można go odrzucić. Transformacja PCA pozwala pozbyć się korelacji między cechami i używa się jej głównie w celu redukcji zbioru cech przy zachowaniu jak największej skuteczności. Transformacja PCA należy do grupy metod selekcji cech bez nadzoru, co oznacza, że nie uwzględnia ona przynależności danych wejściowych do poszczególnych klas [57].

### 5.3. Liniowa analiza dyskryminacyjna

Liniowa Analiza Dyskryminacyjna (LDA – ang. *Linear Discriminant Analysis*) została opisana w oryginalnej postaci przez *Fishera* w 1936 r. [62]. Zastosowanie LDA pozwala na redukcję wymiaru danych przy jednoczesnym zachowaniu niezmięnionej wartości statystyki  $T^2$ , która określa w jakim stopniu dane wejściowe przeczą hipotezie o równości wartości średnich poszczególnych klas w przestrzeni cech. Statystyka  $T^2$ , zwana również statystyką *Hotellinga*, jest uogólnieniem statystyki *t-Studenta*, która jest często używana w zagadnieniach wielowymiarowej analizy wariancji [63].

Zastosowanie LDA pozwala na redukcję przestrzeni cech do wymiaru o jeden mniejszego od liczby klas. W pierwotnej postaci *Fishera* rozpatrywany jest przypadek zawierający dwie klasy. Celem analizy LDA jest znalezienie kierunku w przestrzeni, reprezentowanego przez równoległy wektor jednostkowy  $\mathbf{w}$  taki, że skalary powstałe w wyniku rzutowania na ten kierunek maksymalizują kryterium dyskryminacji  $J(\mathbf{w})$ . Na rys. 5.2 zaprezentowano ideę liniowej analizy dyskryminacyjnej – rzut przykładowego zbioru danych dwuwymiarowych  $u_i$ , na przypadkowy (a) i optymalny (b) kierunek  $\mathbf{w}$ , który zapewnia maksymalną separację w przestrzeni.



Rys. 5.2. Idea LDA [38]

Operacja rzutowania opisywana jest iloczynem skalarnym

$$u_i = \mathbf{w}^T \mathbf{x}_i = \sum_{j=1}^N w_j x_{ij} \quad (5.6)$$

LDA, jako kryterium dyskryminacji zakłada zbieżność maksymalizującą różnicę wartości oczekiwanych w poszczególnych klasach po operacji rzutowania, przy jednoczesnej minimalizacji poszczególnych rozprośnień. Rozproszenia są najczęściej definiowane jako wariancja czyli wartość skalarna. W przypadku wektora wejściowego  $\mathbf{x}$  (zmienna losowa) wartością oczekiwaną jest wektor wartości oczekiwanych poszczególnych współrzędnych, a rozproszenie opisywane jest za pomocą zbioru wariancji współrzędnych oraz wszystkich kowariancji tworzących macierz kowariancji.

Transformacja LDA jest metodą uczenia z nadzorem, co oznacza, że z góry znana jest przynależność każdego przypadku do danej klasy i wiedzę tą wykorzystuje się do utworzenia macierzy  $\mathbf{W}$  liniowego przekształcenia danych. Dobór macierzy  $\mathbf{W}$  powinien być przeprowadzony w taki sposób aby osiągnąć maksymalny stosunek rozproszenia międzyklasowego do rozproszenia wewnątrzklasowego. Macierz rozproszenia międzyklasowego zdefiniowana jest równaniem (5.7), natomiast wewnątrzklasowego równaniem (5.8).

$$\mathbf{S}_b = \sum_{i=1}^M N_i (\mathbf{m}_i - \mathbf{m})(\mathbf{m}_i - \mathbf{m})^T \quad (5.7)$$

$$\mathbf{S}_w = \sum_{i=1}^M \sum_{x_c \in \text{klasa}_i} (x_c - \mathbf{m}_i)(x_c - \mathbf{m}_i)^T \quad (5.8)$$

gdzie:  $M$  – liczba klas,

$N_i$  – liczba danych wejściowych należących do  $i$ -tej klasy,

$\mathbf{m}$  – wektor wartości średnich odpowiadający całemu zbiorowi wektorów  $x$ ,

$\mathbf{m}_i$  – wektor wartości średnich odpowiadający wektorom  $x$   $i$ -tej klasy.

Zakłada się, że macierz  $S_w$  jest nieosobliwa, a optymalna macierz transformacji  $W$  składa się z ortogonalnych wektorów kolumnowych, które maksymalizują wyznacznik macierzy definiowany następująco

$$W_{opt} = \max_W \left| \frac{W^T S_b W}{W^T S_w W} \right| = [w_1, w_2, \dots, w_K] \quad (5.9)$$

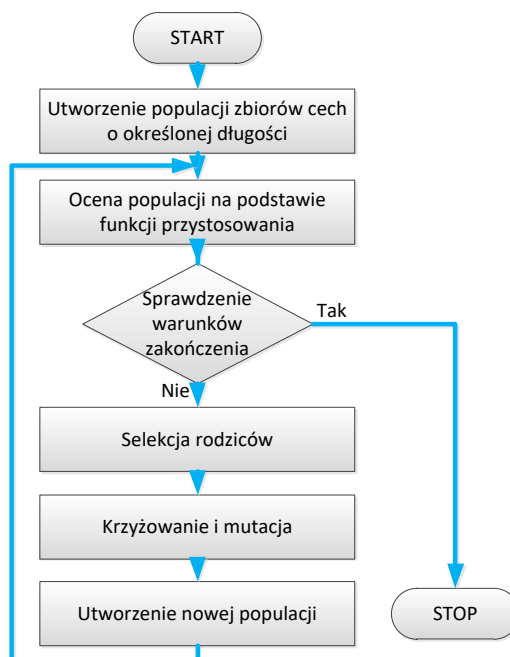
W równaniu (5.9)  $w_i$  oznacza zbiór uogólnionych wektorów własnych macierzy rozproszenia wewnątrzklasowego i międzyklasowego odpowiadający  $K$  największym wartościom własnym. Ostatecznie wzór przekształcenia LDA Fishera przyjmuje postać

$$y = Wx \quad (5.10)$$

Podczas praktycznego stosowania *LDA* problemem może okazać się złe uwarunkowanie macierzy rozproszenia wewnątrzklasowego  $S_w$ , które wynika z jej osobliwości. W rzeczywistych zastosowaniach dla  $M$  klas istnieje maksymalnie  $K = M - 1$  niezależnych wartości własnych, dlatego w praktycznych zastosowaniach często transformacja *LDA* jest poprzedzona transformacją *PCA*, której zadaniem jest redukcja wymiaru wektorów do wielkości  $K$ .

## 5.4. Ewolucyjna selekcja cech osobniczych

Ewolucyjna selekcja cech osobniczych wykorzystuje tzw. *algorytm genetyczny* (ang. *genetic algorithm* – *GA*), jest to rodzaj heurystyki przeszukującej przestrzeń alternatywnych rozwiązań problemu, której celem jest znalezienie najlepszego rozwiązania. Działanie algorytmu genetycznego przypomina zjawisko ewolucji genetycznej, a jego autorem jest *John Henry Holland* [64][65], który inspirację do swoich prac czerpał z biologii. Na rys. 5.3 przedstawiono strukturę algorytmu genetycznego przystosowanego do selekcji cech.




Rys. 5.3. Schemat blokowy procesu selekcji cech z zastosowaniem algorytmu genetycznego [48]



Wszystkie algorytmy genetyczne charakteryzują się pewnymi cechami, które odróżniają je od pozostałych metod optymalizacyjnych. Zawsze stosuje się operatory genetyczne, które są dostosowane do danego problemu, ponadto celowo wprowadza się elementy losowości, które powodują lekkie zaburzenia ułatwiające wyjście algorytmu z minimów lokalnych.

W pierwszym etapie działania algorytmu genetycznego należy utworzyć populację początkową. Populacja składa się z tzw. *chromosomów*. Każdy chromosom ma długość wektora cech i jest wypełniony pseudolosowo wartościami 1 i 0 czyli genami. Na rys. 5.4 zilustrowano postać chromosomu. Populacja zawiera  $N$  pseudolosowych chromosomów.



Rys. 5.4. Prezentacja chromosomu w algorytmie genetycznym

W prezentowanym algorytmie wykorzystano tzw. kodowanie binarne, co oznacza, że gen może być zakodowany tylko wartościami binarnymi. Jedynka logiczna w genie na  $i$ -tej pozycji, oznacza że  $i$ -ta cecha widmowa zostanie wykorzystana do tworzenia nowej populacji lub oceny na podstawie funkcji przystosowania. Dzięki takiemu kodowaniu każdy chromosom to zestaw cech które mogą być wykorzystane w danej populacji.

Po utworzeniu pseudolosowej populacji początkowej dokonywana jest jej ocena na podstawie funkcji przystosowania. Funkcja przystosowania jest miarą dopasowania danego osobnika w populacji. Jest ona niezmiernie istotna ponieważ pozwala ocenić stopień przystosowania poszczególnych chromosomów (osobników) w populacji i na tej podstawie należy wybrać te najlepiej przystosowane do generacji potomków. Nazwa funkcji przystosowania pochodzi bezpośrednio z genetyki [66]. Ma ona duży wpływ na działanie algorytmu i od jej poprawnego zdefiniowania zależy kierunek, w którym podąży rozwój populacji. W zagadnieniach minimalizacji należy przekształcić funkcję przystosowania (celu) sprowadzając problem do maksymalizacji. W niniejszym algorytmie funkcja celu jest wagową średnią dwóch współczynników. Pierwszym współczynnikiem, który ma decydującą wagę jest skuteczność klasyfikacji określana za pomocą transformacji LDA wykorzystującej cechy z danego chromosomu

$$LDA_{ACC} = \frac{TP + TN}{TP + FP + TN + FN} \quad (5.11)$$

gdzie:  $TP$  – (ang. *True Positive*) – liczba przewidywań prawdziwie pozytywnych,

$TN$  – (ang. *True Negative*) – liczba przewidywań prawdziwie negatywnych,

$FP$  – (ang. *False Positive*) – liczba przewidywań fałszywie pozytywnych,

$FN$  – (ang. *False Negative*) – liczba przewidywań fałszywie negatywnych.

Skuteczność  $LDA_{ACC}$  może przyjmować wartości od 0 do 1, gdzie 1 oznacza 100% skuteczność klasyfikacji.

Drugim współczynnikiem jest liczba cech wykorzystanych w danym chromosomie. Im więcej wykorzystanych cech tym wartość współczynnika jest mniejsza

$$Feat_{ACC} = \frac{L - \sum_{i=1}^L g_i}{L} \quad (5.12)$$

gdzie:  $L$  – długość chromosomu – liczba genów w chromosomie (liczba cech),

$g_i$  – wartość  $i$ -tego genu w danym chromosomie (0 lub 1).

Skuteczność  $Feat_{ACC}$  będzie tym większa im mniej będzie genów o wartości 1, czyli cech wykorzystanych do transformacji LDA, będzie zawierał chromosom.

Finalna wartość funkcji przystosowania ma postać

$$F(ch_i) = \frac{LDA_{ACC}(ch_i) \cdot w_1 + Feat_{ACC}(ch_i) \cdot w_2}{w_1 + w_2} \quad (5.13)$$

W równaniu (5.13)  $w_1$  oraz  $w_2$  oznaczają wagi poszczególne współczynników.

Kryterium przerywania dalszych obliczeń było osiągnięcie maksymalnej wartości funkcji przystosowania. Zakończenie obliczeń następowało również w przypadku osiągnięcia maksymalnej, określonej przez autora, liczby pokoleń.


