

Zpracování signálů z optovláknových interferometrických senzorů pro monitorování srdeční tepové frekvence

Processing of Signals from Fiber-Optic Interfererometric Sensors
for Heart Rate Activity Monitoring

Bc. Zdeňka Dostálová

Diplomová práce

Vedoucí práce: Ing. René Jaroš, Ph.D.

Ostrava, 2021

Abstrakt

Tato diplomová práce je zaměřena na prostudování možností využití funkčního vzorku optovláknového interferometrického senzoru v biomedicinských aplikacích. Teoretická část se zaměřuje na prostudování problematiky zpracování optovláknových interferometrických signálů pomocí různých pokročilých metod zpracování signálu. Výstupem této části byly zvoleny hodnotící metody, které dle rešerše dosahují nejlepších výsledků. Jedná se o metody vlnkové transformace (WT), empirické modální dekompozice (EMD) a Hilbertovy transformace (HT). Experimentální část byla realizována na reálných datech, naměřených pomocí optovláknových interferometrů. Hodnocení bylo provedeno na základě stanovené celkové pravděpodobnosti správné detekce (ACC), senzitivity (SE), pozitivní prediktivní hodnoty (PPV) a harmonického průměru mezi SE a PPV (F1). Funkcionalita systému byla verifikována vůči relevantní referenci v podobě naměřeného EKG signálu, ze kterého byly odhadnuty referenční anotace. Tato práce ukázala, že nejlepších výsledků dosáhla hodnotící metoda WT.

Klíčová slova

empirická modální dekompozice, extrakce signálu, filtrace, Hilbertova transformace, interferometr, interferometrie, Mach-Zehnderův interferometr, optická vlákna, optika, senzory, vlnková transformace

Abstract

This diploma thesis is focused on studying the possibilities of using a functional sample of an optical fiber interferometric sensor in biomedical applications. The theoretical part focuses on the study of optical fiber interferometric signal processing using various advanced signal processing methods. The output of this part was chosen evaluation methods that achieve the best results according to the results. These methods are wavelet transform (WT), empirical mode decomposition (EMD), and Hilbert transform (HT). The experimental part was realized on real data measured using optical fiber interferometers. The evaluation was demonstrated by determining the overall probability of correct detection (ACC), sensitivity (SE), positive predictive value (PPV), and harmonic mean between SE and PPV (F1). The functionality of the system was verified using appropriate references in the form of a measured ECG signal, from which we estimated the reference annotation. This work influences that the best results are achieved by WT evaluation methods.

Key words

empirical mode decomposition, signal extraction, filtration, Hilbert transform, interferometer, interferometry, Mach-Zehnder interferometer, optical fibers, optics, sensors, wavelet transform

Poděkování

Ráda bych poděkovala vedoucímu práce Ing. Renému Jarošovi, Ph.D. za odborné vedení, cenné rady a čas strávený nad problematikou této diplomové práce.

Obsah

Seznam použitých zkratek	- 8 -
Seznam obrázků	- 10 -
Seznam tabulek	- 12 -
Úvod	- 13 -
1 Úvod do kardiovaskulárního systému	- 14 -
1.1 Srdeční cyklus	- 14 -
1.2 Srdeční rytmus	- 14 -
1.3 Variabilita srdeční frekvence	- 15 -
2 Optická vlákna	- 16 -
2.1 Princip šíření světla optickým vláknem	- 17 -
2.1.1 Šíření vln	- 17 -
2.2 Druhy optických vláken	- 19 -
2.2.1 Mnohavidová optická vlákna	- 19 -
2.2.2 Jednovidová optická vlákna	- 20 -
3 Interferometrie	- 22 -
3.1 Interference	- 22 -
3.2 Koherence	- 23 -
3.3 Princip interferometrů	- 24 -
4 Senzory z optických vláken	- 26 -
4.1 Sagnacův interferometr	- 26 -
4.2 Michelsonův interferometr (MI)	- 27 -
4.3 Fabry-Perotův interferometr (FPI)	- 27 -
4.4 Mach-Zehnderův interferometr (MZI)	- 29 -
4.4.1 Optický senzor s Mach-Zehnderovým interferometrem	- 30 -
4.4.2 Vlastní senzor pro měření	- 30 -
5 Současný stav řešené problematiky	- 32 -
5.1 Metody vlnkové transformace	- 32 -
5.1.1 Extrakce EKG pomocí vlnkové transformace a podpory vektorových strojů ...	- 32 -
5.1.2 Extrakce funkcí EKG pomocí optimální mateřské vlnky	- 32 -

5.1.3	Extrakce funkcí EKG pomocí vln Daubechies.....	- 33 -
5.1.4	Extrakce signálu EKG pomocí diskrétní vlnové transformace	- 33 -
5.1.5	Klasifikace EKG na základě vlnkové transformace a neurální sítě.....	- 33 -
5.1.6	Extrakce funkcí ze signálů EKG pomocí vlnkových transformací.....	- 33 -
5.1.7	Potlačení signálu EKG pomocí empirické vlnkové transformace	- 34 -
5.1.8	Systém detekce a klasifikace EKG úderů využívající vlnkovou transformaci....	- 35 -
5.2	Metody neuronových sítí	- 36 -
5.2.1	Extrakce EKG založená na matematické morfologii	- 36 -
5.2.2	Kompresce dat a extrakce funkcí signálů EKG	- 36 -
5.2.3	Automatická extrakce pro klasifikaci signálů EKG	- 37 -
5.2.4	Extrakce a klasifikace EKG pomocí cepstrum koeficientu a neuronových sítí..	- 37 -
5.2.5	Analýzy nezávislých komponent a neuronových sítí pro klasifikaci EKG.....	- 38 -
5.3	Metody slepé separace zdrojů	- 38 -
5.3.1	Zpracování signálu fetální fonokardiografie z břišních záznamů neadaptivními metodami	- 38 -
5.3.2	Aplikace analýzy nezávislých komponent při odstraňování artefaktů z EKG ...	- 39 -
5.3.3	Analýza šumu EKG signálu pomocí fastICA.....	- 39 -
5.4	Přehled dalších metod.....	- 40 -
5.4.1	Metoda adaptivního tréninku BEAT	- 40 -
5.4.2	Metoda chaosu.....	- 40 -
5.4.3	Metoda založena na klouzavých průměrech pro detekci komplexů QRS	- 42 -
5.4.4	Algoritmus využívající vlnovou křivku sklonu vektoru.....	- 42 -
5.4.5	Extrakce vlnového průběhu elektrokardiogramu pomocí vhodného filtru	- 42 -
5.4.6	Metoda vzájemné korelace	- 43 -
5.4.7	Klasifikace EKG rytmů pomocí PCA, LDA, ICA a DWT	- 43 -
5.4.8	Zpracování signálu fonokardiogramu pomocí empirického modálního rozkladu....	- 44 -
5.4.9	Odhad srdeční frekvence, dýchání a pohybu pomocí interferometru.....	- 44 -
5.4.10	Srovnání signálů BKG, FKG a EKG při aplikaci sledování srdeční frekvence v lidském těle	- 45 -
5.4.11	Adaptivní zpracování signálu fetálního FKG zaznamenaného interferometrickým senzorem	- 46 -
5.5	Zhodnocení vybraných metod.....	- 47 -

6	Matematický popis vybraných metod.....	- 48 -
6.1	Filtrování signálu	- 49 -
6.2	Vlnková transformace	- 50 -
6.3	Empirická modální dekompozice	- 53 -
6.4	Hilbertova transformace	- 55 -
7	Experimentální část.....	- 57 -
7.1	Data pro testování.....	- 57 -
7.2	Statistické vyhodnocení	- 59 -
7.3	Grafické uživatelské rozhraní	- 61 -
7.4	Předzpracování signálu.....	- 64 -
7.5	Vlnková transformace	- 64 -
7.6	Empirická modální dekompozice	- 68 -
7.7	Hilbertova transformace	- 72 -
7.8	Diskuse	- 77 -
	Závěr.....	- 81 -
	Bibliografie	- 83 -
	Přílohy.....	- 89 -

Seznam použitých zkratk

Zkratka	Význam
ANN	Umělá neuronová síť (Artificial Neural Networks)
ANS	Nelineární autonomní soustava (Nonlinear Autonomous System)
APC	Předčasná kontrakce síní (Atrial Premature complexes)
AR	Autoregresní modelování (Autoregressive model)
BKF	Balistokardiograf
BKG	Balistokardiogram
bmp	Údery za minutu (Beats per Minute)
DWT	Diskrétní vlnková transformace (Discrete Wavelet Transform)
EDM	Empirický režim rozkladu (Empirical Mode Decomposition)
EWT	Empirická vlnková transformace (Empirical Wavelet Transform)
FFT	Rychlá Fourierova transformace (Fast Fourier Transform)
FIR	Frekvenčně selektivní filtr s konečnou impulzní odezvou (Finite Impulse Response)
FN	Falešně negativní detekce (False Negative)
FOI	Optovláknový interferometr (Fibre-optic interferometer)
FP	Falešně pozitivní detekce (False Positive)
FPI	Fabry-Perotův interferometr (Fabry-Perot interferometer)
GMM	Modelová Gaussovská směs (Model Gaussian Mixture)
HMM	Skrytý Markovův model (Hidden Markov Model)
HR	Srdeční frekvence (Heart Rate)
HRV	Variabilita tepové frekvence (Heart Rate Variability)
ICA	Analýza nezávislých komponent (Independent Component Analysis)
LBBB	Blokáda levého Tawarova raménka (Left bundle branch block)
LDA	Lineární diskriminační analýza (Linear Discriminant Analysis)
LVQ	Kvantifikace vektoru učení (Learning Vector Quantization)
MLP	Vícevrstvý perceptron (Multi Layer Perceptron)
NN	Neurální síť (Neural Network)
OSELM	Online sekvenční extrémní výukové zařízení (Online Sequential Extreme Learning Machine)
PDMS	Polydimethylsiloxanový polymer (Polydimethylsiloxane polymer)
PI	Redukce interference elektrického vedení
PNN	Pravděpodobnostní neurální síť (Probabilistic Neural Network)
RBBB	Blok větve pravého svazku (Right bundle branch block)
RR	Respirační frekvence (Respiration Rate)
SA	Sinoatriální uzel (Sinoatrial node)
SNR	Odstup signálu od šumu (Signal-to-noise Ratio)
SOM	Samoorganizující mapa (Self-organizing Map)
SVEB	Ventrikulární ektopické beaty (Support Vector Machine)
SVM	Podpůrný vektorový stroj (Ventricular Ectopic Beats)
SVT	Supra ventrikulární tachykardie (Supraventricular tachycardia)
TN	Skutečně negativní (True Negative)
TP	Skutečně pozitivní (True Positive)
VA	Atrioventrikulární uzel (Atrioventricular node)
VEB	Entrikulární ektopické beaty (Entricular Ectopics Beat)
VF	Ventrikulární flutter (Ventricular flutter)

VPC	Předčasná kontrakce komor (Premature ventricular contractions)
VT	Ventrikulární tachykardie (Ventricular tachycardia)
WT	Waveletová transformace (Wavelet Transform)

Seznam obrázků

Obrázek 1.1	Zobrazení: a) okamžité srdeční frekvence, b) elektrokardiogramu.....	- 15 -
Obrázek 2.1	(a) Vnější nebo hybridní optický senzor sestávající se ze vstupních a výstupních vláken přenášejících světlo do a z černé skříňky, která moduluje světelný paprsek po aktivaci signálem z prostředí. (b) Vnitřní nebo celovláknový optický snímač, jehož vlastnosti jsou modulovány dopadajícím signálem prostředí.	- 16 -
Obrázek 2.2	Odraz a lom světla na hranici skla a vzduchu.....	- 18 -
Obrázek 2.3	Kritický úhel dopadu.	- 19 -
Obrázek 2.4	Princip šíření světla v mnohavidovém gradientním vlákne.	- 20 -
Obrázek 2.5	Princip šíření světla ve vláknu se skokovým indexem lomu.....	- 20 -
Obrázek 2.6	Princip šíření světla u jednovidových vláken.	- 21 -
Obrázek 3.1	a) Konstruktivní interference – kombinací dvou nebo více vln vznikne třetí, větší. Nová vlna má stejnou vlnovou délku a frekvenci, ale větší amplitudu. b) Destruktivní interference – odečítání a rušení vln.	- 23 -
Obrázek 3.2	Funkce základního interferometru.	- 25 -
Obrázek 4.1	Michelsonův interferometr.....	- 27 -
Obrázek 4.2	Fabry-Perotův interferometr: Dva optické prvky oddělené malou vzdáleností odrážejí optický paprsek tam a zpět a vytvářejí interferenční obrazec.....	- 28 -
Obrázek 4.3	Klasická konfigurace Mach-Zehnderova interferometru.....	- 29 -
Obrázek 4.4	Základní reprezentace MZI v integrovaném obvodu.....	- 29 -
Obrázek 4.5	Neinvazivní interferometrická sonda [21].	- 31 -
Obrázek 6.1	Diagram zpracování signálu a časové, frekvenční a časově-frekvenční oblasti.....	- 49 -
Obrázek 6.2	Schéma rozkladu signálu na aproximační a detailní koeficienty DWT.....	- 51 -
Obrázek 6.3	Přehled základních vlnek.	- 52 -
Obrázek 6.4	Ukázka původního signálu, předzpracovaného a rozloženého pomocí WT.	- 52 -
Obrázek 6.5	Vývojový diagram EMD algoritmu.	- 53 -
Obrázek 6.6	Ukázka rozkladu metodou EMD původního signálu na IMF1, IMF2, IMF3 a zbytkovou vlnu.	- 54 -
Obrázek 6.7	Ukázka Hilbertovy transformace.....	- 56 -
Obrázek 7.1	Ukázka původních dat.	- 58 -
Obrázek 7.2	EKG vs. FKG.....	- 59 -
Obrázek 7.3	Grafické uživatelské rozhraní pro testování jednotlivých metod.	- 61 -
Obrázek 7.4	Blok s vypočtenou statistikou pro jednotlivé parametry.	- 62 -
Obrázek 7.5	GUI, které slouží ke kontrole a případné úpravě referenčních anotací	- 63 -
Obrázek 7.6	Původní signál a filtrovaný signál pomocí FIR filtru pro záznam male_3.....	- 64 -
Obrázek 7.7	Signály zpracované pomocí vlnkové transformace pro záznam male_3.....	- 65 -
Obrázek 7.8	Blant-Altmanovy grafy pro signály Male 1 až 6.	- 66 -
Obrázek 7.9	Blant-Altmanovy grafy pro signály Female 1 až 5.....	- 67 -
Obrázek 7.10	Srovnání referenčních a extrahovaných křivek HR pro záznam Male 3 u metody WT.....	- 68 -

Obrázek 7.11	Signály zpracované pomocí EMD pro záznam Male 3. Vykresleno zobrazení IMF1.	- 69 -
Obrázek 7.12	Blant-Altmanových grafy pro signály Male 1 až 6.....	- 70 -
Obrázek 7.13	Blant-Altmanovy grafy pro signály Female 1 až 5.....	- 71 -
Obrázek 7.14	Srovnání referenčních a extrahovaných křivek HR pro záznam Male 3 u metody EMD	- 72 -
Obrázek 7.15	Vyfiltrována obálka získání pomocí metody HT pro signál Male 3.	- 73 -
Obrázek 7.16	Bland-Altmanovy grafy pro signály Male 1 až 6.	- 74 -
Obrázek 7.17	Bland-Altmanovy grafy pro signály Female 1 až 5.....	- 75 -
Obrázek 7.18	Srovnání referenčních a extrahovaných křivek HR pro záznam Male 3 u metody HT.....	- 76 -
Obrázek 7.19	Odhadnutá HR křivka pro signál Female 1 vyextrahován pomocí metody WT.....	- 77 -
Obrázek 7.20	Odhadnutá HR křivka pro signále Female 1 vyextrahován pomocí metody WT pro část signálu, kde odhadnutá HR křivka odpovídá referenční HR křivce.....	- 77 -
Obrázek 7.21	Odhadnutá HR křivka pro signál Female 1 vyextrahován pomocí metody WT pro část signálu, ve kterém se odhadnutá křivka výrazně odchýlila od té referenční.....	- 78 -
Obrázek 7.22	Odhadnutá a referenční HR křivka pro signál Male 3.	- 79 -

Seznam tabulek

<i>Tabulka 1</i>	<i>Srovnání různých metod pro zpracování signálů.....</i>	<i>- 47 -</i>
<i>Tabulka 2</i>	<i>Výpočet statistických parametrů pro WT pro všechny záznamy.....</i>	<i>- 65 -</i>
<i>Tabulka 3</i>	<i>Zaznamenané střední hodnoty μ a hodnoty $1,96\sigma$ u metody WT.</i>	<i>- 67 -</i>
<i>Tabulka 4</i>	<i>Výpočet statistických parametrů pro metodu EMD pro všechny záznamy.</i>	<i>- 69 -</i>
<i>Tabulka 5</i>	<i>Zaznamenané střední hodnoty μ a hodnoty $1,96\sigma$ u metody EMD.</i>	<i>- 71 -</i>
<i>Tabulka 6</i>	<i>Zaznamenané střední hodnoty μ a hodnoty $1,96\sigma$ u metody EMD.</i>	<i>- 75 -</i>
<i>Tabulka 7</i>	<i>Souhrnné srovnání metod</i>	<i>- 79 -</i>

Úvod

Interferometrické optické senzory nabývají v posledních letech na popularitě. Mezi výhody patří jejich neinvazivnost, přesnost a malé rozměry. Měření tepové frekvence poskytuje užitečné informace o zdravotním stavu. Tato diplomová práce je zaměřena na zpracování fonokardiografických signálů z Mach-Zehnderova interferometru.

Práce je rozdělena na teoretickou a experimentální část. Úvodní kapitola je zaměřena na kardiovaskulární systém, včetně variability srdeční frekvence. Následující část se zabývá teorií optických vláken a interferometrií. Dále jsou zde uvedeny základní senzory z optických vláken a seznámení se s Mach-Zehnderovým interferometrem, na kterém byla naměřena reálná data pro tuto diplomovou práci.

Literární rešerše se zabývá prostudováním problematiky zpracování elektrokardiografických a fonokardiografických signálů, včetně zpracování signálu z optovláknových interferometrických senzorů. Na základě rešerše byly vybrány tři metody, které dosahují dobrých výsledků a jsou dále aplikovány v experimentální části. Vybrané metody, mezi které patří vlnková transformace, empirický modální dekompozice a Hilbertova transformace jsou matematicky popsány s ukázkou aplikování na naměřených datech.

Experimentální část je zaměřena na vytvoření GUI v programu MATLAB, obsahující předzpracování signálu pomocí FIR filtru a aplikování metod, včetně statistického vyhodnocení a vykreslení spektrogramu a spektra signálu. Další část práce se zaměřuje na vyhodnocení dat, funkcionality systému byla verifikována vůči relevantní referenci v podobě naměřeného EKG signálu, ze kterého byly odhadnuty referenční anotace. Testování reálných dat je provedeno na základě stanovené celkové pravděpodobnosti správné detekce (ACC), senzitivity (SE), pozitivní prediktivní hodnoty (PPV) a harmonického průměru mezi SE a PPV (F1) a tepové frekvence v čase s využitím klouzavého průměru a Bland-Altmanovy statistiky.

1 Úvod do kardiovaskulárního systému

Kardiovaskulární systém lze považovat za transportní systém těla. Srdce je pumpa systému a krevní cévy fungují jako transportní dráhy.

1.1 Srdeční cyklus

Srdeční cyklus je sled událostí, ke kterým dochází v jednom úplném srdečním rytmu. Fáze čerpání cyklu, známá také jako systola, nastává při kontrakci srdečního svalu. Fáze plnění, která se nazývá diastola, nastává, když se uvolní srdeční sval. Na začátku srdečního cyklu jsou síně i komory v diastole. Během této doby jsou všechny srdeční komory uvolněné a proudí do nich krev. Atrioventrikulární chlopně jsou otevřené. Po této fázi následuje síňová systola. Během síňové systoly se levé a pravé síně stahují současně a tlačí krev do levé a pravé komory. Další fází je komorová systola. Během komorové systoly se levá a pravá komora stahují současně a pumpují krev do aorty a plicního kmene. V komorové systole jsou síně uvolněné a dostávají krev. Atrioventrikulární chlopně se uzavírají okamžitě poté, co komorová systola začne zastavovat návrat krve do síní. Semilunární chlopně jsou však během této fáze otevřeny, aby umožnily krvi proudit do aorty a plicního kmene. Po této fázi se komory uvolní, což je komorová diastola. Semilunární chlopně se uzavírají, aby se zastavil tok krve zpět do komor z aorty a plicního kmene. Síně a komory jsou opět v diastole a cyklus začíná znovu [1; 2].

1.2 Srdeční rytmus

Srdeční frekvence je rychlost srdečního rytmu měřená počtem kontrakcí (úderů) srdce za minutu (bpm). Může se lišit podle fyzických potřeb těla, včetně potřeby absorbovat kyslík a vylučovat oxid uhličitý, ale je také ovlivněna řadou faktorů, mimo jiné včetně genetiky, fyzické zdatnosti, stresem nebo psychickým stavem, stravou, návykovými látkami, hormonálními stavy, životním prostředím a nemocemi.

Uvádí se, že normální klidová lidská srdeční frekvence je 60–100 tepů za minutu. Tachykardie je vysoká srdeční frekvence – nad 100 tepů za minutu v klidu a bradykardie je nízká srdeční frekvence, s méně než 60 tepů za minutu v klidovém režimu. Během spánku je pomalý srdeční rytmus s frekvencí kolem 40–50 tepů za minutu běžný a je považován za normální. Když srdce nebije pravidelně, označuje se to jako arytmie. Abnormality srdeční frekvence někdy naznačují nemoc.

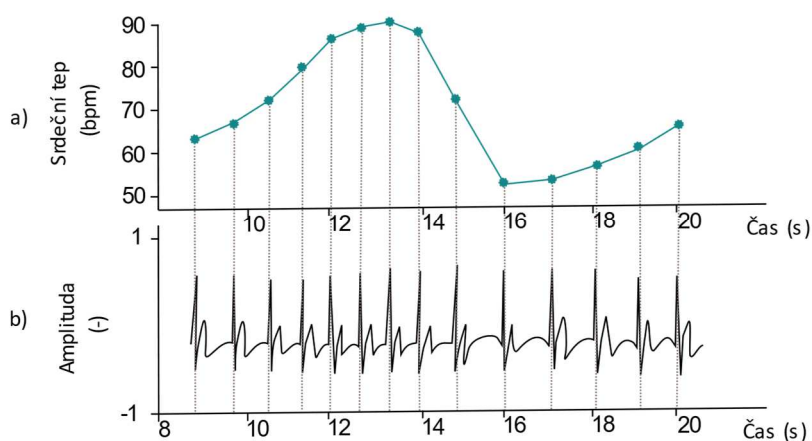
Během odpočinku srdce u dospělého muže bije přibližně 70krát za minutu, zatímco čerpá asi 5 litrů krve. Podnět, který udržuje tento rytmus, je soběstačný. Ve stěně pravé síně pod epikardem se nachází sinoatriální (SA) uzel, který se také nazývá primární pacemaker, protože určuje základní frekvenci, při které srdce bije. Vnitřek vláken srdečního svalu, stejně jako všechny buňky, je negativně nabitý vzhledem k vnějšku. V buňkách S-A uzlu se tento náboj rozpadá spontánně asi 70krát každou minutu. Tento vzruch (depolarizace) iniciuje myokard síní, což způsobí jejich smrštění. Když tento vzruch dosáhne oblasti izolační pojivové tkáně mezi síněmi a komorami, je zachycen atrioventrikulárním (AV) uzlem. Vzruch je veden na systém větvících se vláken, který přenáší proud do všech částí komor. Z AV uzlu na Hissův svazek, dále na pravé a levé Tawarovo raménko a následně

na Purkyňova vlákna. Kontrakce srdce v reakci na tuto elektrickou aktivitu vytváří systolu. Následuje období relaxace stav, které se nazývá diastola [3; 4; 5].

1.3 Variabilita srdeční frekvence

Srdeční frekvence je počet srdečních tepů za minutu. Variabilita srdeční frekvence (HRV) znamená kolísání v časových intervalech mezi sousedními srdečními rytmy. HRV indexuje funkci neurokardu a je generován interakcemi srdce a mozku a procesy dynamické nelineární autonomní soustavy (ANS). HRV představuje nově vznikající vlastnosti vzájemně závislých regulačních systémů, které fungují v různých časových měřítkách a pomáhají přizpůsobit se enviromentálním a psychickým výzvám. HRV odráží regulaci autonomní rovnováhy, krevního tlaku, střev, srdce, cévního tonusu, což se týká průměru cév, které regulují krevní tlak, nebo případně také regulaci obličejových svalů. Zdravé srdce nefunguje jako metronom. Jeho oscilace jsou složité a nelineární. Variabilita nelineárních systémů poskytuje flexibilitu pro rychlé zvládnutí nejistého a měnícího se prostředí. Zatímco zdravé biologické systémy vykazují prostorovou a časovou složitost, onemocnění může zahrnovat ztrátu, nebo naopak zvýšení této složitosti.

Vyšší HRV nemusí nutně znamenat lepší stav, jelikož určité patologické stavy naopak HRV mohou produkovat a tím jej zvyšovat. Zvýšení srdeční abnormality zvyšuje měření HRV, což je silně spojeno se zvýšeným rizikem úmrtnosti (zejména u starších osob). Pečlivé prozkoumání morfologie elektrokardiogramu může odhalit, že za zvýšením HRV mohou být problémy, jako například fibrilace síní. Optimální úroveň HRV je spojena se zdravím a samoregulační kapacitou a přizpůsobivostí nebo odolností. Vyšší úrovně odpočinku vágně zprostředkovaného HRV jsou spojeny s výkonem funkcí, jako je pozornost a emoční upracování prefrontální kůrou. Aferentní zpracování informací vnitřním srdečním nervovým systémem může modulovat frontokortikální aktivitu a ovlivnit funkce vyšší úrovně. Na obrázku 1.1 je znázorněna ukázka závislosti EKG a HRV. [6; 7].




1.1

Obrázek 1.1 Zobrazení: a) okamžitá srdeční frekvence, b) elektrokardiogramu.

2 Optická vlákna

Používání světla pro komunikaci je pravděpodobně stejně staré jako lidské použití ohně pro kouřové signály. S příchodem zrcadla začali lidé využívat slunce jako zdroj světla pro signály směřující k lidem v určité vzdálenosti, kteří pomocí těchto signálů zaznamenávali přenášenou zprávu. Tyto myšlenky se v průběhu staletí zdokonalovaly, včetně pozoruhodného úsilí Grahama Bella s fotonem, který byl použit k přenosu zprávy prostřednictvím světelného paprsku. Tyto rané metody byly omezeny nedostatkem kvalitního zdroje světla a nespolehlivým ztrátovým přenosovým médiem. Vynález laseru v roce 1962 dramaticky změnil tuto situaci dodáním koherentního zdroje světla, který mohl být nasměrován na mnohem delší vzdálenosti ve volném prostoru do vzdáleného přijímače. Nedostatek vhodného přenosového média však nadále bránil postupu v optické komunikaci, dokud vědci neprokázali, že útlum světla ve vláknech byl dostatečně nízký na to, aby umožnilo dlouhé přenosové spoje. Použití dlouhých optických vláken umožňovalo propojit několika kilometrové vzdálenosti a zajistit vysokou přenosovou rychlost. Primární funkcí těchto vláken je jejich využití jako přenosové médium pro komunikační účely. V současné době se však objevuje trend jejich využití pro senzorické aplikace, kde slouží jako senzor požadované měřené veličiny [8; 9; 10].

Optická vlákna se používají ke snímání vlivů prostředí dvěma různými způsoby. Tyto metody, extrinsické a intrinsické jsou znázorněny na obrázku 2.1.



Obrázek 2.1 (a) Vnější nebo hybridní optický senzor sestávající se ze vstupních a výstupních vláken přenášejících světlo do a z černé skříňky, která moduluje světelný paprsek po aktivaci signálem z prostředí. (b) Vnitřní nebo celovláknový optický snímač, jehož vlastnosti jsou modulovány dopadajícím signálem prostředí.

Optická vlákna mohou být použita striktně jako nosiče informací, vedoucí k černé skříňce, která zapůsobí na informaci na světelném paprsku, jež se šíří do vzdáleného přijímače druhým, nebo v některých případech stejným vláknem. Černá skříňka může obsahovat zrcadla, plynový

nebo kapalinový článek, konzolové rameno, nebo desítky dalších mechanismů, které mohou generovat, modulovat nebo transformovat světelný paprsek.

Druhý typ vláknového snímače spoléhá na vlastnosti samotného optického vlákna, aby převedl působení prostředí na modulaci světelného paprsku, který jím prochází. Tuto druhou řadu lze dále rozdělit na podtřídy zvažáním typu modulace působící na světelný paprsek, jako je intenzita, fáze nebo polarizační modulace [11; 8].

2.1 Princip šíření světla optickým vláknem

Světlo můžeme definovat jako viditelnou oblast spektra elektromagnetického záření v přibližném rozsahu 380-780 nm. Současná kvantová mechanika popisuje chování světla jako vlnu, která nese kvantované množství energie.

Vedení a šíření světla v optickém vlákně je založeno na úplném vnitřním odrazu mezi jádrem a pláštěm optického vlákna. Díky nízkému útlumu se mohou optické signály přenášet na velmi dlouhou vzdálenost optickým vláknem, bez významné ztráty optického výkonu. Abychom pochopili tento mechanismus, je třeba znát základní koncept odrazu a lomu světelných vln na optickém rozhraní.

Propustnost světla podél optických vláken závisí nejen na povaze světla, ale také na struktuře optického vlákna. K popisu přenosu světla podél optického vlákna se používají dvě metody. První metoda, teorie paprsků, využívá koncepty odrazu a lomu světla a používá se k aproximaci vlastností optických vláken při přijímání a vedení světla. Druhá metoda, teorie režimů, zachází se světlem jako s elektromagnetickými vlnami. Popisuje chování světla v optickém vlákně. Teorie režimů je užitečná při popisu vlastností optických vláken absorpce, útlumu a disperze.

Důležité jsou optické vlastnosti materiálů použitých k výrobě optických vláken. Tyto vlastnosti ovlivňují, jak je světlo vláknem přenášeno [12; 13].

2.1.1 Šíření vln

Základní optickou vlastností materiálu, souvisejícího s optickými vlákny, je index lomu. Index lomu (n) měří rychlost světla v optickém médiu. Index lomu materiálu je poměr rychlosti světla ve vakuu k rychlosti světla v materiálu samotném.

Rychlost světla (c), dle Teorie relativity, je nejvyšší možná dosažitelná rychlost ve vesmíru. Ve volném prostoru (vakuu) je $c = 299792458 \text{ m/s}$. Rychlost světla je frekvence světla (f) vynásobená vlnovou délkou světla (λ). Když světlo vstupuje do vláknitého materiálu (opticky hustého média), světlo se pohybuje pomaleji, rychlostí (v). Ve vláknitém materiálu bude vždy cestovat pomaleji než ve vzduchu. [12; 13]


Absolutní index lomu (n) je dán vztahem:

$$n = \frac{c}{v} \quad (1)$$

c – rychlost šíření světla ve vakuu,

v – rychlosti v daném prostředí.

Světelný paprsek se odráží a láme, když narazí na hranici mezi dvěma různými průhlednými médii. Na obrázku 2.2 je znázorněno, co se stane se světelným paprskem, když narazí na rozhraní mezi sklem a vzduchem. Index lomu skla (n_1) je 1,5. Index lomu vzduchu (n_2) je 1.



Obrázek 2.2 Odraz a lom světla na hranici skla a vzduchu.

Předpokládejme, že dopadající paprsek prochází sklem. Když světelný paprsek narazí na hranici skleněného vzduchu, skla a vzduchu, existují dva výsledky. Prvním je, že část paprsku se odráží zpět do skla. Druhým výsledkem je, že část paprsku se při vstupu do vzduchu láme (ohýbá). Ohyb světla na rozhraní sklo-vzduch je výsledkem rozdílu mezi indexem lomu. Protože n_1 je větší než n_2 , bude úhel lomu (θ_2) větší, než úhel dopadu (θ_1). Snellův zákon lomu se používá k popisu vztahu mezi incidentem a lomenými paprsky na hranici.

Snellův zákon je dán vztahem:

$$n_2 \sin \theta_2 = n_1 \sin \theta_1. \quad (2)$$

n_2 – index lomu prostředí,

θ_2 – úhel lomu,

n_1 – index lomu materiálu,

θ_1 – úhel dopadu.

Jak se úhel dopadu (θ_1) zvětšuje, úhel lomu (θ_2) se blíží 90 stupňům. V tomto okamžiku není lom možný. Světelný paprsek se úplně odráží zpět do skleněného média. Žádné světlo neuniká

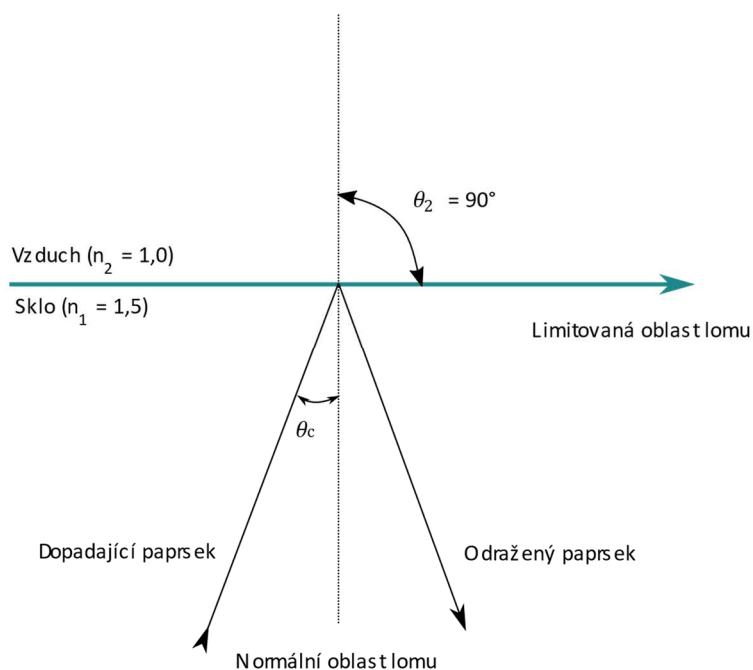
do vzduchu. Tato podmínka se nazývá úplná vnitřní reflexe. Úhel, pod kterým dochází k úplnému vnitřnímu odrazu, se nazývá kritický úhel dopadu (θ_c) – je znázorněn na obrázku 2.3. Při jakémkoli úhlu dopadu (θ_1) větším, než je kritický úhel, se světlo úplně odráží zpět do skleněného média.

Kritický úhel dopadu (θ_c) je určen pomocí Snellova zákona a je dán vztahem:

$$\sin(\theta_c) = \frac{n_2}{n_1}. \quad (3)$$

n_2 – index lomu prostředí,

n_1 – index lomu materiálu.



Obrázek 2.3 Kritický úhel dopadu.

2.2 Druhy optických vláken

Existují dva primární typy vláken, z nichž každý má jinou aplikaci. Jedná se o mnohavidové vlákna (anglicky multimode - MM) vlákno a jednovidová vlákna (anglicky singlemode - SM). Mnohavidová vlákna mají velké jádro a umožňují vést paprsek skrz vlákno pomocí více cest. Jednovidová vlákna naopak umožňují vést paprsek pouze jednou cestou a přes mnohem menší jádro [11].

2.2.1 Mnohavidová optická vlákna


Mnohavidový optický kabel umožňuje průchod více režimů světla velkým jádrem, což zase zvyšuje počet odrazů při průchodu světla. Výhodou tohoto typu vlákna je to, že lze použít

levnější vysílače a přijímače, ale také přináší spoustu rozptylu a útlumu. Stručně řečeno, znamená to, že velikost jádra ponechává tolik prostoru pro odraz světla, které prochází vláknem, že kvalita signálu rychle klesá. Nelze jej ani zesílit, což znamená, že je vhodný pouze na krátké vzdálenosti, kde je potřeba levné řešení. Pro jakoukoli vzdálenost větší než 200–300 metrů není mnohavidové vlákno vhodné. Nejčastější využití se nalézá tam, kde jsou tyto krátké vzdálenosti potřeba, například uvnitř datového centra. Příkladem toho je vlákno OM4, které dokáže zpracovat dopravní signály 10 a 100G až do vzdálenosti 100 metrů.

Existují dva hlavní typy mnohavidového vlákna: gradientní vlákna a vlákno se skokovým indexem lomu [9; 10].

Gradientní vlákno


Toto je dnes běžnější typ mnohavidového vlákna. S mnohavidovým vláknem s gradientovým indexem se světlo pohybující se blízko k ose pohybuje pomaleji než světlo v blízkosti pláště, což vede k lepšímu seskupení světelných paprsků. Index lomu se pak postupně zmenšuje od středové osy směrem k plášti, viz obrázek 2.4.



Obrázek 2.4 Princip šíření světla v mnohavidovém gradientním vlákně.

Optické vlákno se skokovým indexem lomu

U tohoto typu vlákna se světlo pohybuje různými klikatými a přímými cestami a odráží se od pláště. Výsledkem je, že různé „režimy“ světla přicházejí v různé době na druhý konec vlákna. Když se různé režimy začnou šířit, ztratí signál část svého tvaru, viz obrázek 2.5. [10].




Obrázek 2.5 Princip šíření světla ve vlákně se skokovým indexem lomu.

2.2.2 Jednovidová optická vlákna

Jednovidové optické vlákno má menší jádro než vlákno mnohavidové a umožňuje průchod pouze jednomu režimu světla. Protože ve vlákně dochází k méně odrazům světla, má tento typ nejnižší útlum signálu a světlo může cestovat dále. Rozhraní s optikou s jedním režimem, která jako zdroj světla

používá lasery a vysílá jednu vlnovou délku v přímé linii po vlákně. Jednovidové vlákno má vyšší šířku pásma a je nejvhodnějším typem vlákna pro síťové připojení na velké vzdálenosti. Protože se vláknem šíří pouze jeden vid, je tímto zamezeno vzniku vidové disperze. Začíná se ale uplatňovat jiný problém: chromatická disperze. Ta byla přítomná i u mnohavidových vláken, ale vzhledem k vidové disperzi byl její vliv zanedbatelný. Chromatická disperze je způsobena rozdílnou rychlostí šíření (rozdílným indexem lomu) pro různé vlnové délky. "Obyčejný" zdroj světla – například dioda LED je zdrojem více vlnových délek. Spektrum barev sice může být (je) nějak omezeno – například vnímáme světlo jako červené, ale ve skutečnosti se jedná o směs různých vlnových délek v oblasti červené barvy. Proto se jako zdroj světla pro jednovidová vlákna používá laser. Jím emitované světlo je monochromatické – obsahuje jednu vlnovou délku. Tím se chromatická disperze omezí [11; 10].



Obrázek 2.6 Princip šíření světla u jednovidových vláken.

3 Interferometrie

Interferometrie je metoda měření, využívající jev interference vln (obvykle světelných, rádiových nebo zvukových vln). Měření také mohou zahrnovat charakteristiky samotných vln a materiálů, se kterými vlny interagují. Kromě toho se interferometrie používá i k popisu technik, které používají světelné vlny ke studiu změn v posunutí.


Použitím dvou světelných paprsků (obvykle rozdělením jednoho paprsku na dva) lze vytvořit interferenční obrazec, když se tyto dva paprsky překrývají. Protože vlnová délka viditelného světla je velmi krátká, lze detekovat malé změny v rozdílech v optických drahách mezi dvěma paprsky. Tyto rozdíly způsobí znatelné změny v interferenčním vzoru. Optická interferometrie patří mezi cennou měřicí techniku již více než sto let. Její přesnost byla později vylepšena vynálezem laserů.