Jeżeli warunki zakończenia nie zostały osiągnięte, to następuje przejście algorytmu do kolejnego kroku – selekcji rodziców. Selekcja chromosomów polega na wybraniu – na podstawie wartości funkcji przystosowania – chromosomów, które posłużą do tworzenia potomków nowej populacji. Wybór ten odbywa się zgodnie z zasadą naturalnej selekcji, tj. większe szanse na udział w tworzeniu potomków mają chromosomy o największej wartości funkcji przystosowania. Istnieje wiele metody selekcji, jednak najpopularniejszą i jednocześnie wybraną przez autora jest tzw. *metoda ruletki*, która swą nazwą nawiązuje do losowania za pomocą koła ruletki. Każdy chromosom otrzymuje przydzielony wycinek koła ruletki, którego wielkość jest proporcjonalna do wartości funkcji przystosowania. Dzięki takiemu rozwiązaniu, im lepszy chromosom (większa wartość funkcji przystosowania) tym większy wycinek koła zostanie mu przydzielony, czyli większe prawdopodobieństwo jego wyboru. Całe koło ruletki to suma wartości funkcji przystosowania wszystkich chromosomów w populacji. Jeżeli oznaczymy każdy chromosom przez  $ch_i$  dla  $i = 1, 2, \dots, N$  gdzie  $N$  jest liczebnością populacji, to  $v(ch_i)$  oznacza odpowiadający mu wycinek koła który stanowi część całego koła wyrażony w procentach

$$v(ch_i) = p_s ch_i \cdot 100\% \quad (5.14)$$

gdzie

$$p_s(ch_i) = \frac{F(ch_i)}{\sum_{i=1}^N F(ch_i)} \quad (5.15)$$

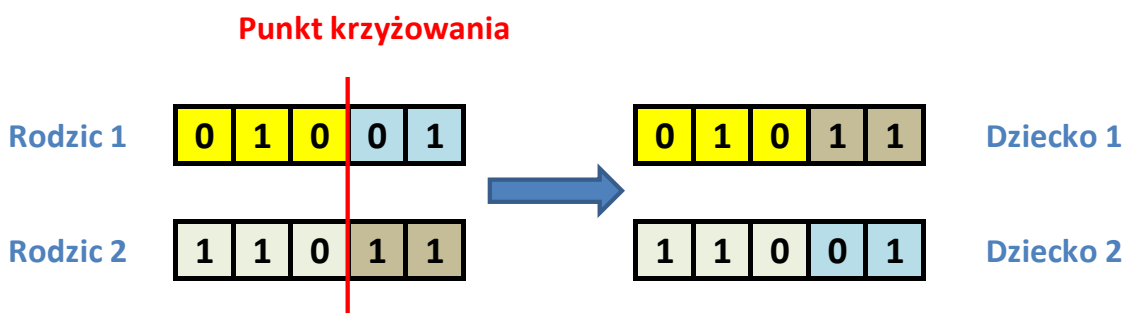
W równaniu (5.15)  $F(ch_i)$  oznacza wartość funkcji przystosowania  $i$ -tego chromosomu, natomiast  $p_s(ch_i)$  jest prawdopodobieństwem selekcji  $i$ -tego chromosomu. Selekcja metodą koła ruletki może być widziana jako obrót kołem ruletki, w wyniku czego wybrany zostaje chromosom należący do wybranego wycinka koła ruletki. Im większy wycinek, tym większe prawdopodobieństwo wyboru. Na rys. 5.5 zaprezentowano przykładową strukturę koła ruletki.



Rys. 5.5. Reprodukacja populacji metodą koła ruletki


Po etapie reprodukcji następuje krzyżowanie i mutacja. W tym miejscu wprowadza się dodatkowy element losowości, który powoduje powstanie zupełnie nowych chromosomów – zestawów cech.

Zadaniem operacji krzyżowania jest łączenie cech pochodzących od różnych osobników populacji. W algorytmach genetycznych, operacja krzyżowania jest stosowana zdecydowanie częściej niż mutacja. Operacja krzyżowania z pary różnych rodziców tworzy parę potomków. W pierwszej kolejności należy wylosować parę rodziców, a następnie losowaniu poddaje się miejsce krzyżowania. W niniejszym algorytmie wykorzystano krzyżowanie jednopunktowe, w którym następuje „przecięcie” chromosomów rodziców (w tym samym punkcie), a następnie dokonuje się wymiany części chromosomów. Na rys. 5.6 przedstawiono schemat krzyżowania.




Rys. 5.6. Operacja krzyżowania jednopunktowego

Po operacji krzyżowania, populacja najlepszych rodziców zostaje zastąpiona ich potomkami. Kolejnym krokiem jest wykonanie mutacji, która odbywa się znacznie rzadziej. Polega ona na zmianie wartości wybranego genu – w przypadku kodowania binarnego jest to negacja wartości danego genu. Celem wykonywania mutacji jest zapewnienie, aby reprodukcja i krzyżowanie nie wyeliminowały potencjalnie korzystnego chromosomu. Jej głównym zadaniem jest wprowadzanie dodatkowej różnorodności w populacji i unikanie przedwczesnej zbieżności algorytmu. Operacja mutowania została przedstawiona na rysunku 5.7.



Rys. 5.7. Operacja mutowania chromosomu

Przebieg selekcji cech metodą genetyczną zilustrowano na rys. 5.8. Na osi poziomej znajduje się numer kolejnej populacji. Pierwszy wykres przedstawia sumaryczną dokładność na danym zbiorze cech, drugi wykres przedstawia składnik odpowiedzialny za skuteczność klasyfikacji metodą LDA, natomiast ostatni wykres wskazuje liczbę zastosowanych cech w danej populacji. Zaobserwować można, że sumaryczna dokładność, jak i dokładność LDA charakteryzują się trendem wzrostowym, co oznacza, że algorytm stara się tak dobierać zestaw cech, aby uzyskać jak największą skuteczność, przy jednoczesnym minimalizowaniu liczby użytych cech.



Rys. 5.8. Przebieg genetycznej selekcji cech dystynktywnych

## 5.5. Podsumowanie

W rozdziale piątym przedstawiono metody selekcji zastosowane w procesie opracowywania optymalnego wektora cech opisujących dany przypadek medyczny. Każda z opisanych metod została przetestowana podczas tworzenia niniejszego systemu służącego do klasyfikacji schorzeń układu sercowo-naczyniowego. Najskuteczniejsza w tym względzie okazała się ewolucyjna metoda selekcji cech. Z tym etapem wiąże się wyzwanie, jakim jest właściwa fuzja wyselekcjonowanych cech, a także możliwość selekcji przed ich fuzją oraz na całościowym wektorze deskryptorów. Autor przetestował różne warianty zarówno selekcji, jak i fuzji cech dystynktywnych. Etap selekcji cech dystynktywnych stanowi jeden z bardziej czasochłonnych etapów tworzenia systemu klasyfikacji, jednakże optymistyczny jest fakt, że selekcja wykonywana jest wyłącznie na etapie projektowania klasyfikatora. Kolejnym etapem przetwarzania w niniejszym systemie jest optymalizacja parametrów pod kątem szerokości podpasm, długości analizowanych tonów oraz utworzenie finalnego klasyfikatora, co jest celem rozdziału szóstego.

# 6

## KLASYFIKACJA SYGNAŁÓW FONOKARDIOGRAFICZNYCH


W niniejszym rozdziale zostanie opisany proces optymalizacji szerokości analizowanych podpasm częstotliwości, oraz czasu trwania tonu skurczowego. Są to parametry ściśle wpływające na zdolności klasyfikatora, ponieważ określają fragment sygnału podlegający analizie. W kolejnym etapie zostaną przetestowane różne metody klasyfikacji sygnałów fonokardiograficznych. Opisane zostaną wyniki analizy składowych głównych, liniowej analizy dyskryminacyjnej oraz sieci wektorów nośnych [38][48][67][68]. Na koniec zostanie wskazany najlepszy klasyfikator służący do diagnostyki stanów patologii w układzie sercowo-naczyniowym.

## 6.1. Wielokryterialna optymalizacja parametrów

Optymalizacji podlegały poszczególne podpasma częstotliwości, które służą do ekstrakcji cech dystynktywnych. W rozdziale 4 wskazano podpasma widmowe, które według autora mogły zawierać cenne informacje diagnostyczne. W ramach wykonanej optymalizacji wielokryterialnej wykorzystującej algorytm genetyczny [69] udało się wyselekcjonować podpasma zawierające cenną informację diagnostyczną. Jako funkcje celu przyjęto maksymalną skuteczność i margines separacji danych wykorzystując *Liniową Analizę Dyskryminacyjną* [70].

Kolejnym elementem podlegającym optymalizacji był wybór okna czasowego zastosowanego podczas okienkowania tonu analizowanego tonu skurczowego. Pierwotnie wybrano okno *Hamminga* ze względu na jego właściwości, takie jak duże tłumienie przecieku widma i małe poszerzenie prążka głównego. Wykonana optymalizacja rodzaju okna potwierdziła przypuszczenia autora co do jego słusznego wyboru [54].

Ostatnim elementem który podlegał optymalizacji był czas trwania tonu skurczowego. Literatura wskazuje że czas trwania tonu S1 wynosi około 200 ms [71]. Zastosowany algorytm wykrywający tony skurczowe wskazuje na pozycje najwyższego punktu amplitudy w skali czasu. W pierwszym etapie autor założył że jest to punkt środkowy tonu skurczowego, i należy brać pod uwagę 100 ms przed punktem maksymalnym, i 100 ms za punktem maksymalnym, łącznie 200 ms. Wykonana optymalizacja zakładała niesymetryczne ułożenie najwyższego punktu tonu skurczowego, dlatego optymalizacji podlegała para zmiennych – czas trwania lewej i prawej części tonu. Na rys. 6.1 zilustrowano niesymetrię tonu skurczowego. W efekcie przeprowadzonych analiz otrzymano zoptymalizowany prawy i lewy czas trwania tonu skurczowego.



Rys. 6.1. Ilustracja optymalizacji czasu trwania tonu skurczowego

## 6.2. Klasyfikacja

W niniejszym podrozdziale opisane zostaną wyniki klasyfikacji zebranych danych z wykorzystaniem różnych metod klasyfikacyjnych [72]. Do klasyfikacji wykorzystano przedstawione we wcześniejszych

rozdziałach metody takie jak *Analiza Składowych Głównych*, *Liniowa Analiza Dyskryminacyjna* czy *Sieć Wektorów Nośnych*.

### 6.2.1. Zbiór uczący i testowy

Konstruowany klasyfikator ma służyć do predykcji (przewidywania) pewnych wartości na podstawie danych uczących. Istotnym problemem jest ocena jakości uczenia oraz predykcji. Częstym błędem jest przeprowadzenie testów klasyfikatora na tym samym zbiorze, na którym był on uczony [73]. Uzyskane w ten sposób wyniki nie są wiarygodne, gdyż testowany klasyfikator jest przeuczony czyli zbyt dobrze dopasowany do danych. Należy pamiętać, że klasyfikator ma zostać przystosowany do predykcji wyników na podstawie danych, które nie były dostępne na etapie uczenia, dlatego spośród zbioru dostępnych danych, należy odpowiednio wybrać niezależny zbiór uczący – który posłuży do nauczania klasyfikatora, jak i niezależny zbiór testowy – który posłuży do walidacji klasyfikatora. Taki podział zwykle realizowany jest w stosunku 70% dla danych uczących, i 30% dla danych testowych. Ideą takiego podziału jest nauczenie klasyfikatora na maksymalnej liczbie dostępnych danych, i przetestowanie go na części danych niedostępnych w trakcie uczenia. Na tym etapie autor dysponował zbiorem 390 sygnałów fonokardiograficznych charakteryzujących się bardzo dobrą jakością określoną przez klasyfikator opisany w rozdziale 3. Wśród tych sygnałów znajdują się sygnały rejestrowane w dwóch różnych postawach (siedzącej i leżącej) oraz w dwóch różnych punktach pomiarowych (koniuszek serca i punkt Erba). Podział ilościowy tych sygnałów przedstawiony jest w tabeli 6.1.

Tabela 6.1. Zestawienie ilościowe sygnałów fonokardiograficznych

Pozycja pacjenta	Punkt pomiarowy	Ilość	Chorzy/Zdrowi
Siedząca	Koniuszek serca	103	52/51
Siedząca	Punkt Erba	94	39/55
Leżąca	Koniuszek serca	101	48/53
Leżąca	Punkt Erba	92	43/49

Po konsultacjach z personelem medycznym, jak i ze względu na największą liczbę danych do klasyfikacji wybrano sygnały rejestrowane w pozycji siedzącej i w koniuszku serca, łącznie 103 sygnały pochodzące od różnych osób. Zdecydowano na niemieszanie różnych punktów pomiarowych i pozycji pomiarowych do tworzenia jednego klasyfikatora, ze względu na możliwe zaburzenia cech dystynktywnych. Zbiór uczący i testowy został wyznaczony zgodnie z zasadą 70/30. W zbiorze uczącym znalazło się 70 sygnałów (35 zdrowych i 35 chorych), a w zbiorze testowym 33 sygnały (16 zdrowych i 17 chorych).