První ukázkou použití principů interference světla, jako nástroje pro měření, dosáhl Albert A. Michelson v 80. letech 20. století vyvinutím prvního interferometru. Ačkoli technologie a přesnost měření byla vyvinuta v průběhu let, základní principy Michelsonova interferometru stále zůstávají jádrem interferometrie [14; 15].

3.1 Interference

Jak již bylo nastíněno, interferometrie funguje na principu interference. Jednoduše řečeno, interference je to, co nastane, když se dvě vlny nesoucí energii setkají a překrývají. Energie, kterou nesou, se smíchá dohromady, takže místo dvou vln vznikne jedna třetí vlna, jejíž tvar a velikost závisí na vzorcích původních dvou vln. Proces takových kombinací vln se nazývá superpozice.

Jednoduchým příkladem interference a superpozice jsou vlny ve vaně. Pokud budete v napuštěné vaně tlačit vodu rukou sem a tam, můžete vyslat vlny energie vody ze středu ke stěnám vany. Když se vlny dostanou ke stěnám, odrazí se zpět od tvrdého povrchu, víceméně nezměněné velikosti, ale s obrácenou rychlostí. Každá vlna se od vany odráží zpět. Jakmile se vlny vrátí tam, kde máte ruku, můžete je zvětšit posunutím ruky směrem s nimi. Ve skutečnosti vytváříte nové vlny, které se přidávají k těm původním a zvyšují velikost jejich amplitudy. Když se vlny spojí a vytvoří větší, dochází k tzv. konstruktivní interferenci, viz obrázek 3.1. Pokud budete hýbat rukama jiným způsobem, můžete vytvořit vlny, které jsou v rozporu s těmi původními. Odebírají z nich energii a zmenšují je. Tento jev je nazýván destruktivní interference.



a) Konstruktivní interference b) Destruktivní interference

Obrázek 3.1 a) Konstruktivní interference – kombinací dvou nebo více vln vznikne třetí, větší. Nová vlna má stejnou vlnovou délku a frekvenci, ale větší amplitudu. b) Destruktivní interference – odečítání a rušení vln.

Rozsah, ve kterém je jedna vlna v kroku s druhou, se nazývá její fáze. Pokud jsou dvě identické vlny „ve fázi“, znamená to, že jejich vrcholy se vyrovnají. Takže pokud je sečteme dohromady, získáme novou vlnu, která je dvakrát tak velká, ale jinak přesně stejná jako původní vlny. Podobně, pokud jsou dvě vlny zcela mimo fázi, tzv. anti-fázi, kdy vrcholy jedné se přesně shodují se žlaby druhé, sloučení vln dohromady nezpůsobí vůbec nic. Mezi těmito dvěma extrémy je celá řada dalších možností, kdy je jedna vlna částečně ve fázi s druhou. Přidáním dvou vln, jako je tato, vznikne třetí vlna, která má neobvyklý, stoupající a klesající vzorec vrcholů a koryt. Pokud by byla taková vlna zobrazena na obrazovku, získáme její charakteristický vzor světlých a tmavých oblastí, nazývaných interferenční proužky. Tento vzor je studován a měřen pomocí interferometru [13; 14; 16].

3.2 Koherence

Koherence je silně spojena se schopností světla vykazovat rušivé účinky. Světelné pole se nazývá koherentní, pokud existuje pevný fázový vztah mezi hodnotami elektrického pole na různých místech nebo v různých časech. Částečná koherence znamená, že mezi fázovými hodnotami existuje určitá (i když ne dokonalá) korelace.

Je také běžné označit určité procesy nebo techniky za koherentní nebo nekoherentní. V takovém případě „koherentní“ v podstatě znamená fázově citlivý. Například obecná metoda kombinování koherentního paprsku se opírá o vzájemnou koherenci paprsků, zatímco spektrální (nekoherentní) kombinování paprsků ne.

Existují dva velmi odlišné aspekty soudržnosti:

Prostorová koherence znamená silnou korelaci (vztah pevné fáze) mezi elektrickými poli na různých místech, napříč profilem paprsku. Například v průřezu paprsku z laseru s kvalitou paprsku omezenou difrakcí elektrického pole v různých polohách kmitají zcela korelovaným způsobem, i když je časová struktura komplikována superpozicí různých frekvenčních složek.

Časová koherence znamená silnou korelaci mezi elektrickými poli na jednom místě, ale v různých časech. Například výstup jednofrekvenčního laseru může vykazovat velmi vysokou časovou koherenci, protože elektrické pole se dočasně vyvíjí vysoce předvídatelným způsobem: vykazuje čistý sinusový kmit po delší dobu [14; 17].

Kvantifikace koherence

Kvantifikovat stupeň koherence můžeme různými způsoby:


- Korelační funkce určují stupeň korelace jako funkci prostorové nebo časové vzdálenosti. Existují korelační funkce různých řádů. Korelační funkce prvního řádu souvisí s optickým spektrem. Korelační funkce druhého řádu popisuje korelace intenzity, tj. efekty jako slukování fotonů nebo anti-slukování. Funkce vyššího řádu popisují ještě jemnější detaily.
- Čas koherence kvantifikuje stupeň časové koherence prvního řádu prostřednictvím doby, po kterou je koherence ztracena.
- Délka koherence je čas koherence vynásobena rychlosti světla ve vakuu, délka koherence také charakterizuje časovou koherenci prostřednictvím délky šíření (a tedy doby šíření), po kterou je koherence ztracena.
- Šířka čáry jednofrekvenčního laseru také souvisí s časovou koherencí: úzká šířka čáry (vysoká monochromatická) znamená vysokou časovou koherenci.
- Parametry interferometrické viditelnosti v podstatě určují viditelnost (kontrast) interferenčního vzoru generovaného superpozicí dvou elektrických polí.

Vztah mezi optickou šířkou pásma a časovou koherencí může být netriviální. Například řada pulzů z laseru s blokováním režimu může mít širokou celkovou šířku pásma, přičemž Fourierovo spektrum se skládá z diskrétních velmi úzkých čar. Časová koherence může být velmi vysoká v tom smyslu, že existují silné korelace pole pro velká časová zpoždění, která jsou blízká celočíselným násobkům periody pulzu [17].

3.3 Princip interferometrů

Interferometr je vědecký přístroj určený k měření s mimořádnou přesností. Základní myšlenka interferometrie zahrnuje přijetí paprsku světla (nebo jiného typu elektromagnetického záření) a jeho rozdělení na dvě stejné poloviny pomocí takzvaného rozdělovače paprsků, nazývaného také poloprůhledné zrcadlo nebo polozrcadlo. Jedná se o kus skla, jehož povrch je velmi tence potažen stříbrem. Pokud na něj dopadá světlo, polovina světla prochází přímo a polovina se odráží zpět, – takže rozdělovač paprsků je jako kříž mezi obyčejným kouskem skla a zrcadlem. Jeden z paprsků, známý jako referenční paprsek, svítí na zrcadlo a z něj na obrazovku, kameru nebo jiný detektor. Druhý paprsek svítí na nebo skrz něco, co má být měřeno, na druhé zrcadlo, zpět přes rozdělovač paprsků a na stejnou obrazovku. Tento druhý paprsek cestuje o další vzdálenost (nebo jiným mírně odlišným způsobem) k prvnímu paprsku, takže se mírně dostává mimo fázi.

Když se dva světelné paprsky setkají na obrazovce, překrývají se a interferují a fázový rozdíl mezi nimi vytváří vzor světlých a tmavých oblastí, tzv. sadu interferenčních proužků. Světlé oblasti jsou místa, kde se dva paprsky konstruktivně spojily a zesvětlily se; tmavé oblasti jsou místa, kde se paprsky od sebe destruktivně odečetly. Přesný vzor rušení závisí na odlišném způsobu nebo zvláštní vzdálenosti, kterou jeden z paprsků urazil. Kontrolou a měřením okrajů vypočteme změny s vysokou přesností. Místo toho, aby interferenční proužky padaly na jednoduchou obrazovku, jsou často směřovány do kamery a vytvářejí trvalý obraz, zvaný interferogram. V jiném uspořádání je interferogram vytvářen detektorem, jako je například CCD obrazový snímač, používaný ve starších digitálních fotoaparátech. Převádí obraz fluktuujících proužků optického rušení na elektrický signál, který lze velmi snadno analyzovat pomocí počítače [14; 16].



Obrázek 3.2 Funkce základního interferometru.

Přesnost u nejmodernějších interferometrů může dosahovat změření i vzdálenosti do 1 nm, ale jako každý jiný druh měření podléhá chybám. Největší zdroj chyby pravděpodobně pochází ze změn vlnové délky laserového světla, které závisí na indexu lomu materiálu, jímž prochází. Teplota, tlak, vlhkost a koncentrace různých plynů ve vzduchu mění svůj index lomu, mění vlnovou délku procházejícího laserového světla a potenciálně zavádějí chyby měření. Naštěstí to mohou dobré interferometry kompenzovat. Některé mají samostatné lasery, které měří index lomu vzduchu, zatímco jiné měří teplotu, tlak a vlhkost vzduchu a nepřímo vypočítávají účinek na index lomu; v obou případech mohou být měření opravena a celková chyba je značně snížena [14].

4 Senzory z optických vláken

Jako první senzory z optických vláken byly flexibilní endoskopy vyvinuté v první polovině dvacátého století. Jejich vývoj a použití způsobil revoluci v medicíně, která trvá dodnes. Moderní doba senzorů z optických vláken začala vývojem extrémně nízko-ztrátových optických vláken na konci 70. let.

Existují tři odlišné vlny vývoje optických senzorů, které lze rozlišit dle názvů senzorů, jež jsou s nimi spojeny.

Nejúspěšnějšími senzory první vlny byly gyroskopy z optických vláken založené na Sagnacově efektu a hydrofon z optických vláken založený na Mach-Zenderových interferometrech. Tyto senzory byly vyvinuty tak, aby byly v praxi použitelné jak pro komerční, tak i vojenské systémy, z nichž některé se používají dodnes. Druhá vlna senzorů byla založena na interferometrech Fabry-Perot, a to jak extrinsických, tak i intrinsických. Třetí vlna senzorů z optických vláken začala vývojem in-line Braggových mřížkových optických filtrů pro účely optické komunikace. Brzy bylo zjištěno, že vláknové Braggovy mřížky (zkráceně FBG) vytvářely vynikající optické měniče pro snímání řady různých parametrů. V rámci každé vývojové vlny bylo předvedeno a popsáno mnoho dalších senzorů, ovšem tyto tři jsou ty nejdůležitější, jejichž použití definovalo celou jednu éru [16; 18].

Mezi výhodné charakteristické vlastnosti senzorů s optickými vlákny patří jejich nezávislost na činném napájení a vysoká odolnost vůči elektromagnetickému rušení. Díky těmto atributům mohou být tyto senzory použity s jinými elektronickými zařízeními bez generování elektrického šumu, který může narušit kvalitu monitorování vitálních funkcí a potenciálně vést k obavám o bezpečnost pacientů. Senzory s optickými vlákny si získávají větší popularitu díky své flexibilitě, velmi malým rozměrům a spolehlivosti [14; 16].

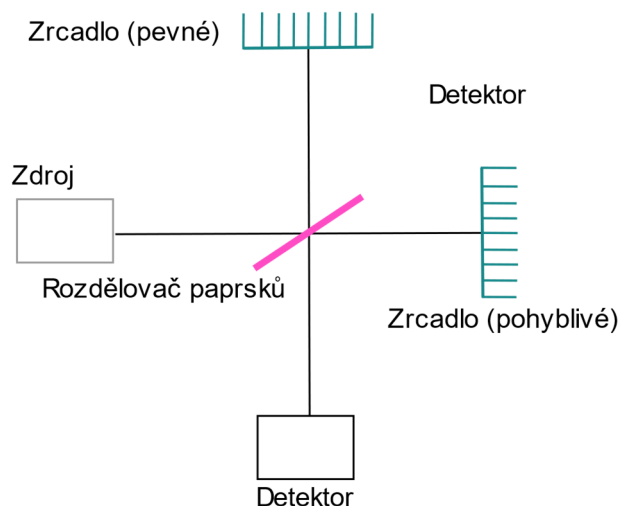
Existuje několik typů interferometrů. Nejběžnější jsou: Sagnacův, Michelson, Fabry-Perot a Mach-Zehnder.

4.1 Sagnacův inteferometr

Sagnacův interferometr se používá především k měření rotace a je náhradou gyroskopů s kruhovým laserem a mechanických gyroskopů. Může být také použit k měření časově proměnlivých účinků, jako je akustika, vibrace, a pomalu se měnících jevů, jako je napětí. Použitím více konfigurací interferometru je možné použít interferometr Sagnac jako distribuovaný senzor schopný měřit amplitudu a umístění rušení. Jednou z nejdůležitějších aplikací senzorů z optických vláken z hlediska komerční hodnoty je gyroskop z optických vláken. Gyroskop z optických vláken nabízí perspektivu celého polovodičového inerciálního senzoru bez pohyblivých částí, bezprecedentní spolehlivost a potenciál velmi nízkých nákladů [14].

4.2 Michelsonův interferometr (MI)

Indikátor Michelsonova interferometru je zobrazen na 21. Používá se zde méně prvků než u Mach-Zehnderova interferometru. Má pouze jeden rozdělovač paprsků a jeden detektor. Velmi častým používáním MI je detekce změn polohy cílového zrcadla [14].



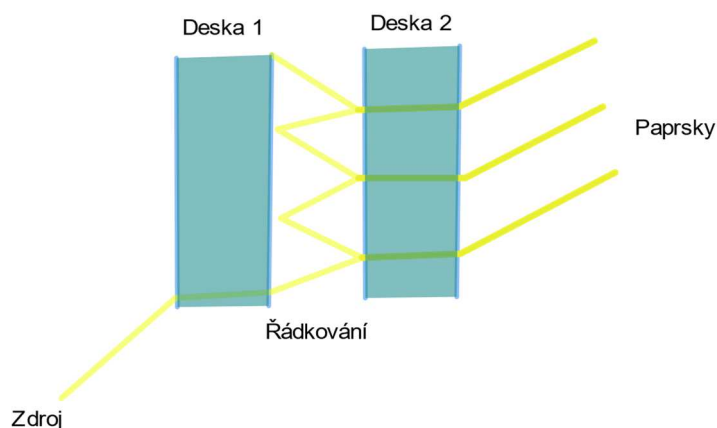
Obrázek 4.1 Michelsonův interferometr.

V historii fyziky zaujímá Michelsonův interferometr velmi zvláštní místo. Byl vyvinut Albertem Michelsonem pro použití v jednom z nejslavnějších fyzikálních experimentů v historii: Michelson-Morleyův experiment. Cílem tohoto experimentu bylo detekovat přítomnost světelného éteru měřením změn rychlosti světla, jak Země cestovala vesmírem. Aether měl existovat ve vesmíru a měl by umožňovat průchod světla skrz něj (stejně jako vzduch je potřebný pro zvukové vlny). Michelson a Morley nikdy nebyli schopni detekovat žádnou změnu rychlosti světla a rozbili představu o existenci éteru. O několik let později, v roce 1905, navrhl Albert Einstein svou speciální teorii relativity, kde předpokládal, že rychlost světla ve vakuu bude neměnná.

Druhým důvodem, proč je MI tak relevantní, je to, že experiment LIGO použil k detekci gravitačních vln Michelsonův interferometr. Jak již bylo zmíněno dříve, experiment LIGO nám umožňuje detekovat přítomnost gravitačních vln. Proč je to relevantní? Představte si, že jste v lese a vidíte kolem sebe všechny ptáky, hmyz a rostliny. Můžete je identifikovat a naučit se jejich chování, ale jednoho dne někdo odstraní špunty do uší, o kterých jste ani nevěděli, že je máte. Nyní můžete slyšet ptáky, slyšet vítr mezi listy, a dokonce slyšet řeku, o které jste ani nevěděli, že tam je. Tak důležitý je experiment LIGO, který nám dal nový smysl pro prozkoumání vesmíru [14].

4.3 Fabry-Perotův interferometr (FPI)

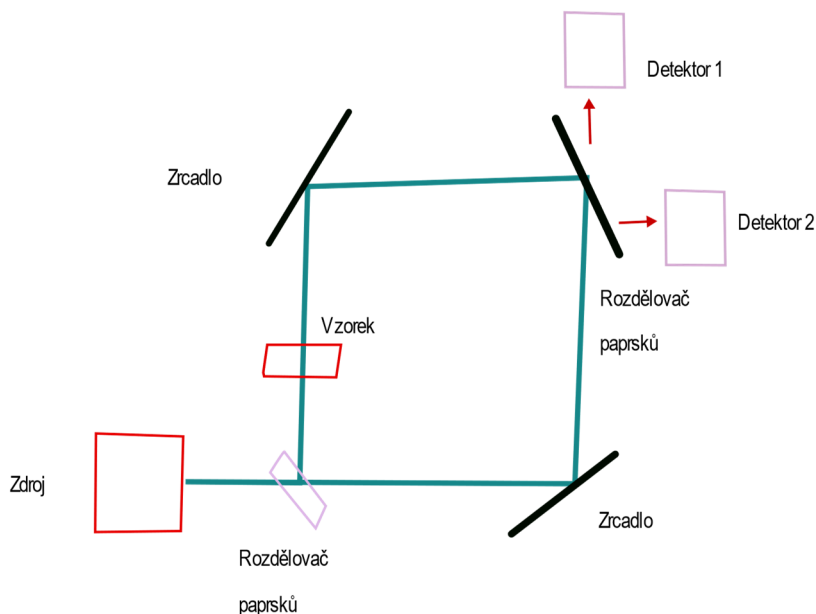
Fabry-Perotův interferometr, zobrazen na Ose skládá ze dvou plochých povrchů s částečnými reflexními zrcadly. Povrchy jsou obráceny k sobě a mezi nimi může být malá mezera. Někdy je možné vytvořit FPI s jedinou skleněnou deskou, jejíž dva povrchy jsou částečně odrazivé.



Obrázek 4.2 Fabry-Perotův interferometr: Dva optické prvky oddělené malou vzdáleností odrážejí optický paprsek tam a zpět a vytvářejí interferenční obrazec.


Při každém odrazu je paprsek rozdělen, což dělá z FPI interferometr s více paprsky. Jednou z výhod interferometru s více paprsky je to, že má velmi vysoké rozlišení (podobné tomu, jak vysoký počet čar / mm vytváří difrakční mřížku s vysokým rozlišením). Je možné mít velmi dobře definovaný interferenční vzor s vysokým kontrastem mezi tmavými a jasnými okraji. FPI má několik aplikací. Nejběžnější je vytvoření dutinového laseru Fabry-Perot, kde je možné vytvořit laser s velmi kvalitním faktorem Q [14].

4.4 Mach-Zehnderův interferometr (MZI)



Obrázek 4.3 Klasická konfigurace Mach-Zehnderova interferometru.

Mach-Zehnderův interferometr je znázorněn na OJe vidět, jak je kolimovaný paprsek rozdělen na dva paprsky: jeden referenční (RB) a paprsek snímače (SB). Oba paprsky cestují nezávislými optickými cestami stejné délky, odrážejí se zrcadlem a jsou rekombinovány pomocí děliče paprsků. Interferenční obrazec pak může být detekován jedním detektorem (obvykle CMOS kamerou). Jednou z atraktivních vlastností konfigurace MZI je, že ji lze implementovat do integrované optiky. Světlo je omezeno na vlnovod, který chrání zařízení před mechanickými vibracemi, zmenšuje jeho velikost a přidáním dalších vrstev do ramene snímače je možné detekovat biomolekuly nebo použít elektrooptické efekty. O ukazuje, jak lze MZI implementovat v integrované optice [14].



Obrázek 4.4 Základní reprezentace MZI v integrovaném obvodu.

4.4.1 Optický senzor s Mach-Zenderovým interferometrem

Jednou z nejcitlivějších metod monitorování životně důležitých funkcí je použití interferometrů z optických vláken. Princip funkce spočívá v měření změn v dráze elektromagnetických vln v důsledku působení sil z vnějšího prostředí. V případě interferometrů lze tyto změny měřit s vysokou přesností na úrovni hodnot menších, než je vlnová délka světla. Citlivost je tak vysoká, že řadu měření lze provádět také v nepřímém kontaktu s lidským tělem.