### 6.2.2. Miary oceny jakości klasyfikatorów

Jeżeli zestaw danych jest odpowiednio podzielony na zbiór uczący i testowy przy czym obie podgrupy (chorzy i zdrowi) są równolicznie reprezentowane możemy uzupełniać wynikami *tabelę prawdy* [74].

Tabela 6.2. Tabela prawdy

		Prawdziwy stan zdrowia	
		Pacjenci chorzy	Pacjenci zdrowi
Wynik diagnozy (klasyfikacji)	Pacjenci chorzy (+)	TP – ang. <i>true positive</i>	FP – ang. <i>false positive</i>
	Pacjenci zdrowi (-)	FN – ang. <i>false negative</i>	TN – ang. <i>true negative</i>

Na podstawie tabeli 6.2 możemy wyznaczyć kilka istotnych parametrów określających jakość klasyfikatora. Między innymi są to:

- *Czułość* (ang. *sensitivity* – *Se*) – reprezentuje stosunek liczby prawidłowo wykrytych chorych do liczby wszystkich chorych. Określa ona zdolność danego klasyfikatora do poprawnego rozpoznania choroby.

$$Se = \frac{TP}{TP + FN} \quad (6.1)$$

- *Specyficzność* (ang. *specificity* – *Sp*) – reprezentuje stosunek liczby prawidłowo wykrytych zdrowych do liczby wszystkich zdrowych. Określa ona zdolność danego klasyfikatora do poprawnego wykluczenia choroby.

$$Sp = \frac{TN}{TN + FP} \quad (6.2)$$

- *Dodatnia wartość prognostyczna* (ang. *Positive Predictive Value* – *PPV*) – reprezentuje prawdopodobieństwo określające, że dany przypadek jest chory mając pozytywny wynik testu. PPV określa na ile dany pacjent może być pewien, że faktycznie jest chory jeśli wynik testu (klasyfikacji) jest pozytywny.

$$PPV = \frac{TP}{TP + FP} \quad (6.3)$$

- *Ujemna wartość prognostyczna* (ang. *Negative Predictive Value* – *NPV*) – reprezentuje prawdopodobieństwo określające, że dany przypadek jest zdrowy mając negatywny wynik testu. NPV określa na ile dany pacjent może być pewien, że faktycznie jest zdrowy jeśli wynik testu (klasyfikacji) jest negatywny.

$$NPV = \frac{TN}{TN + FN} \quad (6.4)$$

- *Dokładność* (ang. *Accuracy* – *ACC*) – reprezentuje liczbę wszystkich poprawnie zdiagnozowanych przypadków w odniesieniu do wszystkich przypadków.

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (6.5)$$

- *Błąd całkowity* (ang. *Total Error* – *TE*) – reprezentuje liczbę wszystkich błędnie zdiagnozowanych przypadków w odniesieniu do wszystkich przypadków.


$$TE = 1 - ACC = \frac{FP + FN}{TP + TN + FP + FN} \quad (6.6)$$

Powyższe parametry pozwalają na jednoznaczną ocenę danego klasyfikatora. Warto zauważyć, że budując klasyfikator możemy regulować progiem decyzyjnym, czyli wartością graniczną oceny danego przypadku. Dzięki temu możemy przesunąć próg w kierunku lepszej czułości aby uzyskać 100% skuteczność wykrywania osób chorych, jednocześnie pogarszając specyficzność co spowoduje wzrost prawdopodobieństwa fałszywego alarmu – więcej osób zdrowych zostanie zakwalifikowana jako chora. Wpływ zmian progu decyzyjnego w całym zakresie pracy klasyfikatora obrazujemy za pomocą



krzywej *ROC* (ang. *Receiver Operating Characteristics*) [38][75]. Krzywa ta obrazuje zależność pomiędzy czułością a specyficznością i umożliwia porównanie różnych klasyfikatorów.

Przestrzeń *ROC* przedstawiono na rys. 6.2. Przesunięcie progu w kierunku lepszej specyficzności spowoduje spadek czułości diagnostycznej, ponieważ więcej przypadków chorych zostanie zakwalifikowano jako zdrowa, jednocześnie spadnie prawdopodobieństwo fałszywego alarmu gdyż więcej zdrowych zostanie poprawnie zdiagnozowanych. Przeciwna sytuacja będzie miała miejsce, gdy zaczniemy przesuwac próg w kierunku lepszej czułości. Linia przerywana prezentuje klasyfikator całkowicie losowy (wynik klasyfikacji odbywa się na drodze losowania). Wygodnym pojedynczym parametrem liczbowym określającym jakość klasyfikatora jest powierzchnia pod krzywą *ROC* (ang. *Area Under Curve – AUC*).



Rys. 6.2. Ilustracja działania krzywej *ROC*


Większość testów medycznych reprezentuje jakość diagnostyczną wyrażoną wartością *AUC* pomiędzy 0,80 a 0,95. Ogólnie przyjmuje się, że:

- $AUC = 0,9$  – klasyfikator bardzo dobry,
- $AUC = 0,8$  – klasyfikator dobry,
- $AUC = 0,7$  – klasyfikator satysfakcjonujący,

- AUC = 0,6 – klasyfikator średni,
- AUC = 0,5 – klasyfikator niedostateczny.

### 6.2.3. Analiza składowych głównych

Metoda analizy składowych głównych została szerzej opisana w podrozdziale 5.2. Przekształcenie PCA jest skutecznym sposobem na usunięcie korelacji w danych wejściowych i skumulowanie istotnej zmienności w kilku pierwszych składowych. Na rys. 6.3 zilustrowano wynik klasyfikacji wykorzystującej dwie pierwsze składowe. Można zaobserwować, że przypadki zdrowe i chore są ze sobą wymieszane, zaproponowana hiperpłaszczyzna rozdzielająca pozwala na uzyskanie około 60% skuteczności klasyfikacji. Parametry klasyfikacji zostały przedstawione w tabeli 6.3.



Rys. 6.3. Wynik klasyfikacji z wykorzystaniem metody PCA

Parametry jakościowe tego klasyfikatora zostały zaprezentowane w tabeli 6.3.


Tabela 6.3. Parametry klasyfikatora PCA

Parametr	Wartość
Czułość $Se$	63,46%
Specyficzność $Sp$	64,71%
Dodatnia wartość prognostyczna $PPV$	64,71%
Ujemna wartość prognostyczna $NPV$	63,46%
Dokładność $ACC$	64,07%
Błąd całkowity $TE$	35,93%

### 6.2.4. Liniowa analiza dyskryminacyjna

Liniowa analiza dyskryminacyjna została szeroko opisana w podrozdziale 5.3. Dzięki zastosowaniu LDA możemy zredukować przestrzeń cech maksymalnie do wymiaru o jeden mniejszego od liczby klas. Celem tej analizy jest znalezienie takiego kierunku w przestrzeni, który maksymalizuje określone kryterium dyskryminacji. Na rys. 6.4 zilustrowano wynik klasyfikacji danych metodą LDA. Po lewej obserwujemy umieszczenie punktów danych charakteryzujących dany przypadek. Widzimy, że

w przeciwieństwie do poprzedniej metody dane są pogrupowane. Co prawda są pojedyncze błędy klasyfikacji w obu klasach, ale nie obserwujemy chaosu rozmieszczenia danych, jak w przypadku poprzednim. Można wskazać hiperpłaszczyznę rozdzielającą na poziomie 0. Po prawej stronie zaprezentowano krzywą ROC, która wskazuje na wysoką jakość klasyfikatora. Powierzchnia pod krzywą wynosi  $AUC = 0,9212$ , co wg klasyfikacji z podrozdziału 6.2.2 wskazuje, że ten klasyfikator jest **bardzo dobry**. Krzywa ROC jest wyznaczana w oparciu o zmianę położenia hiperpłaszczyzny rozdzielającej wzdłuż osi pionowej (Czułość). Zmiana położenia hiperpłaszczyzny powoduje zmianę czułości i specyficzności klasyfikatora, dzięki czemu można wyznaczyć krzywą zależności tych wartości i wskazać na niej punkt optymalny.



Rys. 6.4. Wynik klasyfikacji z wykorzystaniem metody LDA

Parametry jakościowe tego klasyfikatora zostały zaprezentowane w tabeli 6.4.

Tabela 6.4. Parametry klasyfikatora LDA

Parametr	Wartość
Czułość $Se$	86,54%
Specyficzność $Sp$	94,12%
Dodatnia wartość prognostyczna $PPV$	93,75%
Ujemna wartość prognostyczna $NPV$	87,27%
Dokładność $ACC$	90,29%
Błąd całkowity $TE$	9,71%
AUC	0,9212

### 6.2.5. Sieć wektorów nośnych

Technikę obliczeniową zwaną SVM (ang. *Support Vector Machine*) opracował V. Vapnik w latach siedemdziesiątych XX wieku [76][77][78]. Wysoka złożoność obliczeniowa spowodowała, że metoda ta zyskała swoją popularność stosunkowo niedawno. Podstawową zaletą SVM jest maksymalizacja odległości hiperpłaszczyzny separującej najbliższe punkty z dwóch różnych zbiorów danych, która jest osiągnięta metodami programowania kwadratowego [79][80][81][82]. Najprostsza wersja sieci SVM stosowana jest do separacji dwóch grup, które można odseparować hiperpłaszczyzną rozdzielającą. Zakładając, że dany jest zbiór  $M$  par uczących  $\{x_i, y_i\}$ , gdzie  $i = 1, 2, \dots, M$ , a kolumnowy wektor cech


$\mathbf{x}_i = [x_{i1} \ x_{i2} \ \dots \ x_{iN}]^T$  reprezentuje punkt w przestrzeni  $N$  wymiarowej związany z  $i$ -tą obserwacją.  $y_i$  to etykieta określająca przynależność do danej klasy. Istnienie liniowej separowalności klas powoduje, że możemy założyć istnienie pewnej hiperpłaszczyzny  $H_0$  idealnie separującej obie klasy.

$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = 0, \text{ gdzie } \mathbf{w} = [w_1 \ w_2 \ \dots \ w_N]^T \quad (6.7)$$

Wektor kolumnowy  $\mathbf{w}$  nazywany jest wektorem wag, a współczynnik  $b$  polaryzacją [83]. Jeżeli przyrównamy hiperpłaszczyznę  $g(\mathbf{x}) = 0$  to będziemy mogli zdefiniować klasyfikator liniowy (6.8).


$$k(x_i) = \begin{cases} 1, & g(x_i) > 0 \\ -1, & g(x_i) < 0 \end{cases} \quad (6.8)$$

Zgodnie z powyższym każdy element zostanie poprawnie sklasyfikowany, jeśli wartość po przekształceniu *SVM* będzie dodatnia. Należy pamiętać, że istnieje nieskończenie wiele hiperpłaszczyzn separujących ten sam zbiór punktów, co zilustrowano na rys 6.5.



Rys. 6.5. Nieskończenie wiele hiperpłaszczyzn rozdzielających dwie klasy [84]

Najbardziej optymalnym wyborem jest hiperpłaszczyzna wyznaczająca dwie równoległe do niej hiperpłaszczyzny (tzw. hiperpłaszczyzny kanoniczne) „oparte” o punkty z przeciwnych grup, które charakteryzują się największą wzajemną odległością. Określają one maksymalny **margin separacji**. W obszarze marginesu separacji nie powinno być żadnych danych uczących, a hiperpłaszczyzny kanoniczne powinny opierać się na skrajnych wektorach uczących, które w nomenklaturze *SVM* nazywane są wektorami nośnymi [76][77][78]. Optymalna hiperpłaszczyzna rozdzielająca znajduje się pomiędzy hiperpłaszczyznami kanonicznymi – rys. 6.6.



Rys. 6.6. Interpretacja graficzna marginesu separacji

Celem klasyfikacji SVM jest maksymalizacja marginesu separacji, co jest osiągnięte przez minimalizację jego odwrotności, co ostatecznie formułuje się w postaci (6.9).

$$\min_{\mathbf{w}} \left\{ \frac{1}{2} \mathbf{w}^T \mathbf{w} \right\}, \mathbf{w} \in R^N \quad (6.9)$$

Powyższe zadanie to typowy problem programowania kwadratowego z liniowymi ograniczeniami względem wektora wag  $\mathbf{w}$ . Do rozwiązania tego typu zagadnienia stosuje się metodę mnożników *Lagrange'a* [38][84]. Jak wskazano m.in. w [62][80] problem ten, jest nazywany *problemem prymalnym*, który można przekształcić w tzw. *problem dualny*, którego rozwiązanie pozwala na wyznaczenie optymalnych wartości wag  $\mathbf{w}$ . W rezultacie optymalny wektor wag oraz polaryzację można przedstawić w postaci (6.10).

$$\mathbf{w}_{opt} = \sum_{\mathbf{x}_i \in SV} \alpha_i d_i \mathbf{x}_i, \quad b_{opt} = d_i - \mathbf{w}^T \mathbf{x}_i \quad (6.10)$$


gdzie  $\alpha_i$  są mnożnikami *Lagrange'a*.