V této práci se zaměříme na interferometrický měřicí systém, využívající Mach-Zehnderovo rozložení, které představuje základní dvouvlňový interferometr. Optické záření z koherentního zdroje 1550 nm se přivádí do rozdělovače vláken 1x2, který jej rozděluje na měřicí a referenční optické dráhy. Tyto části jsou reprezentovány dvěma jednovlňovými vlákny, která mají stejnou délku (3 m), přičemž referenční část je umístěna v mechanicky stabilní smyčce na zařízení. Zatímco měřicí smyčka je zapouzdřena ve spojovacím prostředku – polydimethylsiloxanovém (PMDS) polymeru, pro vytvoření vibro-akustické citlivé sondy, kterou lze umístit na lidské tělo. Tento materiál nabízí jedinečnou kombinaci vhodných vlastností pro biomedicínské aplikace. Hlavní výhodou PDMS je jeho inertnost vůči lidské pokožce, také je elektricky nevodivý, odolný vůči UV záření a diamagnetický. Mezi další výhody patří jeho mechanická a tepelná odolnost, omyvatelnost a opakovatelnost.

Použitá sonda je vyrobena pomocí 3 m smyčky z optického vlákna v 900 μm trubici o poloměru 5-8 cm a celková hmotnost sondy je 53 g, její připevnění na tělo je zobrazeno na **Chyba! Nenalezen zdroj odkazů.**

Výstupy z obou optických cest se slučují do druhého 3x3 spojovacího prvku, který tvoří Mach-Zehnderův interferometr. Ten převádí rozdíly fázového zpoždění na změny intenzity, měřitelné běžnými výkonovými fotodetektory. Tento vazební prvek má tři výstupy s fázovým posunem, jejichž výstupní optickou intenzitu lze popsat pomocí rovnice (4), kde C je střední hodnota optické intenzity, A je amplituda variace intenzity, A_m je index výstupního portu vlákenného vazebního členu 3x3 za předpokladu hodnot 1, 2 a 3. To umožňuje snadnou pasivní demodulaci fázového rozdílu mezi rameny interferometru [19].

$$I_m(t) = C_m + A_m \cos \left[\Delta\phi(t) + \frac{2\pi}{3}(m - 1) \right]. \quad (4)$$

4.4.2 Vlastní senzor pro měření

Neinvazivní interferometrický senzor, zobrazen na obrázku 4.5, se skládá z Mach-Zehnderova interferometru z optických vláken. Interferometr je tvořen výkonovými vazebními členy 1×2 a 2×1 s rovnoměrným poměrem rozdělení. Interferometrické senzory patří do skupiny optických senzorů s nejvyšším výkonem, protože jsou schopné měřit i malé rozdíly v indexu lomu jádra vlákna a v délce optického vlákna. Zdroj optického laseru, se šířkou pásma $\approx 0,01$ nm a výstupním výkonem ≈ 1 mW, je rozdělen na dvě vlákenná ramena, tvořící referenční a měřicí rameno. Měřicí rameno je zapouzdřeno do polydimethylsiloxanu (PDMS). Polymer PDMS neovlivňuje funkci senzorů. Referenční rameno musí zůstat ve stabilním prostředí. Digitalizace a zesílení signálů se provádí pomocí karty NI-USB 6210, která má 8bitový analogově-digitální převodník se zabudovaným zesilovačem, umožňující volbu

zesílení v krocích po 1, 10 a 50. Vývojové prostředí pro softwarovou podporu této karty – LabVIEW, umožňuje další digitální zpracování dat [20] .



Obrázek 4.5 *Neinvazivní interferometrická sonda [21].*

5 Současný stav řešené problematiky

V uplynulých letech bylo vyvinuto několik výzkumů a algoritmů pro analýzu a klasifikaci signálu EKG a FKG. Metody klasifikace, které byly navrženy během posledního desetiletí a které jsou předmětem hodnocení, zahrnují Hilbertovu transformaci, vlnkovou transformaci, analýzu digitálního signálu, metodu empirického rozkladu, umělou neuronovou síť, genetický algoritmus, podporu vektorových strojů, samoorganizující se mapu, Bayesian a další metody, s každým přístupem vykazují své vlastní výhody a nevýhody. Tyto metody, které se používají pro extrakce prvků EKG signálu lze využít i pro signál FKG, proto tato kapitola obsahuje rešerše studií zaměřujících se na oba biologické signály a poskytuje přehled různých technik a transformací.

5.1 Metody vlnkové transformace

Tato podkapitola se zabývá popisem metod vlnkové transformace. Vlnková transformace spadá mezi integrální transformace. Tyto transformace umožňují získat časově-frekvenční popis signálu. V této kapitole se zaměříme na využití vlnkové transformace jako nástroj pro extrakci EKG a FKG signálu a jeho hodnocení.

5.1.1 Extrakce EKG pomocí vlnkové transformace a podpory vektorových strojů

Zhao a kol. [22] navrhli metodu extrakce funkcí využívající vlnkovou transformaci a podporu vektorových strojů. Příspěvek představil nový přístup k extrakci funkcí pro spolehlivé rozpoznání srdečního rytmu. Navrhovaný systém klasifikace se skládá ze tří složek, které zahrnují předzpracování dat, extrakci funkcí a klasifikaci signálů elektrokardiografie (EKG). K dosažení vektoru funkcí dat elektrokardiogramu (EKG) se používají dvě různé metody extrakce prvků. Waveletová transformace se používá k extrakci koeficientů transformace jako vlastností každého segmentu EKG. Souběžně se také používá autoregresní modelování (AR) k zachycení časových struktur křivek EKG. Nakonec se ke klasifikaci různých srdečních rytmů EKG použije metoda podpurných vektorů (SVM) s Gaussovým jádrem. Výsledky počítačových simulací, poskytnutých ke stanovení výkonnosti navrhovaného přístupu, dosáhly celkové přesnosti 99,68 %.

5.1.2 Extrakce funkcí EKG pomocí optimální mateřské vlnky

Nový přístup k extrakci EKG funkcí navrhli Castro et al. v [23]. Jejich článek představuje algoritmus založený na vlnkové transformaci pro extrakci znaků ze signálu elektrokardiografu a rozpoznání abnormálních srdečních tepů. Jelikož vlnkové transformace mohou být lokalizovány jak ve frekvenční, tak v časové doméně, vyvinuli metodu pro výběr optimální mateřské vlnky ze sady ortogonálních a biortogonálních bank vlnkových filtrů, pomocí nejlepší korelace se signálem EKG. Nejdůležitějším krokem jejich přístupu je odstranit šum ze signálu EKG měkkou nebo tvrdou prahovou hodnotou a poté se každý srdeční cyklus PQRST rozloží na vektor koeficientů, pomocí optimální vlnkové funkce. Pro analýzu EKG jsou použity koeficienty, aproximace poslední úrovně stupnice a podrobnosti všech úrovní. Koeficienty každého cyklu byly rozděleny do tří segmentů, které souvisejí s P-vlnou, QRS komplexem a T-vlnou. Součet hodnot z těchto segmentů poskytly vektory rysů jednotlivých cyklů.

5.1.3 Extrakce funkcí EKG pomocí vln Daubechies

Mahmoodabadi a kol. v [24] popsali přístup k extrakci funkcí EKG, který využívá transformaci vln Daubechies. Vyvinuli a vyhodnotili systém extrakce funkcí EKG, založený na vlnkové transformaci s více rozlišeními. Pro zpracování byly vybrány EKG signály z Modified Lead II. Lepší detekci dosáhl vlnkový filtr s funkcí změny měřítka, který je dále podobný tvaru signálu EKG. Nejdůležitějším krokem jejich přístupu bylo odstranění šumu signálu EKG, odstraněním ekvivalentních vlnkových koeficientů ve vyšších stupnicích. Poté jsou detekovány komplexy QRS a každý jeden komplex se používá ke sledování vrcholů jednotlivých vln, včetně náběhů a posunů vln P a T, které jsou přítomny v jednom srdečním cyklu. Jejich experimentální výsledky odhalily, že jejich navrhovaný přístup k extrakci EKG funkcí dosáhl citlivosti 99,18 % a pozitivní predikce 98 %.

5.1.4 Extrakce signálu EKG pomocí diskrétní vlnové transformace

Emran et al. [25] navrhli metodu extrakce funkcí, pomocí diskrétní vlnkové transformace (DWT). K provedení klasifikační úlohy použili diskrétní vlnkovou transformaci k extrahování příslušných informací ze vstupních dat EKG. Jejich navrhovaná práce zahrnuje následující moduly pro sběr dat, detekci beatů před zpracováním, extrakci funkcí a klasifikaci. V modulu pro extrakci funkcí je DWT navržena tak, aby řešila problém nestacionárních signálů v EKG. Modul byl odvozen z jediné generující funkce zvané mateřská vlnka, pomocí operací překladu a dilatace. Použití DWT při extrakci funkcí může vést k optimálnímu frekvenčnímu rozlišení ve všech frekvenčních rozsazích, protože má různou velikost okna – široké okno při nižších frekvencích a úzké při vyšších frekvencích. Charakterizace DWT dodá stabilní vlastnosti morfologickým variacím křivek EKG.

5.1.5 Klasifikace EKG na základě vlnkové transformace a neuronální sítě

Tayel a Bouridy [26] navrhli techniku klasifikace obrazu EKG extrahováním jejich funkce pomocí vlnkové transformace a neuronových sítí. Funkce jsou extrahovány z vlnkového rozkladu intenzity obrazů EKG. Získané funkce jsou dále zpracovány pomocí umělých neuronových sítí. Jedná se o: průměr, medián, maximum, minimum, rozsah, směrodatná odchylka, rozptyl a průměrná absolutní odchylka. Představená umělá neuronová síť (ANN) byl trénován podle hlavních rysů 63 EKG snímků různých nemocí. Výsledky testu ukázaly, že přesnost klasifikace zavedeného klasifikátoru byla až 92 %. Extrahované vlastnosti signálu EKG pomocí vlnkového rozkladu byly účinně využity ANN při vytváření přesnosti klasifikace 92 %.

5.1.6 Extrakce funkcí ze signálů EKG pomocí vlnkových transformací

Technika modifikovaných kombinovaných vlnkových transformací byla vyvinuta Saxena et al. v [27], k analýze vícesvodých signálů elektrokardiogramu pro diagnostiku srdečních onemocnění. Pro detekci QRS byly použity dvě vlnky, tj. Kvadratický spline wavelet (QSWT) a pro detekci P a T vlnky Daubechiesovy koeficienty (DU6). Byl zaveden postup využívající parametry elektrokardiogramu se systémem bodování pro diagnostiku různých srdečních onemocnění. Konzistence a spolehlivost identifikovaných a měřených parametrů byla potvrzena, když obě diagnostická kritéria poskytla stejné výsledky.

5.1.7 Potlačení signálu EKG pomocí empirické vlnkové transformace

Tento článek [28] představuje nové metody korekce bloudění základní čáry a redukce interference elektrického vedení (PI) v signálech elektrokardiogramu (EKG) pomocí empirické vlnkové transformace (EWT). Během získávání dat EKG signálu kontaminují informace, nesoucí EKG signál, různé zdroje šumu, jako je rušení elektrického vedení, bloudění základní linie a svalové artefakty. Pro lepší analýzu a interpretaci musí být signál EKG bez šumu. V této práci se používá nový přístup k filtrování bloudění základní čáry a interference elektrického vedení ze signálu EKG. Použitou technikou je empirická vlnková transformace, což je nová metoda používaná k výpočtu stavebních režimů daného signálu. Jeho výkon jako filtru je srovnáván se standardními lineárními filtry a empirickým rozkladem. Výsledky ukazují, že empirická vlnková transformace (EWT) přináší lepší výkon.

Empirická vlnková transformace je plně adaptivní a datově řízená technika zpracování signálu s dobře definovaným matematickým pozadím a je analogická s rozkladem empirického režimu. Empirický režim rozkladu ([20]) adaptivně rozkládá časovou řadu na součet „dobře vychovaných“ komponent AM-FM. Algoritmus EMD je přístup založený na datech a navrhuje rozložit signál podle jeho obsažených informací. Nový přístup k rozkladu časové řady na různé režimy je empirická vlnková transformace a je založena na návrhu adaptivní banky vlnkových filtrů. EWT poskytují konzistentnější rozklad, zatímco EMD vykazuje příliš mnoho režimů, které je někdy těžké interpretovat. EWT nejprve vypočítá rychlou Fourierovu transformaci (FFT) signálu, poté vypočítá hranice na základě segmentace Fourierova spektra, a nakonec extrahuje oscilační režimy pomocí adaptivní banky vlnkových filtrů na základě vypočítaných hranic.

Algoritmus EWT byl použit k eliminaci interference elektrického vedení ze signálu EKG. Hlučné EKG (ECG + PI) rozložíme na dva režimy, pomocí EWT s optimalizovanou hranicí. Abychom oddělili frekvenci elektrického vedení od spektra EKG, můžeme pomocí EWT rozložit EKG na dva režimy. Pokud si přejeme takto rozložit hlučné EKG, musíme určit jednu hranici v hlučném spektru dat. Obecně je hranice zadána jako střed mezi dvěma hlavními maximy. Tím získáme hranici, která leží mezi maximálním vrcholem EKG a frekvencí elektrického vedení. Poté navrhujeme dolní a horní propust pomocí empirického měřítka a funkce wavelet. Funkce wavelet oddělí frekvenci elektrického vedení, a tak lze výstup funkce wavelet odečíst od hlučného EKG, aby se získal čistý signál EKG. Pokud však signál EKG již čistý je (bez rušení elektrického vedení), nebo pokud je poměr signálu k šumu (SNR) hlučného EKG nízký, v takovém případě bude hranice vypočítána jako střed mezi dvěma hlavními vrcholy spektrum EKG, a tím proces odečítání odstraní skutečné spektrum signálu EKG. Navrhujeme tedy jiný přístup k optimalizaci hraniční frekvence. Protože frekvence elektrického vedení má konstantní frekvenci 50/60 Hz. Vrchol v hlučném datovém spektru způsobený PI nastane při pevné frekvenci ωn , $(0 - \pi)$ (odpovídá 50/60 Hz). Banka filtrů je navržena na základě zadané hranice; hranice tedy nemůže být specifikována v místě vrcholu PI. Musí však být specifikováno před umístěním vrcholu, aby prošlo celé spektrum šumu. Poté vypočítáme průměr (d) a směrodatnou odchylku (σ) maxim a minim režimu. Velikost každého maxima se porovnává s $m \pm 2 \times$ standardní. Pokud je velikost píku větší než $(m + 2\sigma)$ nebo menší než $(m - 2 \times \sigma)$, definujeme okno mezi předcházejícím a následujícím minimem na obou stranách aktuálního maxima. Část signálu v tomto okně, která má velikost větší

než nula, je zmenšena faktorem $m \cdot \frac{x}{max}$, kde x je signál v okně a max je maximální amplituda x . U minim se používá podobný přístup. Výstup po této operaci je dále předán pásmovým filtrem, který má šířku pásma 49–50 Hz. Tento signál se poté odečte od EKG, aby se získal signál EKG bez šumu.

Navrhované metody v zásadě spočívají v dolní propusti / pásmové propusti, kde je mezní frekvence získána z analýzy datového spektra. V navrženém algoritmu pro odstranění PI se výstupní SNR zvyšuje se zvýšením vstupního SNR. V případě metody EMD se však SNR nejprve zvýší a poté sníží, protože při nízkém vstupním SNR neposkytuje algoritmus EMD přesný odhad frekvence elektrického vedení. V případě Notch filtrování se výstupní SNR zvyšuje s poklesem vstupního SNR, ale zlepšení je menší. Pro odstranění BW má empirický vlnkový filtr v podstatě stejnou mezní frekvenci jako filtr Butterworth, ale poskytuje trochu vysoký výstupní SNR ve srovnání s filtrem Butterworth, kvůli své charakteristice frekvenční odezvy. Pro úplné potlačení šumu lze oba algoritmy použít postupně, protože dva filtry ve dvou případech mají různá propustná pásma a navzájem tak neovlivňují výkon.

5.1.8 Systém detekce a klasifikace EKG úderů využívající vlnkovou transformaci

V této studii [29] je navržen systém rozpoznávání pro detekci a klasifikaci srdečních tepů v EKG signálech. Tepy v EKG datech byly detekovány pomocí metody vlnkové transformace (WT) a tyto tepy jsou segmentovány se stanovenými periodami. Pro získání charakteristických rysů z rytmů se na tyto segmentované signály aplikuje WT s vysokým rozlišením a vlnkové koeficienty se získají z různých frekvenčních úrovní. Vektory prvků jsou generovány na těchto koeficientech pomocí různých statistických metod. Navrhovaný systém rozpoznávání je trénován na vektorech funkcí pomocí klasifikátoru OSELM (Online sekvenční extrémní výukové zařízení) během fáze učení k automatickému rozpoznávání signálů. Z datové sady arytmií MIT-BIH bylo získáno pět různých typů rytmů. Mezi těmito typy beatů byla vytvořena datová sada pro více tříd, která zahrnuje pět tříd, a datová sada pro binární třídy, která zahrnuje dvě třídy. S těmito dvěma datovými soubory byly provedeny výkonostní testy navrhované metody OSELM, založené na waveletech (W-OSELM). Tento algoritmus dokáže automaticky detekovat a klasifikovat rytmy v EKG signálech. V metodě W-OSELM jsou primárně detekovány úder v datech EKG metodou WT a provádí se segmentace těchto signálů. Rozlišovací znaky byly získány použitím metody extrakce znaků na tyto segmentované signály. Klasifikátor OSELM byl trénován s dosaženými funkcemi pro automatickou detekci úderů, které mají neznámé třídy. Testy výkonu navrhovaného klasifikátoru byly získány ze záznamů datové sady arytmií MIT-BIH. Normální, blok větve levého svazku (LBBB), blok větve pravého svazku (RBBB), předčasná kontrakce síní (APC), předčasná kontrakce komor (VPC) a Paced rytmické záznamy se používají k vytvoření dvou různých pracovních sad jako binární a vícetřídové. Podle experimentálních studií navrhovaný systém rozpoznávání W-OSELM provedl 97,29 % detekci srdečních tepů v souborech dat EKG. U detekovaných úderů bylo prokázáno, že výkon automatického rozpoznávání je až 98,51 % pro datovou sadu s více třídami a 99,46 % pro datovou sadu s binárními třídami. Nakonec byly na stejné datové sadě použity různé klasifikátory k vyhodnocení výkonu navrhovaného klasifikátoru OSELM. Bylo zjištěno, že navrhovaný klasifikátor OSELM je docela výhodný, pokud jde o správnou míru rozpoznání a výkon. Dále, aby se prozkoumala výkonost navrhované metody W-OSELM pro rozpoznávání rytmu, byla provedena rozšířená srovnávací studie s nejmodernějším použitím různých extraktorů a klasifikátorů

v literatuře. Získané výsledky naznačují, že navrhovaná metoda je efektivní přístup, který lze použít pro automatickou analýzu signálů EKG.

5.2 Metody neuronových sítí

Neuronová síť je obvod neuronů, nebo v moderním smyslu umělá neuronová síť složená z umělých neuronů nebo uzlů. Neuronová síť je tedy buď biologická neurální síť složená ze skutečných biologických neuronů, nebo umělá neurální síť pro řešení problémů umělé inteligence. Tyto umělé sítě lze použít pro prediktivní modelování, adaptivní řízení a aplikace, kde je lze procvičovat pomocí datové sady. Tato kapitola je zaměřena na extrakci EKG a jeho kvalifikaci a zpracování právě za pomoci metod těchto neuronových sítí.