W sytuacji, kiedy nie jest możliwe liniowe odseparowanie klas stosuje się modyfikację [85] która wprowadza nieujemne parametry  $\xi = [\xi_1, \xi_2, \dots, \xi_p]$  takie, że

$$\begin{cases} (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, & \text{dla } \mathbf{x}_i \in \text{klasa 1} \\ (\mathbf{w}^T \mathbf{x}_i + b) \leq -1 - \xi_i, & \text{dla } \mathbf{x}_i \in \text{klasa 2} \end{cases} \quad (6.11)$$


Modyfikacja ta dopuszcza sytuację, w której pewne elementy są błędnie klasyfikowane. Sytuację tę zobrazowano na rys. 6.7. Parametr  $\xi$  umożliwia lokalną zmianę marginesu dla punktów spornych – jest to tzw. miękki margines (ang. *soft margin*).





Rys. 6.8. Przebieg optymalizacji stałej regularyzacji C

W procesie optymalizacji dążono do minimalizacji tych parametrów. W rezultacie dla stałej  $C = 4171$  osiągnięto 4 błędy w grupie testowej, 0 błędów w grupie uczącej oraz 13 wektorów nośnych. Na rys. 6.9 zaprezentowano wynik klasyfikacji SVM wykorzystując zoptymalizowaną stałą regularyzacji. Po lewej stronie można zaobserwować wyraźnie oddzielone klasy danych. Hiperpłaszczyzna rozdzielająca jest umieszczona na poziomie 0. Tylko cztery chore przypadki zostały błędnie sklasyfikowane jako zdrowe. Krzywa ROC przypomina kształtem krzywą klasyfikatora LDA, co wskazuje na wysoką jakość klasyfikatora. Pole pod krzywą AUC = 0,9480 co wskazuje na klasyfikator **bardzo dobry**.



Rys. 6.9. Wynik klasyfikacji z wykorzystaniem metody SVM

Parametry jakościowe tego klasyfikatora zostały zaprezentowane w tabeli 6.5.

Tabela 6.5. Parametry klasyfikatora SVM

Parametr	Wartość
Czułość $Se$	92,31%
Specyficzność $Sp$	100,00%
Dodatnia wartość prognostyczna $PPV$	100,00%
Ujemna wartość prognostyczna $NPV$	92,73%
Dokładność $ACC$	96,12%
Błąd całkowity $TE$	3,88%
AUC	0,9480

Wykorzystując sieć SVM można oszacować maksymalny błąd klasyfikacji w zbiorze testowym wg zależności [38].

$$P_{max} = \frac{N_{svm}}{M - 1} \quad (6.13)$$

gdzie  $N_{svm}$  oznacza liczbę wektorów nośnych określoną na pełnym zbiorze uczącym.

Zgodnie z (6.13) maksymalny błąd wynosi

$$P_{max} = \frac{N_{svm}}{M - 1} = \frac{13}{70 - 1} \cdot 100\% = 18,84\% \quad (6.14)$$

W analizowanym zagadnieniu otrzymano 4 błędy w zbiorze testowym liczącym 33 przypadki, co oznacza że błąd klasyfikacji wynosi 12,12%, co zgadza się ze wzorem (6.14).

### 6.3. Podsumowanie

W niniejszym rozdziale przedstawiono w jaki sposób został dobrany zbiór danych uczących oraz testowych. Ponadto opisano czego dotyczyła wielokryterialna optymalizacja parametrów. W głównej części rozdziału opisano trzy zaprojektowane klasyfikatory, oraz przedstawiono wyniki uzyskanej za ich pomocą klasyfikacji. Zaprezentowano parametry jakościowe charakteryzujące dane klasyfikatory, dzięki czemu możliwe jest wskazanie najlepszego i najwydajniejszego klasyfikatora. W tabeli 6.6 zaprezentowano parametry wszystkich przetestowanych klasyfikatorów, podkreśleniem wskazano wartość najlepszą.

Tabela 6.6. Zestawienie parametrów jakościowych poszczególnych klasyfikatorów

Parametr	PCA	LDA	SVM
Czułość $Se$	36,5%	86,54%	<u>92,31%</u>
Specyficzność $Sp$	39,2%	94,12%	<u>100,00%</u>
Dodatnia wartość prognostyczna $PPV$	38,0%	93,75%	<u>100,00%</u>
Ujemna wartość prognostyczna $NPV$	37,7%	87,27%	<u>92,73%</u>
Dokładność $ACC$	37,9%	90,29%	<u>96,12%</u>
Błąd całkowity $TE$	62,1%	9,71%	<u>3,88%</u>
AUC	0,3635	0,9212	<u>0,9480</u>

W rezultacie wykonanych badań można wskazać klasyfikator SVM jako najlepszy klasyfikator, który finalnie posłuży do klasyfikacji przypadków w algorytmie detekcji schorzeń kardiologicznych.



---

Klasyfikator ten uzyskał najlepsze wyniki, a uzyskany błąd klasyfikacji w grupie testowej jest mniejszy niż oszacowany błąd maksymalny, co potwierdza poprawność wyuczenia sieci.

**System finalnie pozwala na skuteczną detekcję schorzeń sercowo-naczyniowych na poziomie 96 % w zbiorze 103 sygnałów fonokardiograficznych zmierzonych w pozycji siedzącej w koniuszku serca, co spełnia początkowe założenia autora.**

## PODSUMOWANIE

Na kartach niniejszej rozprawy zaprezentowana została tematyka fonokardiografii i związana z nią problematyka automatycznego systemu detekcji schorzeń układu sercowo-naczyniowego. Celem pracy było zaprojektowanie systemu detekcji schorzeń układu krążenia na podstawie sygnału fonokardiograficznego o czasie trwania 30 s. Rezultaty przeprowadzonych badań potwierdzają tezę, że **możliwe jest opracowanie metody diagnostycznej przyporządkowującej zarejestrowane przypadki do klasy chory lub zdrowy z prawdopodobieństwem wystarczającym do współczesnych zastosowań medycznych, z wykorzystaniem sygnałów fonokardiograficznych rejestrowanych w typowych warunkach ambulatoryjnych.**

Postawiona teza została potwierdzona doświadczalnie z wykorzystaniem bazy sygnałów fonokardiograficznych powstałych przy współpracy z lekarzami i personelem medycznym Wojskowego Instytutu Medycznego w Warszawie oraz Oddziału Dowództwa Garnizonu Warszawa.

System został zoptymalizowany w toku długotrwałej optymalizacji za pomocą algorytmu genetycznego. Sygnały poddane klasyfikacji zostały starannie opisane przez wykwalifikowany personel medyczny, co daje gwarancje poprawności przydziału danych przypadków do określonych klas

chorobowych i jednocześnie potwierdza skuteczność systemu. W pełnym 103 osobowym zbiorze przypadków dokładność opracowanej metody wynosi 96%, a czułość i specyficzność odpowiednio 92% i 100%.

Do najważniejszych osiągnięć autora przedstawionych w rozprawie można zaliczyć:

- zbudowanie autorskiego rejestratora fonokardiogramów (*hardware, firmware i software*) służącego do współpracy ze stetoskopem cyfrowym *JABES* z jednoczesną rejestracją sygnału EKG;
- zbudowanie – we współpracy z personelem Wojskowego Instytutu Medycznego – autorskiej bazy danych sygnałów fonokardiograficznych;
- opracowanie autorskiej metody uśredniania tonów skurczowych w dziedzinie częstotliwości;
- wielokryterialną optymalizację systemu (w tym z zastosowaniem algorytmu genetycznego), dostosowującą go do skutecznego działania w warunkach ambulatoryjnych;
- autorskie zastosowanie algorytmu genetycznego do selekcji cech wraz z autorską funkcją przystosowania;
- autorski klasyfikator oceny jakości zarejestrowanego sygnału fonokardiograficznego;
- opracowanie algorytmu klasyfikującego o wysokich parametrach jakościowych.

Z pewnością opracowany system detekcji schorzeń można wciąż udoskonalać. Dla przykładu w rozprawie nie uwzględniono klasyfikacji dla innych pozycji pacjenta, jak i innych punktów pomiarowych. Ponadto system jest gotowy do rozpoczęcia prac implementacyjnych polegających na utworzeniu oprogramowania desktopowego stosowanego do testów przesiewowych, dostosowanego do potrzeb personelu medycznego. Kolejnym pomysłem jest zgromadzenie bazy danych sygnałów fonokardiograficznych zarejestrowanych mikrofonem telefonu komórkowego (ewentualnie z wykorzystaniem prostego falowodu akustycznego) i weryfikacja, czy w takim torze akustycznym, detekcja schorzeń może nadal odbywać się prawidłowo. Pozytywna ocena tego typu badań pozwoliłaby na implementację systemu w aplikacji mobilnej i łatwy dostęp do testów przesiewowych dla każdego potencjalnego pacjenta. Warte rozpatrzenia w przyszłości, jest również rozpoznawanie różnych rodzajów schorzeń. Wymagałoby to jednak stworzenie bardzo dużej bazy danych wraz ze szczegółowymi opisami lekarskim każdego z przypadków. Ponadto przy rejestracji dłuższych nagrań zawierających kilkadziesiąt tonów skurczowych warto rozważyć zastosowanie modeli mieszanin gaussowskich do budowy klasyfikatora. GMMy (ang. *Gaussian Mixture Models*) skutecznie sprawdzają się w systemach automatycznego rozpoznawania mówcy, analizując ramki mowy. Takie zastosowanie sugeruje, że świetnie mogą się sprawdzić jako klasyfikator wybranych stanów patologii układu krążenia, analizujący tony serca w sygnale fonokardiograficznym.

Podsumowując, można stwierdzić, że postawiona teza rozprawy doktorskiej została udowodniona, a założone cele w pełni osiągnięte. Jednocześnie należy podkreślić, że rezultaty pracy w poszczególnych etapach jej tworzenia zostały opublikowane i zaprezentowane na konferencjach naukowych.

## LITERATURA

- [1] Nkomo VT, et al. *Burden of valvular heart diseases: a population-based study*. Lancet. 2006;368:1005–1011. doi: 10.1016/s0140-6736(06)69208-8.
- [2] d’Arcy JL, Prendergast BD, Chambers JB, Ray SG, Bridgewater B. *Valvular heart disease: the next cardiac epidemic*. Heart. 2011;97:91–93. doi: 10.1136/hrt.2010.205096
- [3] Rogunin A., *Rene Theophile Hyacinthe Laënnec (1781–1826): The Man Behind the Stethoscope*, Clin Med Res. 2006 Sep; 4(3): 230–235, doi: 10.3121/cmr.4.3.230
- [4] Jaroszczyk F., *Biofizyka*, Wydawnictwo Lekarskie PZWL, ISBN 978-83-200-3676-3
- [5] WHO Technical Report Series, *Diet, Nutrition and the prevention of chronic diseases*, Report of a Joint WHO/FAO Expert Consultation, Geneva 2003
- [6] Global Health Estimates 2016: *Death by Cause, Age, Sex, by Country and by Region, 2000-2016*, Geneva, World Health Organization; 2018

- [7] OECD, *Health at a Glance 2019 OECD Indicators*, ISBN 978-92-64-38208-4, doi: <https://doi.org/10.1787/4dd50c09-en>
- [8] Pocock S. J., Wang D., Pfeffer M. A., Yusuf S., McMurray J.J.V., Swedberg K. B., Östergren J., Michelson E. L., Pieper K. S., Granger C. B., *Predictors of mortality and morbidity in patients with chronic heart failure*, *European Journal of Heart Failure* (2006) 27, 65–75, doi:10.1093/eurheartj/ehi555
- [9] Damy T., Kallvikbacka-Benett A., Zhang J., Goode K., Laszlo B., Hobkirk J., Yassin A., Dubois-Rande J. L., Hittinger L., Cleland J., Clark A. L., *Does the physical examination still have a role in patients with suspected heart failure?*, *European Journal of Heart Failure* (2011) 13, 1340–1348, doi:10.1093/eurjhf/hfr128
- [10] Górski J. *Fizjologiczne podstawy wysiłku fizycznego*, Wydawnictwo Lekarskie PZWL Warszawa, ISBN 83-200-3250-4
- [11] Ministerstwo Edukacji Narodowej, platforma e-podręczniki *Układ krążenia* - <https://epodreczniki.pl/a/uklad-krazenia/DXdj9hKWj>, dostęp z dnia 2.06.2020
- [12] Konturek S. J. *Fizjologia człowieka*, Elsevier Urban & Partner, ISBN: 978-83-89581-93-8
- [13] Tadeusiewicz R. *Podstawy elektroniki medycznej Część 1*, Akademia Górniczo-Hutnicza w Krakowie, Skrypt uczelniany nr 640
- [14] Goda M. A., Hajas P., *Morphological Determination of Pathological PCG Signals by Time and Frequency Domain Analysis*, Meditech Ltd., Budapest, Hungary
- [15] Gradolewski D., Tojza P., Redlarski G., *Adaptacyjny algorytm filtracji sygnału fonokardiograficznego, wykorzystujący sztuczną sieć neuronową*, *Przegląd Elektrotechniczny*, R. 90 NR 11/2014
- [16] MAHTA Sp. z o. o. *Barometr Fundacji Watch Health Care* nr 19/15/02/2019, [www.korektorzdrowia.pl](http://www.korektorzdrowia.pl)
- [17] Plomp R. *The Ear as a Frequency Analyzer*, *The Journal of the Acoustical Society of America* 36, 1628 (1964); <https://doi.org/10.1121/1.1919256>
- [18] Varady P., *Wavelet-based adaptive denoising of phonocardiographic records*, *Engineering in Medicine and Biology Society*, 2001. Proceedings of the 23rd Annual International Conference of the IEEE, vol.2, no., pp. 1846-1849 vol.2, 2001
- [19] Strona internetowa: <https://www.stetoskop.pl/o-stetoskopach/budowa-i-dzialanie>, dostęp z dnia 2.06.2020 r.
- [20] Strona internetowa: <https://www.allheart.com/jabes-electronic-stethoscope/p/jsjabes3/>, dostęp z dnia 2.06.2020 r.
- [21] Lejkowski W., Dobrowolski A. P., *The project of function generator with implementation of the integrated circuit MAX038*, *The Student's Scientific Conference "CERC 2012"*, Bucharest, Romania
- [22] Lejkowski W., Dobrowolski A., Olszewski R., *„System pomiarowy do analizy tonów serca z referencyjnym sygnałem EKG”*, *Przegląd Elektrotechniczny*, 11/2016 str. 31, doi:10.15199/48.2016.11.08
- [23] Lejkowski W., Dobrowolski A. P., Olszewski R., *The measurement system for analyzing heart sounds with ECG reference signal*, *Przegląd Elektrotechniczny*, vol. 92, nr. 11, 2016, s. 31-34
- [24] Lejkowski W., Dobrowolski A. P., *Digital stethoscope*, *Student's International Conference „CERC 2014”*, Bucharest, Romania

- [25] Lejkowski W., Dobrowolski A. P., *Czterokanałowy stetoskop cyfrowy*, XXXII Konferencja Elektroniki, Telekomunikacji i Energetyki Studentów i Młodych Pracowników Nauki (SECON'14), Warszawa, 26 – 28.03.2014
- [26] Dokumentacja techniczna, ADS8866 16-bit, 100-kSPS, serial interface, micropwer, miniature, single-ended input, SAR analog-to-digital converter, Texas Instruments, SBAS614C – MAY 2013 – Revised March 2019
- [27] Lejkowski W., Dobrowolski A. P., *Projekt generatora funkcji z wykorzystaniem układu scalonego MAX038*, XXXI Konferencja Elektroniki i Telekomunikacji Studentów i Młodych Pracowników Nauki – SECON 2012, Warszawa, 20 – 22.03.2012;
- [28] Dokumentacja techniczna, REF3230 4 ppm/°C, 100µA, SOT23-6 Series Voltage Reference, Texas Instruments, SBVS058C – JUNE 2005 – Revised AUGUST 2011
- [29] Carter B., Mancini R., *OP AMPS for everyone*, ©Copyright 2008 by Texas Instruments, ISBN 978-83-60233-71-9
- [30] IEC 62680-1-2:2018, Universal serial bus interfaces for data and power - Part 1-2: Common components - USB Power Delivery specification, TC 100/TA 18
- [31] Felner JM. The First Heart Sound. In: Walker HK, Hall WD, Hurst JW, editors. *Clinical Methods: The History, Physical, and Laboratory Examinations*. 3rd edition. Boston: Butterworths; 1990. Chapter 22.
- [32] Strona internetowa: [https://www.littmann.com/3M/en\\_US/littmann-stethoscopes/products/~/3M-Littmann-Electronic-Stethoscope-Model-3200/?N=5932256+8711017+3293188392+3294857497&preselect=8727094+3293786499&rt=rud](https://www.littmann.com/3M/en_US/littmann-stethoscopes/products/~/3M-Littmann-Electronic-Stethoscope-Model-3200/?N=5932256+8711017+3293188392+3294857497&preselect=8727094+3293786499&rt=rud) dostęp z dnia 28.06.2020 r.
- [33] Weiss D, Erie C, Butera III J, Copt R, Yeaw G, Harpster M, Hughes J, Salem DN. *An in vitro acoustic analysis and comparison of popular stethoscopes*. *Med Devices (Auckl)*. 2019;12:41-52 <https://doi.org/10.2147/MDER.S186076>
- [34] Stasiakiewicz P., Dobrowolski A. P., Olszewski R., Lejkowski W., *Klasyfikacja szmerów oddechowych – badania pilotażowe*, *Elektronika: konstrukcje, technologie, zastosowania*, 2019, t nr 2, s. 4-12
- [35] Bielawa A. *Postrzeganie i rozumienie jakości* Wydział Nauk Ekonomicznych i Zarządzania, Uniwersytet Szczeciński
- [36] Lejkowski W., Dobrowolski A. P., Olszewski R., *Ocena jakościowa cyfrowych sygnałów fonokardiograficznych*, VIII Kongres Metrologii, Augustów 2019
- [37] Lejkowski W., Dobrowolski A. P., Olszewski R., *Ocena jakości sygnałów fonokardiograficznych*, XXXII Konferencja Naukowo-Techniczna „Ekomilitaris 2018”, 2018 Zakopane;
- [38] Dobrowolski A. *Transformacje sygnałów – od teorii do praktyki*, wydawnictwo BTC, ISBN 978-83-64702-15-0
- [39] L. Hamza Cherif, S.M. Debbal, F. Bereksi-Reguig, Choice of the wavelet analyzing in the phonocardiogram signal analysis using the discrete and the packet wavelet transform, *Expert Systems with Applications*, 37 (2010) 913-918.
- [40] Batko W., Ziółko M., *Zastosowanie teorii falek w diagnostyce technicznej*. WIMiR, Kraków 2002
- [41] Batko W., Mikulski A., *Nowe metody badawcze w rozpoznawaniu uszkodzeń lin stalowych*. WIMiR, Kraków 2002
- [42] Józefczyk I., *Dyskretna transformata falkowa dla wybranego modelu symulacyjnego sygnału wibroakustycznego*, *Diagnostyka'34*, 2005.

- [43] Wilk B., Wybrane przykłady zastosowania transformaty falkowej do przetwarzania sygnałów biomedycznych, PAK 7-8/2003, pp. 29-31
- [44] Mallat S.G., A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Trans. On Pattern Analysis and Machine Intelligence*, Vol. 11, No. 7, 1989, pp. 674-693
- [45] Szwangruber P., *Wykorzystanie analizy falkowej do odszumiania oraz kompresji sygnałów*, Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej Nr 26, 2009
- [46] Lejkowski W., Dobrowolski A. P., Olszewski R., Ocena jakości sygnałów fonokardiograficznych w monografii „Ochrona przed skutkami nadzwyczajnych zagrożeń Tom 5”, Wyd. WAT, Warszawa, 2019
- [47] Mubarak Q., Shaukat A., Hussain F., Akram M. *Analysis of PCG Signals using Quality Assessment and Homomorphic Filters for Localization and Classification of Heart Sounds*. *Computer Methods and Programs in Biomedicine*. 164. 10.1016/j.cmpb.2018.07.006.
- [48] Osowski S., *Metody i narzędzia eksploracji danych*, BTC, 2013
- [49] Anderson T. W., R. A. *Fisher and multivariate analysis*, *Statistical Science*, t. 11, nr 1, s. 20-34, 1996
- [50] Jrad N., Phlypo R., Congedo M., *Acoustics, SVM feature selection for multidimensional EEG data*, *Speech and Signal Processing (ICASSP)*, 2011, pp. 781-784
- [51] Lejkowski W., Dobrowolski A. P., Majka K., Olszewski R., *Czasowo-częstotliwościowa analiza sygnałów fonokardiograficznych*, *Elektronika: konstrukcje, technologie, zastosowania*, vol. 59, nr. 2, 2018, s. 2-7
- [52] Lejkowski W., Dobrowolski A. P., Olszewski R., Gawron B., *Wieloaspektowa analiza spektralna sygnałów fonokardiograficznych*, *Przegląd Elektrotechniczny*, vol. 93, nr. 10, 2017, s. 73-76
- [53] Lejkowski W., Dobrowolski A. P., Olszewski R., *Automatic analysis of phonocardiogram evaluation in elderly patients with cardiovascular diseases*, *European Congress of Preventive Cardiology EuroPrevent 2019*, Lizbona 2019
- [54] Lejkowski W., Dobrowolski A. P., Majka K., Olszewski R., *Spectral analysis of major heart tones*, *2017 Radioelectronic Systems Conference (URSI'17)*, edited by A. Kawalec, *Proceedings of SPIE*, vol. 10715, pp. 1071508-1 - 1071508-8 Jachranka, 14-16.11.17, doi: 10.1117/12.2316785
- [55] Lejkowski W., Dobrowolski A. P., Olszewski R., Gawron B., *Wieloaspektowa analiza spektralna sygnałów fonokardiograficznych*, *XI Szkoła-Konferencja „Metrologia wspomagana komputerowo” (MWK 2017)*, Waplewo, 23-26.05.2017
- [56] Kamiński K., Dobrowolski A., Majda E., *Selekcja cech osobniczych sygnału mowy z wykorzystaniem algorytmów genetycznych*, *Biuletyn WAT*, 2016, t. 65, nr 1, s. 147-158
- [57] Majda E. *Rozprawa doktorska: Automatyczny system wiarygodnego rozpoznawania mówcy oparty na analizie cepstralnej sygnału mowy*, Warszawa 2013
- [58] Al.-Rajab M., Lu J., Qiang X. *Examining applying high performance genetic data feature selection and classification algorithms for colon cancer diagnosis*, *University of Huddersfield, Queensgate, Huddersfield, United Kingdom*, doi: <https://doi.org/10.1016/j.cmpb.2017.05.001>
- [59] Niedziejko P., Dobrowolski A. P., Krysowaty I., *Współczesne metody analizy dźwięku serca*, *Przegląd Elektrotechniczny*, R. 87 NR 9/2011, s. 1-7
- [60] Budak H., Taşaba S., (2016). *A modified t-score for feature selection*. *Anadolu university journal of science and technology a - Applied Sciences and Engineering*. 17. 845-845. 10.18038/aubtda.279853.