5.2.1 Extrakce EKG založená na matematické morfologii

Matematickou morfologii pro extrakci funkcí EKG navrhli Tadejko a Rakowski v [30]. Primárním zaměřením jejich práce je vyhodnocení klasifikačního výkonu automatického klasifikátoru elektrokardiogramu (EKG) pro detekci abnormálních úderů s novým konceptem fáze extrakce znaků. Získané sady funkcí byly založeny na morfologii EKG a RR intervalech. Pro analýzu signálních funkcí a shlukování byla přijata technika Kohonenovy samoorganizující se mapy (SOM). Dále byl v této studii vyvinut klasifikátor s algoritmy SOM a Learning Vector Quantization (LVQ), využívající data ze záznamů doporučených standardem ANSI / AAMI EC57. SOM je architektura umělé neuronové sítě, založená na bezkontrolovém, kompetitivním učení. Poskytuje zachování topologie a plynulé mapování z vysokorozměrného vstupního prostoru do mapových jednotek, obvykle uspořádaných jako dvourozměrná mřížka neuronů (uzlů). SOM tedy může sloužit jako nástroj pro klastrovou analýzu komplexních, vysoce dimenzionálních dat. LVQ je supervizovaná klastrová klasifikační technika, která klasifikuje vektor funkcí $x(t)$ podle označení prototypu klastru (kódového slova), do kterého je $x(t)$ seskupeno. K chybě klasifikace dochází, když jsou vektory prvků ve stejném klastru (tedy přiřazené ke stejnému štítku třídy) ve skutečnosti kresleny z různých tříd. Aby se minimalizovala chyba klasifikace, algoritmus LVQ doladí hranici shlukování mezi klastry různých popisků tříd úpravou polohy centra shlukování (prototyp nebo kódové slovo). Tato metoda se nazývá „kvantifikace vektoru učení“, protože tato klasifikační metoda, založená na shlukování, je podobná metodě „vektorové kvantizace“, používané pro kompresi signálu v oblastech komunikace a zpracování signálu. Tento článek porovnává dvě strategie pro klasifikaci anotovaných komplexů QRS: na základě původních morfologických vlastností EKG a navrhovaný nový přístup – založený na předzpracovaných morfologických vlastnostech EKG. Matematické morfologické filtrování se používá pro předzpracování signálu EKG. Byl studován problém výběru vhodného strukturního prvku matematické filtrace morfologie pro zpracování signálu EKG. Výkonnost algoritmu je hodnocena v databázi MIT-BIH podle doporučení Asociace pro povýšení lékařských přístrojů (AAMI). Použitím této metody byly vylepšeny výsledky rozpoznávacích tepů buď jako normálních, nebo arytmií.

5.2.2 Kompresie dat a extrakce funkcí signálů EKG

Saxena et al. [31] popsali přístup k efektivní extrakci znaků ze signálů EKG. kompetentní kompozitní metodou, která byla vyvinuta pro kompresi dat, vyhledávání signálů a extrakci funkcí

signálů EKG. Po získání signálu z komprimovaných dat bylo zjištěno, že síť nejen komprimuje data, ale také zlepšuje kvalitu získaného signálu EKG s ohledem na eliminaci vysokofrekvenčního rušení přítomného v původním signálu. S ANN se zvyšuje kompresní poměr se zvyšujícím se počtem cyklů EKG. Funkce extrahované kritérii amplitudy, strmosti a doby trvání z načteného signálu se navíc shodují s vlastnostmi původního signálu. Jejich experimentální výsledky v každé fázi jsou stabilní a konzistentní a bezpochyby dokazují, že kompozitní metodu lze použít pro efektivní správu dat a extrakci funkcí signálů EKG v mnoha aplikacích v reálném čase.

5.2.3 Automatická extrakce pro klasifikaci signálů EKG

Alexakis et al. [32] popsali metodu pro automatickou extrakci jak časových intervalů, tak morfologických znaků z elektrokardiogramu ke klasifikaci EKG na normální a arytmiické. Metoda využívá kombinaci technik ANN a metod lineární diskriminační analýzy (LDA) pro extrakci prvků. ANN se „učí“ přizpůsobením spojení mezi svými výpočetními neurony tak, aby odpovídaly kombinacím vstup-výstup. Architektura neuronové sítě použitá v této studii pro klasifikaci stop EKG byla vícevrstvá neuronová síť (MLP). Klasifikace byla binární, do normálních a arytmiických záznamů EKG. ANN mapoval normální EKG záznamy jako negativní a arytmiické jako pozitivní. V metodě bylo použito pět funkcí EKG, jmenovitě RR, RTc, amplituda vlny T, šikmost vlny T a špičatost vlny T. Tyto funkce byly získány pomocí automatických algoritmů. Začátek a konec vlny T byly detekovány pomocí tangensové metody. Pro každého pacienta uvažovaného ve studii byl vyškolen klasifikátor. Alternativně mohl být vyškolen jediný klasifikátor, který by pracoval na všech pacientech. Druhý přístup nebyl upřednostňován kvůli problémům s variabilitou mezi pacienty. Taková variabilita je běžná při práci s fyziologickými údaji, což klasifikátorům ztěžuje generalizaci na neviditelných datech napříč populací všech pacientů. Výkonnostní měřítka použitá k hodnocení výkonu klasifikátorů byla: přesnost, míra zásahu (citlivost), míra falešných poplachů, poměr skutečných negativů (tnratio) a poměr falešných negativů. Míra zásahu popisuje počet arytmiických stop správně klasifikovaných, zatímco falešný poplach popisuje počet normálních stop, které byly klasifikovány jako arytmiické (například falešné poplachy). Tnratio popisuje počet normálních stop klasifikovaných správně, zatímco poměr falešných negativů popisuje počet arytmiických stop klasifikovaných jako normální, tj. Počet hypoglykemických příhod, které byly vynechány. Celkově byla metoda ANN lepší než LDA. Nejslabším bodem LDA bylo procento falešných poplachů (špatně určených hypoxií). Tento poměr byl vysoký i pro soubor tréninkových dat. Jak pro ANN, tak pro LDA byla míra úspěšnosti větší než celková doba pro výsledky školení i testů. To znamená, že oba klasifikátory byli lepší ve správné klasifikaci hypoglykemických záznamů než ve správné klasifikaci normálních záznamů.

5.2.4 Extrakce a klasifikace EKG pomocí cepstrum koeficientu a neuronových sítí

Jen a kol. v [33] formulovali přístup využívající neuronové sítě pro stanovení vlastností signálu EKG. Představili integrovaný systém pro diagnostiku EKG. Integrovaný systém sestával z metody cepstrum koeficientu pro extrakci prvků z dlouhodobých signálů EKG a modelů pro klasifikaci pomocí ANN. Použitím navrhované metody lze identifikovat charakteristiky skrývající se uvnitř signálu EKG a poté klasifikovat signál a diagnostikovat abnormality. K prozkoumání výkonnosti navrhované metody byly pro ověření použity různé typy EKG dat z databáze MIT-BIH. Experimentální výsledky ukázaly,

že přesnost diagnostiky srdečních onemocnění byla nad 97,5 %. Dále také navrhovaná metoda úspěšně extrahovala odpovídající charakteristické vektory, rozlišovala rozdílové a klasifikované signály EKG.

5.2.5 Analýzy nezávislých komponent a neuronových sítí pro klasifikaci EKG

Autoři v tomto článku [34] navrhují schéma integrace analýzy nezávislých komponent (ICA) a neuronálních sítí pro klasifikaci rytmu elektrokardiogramu (EKG). ICA se používá k rozložení signálů EKG na vážený součet základních komponent, které jsou statisticky vzájemně nezávislé. Projekce na tyto komponenty spolu s intervalem RR pak představují vektor funkcí pro následující klasifikátor. Jako klasifikátory se používají dvě neuronální sítě, včetně pravděpodobnostní neuronální sítě (PNN) a neuronové sítě se zpětným šířením (BPNN). PNN použitá v této studii má dvouvrstvou strukturu, včetně radiální základní vrstvy a konkurenční vrstvy. Radiální základní vrstva obsahuje stejný počet neuronů jako u tříd, které mají být klasifikovány. Každý neuron je zodpovědný za výpočet pravděpodobnosti, že je vektor vstupního prvku spojen se specifickou třídou. Vzorky EKG přisuzované osmi různým typům rytmu byly pro experimenty odebrány z databáze MIT-BIH arytmií. Výsledky ukazují vysokou přesnost klasifikace přes 98 % u jednoho ze dvou klasifikátorů. Mezi nimi PNN vykazuje o něco lepší výkon než BPNN, pokud jde o přesnost a robustnost oproti počtu ICA-bází. Výsledky dokazují, že integrace analýzy nezávislých komponent a neuronálních sítí, zejména PNN, je slibným schématem pro počítačovou diagnostiku srdečních onemocnění založenou na EKG.

5.3 Metody slepé separace zdrojů

Slepá separace zdrojů představuje oddělení sady zdrojových signálů od sady smíšených signálů bez ztráty potřebné informace. Nejčastěji se používá při číslicovém zpracování signálu a zahrnuje analýzu směsí signálů; cílem je obnovit původní signály komponent ze signálu směsi. Do této metody spadají jak ICA, tak i PDA, což jsou metody, na které je tato kapitola zaměřena.

5.3.1 Zpracování signálu fetální fonokardiografie z břišních záznamů neadaptivními metodami

Autoři článku Slanina a kol. se zaměřili především na extrakci fFKG z aFKG pomocí metod ICA a PCA. Po provedení algoritmů byly z každé metody získány dvě složky. Nejprve byl vybrán ten signál, který subjektivním pozorováním lépe reaguje na fFKG. Poté bylo potřeba vyrovnat amplitudu výstupních ICA komponent s amplitudou ideální formy fFKG, protože ICA algoritmus mění amplitudu extrahovaných komponent. K tomuto problému nedochází u algoritmu PCA. Nakonec byl použit klouzavý průměr se vzorky jako postprocessing k vyhlazení výstupních signálů fFKG. Pro experimenty byly použity všechny možné kombinace vstupních dat, a protože vstupem byl smíšený břišní signál, bylo možné společně otestovat kombinace elektrod. Stanovení fHR bylo provedeno z predikovaného fFKG metodami ICA a PCA. Z obou předpovězených fFKG (použitých pro všechny kombinace) byla odhadnuta stejná fHR, jaká měla ideální formu fFKG. Další vyhodnocení bylo provedeno výpočtem SNR. Algoritmus ICA zlepšuje SNR v rozsahu 4,56 až 11,29 dB a algoritmus PCA zlepšuje SNR v rozsahu od 1,67 do 7,67 dB. Z výsledků vyplývá, že algoritmus ICA funguje velmi dobře, jelikož tolik vylepšil signál [35].

5.3.2 Aplikace analýzy nezávislých komponent při odstraňování artefaktů z EKG

Autoři [36] představili techniku založenou na jednoduchých statistických indexech a byla úspěšně otestována na reálných datech EKG. Výhodou této metody je její jednoduchost, účinnost, a tedy i potenciál pro online zpracování EKG pomocí analýzy nezávislých komponent (ICA). ICA je úspěšná v oddělování artefaktů a šumu z EKG a také dokáže účinně detekovat a odstranit značné množství šumu a artefaktů, zvláště když jsou poškozeny pouze jeden nebo dva kanály EKG. To naznačuje, že artefakty a hluk jsou nezávislé zdroje z fyziologických zdrojů, generujících srdeční signály. Jednou z potíží s aplikací této metody je stanovení pořadí nezávislých složek a také to, že při dalším zpracování je nutné spoléhat se na vizuální kontrolu složek ICA. Pro zpracování ICA je nejprve vybrána 10 s epocha EKG. Dále se vypočítá hodnota Kurtosis každé složky ICA. Složka, jejíž modul pružnosti je pod prahovou hodnotou, je označena jako spojitý šum. Poté jsou zbývající komponenty ICA rozděleny do 10 nepřekrývajících se bloků, každý s trváním 1 s. Vypočítají se odchylky 10 segmentů pro každou složku, poté se odchylka těchto 10 hodnot odchylek získá jako parametr Var_{var} . Složka, jejíž hodnota Var_{var} je nad předem stanovenou prahovou hodnotou, je označena jako součást náhlé změny. Používají se pouze tři elektrody, jedna na V5, jedna na pravé paži (RA) a jedna na levé noze (LL). Odpovídají dvěma různým klinickým kanálům, V5 a svodu II, stejně jako třetímu kanálu bez konkrétně definovaného významu. Aby se udržel počet elektrod na pacientovi na minimum, není k dispozici žádná referenční elektroda, a proto je uzemnění považováno za průměr ze tří různých kanálů. EKG je vzorkováno na 256 Hz, v souladu s normami ANSI z roku 1994. Filtr s konečnou impulzivní odezvou (FIR) je navržen pomocí algoritmu Parks - McClellan. Filtry navržené touto metodou vykazují rovnoměrné chování ve své frekvenční odezvě a mají lineární fázovou odezvu v sledovaném rozsahu, takže tvar křivky EKG není zkreslený.

5.3.3 Analýza šumu EKG signálu pomocí fastICA

K izolaci čistého pozorovatelného EKG od šumů a artefaktů se používají různé techniky okna, jako je Gaussovo okno nebo okno Kaiser. Výsledkem těchto technik je lepší SNR s přijatelným tvarem křivky. Nevýhodou těchto metod je úprava mezní frekvence. Průzkum ukázal, že nelineární adaptivní filtrování je dobrou volbou pro zrušení artefaktu a poskytuje dobrou přesnost. Technika prostorového průměrování nebo průměrování souboru vykazuje dobrou redukci šumu, vyžaduje však velké záznamy pro odhad správného signálu. Také pro detekci pohybu pacientů se používají různé senzory pro potlačení šumu, které ale mají omezení nízké korelace mezi výstupem senzoru a pohybovými artefakty. Zde navrhovaná metoda je založena na implementaci techniky ICA pro odstranění artefaktů a PCA se používá pro zmenšení rozměrů. Metoda ICA využívá statistickou analýzu EKG dat pro správné potlačení šumu.

Analýza hlavních komponent (PCA) je prováděná na pozorovaném vektoru \vec{X} , který je nejprve vycentrován odstraněním jeho průměru. Poté je vektor transformován lineární transformací na nový vektor, případně nižší dimenze, jehož prvky spolu nekorelovaly. Lineární transformace dává vlastní hodnotu (D) a vlastní vektory (\vec{E}) kovarianční matice $E (XX')$, které se používají pro další zpracování v ICA. Metoda ICA využívá statistickou analýzu dat EKG pro správné potlačení šumu. Pro analýzu různých šumů a artefaktů, které signál EKG zpracovává mnoha kroky, může zpracování ICA

na původních rozměrných datech poskytnout špatné výsledky. Aby se tomu zabránilo, před použitím techniky ICA se použije PCA. Separaci šumu v EKG signálu je provedena pomocí techniky Fast ICA. Oddělené signály poskytují požadovaný signál na základě hodnoty špičatosti. Jelikož ICA závisí na statistických vlastnostech, tak úspěšně eliminuje artefakty, i když se překrývají s frekvencí EKG. Techniky ICA zachovávají tvar signálu a nevytvářejí nepravé tvary EKG. Také mají dobré experimentální výsledky z hlediska doby konvergence a SNR, přestože zde jsou určité nejasnosti a problémy týkající se nedostatku předchozích informací o tvaru zdrojového signálu. Analýza PCA – ICA ukazuje, že nedochází k významné ztrátě informací a že poskytuje lepší řešení i z morfologického hlediska. ICA technika může filtrovat interference, pokud hluk a artefakty mají stejný frekvenční rozsah jako srdeční signál, což není možné pomocí filtrů [37].

5.4 Přehled dalších metod

Jelikož metod, jak signál EKG zpracovat a vyhodnotit existuje nespočetné množství, tato kapitola je zaměřena na další a méně známé metody.

5.4.1 Metoda adaptivního tréninku BEAT

Autoři [38] představili novou metodu odhadování beat-to-beat intervalových délek z balistokardiografu (BKG) pomocí algoritmu adaptivního tréninku (BEAT). BEAT algoritmus je založen na technikách učení, které se automaticky přizpůsobují variabilitě nahrávek BKG pomocí krátké (např. 30 s dlouhé) trénovací fáze. Během tohoto tréninku se stanoví sada parametrů, popisujících vlastnosti individuálního srdečního rytmu v daném signálu. Použitím těchto parametrů se kombinují tři nezávislé metody k nalezení srdečních rytmů v BKG signálu.

Algoritmus BEAT se autonomně učí a detekuje vzory peaku BKG, odpovídající jednotlivým srdečním rytmům. Surový signál BKG je předzpracován použitím Butterworthova vysokofrekvenčního filtru druhého řádu s 3 dB a mezní frekvencí 1 Hz, k odstranění nízkofrekvenčních dýchacích složek. Krátký segment filtrovaného signálu je poté analyzován, aby se určily rysy srdečního rytmu v takzvané „tréninkové fázi“. Tento tréninkový krok je založen na parametrizaci a porovnávání lokálních maxim v BKG, jakož i na modifikovaném algoritmu k-means shlukování.

V další fázi, tj. fázi detekce rytmu, je zbývající signál skenován na srdeční rytmus pomocí funkcí, které byly extrahovány během tréninkového postupu. Výsledkem je seznam odhadovaných lokací srdečního rytmu. V konečném kroku se odhadované umístění srdečního rytmu použijí k vytvoření definovaného seznamu délek intervalů mezi dvěma rytmy.

Pro vyhodnocení dosažené kvality odhadů tepové frekvence beat-to-beat bylo zaznamenáno BKG a referenční EKG od 16 testovaných subjektů v laboratorním prostředí. Bylo možné pozorovat dobrou shodu mezi výstupem algoritmu BEAT a zlatým standardem.

5.4.2 Metoda chaosu

Jovic a Bogunovic v [39] navrhli teorii chaosu, kterou lze úspěšně aplikovat na extrakci funkcí EKG. Úspěšnou extrakci funkcí pomocí analýzy chaosu lze provést pouze v případě, že se systém ukáže

jako deterministický a nelineární. Ačkoli toto tvrzení nelze přesně dokázat, logika diktuje, že je pravdivé. Pokud je tedy systém například lineární a deterministický, nemá analýza chaosu žádný význam. Protože se lidské srdce mírně odchyluje ve své anatomii a dalších vlastnostech, nelze říct, že každé srdce je v každém okamžiku nelineární a deterministický systém. Aby se potvrdila nelinearita a determinismus, musí být splněny dvě podmínky a musí být také vytvořen předpoklad. Nejprve je třeba vyvrátit, že systém je lineární a stochastický. To lze efektivně provést ukázkou, že systém není v souladu s nulovou hypotézou. To znamená, že časová řada systémové proměnné se nechová tak, jak to dělá Gaussův šum. Abychom to dokázali, je třeba provést Fourierovu transformaci původních časových řad. Poté jsou jeho fáze randomizovány ve frekvenční doméně v intervalu $[0, 2\pi]$. Následně se provede inverzní Fourierova transformace, čímž se vrátí zamíchané hodnoty zpět do časové domény. Pokud hodnoty původní časové řady významně odpovídají této tzv. Náhradní časové řadě, znamená to, že původní časová řada je lineární a stochastická. V tomto případě nelze použít analýzu chaosu. Pokud se však jejich hodnoty významně liší (obvykle o jeden řád), pak je nulová hypotéza vyvrácena a systém není lineární ani stochastický.

Systém může být stále:

1. Nelineární a deterministický
2. Nelineární a stochastický
3. Lineární a deterministický.

Dále se vytváří předpoklad pro časové řady EKG a obecně pro srdce. Předpokládá se, že lidské srdce není lineární ani deterministické. Ačkoli je tento předpoklad obecně pravdivý, některá srdce mohou vykazovat lineární a deterministické chování, obvykle ty, která mají velmi nízkou variabilitu srdeční frekvence. Nakonec se k určení, zda srdce vykazuje deterministické nebo stochastické nelineární chování, používá metoda používající dimenzi rekonstrukce atraktoru d a korelační dimenzi $D2$. Pokud v nějakém dimenzionálním popisu dimenze korelace atraktoru systému $D2$ dojde k nasycení, pak lze systém považovat za deterministický. Pokud v EKG existuje příliš mnoho šumu, je možné, že je atraktor „maskovaný“, a proto jeho korelační rozměr nikdy nenasycuje, což z EKG dělá stochastický systém.