- [61] Pearson K., *On Lines and Planes of Closest Fit to Systems of Points in Space*, Philosophical Magazine, t. 2, nr 6., 1901, s. 559-572
- [62] Fisher R. A., *The use of multiple measurements in taxonomic problems*, Annals of Eugenics, vol. 7, 1936, s. 179-188
- [63] Tadeusiewicz R., Izvorski A., Majewski J., *Biometria*, Wydawnictwo AGH, Kraków 1993
- [64] Holland J. H., *Adaptation in Natural and Artificial Systems* The University of Michigan Press, Ann Arbor, MI (1975)
- [65] McCall J., *Genetic algorithms for modelling and optimization*, School of Computing, Robert Gordon University, Aberdeen, Scotland, UK, doi: <https://doi.org/10.1016/j.cam.2004.07.034>
- [66] Ghaheri A, Shoar S, Naderan M, Hoseini SS. *The Applications of Genetic Algorithms in Medicine*. Oman Med J. 2015;30(6):406-416. doi:10.5001/omj.2015.82
- [67] Osowski S., *Cyfrowe przetwarzanie sygnałów z zastosowaniem Matlab*, Warszawa 2016, Oficyna Wydawnicza Politechniki Warszawskiej
- [68] Smith S.P., *Cyfrowe Przetwarzanie sygnałów. Praktyczny poradnik dla inżynierów i naukowców*, BTC, 2007
- [69] MathWorks. *Genetic Algorithm*. Available from: <http://www.mathworks.in/help/gads/what-is-the-genetic-algorithm.html>.
- [70] Shashoa, N. A., Ahmed N., Jleta I., Abusaeeda O. (2016). *Classification depend on linear discriminant analysis using desired outputs*. 10.1109/STA.2016.7952041.
- [71] Giordano N., Knaflitz M., *A Novel Method for Measuring the Timing of Heart Sound Components through Digital Phonocardiography*, Published online 2019 Apr 19. doi: 10.3390/s19081868
- [72] Lejkowski W., Dobrowolski A. P., Majka K., Olszewski R., *Czasowo-częstotliwościowa analiza sygnałów fonokardiograficznych*, VII Konferencja EIT- 2017, Warszawa, 22.11.2017
- [73] IAbdel-Motaleb I., Akula R., *Artificial intelligence algorithm for heart disease diagnosis using phonocardiogram signals*, IEEE International Conference on Electro/Information Technology (EIT), 6-8 May 2012, Indianapolis, USA
- [74] Parikh R., Mathai A., Parikh S., Chandra Sekhar G., Thomas R. *Understanding and using sensitivity, specificity and predictive values*. Indian J Ophthalmol. 2008;56(1):45-50. doi:10.4103/0301-4738.37595
- [75] Hajian-Tilaki K. Receiver Operating Characteristic (ROC) Curve Analysis for Medical Diagnostic Test Evaluation. Caspian J Intern Med. 2013;4(2):627-635.
- [76] Vapnik V., *Statistical learning theory*, Wiley, N.Y., 1998.
- [77] Vapnik V., *An overview of statistical learning theory*, IEEE Trans. Neural Networks, 1999, Vol. 10, pp. 988-999
- [78] Vapnik V., *The nature of statistical learning theory*, Springer, 2000
- [79] Abe S., *Support Vector Machines for Pattern Classification*, Springer-Verlag London 2010, 978-1-84996-098-4
- [80] Osowski S. *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza PW, Warszawa 2006
- [81] Koronacki J., Ćwik J., *Statystyczne systemy uczące się*, WNT, Warszawa 2005
- [82] Krzyśko M., Wołyński W., Górecki T., Skorzybut M., *Systemy uczące się*, WNT, Warszawa 2008