Program ECG Chaos Extractor (ECE) byl vytvořen jako prostředí pro extrakci funkcí pro metody chaosu. Je napsán v jazyce Java 1.5 a je nezávislý na platformě. Grafické rozhraní se používá k určení souborů EKG použitých při extrakci a také k výběru metody a uložení výsledků. Program extrahuje funkce ze souborů EKG. Cílem je extrahovat prvky buď ze souboru signálu EKG, nebo ze souboru anotací EKG. Tento soubor obsahuje doby a typ srdečního rytmu, zatímco signální soubor obsahuje celý vzorkovaný signál. Analýza je v zásadě stejná pro oba typy souborů. Soubor může také obsahovat jednu nebo dvě stopy EKG. Signál a poznámky lze vizuálně prezentovat ve speciálním okně pro vizualizaci signálu. Po výběru stopy EKG je třeba nejprve provést test na determinismus. Program ECE má samostatné okno, které představuje vztah mezi korelační dimenzí $D2$ a rekonstrukční dimenzí d . Uživatel musí potvrdit, zda $D2$ dojde k nasycení pro nějakou dimenzi d , a také zkontrolovat význam rozdílu pro skutečnou a náhradní sérii. Po extrahování požadovaných funkcí mohou být výsledky uloženy do souboru ve formátu rff.

5.4.3 Metoda založena na klouzavých průměrech pro detekci komplexů QRS

Chouhan a Mehta představili algoritmus [40] pro detekci komplexů QRS. Rozpoznávání komplexů QRS tvoří základ ve většině algoritmů automatizované analýzy EKG. Předložený algoritmus využívá upravenou definici sklonu EKG signálu jako funkci pro detekci QRS. Posloupnost transformací filtrovaného signálu EKG a signálu upraveného podle driftu základny se používá pro vygenerování nové upravené funkce sklonu. V algoritmu poskytuje filtrační postup založený na klouzavých průměrech [41] hladký EKG signál bez hrotu, který je vhodný pro extrakci svahových prvků. Nejdůležitějším krokem je dosáhnout vlastnost sklonu z filtrovaného a driftem korigovaného signálu EKG zpracováním a transformací takovým způsobem, že signál extrahovaného prvku je významně vylepšen v oblasti QRS a potlačen v oblasti, která není QRS. Navrhovaná metoda má míru detekce 98,56 % a pozitivní prediktivitu 99,18 %.

5.4.4 Algoritmus využívající vlnovou křivku sklonu vektoru

Xu a kol. [42] popsali algoritmus využívající vlnovou křivku vektoru sklonu (Slope Vector Waveform, SVW) pro detekci komplexu QRS a vyhodnocení RR intervalu. V navrhované metodě se používá variabilní diference stupně k dosažení požadovaných sklonových vektorů pro extrakci znaků. Nelineární zesílení se používá k lepšímu poměru signálu k šumu. K získání trvání QRS jsou potřebná pravidla extrakce funkcí. Metoda umožňuje rychlé a přesné vyhledávání polohy R, trvání komplexu QRS a intervalu RR a poskytuje vynikající výsledky extrakce funkcí EKG.

5.4.5 Extrakce vlnového průběhu elektrokardiogramu pomocí vhodného filtru

Olvera [43] navrhl robustní schéma extrakce funkcí EKG. Navrhovaná metoda využívá přizpůsobený filtr k detekci různých signálních rysů na signálu elektrokardiogramu lidského srdce. Jako filtr byl využit elektrokardiogram z databáze MIT-BIH, která obsahuje mnoho datových sad signálu EKG, většinou abnormálních nebo nezdravých. Obsahuje ale také normální EKG signály, které lze poté použít jako referenční. Každý signál EKG byl původně vzorkován při jiné vzorkovací frekvenci. Aby bylo možné aplikovat techniky zpracování signálu rovnoměrně na každý záznam a uchovat co nejvíce informací, byl každý záznam převzorkován na 500 Hz. Po převzorkování byl průměr odstraněn z každého signálu EKG a poté byl každý signál EKG veden přes Chebyshev filtr, dolní propust 6. řádu, aby se odstranily všechny složky signálu nad 50 Hz. Z normálního záznamu EKG byla extrahována šablona signálu. Protože se každý interval R-R mírně liší, byl interval šablony zvolen čistě subjektivně. Z této šablony byla každá vlastnost křivky EKG použita jako signál zájmu pro odpovídající filtr specifického prvku. Kauzálně přizpůsobený filtr funkce byl aplikován na každý ze čtyř signálů EKG a komplex QRS, vrchol R vlny a S. Detekce segmentu ST, který je předchůdcem možných srdečních problémů, bylo obtížnější extrahovat pomocí přizpůsobeného filtru kvůli šumu a variabilitě amplitudy. Zdokonalením použitých metod; s použitím jiné formy přizpůsobeného filtru a lepší detekce prahové hodnoty by mohla být úspěšnější extrakce funkcí EKG přizpůsobeného filtru. Detekce různých funkcí v průběhu EKG byla mnohem těžší, než se očekávalo, složitou částí bylo vytvoření metody odhalení k odstranění prvku zájmu v každém signálu EKG.

5.4.6 Metoda vzájemné korelace

Korelační analýza pro extrakci abnormálního signálu EKG byla vysvětlena autory článku [44] Ramli a Ahmadem. Jejich navrhovaná práce zkoumala techniku extrakce důležitých funkcí ze signálů EKG s 12 svody. Pro celou svou analýzu si vybrali II. svod, kvůli jeho reprezentativním charakteristikám pro identifikaci běžných srdečních onemocnění. Zvolenou technikou analýzy je analýza vzájemné korelace, která měří podobnost mezi dvěma signály a extrahuje informace přítomné v signálech. Výsledky jejich testů naznačují, že navrhovaná technika může účinně extrahovat vlastnosti, které rozlišují mezi analyzovanými typy srdečních onemocnění a také pro normální srdeční signál.

5.4.7 Klasifikace EKG rytmů pomocí PCA, LDA, ICA a DWT

V tomto článku [45] bylo pomocí lokální fraktální dimenze, bylo klasifikováno šest typů EKG tepů (normální, blok větve levého svazku (LBBB), blok větve pravého svazku (RBBB), předčasná kontrakce síní (APC), předčasná kontrakce komor (VPC) a stimulované rytmy) s více než 97 % citlivosti pro normální, LBBB, RBBB, stimulované a VPC rytmy; a více než 86% citlivost pro APC beaty. Pět typů EKG rytmů (normální, LBBB, RBBB, APC a VPC) bylo klasifikováno s 93,97 % přesností. Ke klasifikaci těchto šesti typů EKG byla použita technika vlnkové transformace a optimalizace hejnem částic a získala 88,84 % přesnost. Minipočítačový systém byl navržen pro analýzu 24hodinového ambulantního EKG a automaticky klasifikoval normální, nad ventrikulární ektopické tepny a ventrikulární ektopické tepy pomocí časových intervalů mezi různými charakteristickými vrcholy EKG. Použitím metody lineární predikce byl detekován VPC s citlivostí 92 %. Pomocí modelu Hidden Markov Model (HMM) byly modelovány různé segmenty EKG a následně klasifikovány EKG beaty na normální, nad ventrikulární ektopické beaty (SVEB) a ventrikulární ektopické beaty (VEB) s využitím funkcí časové domény. Vlastnosti morfologie EKG a RR intervalu byly použity pro klasifikaci normálních a pěti typů arytmií pomocí optimalizace částicového roje a získali průměrnou přesnost 93,27 %. Pomocí auto-regresního modelu a generalizovaného klasifikátoru lineárních modelů byly klasifikovány normální EKG, normální, APC, supra ventrikulární tachykardie (SVT), ventrikulární tachykardie (VT), VPC a ventrikulární flutter (VF) s 93,2 % přesností. Pomocí Hermitových koeficientů EKG tepů a techniky neurofuzzy byly EKG tepy klasifikovány s 96 % přesností. Byl vyvinut hardwarový systém se čtyřmi signály (balistokardiogram, EKG, pletysmogram dolní části těla a elektromyogram dolní části těla) pro sledování kardiovaskulárního zdraví doma. Dva druhy abnormalit v EKG byly klasifikovány pomocí modelu Gaussian Mixture (GMM) a vykazují přesnost více než 94 %. Pomocí vlnové transformace a PCA byly normální a abnormální rytmy v EKG klasifikovány pomocí různých klasifikátorů a u klasifikátorů metody podpůrných vektorů (Support Vector Machines, SVM) byly hlášeny 95,6% přesnosti. Všechny tyto metody však mají následující nevýhody. V naší navrhované metodě byly EKG rytmy transformovány metodou diskrétní vlnkové transformace (DWT) a následně byly samostatně použity metody redukce trojrozměrnosti k extrakci funkcí. Byly použity tři metody redukce rozměrů: PCA, LDA a ICA. Tyto funkce se sníženou dimenzionálností byly přiváděny do neurální sítě (NN), SVM s různými funkcemi jádra a pravděpodobnostní neurální sítě (PNN) pro automatickou klasifikaci.

Celý experiment byl simulován v prostředí MATLABu. Signál EKG z databáze arytmií MIT-BIH byl denoizován technikou denoise založenou na vlnkách. Odšuměný signál byl podroben detekci komplexu QRS pomocí metody Pan-Tompkins. Po detekci komplexu QRS bylo jako segment EKG rytmu

vybráno 100 vzorků zprava od QRS píku, 99 vzorků nalevo od QRS komplexu a samotný pík QRS. Volba 200 vzorků kolem vrcholu R jako délky signálního okna je taková, že sestává přibližně z jednoho cyklu srdeční aktivity. Na základě variability způsobu dimenze redukce (PCA, LDA nebo ICA) vyřadí zbytečné dimenze. Celkově bylo pro analýzu z databáze MIT-BIH zváženo 110 094 úderů. Diskrétní vlnková transformace byla vypočítána na každém z úderů EKG pomocí aproximace konečné impulsní odezvy (FIR) Mayerova waveletu („dmey“). Na základě charakteristik signálu EKG byla pro následnou redukci rozměrů a klasifikaci vzoru zvážena aproximace 4. úrovně a detail 4. úrovně. Na každé dílčí pásmo byly použity tři metody redukce rozměrů: PCA, LDA a ICA. Po zmenšení rozměrů bylo pro následnou identifikaci vzoru zváženo šest složek z každého dílčího pásma. Z výsledků je patrné, že všech dvanáct znaků (šest z každého dílčího pásma) bylo statisticky významných s nízkou hodnotou p ($<0,0001$). Dvanáct funkcí po PCA bylo zavedeno do různých klasifikátorů (NN, SVM s různými jádry a PNN) pro automatickou klasifikaci. Autoři v této studii použili 10krát křížovou validační techniku pro trénink a testování klasifikátorů. V této technice byl celý datový soubor (110 094 úderů) sub-vzorkován do deseti sad, z nichž každá měla téměř stejnou distribuci vzorků z každé z tříd. K trénování klasifikátorů bylo použito devět sad (99 085 úderů) a zbývající jedna sada (11 009 úderů) byla použita k testování a hodnocení výkonu klasifikátoru. Proces byl opakován desetkrát, takže každá podmnožina je použita k testování. Celkový výkon klasifikátoru byl hodnocen průměrem desetkrát. Správná klasifikace nebo nesprávná klasifikace byla hodnocena jako skutečně pozitivní (TP), skutečně negativní (TN), falešně pozitivní (FP) a falešně negativní (FN). Na základě těchto opatření byla stanovena sensitivita, specifita, pozitivní prediktivní hodnota (PPV) a přesnost.

Z výsledků bylo patrné, že SVM s funkcí lineárního jádra poskytuje trvale menší přesnost a SVM s RBF jádrem poskytuje nejvyšší citlivost. NN a PNN přinesly téměř stejnou citlivost. Dále je patrné, že SVM s lineárním jádrem poskytuje menší specifitu, PNN poskytuje nejvyšší specifitu. NN také poskytla specifitu blízkou klasifikátoru PNN.

5.4.8 Zpracování signálu fonokardiogramu pomocí empirického modálního rozkladu

Autoři článku [46] zpracovávali signál FKG získaný pomocí stetoskopu, který byl digitalizován analogově-digitálním převaděčem. Na získaném signálu bylo provedeno předzpracování signálu, aby se odstranil možný šum a zkreslení. K rozkladu signálu byl použit přístup, známý jako empirický režim rozkladu (EMD). Po předzpracování byla provedena extrakce funkcí, aby se zachytily nejvýznamnější a rozhodující informace z různých tříd signálů FKG. Mel-kmitočtový cepstrální koeficient (MFCC) a časové prvky byly extrahovány a spojeny, aby lépe reprezentovaly signál. Nakonec byl použit klasifikátor podpory vektorových strojů k rozlišení různých tříd dat FKG. Na výstupech klasifikátorů bylo implementováno jednoduché rozhodovací pravidlo, které generuje konečné výsledky klasifikace s celkovou hlášenou přesností 89 %. V jiné studii autoři použili Hammingův filtr pro redukci šumu v signálech FKG. Pro klasifikaci signálu FKG pak byla použita čtyřvrstvá 1D konvoluční neuronová síť a celková přesnost této metody byla 79 %.

5.4.9 Odhad srdeční frekvence, dýchání a pohybu pomocí interferometru

V tomto článku je autory [47] prováděna metoda odhadu srdeční frekvence, respiračního rytmu a pohybu, pomocí optického interferometru.

Životní funkce člověka, jako je pohyb, dýchání a srdeční rytmus, způsobují po sobě jdoucí časové intervaly, se značně odlišným chováním: po intenzivních změnách délky vlákna, které se v interferometrickém signálu objevují jako segmenty kmitočtů s vyšší frekvencí, jsou následovány segmenty s menší aktivitou a kmity s nižší frekvencí, nebo dokonce bez oscilací. Proto bylo důležité se zaměřit na nulové přechody v interferometrickém signálu.

Měřený optický signál byl nejprve filtrován pomocí třetího řádu dolní propusti Butterworthova filtru s mezní frekvencí 200 Hz. Tento krok byl nezbytný k potlačení vysokofrekvenčního šumu a zejména možných oscilací kolem hodnoty nulové amplitudy. Hustota křížení nuly je vyšší v intervalech s vyšší aktivitou a naopak. Předpoklad, že dva po sobě jdoucí přechody nuly určují jednu kosinovou oscilaci v signálu optického interferometru, je velmi realistický. Každý z těchto kmitů odpovídá konstantní změně délky vlákna. To také znamená, že čím blíže jsou nulové přechody, tím větší je změna vlákna v předem zvoleném časovém intervalu.

Měřený signál je nestacionární. Příspěvky pohybu, dýchání a srdeční činnosti jsou ve smyslu frekvenčního obsahu omezené. Proto lze všechny tyto informace rozložit s pomocí časového rozkladu do dvou fází. V první fázi jsou pohybové události extrahovány jednoduchým dolnoproputním filtrováním. Ve druhé fázi je prováděn pokročilejší přístup pomocí lineární kombinace vln, pro získání dýchacího a srdečního rytmu.

Odhadované lidské vitální signály, extrahované z optického signálu, byly zkontrolovány dalšími senzory. Navrhovaná metodika prokázala uspokojivé výsledky v kontrolovaných podmínkách – při chůzi a stání.

5.4.10 Srovnání signálů BKG, FKG a EKG při aplikaci sledování srdeční frekvence v lidském těle

Cílem článku [48] bylo vyhodnocení a srovnání tří různých signálů ze tří různých senzorů při aplikaci monitorování srdeční frekvence lidského těla. Autoři sestavili dva různé typy senzorů z optických vláken.

První typ senzoru využívá optovláknovou Braggovu mřížku (FBG) a monitorování srdeční frekvence je založeno na principu balistokardiografie. FBG se vyznačuje periodickou změnou indexu lomu v jádru vlákna (n_1 , n_3). Symbol n_2 představuje index lomu opláštění vláken. Jednobodové FBG lze spojit dohromady v postupném pořadí, čímž se získá vícebodový snímač v rámci jednoho optického vlákna. Nejjednodušší metodou rozlišení jednotlivých senzorů je použití multiplexu s dělením vlnových délek.

Druhý typ senzoru využívá interferometr Mach-Zehnder s optickým vláknem s dvojitým vazebním členem (poměr výkonu 1: 1) a monitorování srdeční frekvence je založeno na fonokardiografii. Interferometrie je optická metoda, která dokáže monitorovat fázový rozdíl mezi dvěma optickými paprsky, které procházejí podobnými optickými cestami.

Vyhodnocení signálu z prvních dvou typů senzorů bylo získáno navrženými optickými mřížkovými dotazovači. V případě třetího typu (referenční signál) byl signál srdeční frekvence získán pomocí standardních gelových elektrod a modulů připevněných k hrudi sledované osoby pomocí

monitorovacího systému v reálném čase pro elektrokardiografii s virtuální instrumentací (National Instruments ELVIS II).

Byla provedena ověřovací studie na skupině šesti subjektů (tři muži a tři ženy) v laboratorních podmínkách. Každý z experimentů zahrnoval simultánní záznam senzoru FBG (signál BKG), senzoru interferometru (Signál FKG) a snímač EKG. Na základě detekce vrcholů a výpočtu časových intervalů mezi těmito vrcholy byla stanovena srdeční frekvence. Ověření zahrnovalo více než 4500 srdečních tepů. Celková doba byla 60 minut 49 sekund.

Pro porovnání rozdílů mezi referenčním signálem EKG a signálem ze snímače FBG a interferometrického snímače byla použita metoda Bland-Altmanových grafů. Pro celou sadu dat ze snímače FKG leží 95,07 % hodnot pro stanovení HR v rozsahu 1,96 SD. Pro celou celý soubor dat ze snímače FBG leží 95,06 % hodnot pro stanovení HR v rozsahu 1,96 SD. Jsou-li porovnány výsledky získané Bland-Altmanovou metodou, můžeme konstatovat, že interferometrický senzor v aplikaci monitorování srdečního rytmu lidského těla je přesnější (0,01 %) oproti FBG senzoru.

5.4.11 Adaptivní zpracování signálu fetálního FKG zaznamenaného interferometrickým senzorem

Cílem této práce [21] bylo navrhnutí adaptivního systému pro elicitaci mateřské složky z břišního signálu. Byla použita syntetická data k vyhodnocení kvality filtrace pomocí objektivních metod, kde je potřebný referenční signál. Aby byla zajištěna co nejpřesnější syntetická data, byla provedena měření na netěhotných ženách. Tímto způsobem byla vytvořena fyziologická a patologická data, obě dlouhá 600 s. Hlavním pozitivem využití syntetických dat je, že umožňují získat referenční (ideální) signál fFKG pro objektivní ověření navrženého systému. Tento adaptivní systém pro FKG extrakci se skládá ze dvou interferometických senzorů – IST a ISA. Senzor IST se umístí na mateřský hrudník, zaznamenaný signál je předzpracován a poté použit jako referenční vstup adaptivního systému, protože je považován za zcela mateřský. Senzor ISA je umístěn na mateřské břicho a zaznamenává signál AB (n), je využíván jako primární vstup adaptivního systému. Adaptivní algoritmus (AA) nastavuje koeficienty FIR filtru na základě zpětně šířeného signálu e (n). Výstup filtru y (n) se poté odečte od předzpracovaného signálu od ISA, AB (n), který obsahuje jak fetální (f), tak mateřskou (m) složku. Výstupní signál f (n) odpovídá odhadovanému signálu fFKG. V tomto článku byli testováni dva zástupci adaptivních algoritmů. Algoritmus nejmenších středních čtverců (LMS) jako zástupce adaptace stochastického gradientu a algoritmus rekurzivních nejmenších čtverců (RLS) jako zástupce rekurzivní optimální adaptace. Systém založený na algoritmu RLS významně překonal algoritmus LMS, proto je vhodnější pro potlačení mateřské složky.

5.5 Zhodnocení vybraných metod

Výše uvedené metody zpracování EKG a FKG signálů byly vzájemně porovnány a zhodnoceny. Parametry pro hodnocení byly složitost použití dané metody, její přesnost a také prediktivita. V tabulce 1 jsou tyto metody klasifikovány písmeny N neboli nízká, S neboli střední a V jako vysoká. Nejlepší metody jsou ty, které jsou nejjednodušší na použití, vysoce přesné a s vysokou prediktivitou. Na základě prostudované literatury byly pro tuto práci vybrány tři hodnotící metody. Tyto metody jsou vlnková transformace, empirická modální dekompozice a Hilbertova transformace.

Tabulka 1 Srovnání různých metod pro zpracování signálů.

Metoda	Jednoduchost	Přesnost	Prediktivita
Extrakce EKG pomocí vlnkové transformace a podpory vektorových strojů	V	V	V
Extrakce funkcí EKG pomocí vln Daubechies	S	V	V
Extrakce EKG založená na matematické morfologii	N	S	S
Klasifikace EKG na základě vlnkové transformace a neurální sítě	S	S	V
Extrakce a klasifikace EKG pomocí cepstra koeficientu a neuronových sítí	V	V	V
Automatická extrakce pro klasifikaci signálů EKG	V	S	S
Metoda vzájemné korelace	S	S	S
Algoritmus využívající vlnovou křivku sklonu vektoru	S	V	V
Extrakce vlnového průběhu elektrokardiogramu pomocí vhodného filtru	V	S	S
Extrakce signálu EKG pomocí diskrétní vlnové transformace	V	S	N
Metoda chaosu	N	S	S
Metoda založená na klouzavých průměrech pro detekci komplexů QRS	V	V	V
Systém detekce a klasifikace EKG úderů využívající vlnkovou transformaci	S	V	V
Extrakce signálu pomocí metod vlnkové transformace	V	V	V
Extrakce signálu pomocí empirické modální dekompozice	S	V	V
Extrakce signálu pomocí Hilbertovy transformace	V	S	V

6 Matematický popis vybraných metod

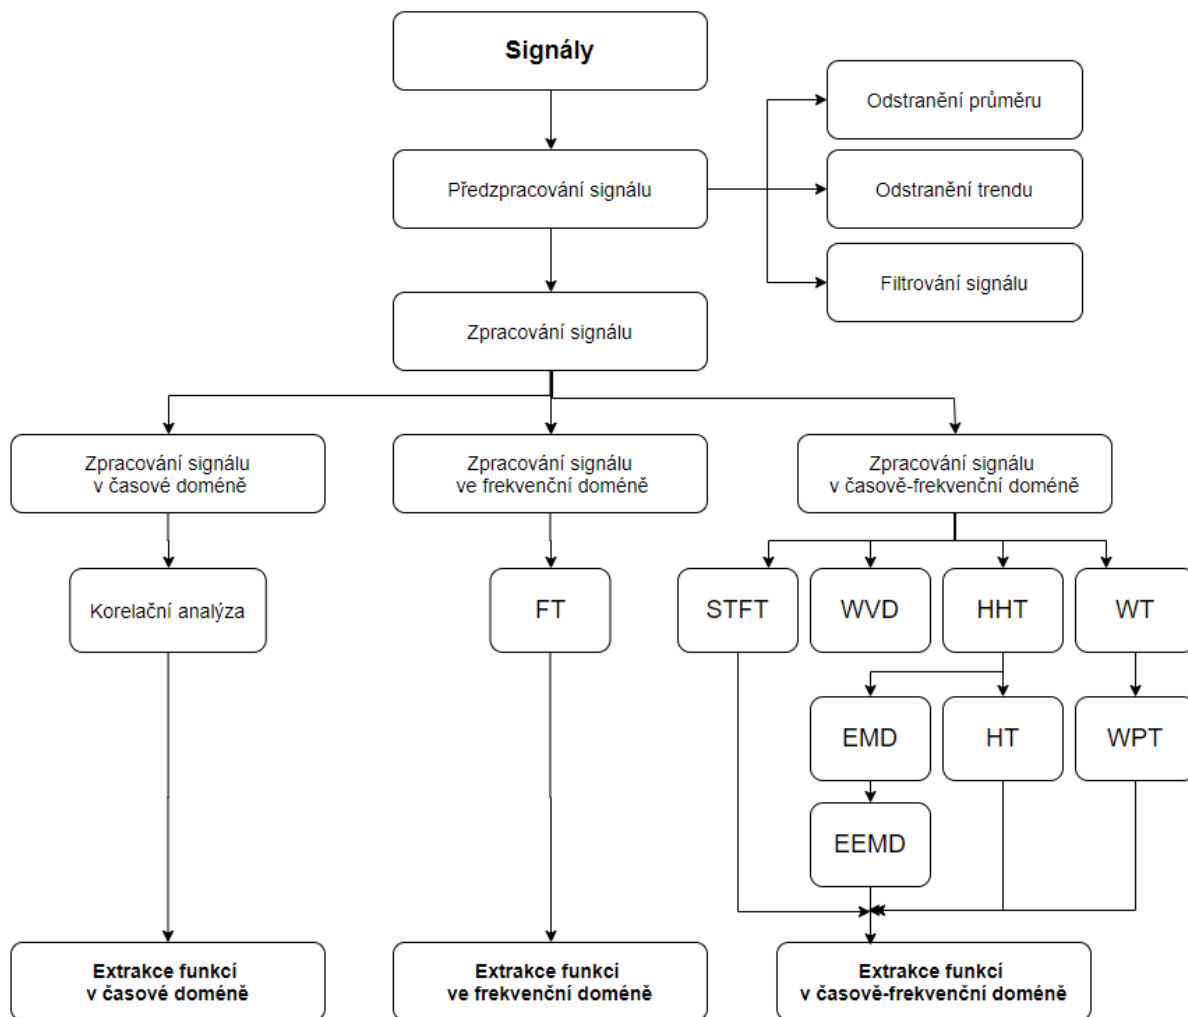
Zpracování signálu má dlouhou a bohatou historii. Doposud bylo vyvinuto a používáno mnoho technik zpracování signálu. Tradiční metody lze rozdělit do tří kategorií: časově doménové, frekvenčně doménové a časově-frekvenčně doménové, jak je znázorněno na obrázku 6.1

Předzpracování signálu se pokouší snížit šum a artefakty v signálu a zlepšit SNR připravující se na následné zpracování, které je vhodné pro všechny kategorie signálů.

Zpracování signálu v časové doméně zahrnuje zejména korelační analýzu a extrakci statistických funkcí v časové oblasti. Autokorelační analýza může zachytit periodické charakteristiky signálu, zatímco analýza vzájemné korelace může měřit stupeň relevance mezi dvěma různými signály. Kromě toho lze statistické vlastnosti v časové doméně extrahovat, aby odrážely statistické vlastnosti signálu z jeho křivky v časové doméně.

Zpracování signálu ve frekvenční doméně obecně označuje Fourierovu transformaci (FT), založenou na Fourierově řadě a později rychlou Fourierovu transformaci (FFT). Jejich základními funkcemi jsou sada trigonometrických funkcí. Technika FT je tedy omezena na zpracování stacionárních signálů. Předpokládáme-li, že signál je v dostatečně krátkém čase stacionární, lze extrahovat některé vlastnosti ve frekvenční oblasti, aby odrážely statistické vlastnosti ve frekvenční oblasti od frekvenčních nebo výkonových spekter signálu. V praxi nelze nestacionární signál úplně popsat pouze v časové doméně nebo frekvenční doméně. Aby se odráželo distribuce nestacionárního signálu z časové domény i frekvenční domény, byly rychle vyvinuty techniky zpracování signálu v časově-frekvenční doméně. Existuje spousta reprezentativních technik, jako je krátkodobá Fourierova transformace (STFT), Wigner-Villeova distribuce (WVD), waveletová transformace (WT), waveletová paketová transformace (WPT) a dokonce Hilbert-Huangova transformace (HHT). Tyto techniky jsou široce používány pro diagnostiku mechanických poruch. Protože různé techniky zpracování signálu charakterizují odlišný výkon, je důležité, aby se zvolila vhodná technika zpracování signálu, k získání užitečných informací [49].

Na základně prostudované literatury a zpracované rešerše se jako nejvhodnější hodnotící metoda jevila vlnková transformace. Právě proto byla použita jako jedna z hodnotících metod. Další metody, které se jevily jako vhodné a jsou pro testování použité, jsou empirická modální dekompozice a Hilbertova transformace. Tyto metody jsou popsány v nadcházejících podkapitolách. Z rešerše vyplývá, že další vhodná testovací metoda by mohla být použita i ICA. Tato metoda se ovšem používá pro hodnocení vícekanálových signálů, a tudíž pro tuto práci a hodnocení jednodokanálového FKG použita být nemohla.



Obrázek 6.1 Diagram zpracování signálu a časové, frekvenční a časově-frekvenční oblasti

6.1 Filtrování signálu

Filtrování signálu má za úkol eliminovat rušení šumu a odstranit nežádoucí signály frekvenčního pásma, čímž si vyhrazuje další užitečné informace. Systémy implementující filtrování signálu se nazývají filtry. Podle různých charakteristik amplitudy a frekvence jsou filtry běžně rozděleny do čtyř kategorií: dolnoproustné, hornoproustné fitry, pásmové propusti a pásmové zádrže. Podle vlastností zpracovávaných signálů lze filtry také rozdělit na analogové a digitální. U digitálních filtrů se dále dělí na filtry s nekonečnou impulzní odezvou (IIR) a filtry s konečnou impulzní odezvou (FIR).

Funkce přenosu filtru IIR je:

$$H(z) = \frac{\sum_{r=0}^m b_r z^{-r}}{1 + \sum_{k=1}^N a_k z^{-k}} \quad (4)$$

kde $z = e^{j\omega\Delta t}$, $a_k (1, 2, \dots, N)$ a $b_r (r = 0, 1, 2, \dots, M)$ jsou koeficienty jmenovatele polynomu a čitatele jedna.

Funkce přenosu filtru FIR je:

$$H(z) = \sum_{n=0}^{N-1} h(n)z^{-n}, \quad (5)$$

kde $h(n)$ ($n = 0, 1, 2, \dots, N - 1$) je jednotka impulzní odezvy digitálního filtru.

Mezi digitálními filtry IIR a digitálními filtry FIR existují velké mezery mezi výkonem a designem. Digitální filtry FIR lze přímo navrhnout podle specifické amplitudově-frekvenční charakteristiky. Metody návrhu digitálních filtrů FIR jsou postaveny na aproximaci ideálních filtrů. Použité přibližné metody obsahují metody okenních funkcí, metody vzorkování frekvence atd. Výkon filtrů velice úzce souvisí s jejich konstrukcí. Kromě toho by měl být filtrovaný signál dále zpracováván, aby se získaly žádoucí informace, například při zpracování signálu v časové doméně [49].

Hlavní výhodou digitálních filtrů IIR oproti filtrům FIR je jejich účinnost při implementaci, aby splňovaly specifikaci, pokud jde o propustné pásmo, stopové pásmo nebo například zvlnění. Takovou sadu specifikací lze dosáhnout filtrem IIR nižšího řádu, než by byl vyžadován pro filtr FIR splňující stejné požadavky. Pokud je implementován v signálním procesoru, znamená to odpovídajícím způsobem menší počet výpočtů za časový krok; výpočetní úspory jsou často poměrně velkým faktorem. Na druhou stranu lze filtry FIR snadněji navrhnout, například tak, aby odpovídaly konkrétním požadavkům na frekvenční odezvu. To platí zejména v případě, že požadavek není jedním z obvyklých případů (horní propust, dolní propust atd.), které byly studovány a optimalizovány pro analogové filtry. Rovněž lze snadno vyrobit filtry FIR jako lineární fázi (konstantní zpoždění skupiny vs. frekvence) - vlastnost, kterou nelze snadno splnit pomocí filtrů IIR a pouze jako aproximace (například s Besselovým filtrem). Dalším problémem týkajícím se digitálních filtrů IIR je potenciál chování mezních cyklů při nečinnosti v důsledku zpětnovazebního systému ve spojení s kvantizací.

Výhodou filtrů IIR oproti filtrům FIR je, že filtry IIR obvykle vyžadují méně koeficientů k provádění podobných operací filtrování, že filtry IIR fungují rychleji a vyžadují méně místa v paměti.

Nevýhodou filtrů IIR je nelineární fázová odezva. Filtry IIR jsou vhodné pro aplikace, které nevyžadují žádné fázové informace, například pro monitorování amplitud signálu. Filtry FIR se lépe hodí pro aplikace, které vyžadují lineární fázovou odezvu [50].

6.2 Vlnková transformace

Vlnková transformace je podobná Fourierově se zcela odlišnou zásluhovou funkcí. Hlavním rozdílem je, že Fourierova transformace rozkládá signál na sinusy a kosiny, tj. funkce lokalizované ve Fourierově prostoru; na rozdíl od toho vlnková transformace využívá funkce, které poskytují informace v časové a frekvenční oblasti, a proto je vhodná pro nestacionární signály.


Obecně lze vlnkovou transformaci vyjádřit následující rovnicí:

$$F(a, b) = \int_{-\infty}^{\infty} f(x)\psi_{(a,b)}^*(x)dx, \quad (6)$$

kde * je komplexní konjugovaný symbol,
funkce ψ je libovolná funkce.

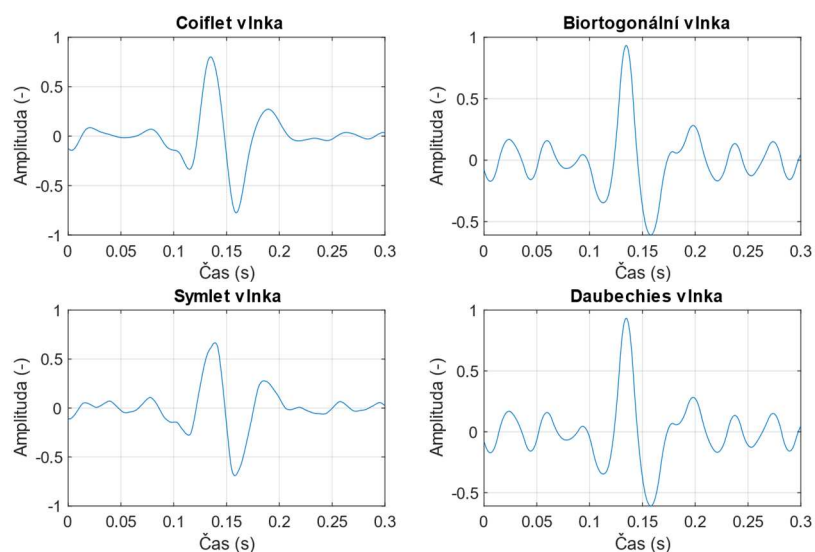
Existuje mnoho způsobů, jak třídit typy vlnkových transformací. Zde je zobrazeno pouze dělení založené na vlnkové ortogonalitě. Běžně se používají ortogonální vlnky pro vývoj diskrétních vlnkových transformací a neortogonální vlnky pro vývoj kontinuálních vlnkových transformací. Tyto dvě transformace mají následující vlastnosti:

1. Diskrétní vlnková transformace vrací datový vektor stejné délky jako je vstup. Obvykle i v tomto vektoru je mnoho dat téměř nulových. To odpovídá skutečnosti, že se rozkládá na sadu vlnek (funkcí), které jsou kolmé na jeho překrytí a změnu měřítka. Diskrétní vlnková transformace rozkládá signál na aproximační koeficienty cA (konvoluce posloupnosti s dolnopropustným filtrem) a detailní koeficienty cD (konvoluce posloupnosti s hornopropustným filtrem). Tento rozklad je zobrazen na obrázku 6.2.
2. Kontinuální vlnková transformace naopak vrací pole o jednu dimenzi větší než vstupní data. Pro 1D data je získán obraz roviny čas-frekvence. Lze snadno sledovat vývoj frekvencí signálů během trvání signálu a porovnat spektrum s jinými spektry signálů. Jelikož se zde používá neortogonální sada vln, jsou data vysoce korelována, takže je zde velká redundance [49].




Obrázek 6.2 Schéma rozkladu signálu na aproximační a detailní koeficienty DWT.

Pro zvolení typu vlnky neexistuje žádný univerzální způsob a volba vlnky závisí na signálu, který má být zpracováván. Na základě prostudované literatury, pro signál FKG nejlépe vychází vlnky Symlet, Coiflet a Daubechies. Na obrázku 6.3. jsou zobrazeny základní typy vlnek.



Obrázek 6.3 Přehled základních vlnek.

Na obrázku 6.4 je zobrazen FKG signál male 3, na který je aplikovaná vlnka coif5 s úrovní rozkladu 6.



Obrázek 6.4 Ukázka původního signálu, předzpracovaného a rozloženého pomocí WT.

6.3 Empirická modální dekompozice

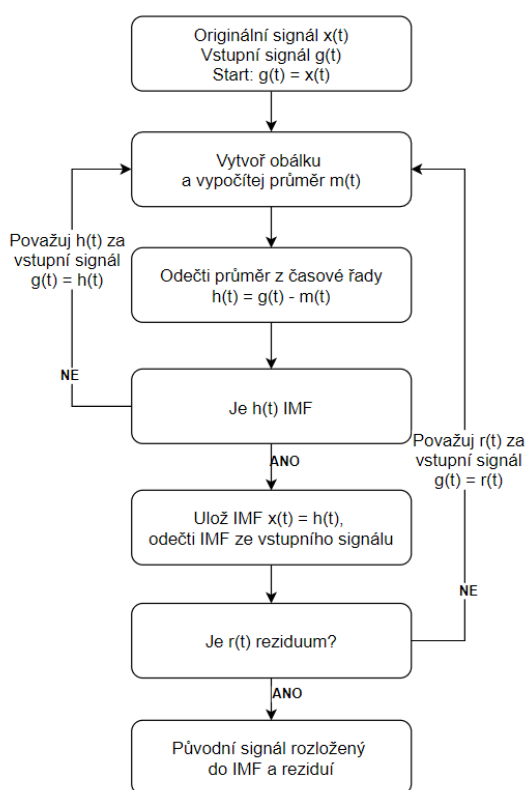
Metoda EMD byla vyvinuta za předpokladu, že jakákoli nestacionární a nelineární časová řada sestává z různých jednoduchých vnitřních režimů oscilace. Podstatou metody je empiricky identifikovat tyto vlastní oscilační režimy podle jejich charakteristických časových měřítek v datech a poté podle nich data rozložit. Prostřednictvím procesu zvaného prosévání lze eliminovat většinu jezdeckých vln, tj. oscilace bez přechodu nuly mezi extrémy. Algoritmus EMD tedy uvažuje oscilace signálu na velmi lokální úrovni a rozděluje data na lokálně nepřekrývající se komponenty časového měřítka. Rozkládá signál $x(t)$ na své komponenty IMF, které splňují dvě vlastnosti:

1. Mezinárodní měnový fond má mezi dvěma následujícími přechody nuly pouze jedno extrém, tj. Počet místních minim a maxim se liší maximálně o jeden.
2. IMF má střední hodnotu nula.

Druhá podmínka znamená, že IMF je nehybný, což zjednodušuje jeho analýzu. Ale IMF může mít amplitudovou modulaci a také měnit se frekvenci [49].