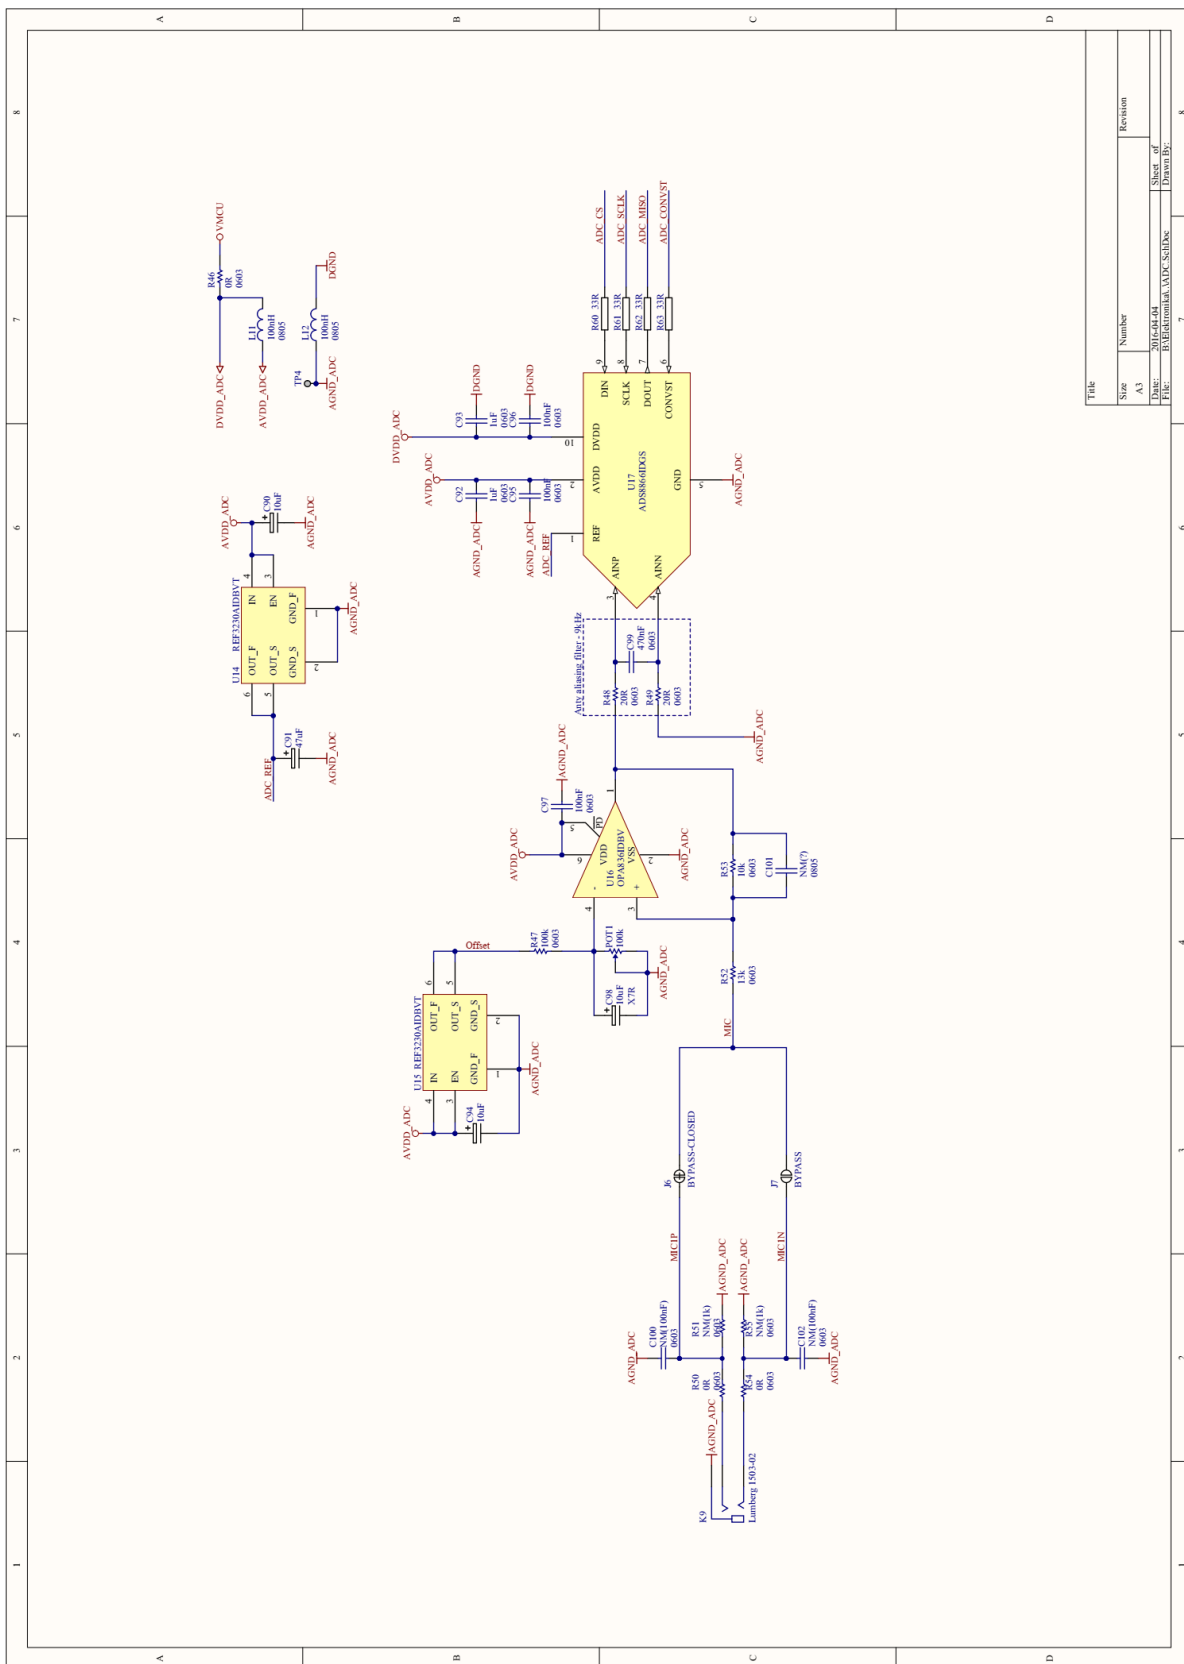


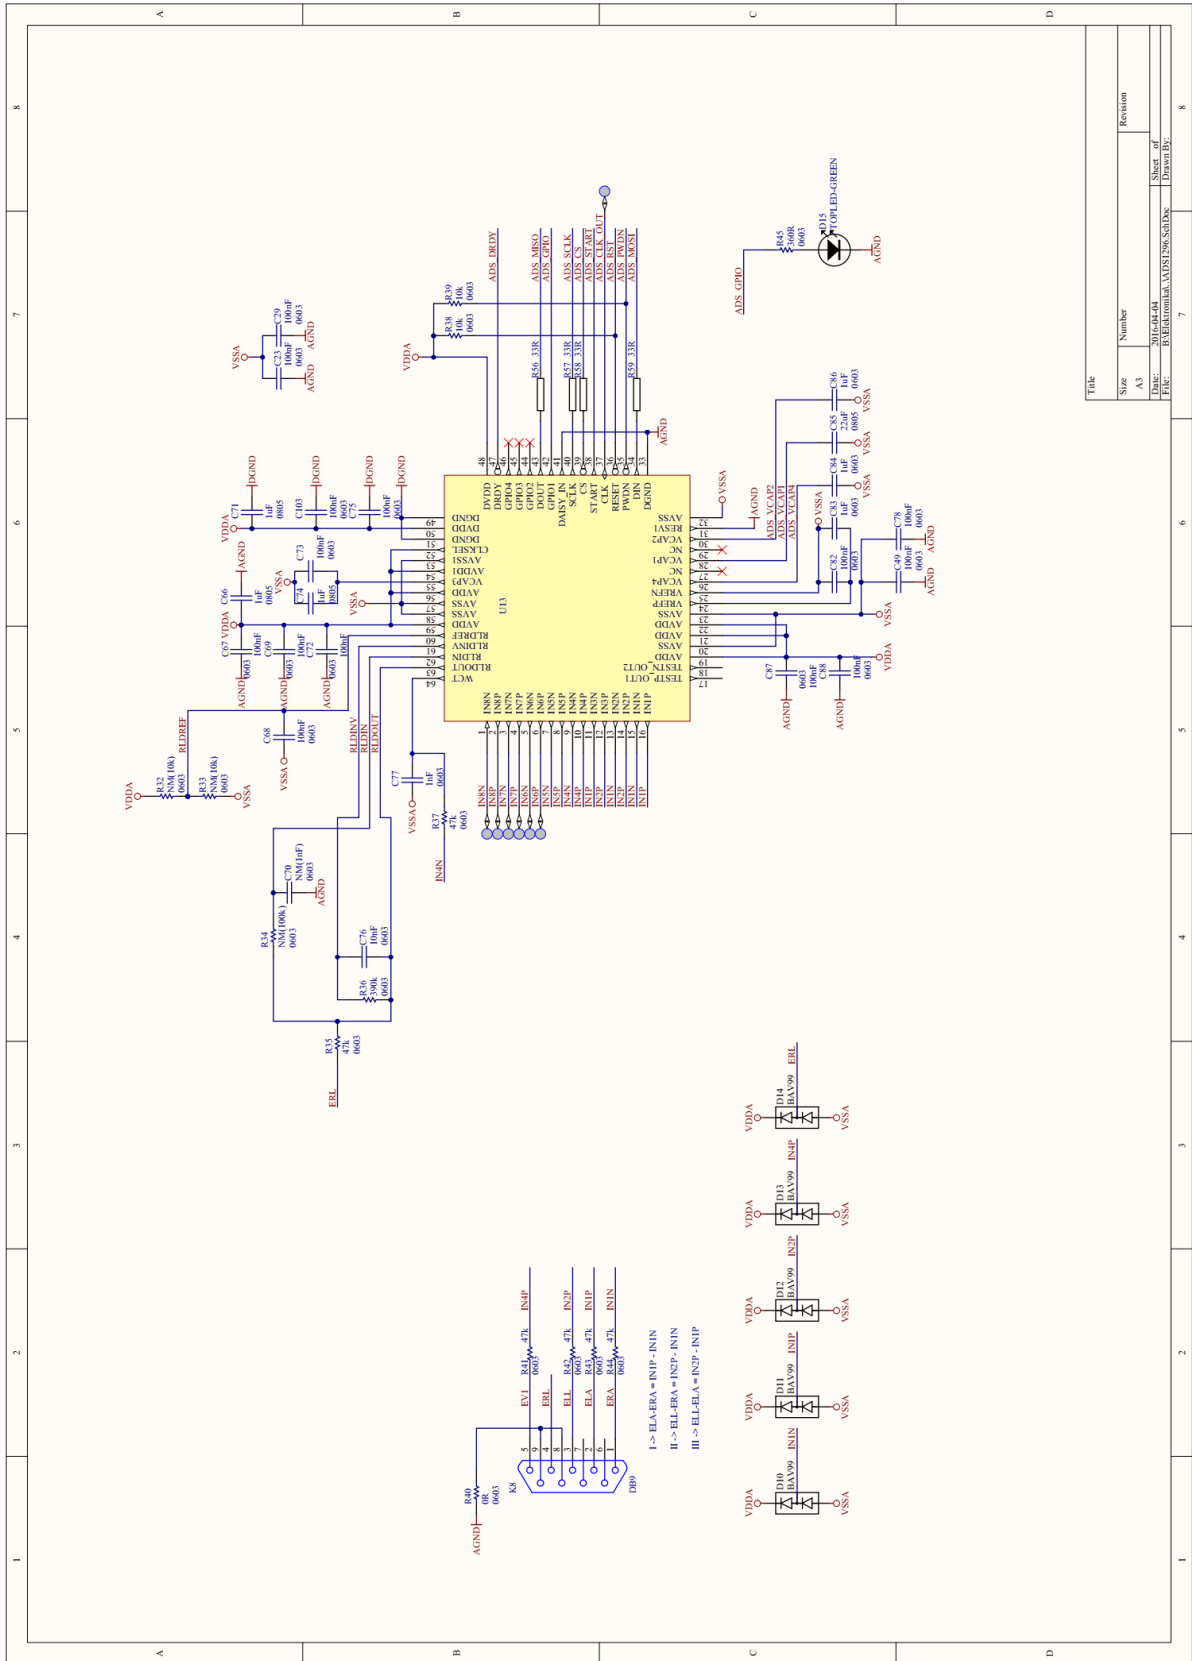
- 
- [83] Findeisen W., Szymanowski J., Wierzbicki A., *Teoria i metody obliczeniowe optymalizacji*, Wydawnictwo Naukowe PWN, Warszawa 1980
  - [84] Aggarwal C. C., *Data Classification, Algorithms and Applications*, IBM T.J. Watson Research Center, CRC Press Taylor & Francis Group, 2015 ISBN: 13: 978-1-4665-8675-8(eBook – PDF)
  - [85] Burges C. J. C., *A Tutorial on Support Vector Machines for Pattern Recognition*, Journal Data Mining and Knowledge Discovery, Vol. 2 Issue 2, June 1998, pp. 121-167

# Z.1

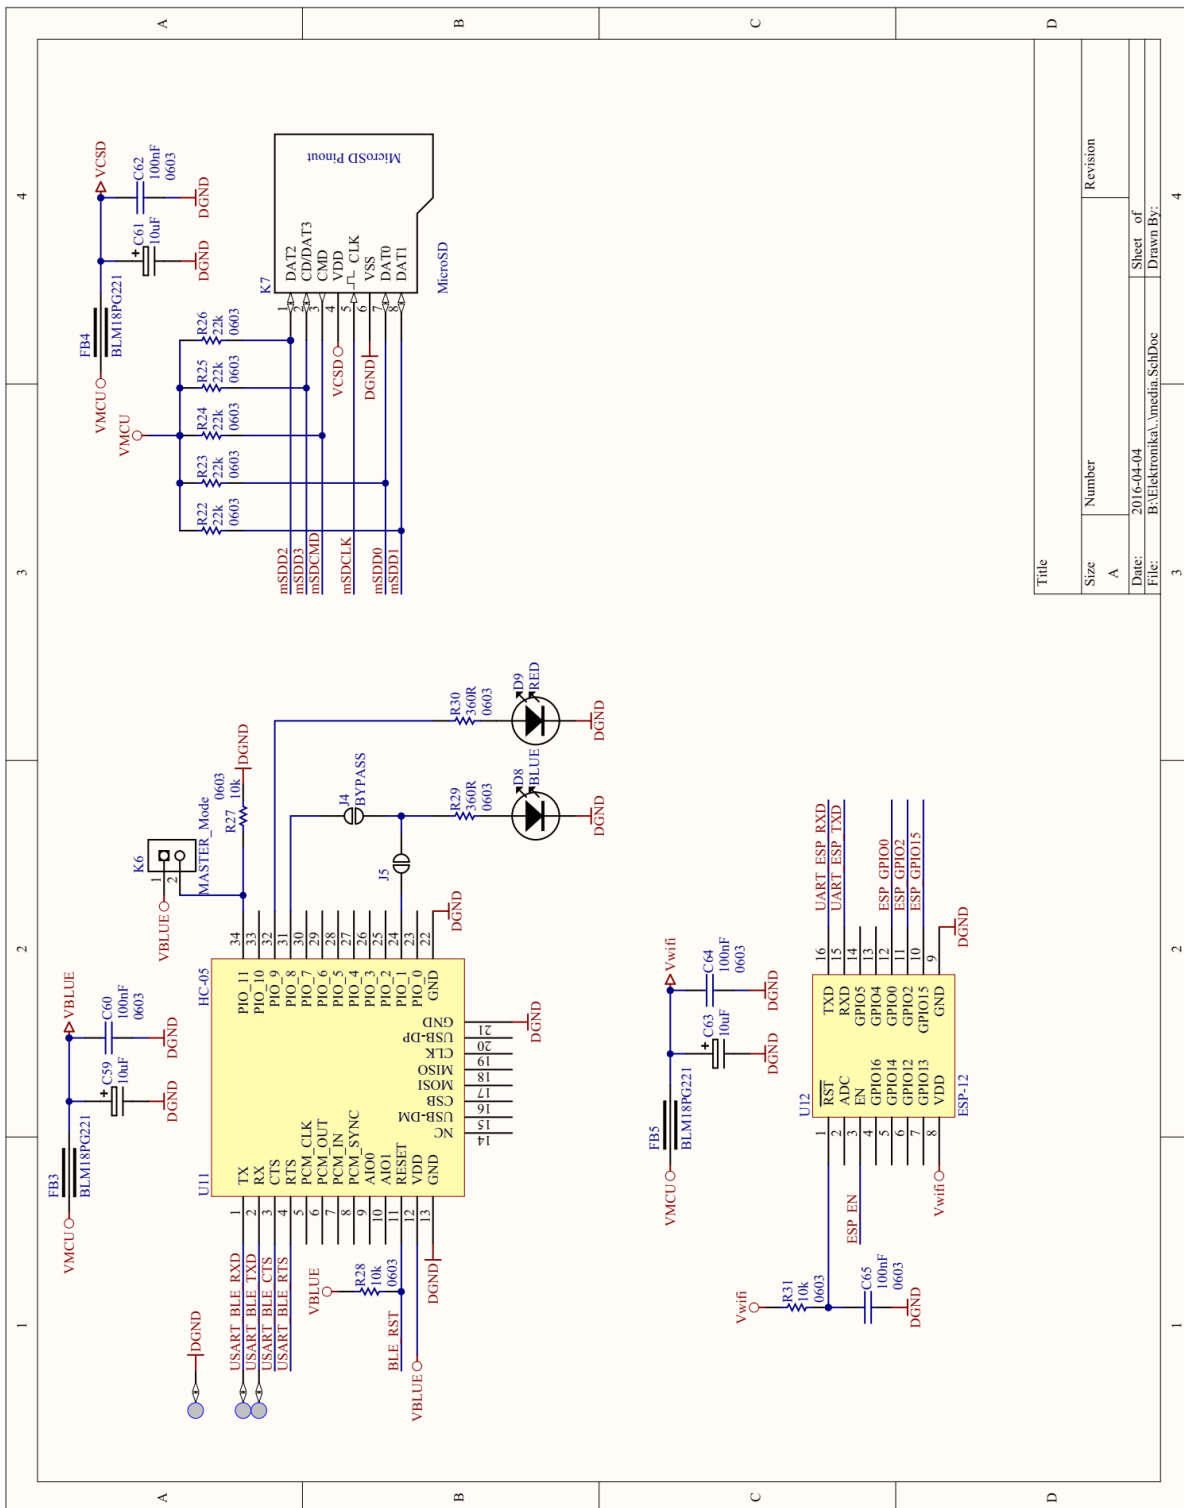
## **DOKUMENTACJA REJESTRATORA FONOKARDIOGRAMÓW**

W niniejszym załączniku przedstawiona została dokumentacja zbudowanego rejestratora fonokardiogramów. Dostępne są schematy ideowe wraz z wartościami najważniejszych elementów.









Title	
Size	Number
A	
Date:	2016-04-04
File:	B:\Elektronika\amedia_SellDoc
Sheet of	4
Drawn By:	



# Z.2

## **REJESTRATOR FONOKARDIOGRAMÓW PODRĘCZNIK UŻYTKOWANIA**

W niniejszym załączniku przedstawiony został podręcznik użytkownika aplikacji rejestratora fonokardiogramów wykorzystywany w początkowej fazie badań pilotażowych przez personel medyczny.



## Rejestrator fonokardiogramów ver. 2.1

**W. Lejkowski**  
**A. Dobrowolski    R. Olszewski**

## Podręcznik użytkownika

---

## Rejestrator fonokardiogramów ver. 2.1

---

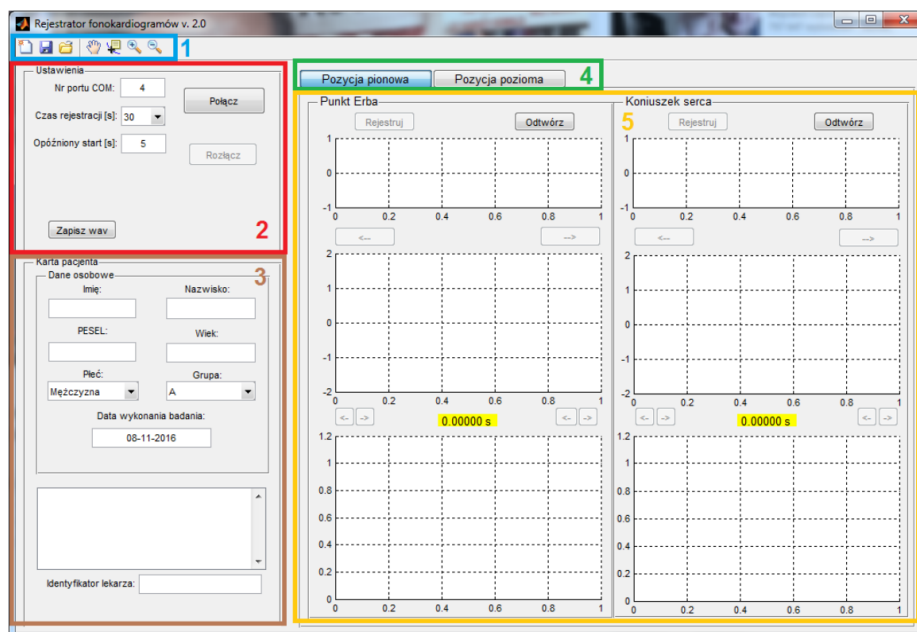
### Spis treści

1. Interfejs .....	3
2. Konfiguracja programu .....	4
3. Rejestracja sygnałów .....	6
4. Obsługa kursorów .....	8
5. Kończenie pracy z programem .....	9

## Rejestrator fonokardiogramów ver. 2.1







### 1. Interfejs

Na rys 1.1. przedstawiono wygląd aplikacji współpracującej z urządzeniem rejestrującym.



**Rys. 1.1.** Główne okno aplikacji

W górnym prawym lewym rogu znajduje się belka podstawowych opcji programu (1).  
Poniżej znajduje się spis ikon i funkcji:

-  **Nowy** - Czyści obszar roboczy i kartę pacjenta - przygotowuje aplikację do rejestracji nowego pacjenta;
-  **Zapisz** - Otwiera okno dialogowe które pozwala zapisać dane pacjenta. Nazwa pliku danych tworzona jest jako: "PESEL\_dzień-miesiąc-rok\_grupa.mat";
-  **Otwórz** - Otwiera okno dialogowe które pozwala wczytać dane pacjenta z wcześniej zapisanego pliku \*.mat;
-  **Narzędzie rączka** - pozwala przesuwać wykres wzdłuż osi x i y;
-  **Narzędzie podgląd punktu** - po kliknięciu na dany punkt na wykresie pokazuje jego współrzędne;
-  **Narzędzia lupa** - Lupa + powiększa zaznaczony obszar, Lupa - pomniejsza prawym kliknięciem myszy.

## Rejestrator fonokardiogramów ver. 2.1

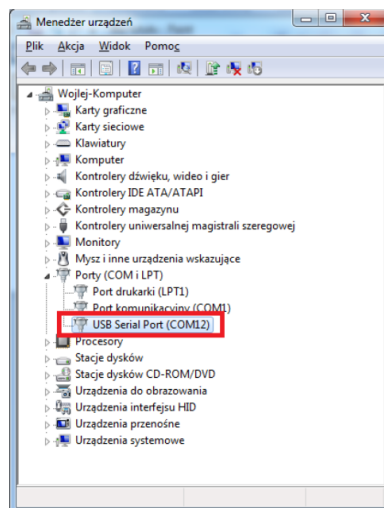
Poniżej znajduje się karta Ustawienia która służy do ustawienia parametrów komunikacyjnych z urządzeniem rejestrującym. W tej karcie należy ustawić nr portu COM, czas rejestracji sygnału i czas opóźnionego startu.

Poniżej znajduje się karta pacjenta w której osoba przeprowadzająca badanie powinna wpisać dane pacjenta i opis przypadku. Po wpisaniu nr PESEL aplikacja sama oblicza wiek pacjenta (oczywiście jest możliwość jego modyfikacji). **Aby dane wprowadzone w formularzu zostały zapisane należy po ich wprowadzeniu kliknąć w dowolny (nieaktywny obszar aplikacji).**

W polu nr 5 zobrazowany jest sygnał referencyjny EKG, sygnał fonokardiograficzny i widmo częstotliwościowe obszaru ograniczonego kursorami. Ponad zobrazowaniami są dwie zakładki które określają w jakiej pozycji pacjenta zostały zarejestrowane owe dane. Można dowolnie przełączać się między zakładkami.

## 2. Konfiguracja programu

Po podłączeniu urządzenia rejestrującego należy w pierwszej kolejności sprawdzić pod którym portem COM widziane jest ono przez komputer. W tym celu należy uruchomić **Menadżer urządzeń** systemu Windows i rozwinąć listę **Porty (COM i LPT)**. Ukaże się nam okno jak na rysunku 2.1.

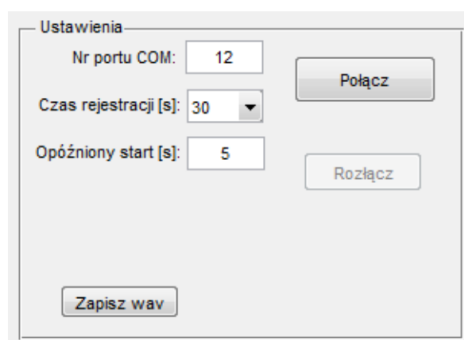


Rys. 2.1. Menadżer urządzeń systemu Windows

## Rejestrator fonokardiogramów ver. 2.1

Nasze urządzenie podłączone pod port USB jest widziane jako USB Serial port (COM12). Oznacza to, że numer portu COM naszego urządzenia to 12.

Kolejnym krokiem jest uruchomienie aplikacji i wpisanie do karty Ustawienia numeru portu COM - rys. 2.2.




Rys. 2.2. Karta Ustawienia aplikacji.

Z listy rozwijanej możemy wybrać interesujący nas **czas rejestracji** sygnału. Dostępne wartości to: 1, 2, 5, 10, 15, 20, 30 s. Aplikacja zarejestruje sygnały pacjenta trwające tę ilość czasu. Rejestrator posiada funkcję **opóźnionego startu** co oznacza, że rozpoczęcie rejestracji następuje określoną ilość sekund po kliknięciu przycisku Rejestruj na karcie wizualizacji danych. Domyślnie Opóźniony start równy jest 5s. W praktyce oznacza to, że po naciśnięciu przycisku Rejestruj na karcie wizualizacji danych, usłyszymy krótki sygnał (beep) który informuje o rozpoczęciu odliczania do startu. Po 5s (wartości ustawionej w oknie Opóźniony start) usłyszymy kolejny sygnał informujący o rozpoczęciu rejestracji. Rejestracja zostaje zakończona podwójnym dźwiękiem.


Po kliknięciu na przycisk **Zapisz wav** zostanie otwarte okno dialogowe które umożliwi zapisanie zarejestrowanych sygnałów fonokardiograficznych do pliku \*.wav.

Ostatnim krokiem konfiguracji urządzenia jest kliknięcie przycisku **Połącz**. Jeżeli wpisany numer portu COM jest nieodpowiedni w polu obok przycisku "Zapisz wav" otrzymamy komunikat:



## Rejestrator fonokardiogramów ver. 2.1

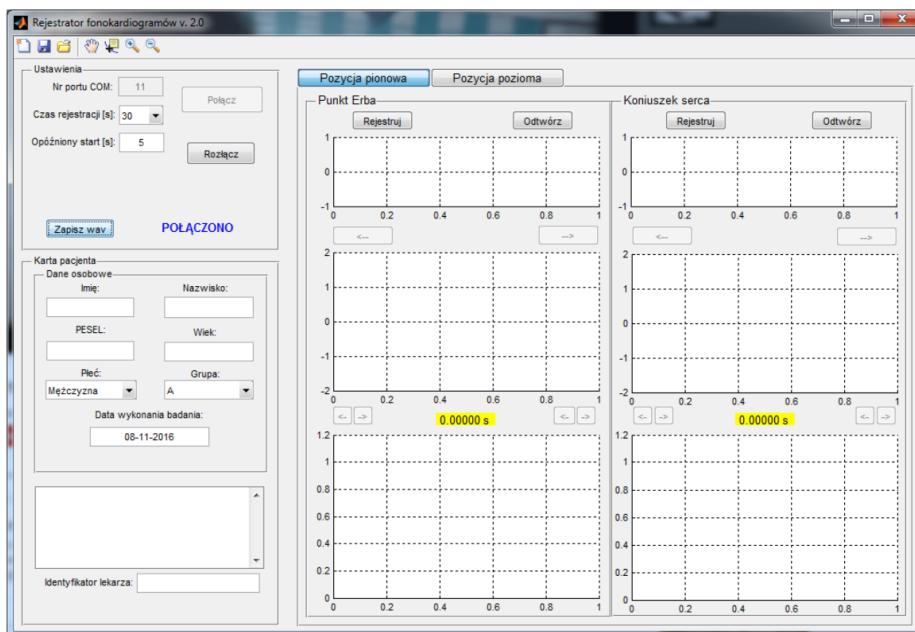
Jeżeli numer portu COM został wpisany poprawnie i aplikacja nawiązała komunikację z urządzeniem otrzymamy numer urządzenia:



Wszelkie parametry na karcie Ustawienia z wyjątkiem numeru Portu COM można zmieniać pomiędzy poszczególnymi pomiarami. Połączenie z urządzeniem następuje tylko raz po otwarciu aplikacji.

### 3. Rejestracja sygnałów

Po połączeniu aplikacji z urządzeniem rejestrującym w polu ID otrzymamy numer urządzenia i zostaną aktywowane przyciski Rejestruj na karcie wizualizacji danych. Aplikacja powinna wyglądać tak jak na rys. 3.1.

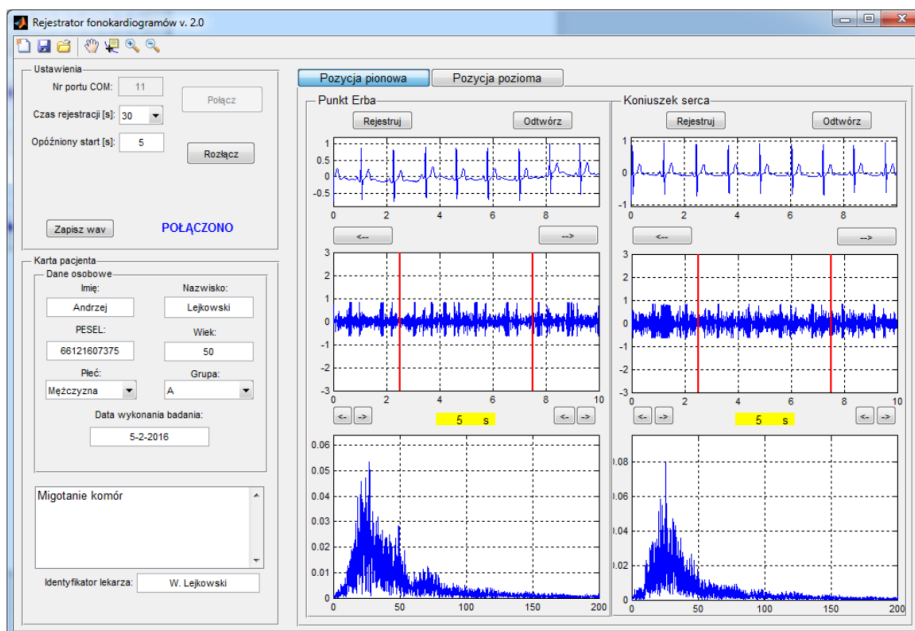


Rys. 3.1. Aplikacja przygotowana do rejestracji danych

Po kliknięciu Przycisku Rejestruj nastąpi rejestracja danych w danej zakładce i punkcie pomiarowym. Należy pamiętać, że pomiar w danym punkcie można powtórzyć, wystarczy

## Rejestrator fonokardiogramów ver. 2.1


nacisnąć ponownie odpowiedni przycisk Rejestruj. Po zarejestrowaniu sygnałów i uzupełnieniu karty pacjenta okno programu powinno wyglądać jak na rys. 3.2.



Rys. 3.2. Aplikacja z zarejestrowanymi sygnałami i uzupełnionym opisem

Należy pamiętać, że aby dane w karcie pacjenta się zapisały należy po wpisaniu kliknąć w jakieś puste miejsce lub nacisnąć klawisz Enter. Po kliknięciu zapisz pojawi się okno jak na rys. 3.3.

## Rejestrator fonokardiogramów ver. 2.1



Rys. 3.3. Zapis danych pacjenta.

Po zapisaniu można kliknąć **Nowy** w celu wyczyszczenia wykresów i przygotowania aplikacji do rejestracji nowego pacjenta. Można również otworzyć zapisane dane klikając na **Otwórz** i wybierając odpowiedni plik. Po kliknięciu **Odtwórz** można odsłuchać wybrany sygnał fonokardiograficzny w głośnikach komputera.

### 4. Obsługa kursorów

Po zarejestrowaniu lub wczytaniu sygnałów aktywne stają się kursory umieszczone na przebiegu fonokardiogramu. Pole sterowania kursorami wygląda jak na rys. 4.1.



## Rejestrator fonokardiogramów ver. 2.1



Rys. 4.1. Sterowanie kursorami

Z sygnału który zawarty jest między kursorami w czasie rzeczywistym liczone jest widmo częstotliwościowe które umieszczone jest na samym dole karty z zarejestrowanymi sygnałami.

## 5. Kończenie pracy z programem

Aby zakończyć pracę programu należy kliknąć czerwony krzyżyk w prawym górnym rogu na belce aplikacji systemu Windows.