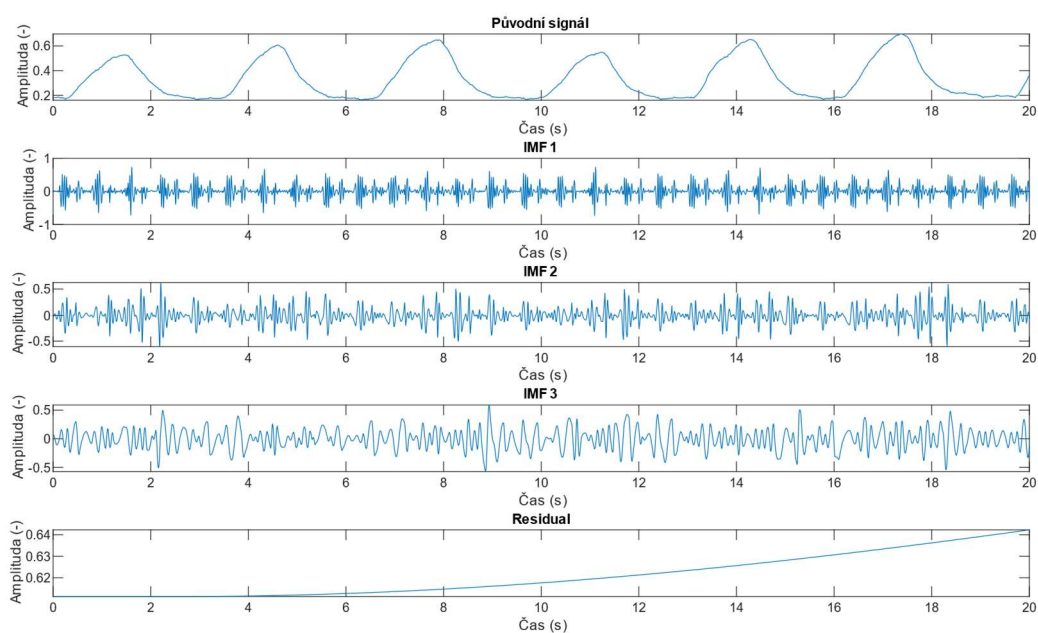
Algoritmus EMD: Proces prosévání lze shrnout do následujícího algoritmu. Rozloží datovou sadu $x(t)$ na IMF $x_n(t)$ a reziduum $r(t)$ tak, aby mohl být signál reprezentován jako:

$$x(t) = \sum_n x_n(t) + r(t). \tag{7}$$



Obrázek 6.5 Vývojový diagram EMD algoritmu.

Průměrnou periodu každého IMF lze vypočítat vydělením dvojnásobku velikosti vzorku $2 * N$ počtem přechodů nulou. Počet IMF extrahovaných z časové řady se zhruba rovná $\log_2 N$. Obrázek 6.4. ukazuje výsledek EMD analýzy nestacionárního signálu skládající se ze superpozice signálu pilovitého zubu, sinusoidy a lineárního trendu. Proces prosévání odděluje nestacionární data časových řad do původních místně nepřekrývajících se funkcí vnitřního režimu (IMF). EMD však není technikou filtrování dílčích pásem s předdefinovanými křivkami, jako jsou vlnky. Spíše výběr režimů odpovídá automatickému a adaptivnímu filtrování časových variant. Aplikovanou metodu na zpracovávaných datech lze vidět na obrázku 6.6.



Obrázek 6.6 Ukázka rozkladu metodou EMD původního signálu na IMF1, IMF2, IMF3 a zbytkovou vlnu.

Úplnost procesu rozkladu je automaticky dosažena algoritmem $x(t) = \sum_{n=1}^i x_n + r$, který reprezentuje identitu. Algoritmus EMD dále produkuje lokálně ortogonální IMF. Globální ortogonalita není zaručena, protože sousední IMF mohou mít v různých časových bodech stejné frekvence (obvykle v < 1 % případů) [49].

6.4 Hilbertova transformace

Hilbertova transformace je nepostradatelnou součástí Hilbert-Huangovy transformace. Obecně je HT pro daný signál $x(t)$ definována jako:

$$\hat{x}(t) = H[x(t)] = \frac{\int_{-\infty}^{\infty} \frac{x(\tau)}{t-\tau} d\tau}{\pi} = x(t) * \frac{1}{\pi t}, \quad (8)$$

kde symbol $*$ označuje konvoluční operaci.

Podle HT lze analytický signál definovat jako:

$$z(t) = x(t) + j\hat{x}(t) = a(t) \exp[j\theta(t)]. \quad (9)$$

Kde $j = \sqrt{-1}$,

$a(t) = \sqrt{x^2 + \hat{x}^2}$,

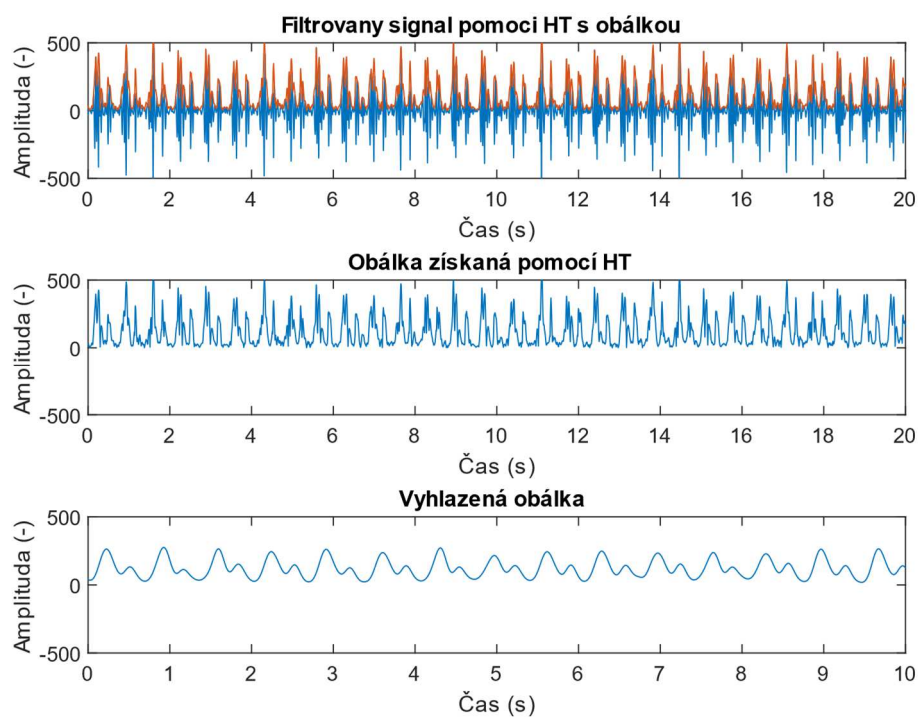
$\theta(t) = \arctan\left(\frac{\hat{x}}{x}\right)$. Zde je $a(t)$ okamžitá amplituda a θ je okamžitá fáze. Okamžitá frekvence

je jednoduše definována $\omega = \frac{d\theta}{dt}$.

Pak lze Hilbertovo obálkové spektrum zadat následovně:

$$h(f) = \int_{-\infty}^{\infty} \sqrt{x^2(t) + \hat{x}^2(t)} \exp(-j2\pi ft) dt \quad (10)$$

HT je také široce používána v demodulaci signálu. Když se vyskytnou mechanické poruchy, shromážděné vibrační signály jsou obecně modulovány. Proto je demodulace signálu schopna oddělit nosnou složku a modulační složku. Na obrázku 6.7 je zobrazena aplikace HT [51].



Obrázek 6.7 Ukázka Hilbertovy transformace.

7 Experimentální část

Cílem této diplomové práce bylo vytvořit SW aplikaci, která bude schopna zpracovat, analyzovat a vyhodnotit tepovou frekvenci z interferometrického senzoru, který je podrobně popsán v kapitole 4.1.2 Vlastní senzor pro měření.

Součástí práce je také testování metod na reálných datech, jejich hodnocení a statistické porovnání jednotlivých metod. Výsledky byly hodnoceny jak formou vizuálních průběhů pro jednotlivé signály, tak i vykreslením variability srdeční frekvence a Bland-Altmanova grafu s aplikovaných klouzavým průměrem a výpočtem statistických parametrů.

Postup práce byl proveden předzpracováním naměřeného signálu, za účelem odstranění artefaktů signálu, jako jsou například dýchání, hýbání subjektu, kašlání a podobně. Následně na tuto filtraci byly implementovány další hodnotící metody. Tyto metody jsou:

- vlnková transformace,
- empirická modální dekompozice,
- Hilbertova transformace.

Výsledné grafy jsou zobrazeny v normovaných jednotkách, které představují bezrozměrnou veličinu, která je rovna poměru filtrovaného signálu a absolutní hodnoty velikosti tohoto signálu.

Tato část práce byla provedena formou vytvoření grafického uživatelského prostředí v aplikaci Matlab. Toto prostředí umožňuje načíst signál, načíst referenční anotace, zpracovat signál pomocí výše uvedených metod, vykreslení spektra a spektrogramu, detekci jednotlivých S1 peaků u každé metody, jejich statistický výpočet a vykreslení Bland-Altmanových grafů a srdeční variability. Součástí práce je i druhé uživatelské prostředí, které slouží ke kontrole a případné úpravě referenčních anotací odhadnutých pomocí R detektoru z kontinuálně naměřených EKG signálů k naměřeným signálům pomocí interferometru. Toto prostředí vzniklo za účelem kontroly, zda použitý R detektor v určitém místě neudělal chybu, jelikož pro verifikaci výsledků jsou důležité co nejobjektivnější reference.


Pro zjištění jednotlivých S1 peaků u FKG signálu byl použit detektor, který v signále nachází lokální minima a maxima, která překračují stanovený práh. Po detektor je nastavený limit, ve kterém hledá lokální minima a maxima, která jsou poté porovnána a je v nich detekován S1 peak. Pro tuto práci bylo otestováno více druhů detektorů, jako například Pan-Tompkin, vlastní detektor u HT a podobně, ale s aktuálně použitým S1 detektorem bylo docíleno nejlepších výsledků.

7.1 Data pro testování

Pro testování metod bylo k dispozici celkem 11 záznamů, z toho 6 záznamů dlouhých 10 minut od mužského subjektu a 5 záznamů dlouhých 10 minut od ženského subjektu. Tyto FKG záznamy byly naměřeny pomocí optovlákonového interferometru, který je podrobně popsán v kapitole 4.1.2 Vlastní senzor pro měření.


Původní vzorkovací frekvence byla 100 kHz, pro potřeby této diplomové práce byla data převzorkovaná na frekvenci 5kHz, což je pro zpracování FKG signálů více než dostačující, za účelem stanovení tepové frekvence. Ke každému signálu byly také naměřeny referenční EKG signály. Ke každému signálu byly také naměřeny referenční EKG signály. Signály byly naměřeny a poskytnuty odbornou skupinou na katedře telekomunikační techniky, která je součástí fakulty elektrotechniky a informatiky na Vysoké škole báňské – Technické univerzitě v Ostravě. V původním plánu bylo realizovat naměření dat na více subjektech, včetně mé osoby, ale vzhledem k epidemiologickým důvodům to nebylo možné.

Na obrázku 7.1 je zobrazena ukázka 10 s záznamu původních dat bez předzpracování.



Obrázek 7.1 Ukázka původních dat.

Na obrázku 7.2 je zobrazený posun EKG, který je v této práci použit jako referenční signál, vůči naměřenému signálu FKG. Z toho důvodu bylo potřeba EKG signál s anotacemi upravit posunutím, u mužských signálů o 700 vzorků a u ženských o 950.



Obrázek 7.2 EKG vs. FKG.

7.2 Statistické vyhodnocení

Ke statistickému vyhodnocení přesnosti odhadnutí tepové frekvence vůči té referenční odhadnuté a vykreslené z referenčních anotací byl použit Bland-Altmanův graf. V této diplomové práci je použit pro statistické vyhodnocení přesnosti detekovaných S1 peaků aplikovanými metodami, vůči referenčních R kmitů z anotací.

Jako další statistické hodnocení lze určit stanovený počet skutečně pozitivních hodnot (TP), což znamená správnou detekci. Interval pro správnou detekci TP se u signálu EKG používá ± 50 ms u FKG signálu je tato hodnota přibližně ± 100 ms. Tento interval byl použit na základě této studie [52]. Stanovený počet falešně pozitivních hodnot (FP), což znamená, že byl detekován S1 peak, který se ale v signálu reálně nenachází. Dále stanovený počet falešně negativních hodnot (FN), což znamená, že nebyl v signálu detekován S1 peak, který se ale reálně v signálu vyskytuje. Dále je vypsán celkový počet n-peaků, které se v anotaci objevují a značí počet tepů v daném záznamu.

Také jsou určeny parametry ACC, neboli vypočítaný parametr přesnosti v procentech, parametr SE, vypočítaný parametr senzitivity v procentech, parametr PPV, což znamená vypočítaný parametr pozitivních prediktivních hodnot v procentech a parametr F1, který představuje harmonický průměr mezi senzitivitou a pozitivní prediktivní hodnotou v procentech. Jako primární se hodnotí výsledek parametru ACC, neboť ostatní parametry nemohou dosáhnout menší hodnoty, než je právě hodnota tohoto parametru. Jako úspěšnou poté považována metoda, pro kterou dosáhne parametr ACC hodnotu větší než 95 %.

$$ACC = \frac{TP}{TP+FP+FN} \cdot 100, \quad (11)$$

$$SE = \frac{TP}{TP+FN} \cdot 100, \quad (12)$$

$$PPV = \frac{TP}{TP + FP} \cdot 100, \quad (13)$$

$$F1 = 2 \cdot \frac{PPV \cdot Se}{PPV+Se} = \frac{2 \cdot TP}{2 \cdot TP+FP+FN} \cdot 100. \quad (14)$$

Další část testování byla provedena pomocí Bland-Altmanových grafů, kde se porovnávaly odhadnuté HR křivky a referenční HR křivky. Pro výpočty Bland-Altmanových grafů byl na jednotlivé signály aplikován klouzavý průměr s oknem 20. Osy X představují průměr mezi hodnotami HR odhadnutými pomocí testovacích metod a hodnot HR referenčních, které jsou zanesené do vektoru \vec{M} . Na osách Y jsou poté zobrazeny rozdíly mezi hodnotami křivek HR odhadnutých a křivek HR referenčních, zanesené do vektoru \vec{D} . Tyto prvky následně jsou vyneseny do jednotlivých Bland-Altmanových grafů. Hlavní součástí těchto grafů je výpočet střední hodnoty μ , která je v grafu znázorněna tlustou rovnou čarou. Po určení střední hodnoty a vypočtení směrodatné odchylky σ jsou stanoveny dva limity shody pomocí $\mu \pm 1,96\sigma$. Toto standardizované normální rozdělení je založeno na bodě $\mu \pm 1,96\sigma$ označující 97,5 % kvantil normálního rozdělení. Tyto limity jsou v grafu znázorněny pomocí dvou tenkých čar. Tyto výpočty jsou provedeny pomocí rovnic:

$$P\left(-1,96 < \frac{\vec{D}-\mu}{\sigma} < 1,96\right) = 0,95, \quad (15)$$

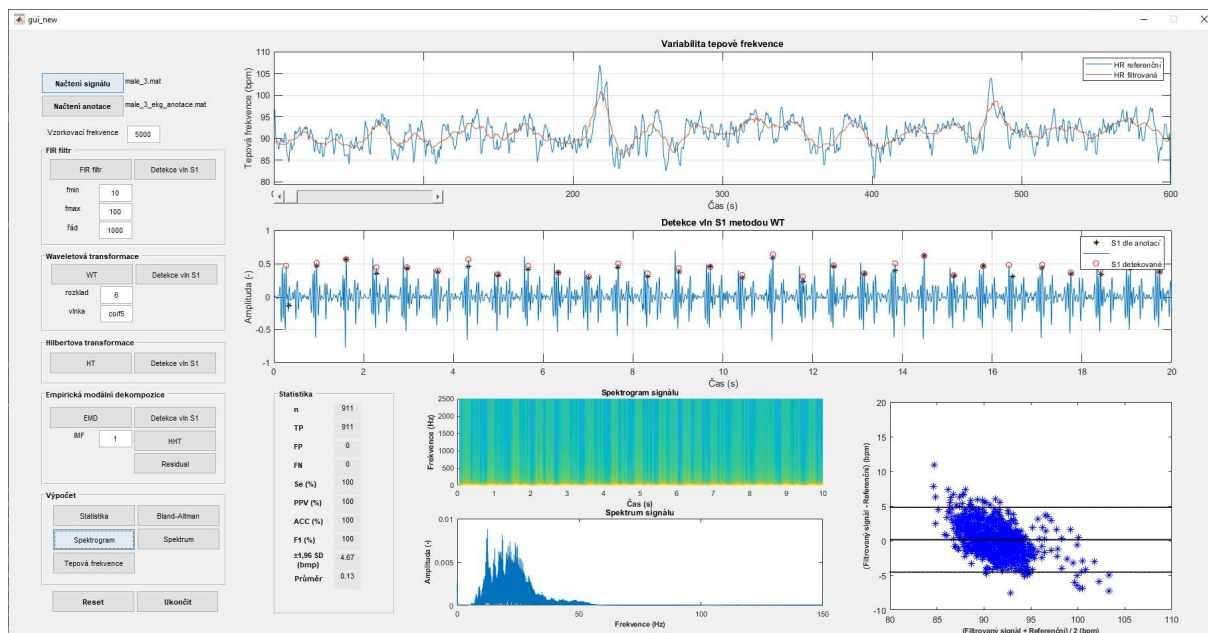
$$P(\mu - 1,96\sigma < \vec{D} < \mu + 1,96\sigma) = 0,95, \quad (16)$$

$$\mu = \frac{\sum_{i=1}^n D_i}{n}, \quad (17)$$

$$96\sigma = 1,96 \cdot \sqrt{\frac{\sum_{i=1}^n (D_i-\mu)^2}{n-1}}. \quad (18)$$

7.3 Grafické uživatelské rozhraní

Hlavním bodem praktické části byla realizace grafického uživatelského rozhraní (GUI) v aplikaci Matlab. Toto rozhraní je možné vidět na obrázku 7.3, na kterém je ukázka WT na záznamu Male 3.



Obrázek 7.3 Grafické uživatelské rozhraní pro testování jednotlivých metod.

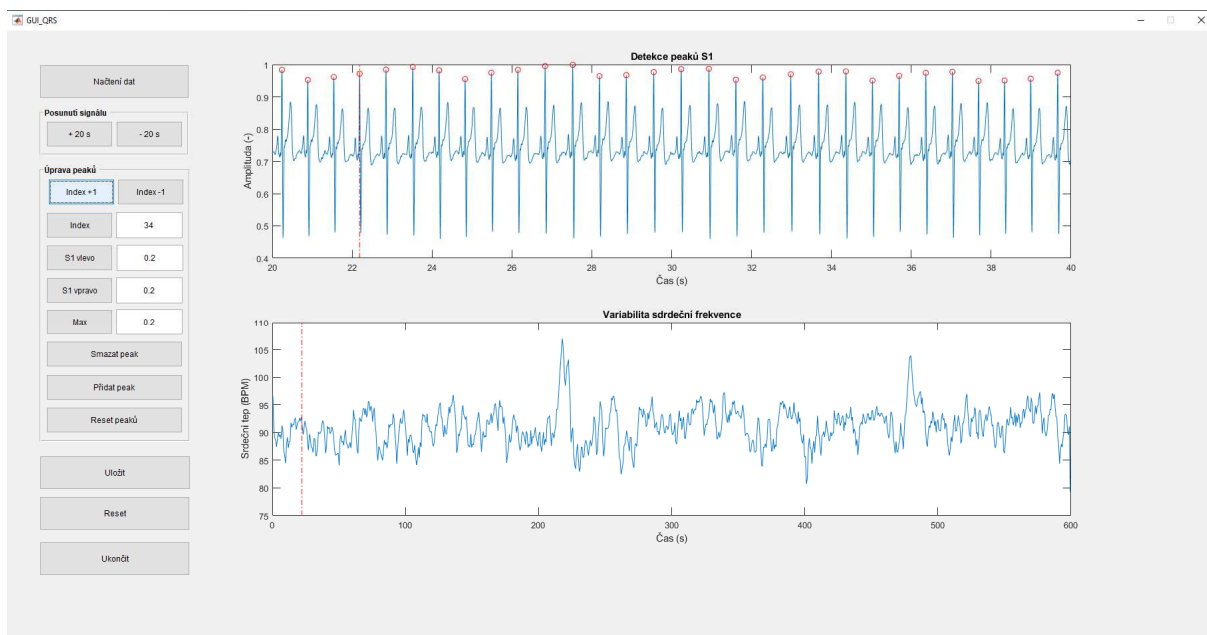
Toto GUI umožňuje předzpracovat signál pomocí FIR filtrace a na tuto filtraci aplikovat další testovací metody. Jednou z metod je vlnková transformace, u které lze nastavit typ vlnky a rozkladu, kde defaultně je nastavena vlnka *coif5* a rozklad 6. Dále empirická modální dekompozice, u které lze nastavit vykreslení jednotlivých IMF, defaultně se vykresluje IMF 1. Třetí metodou je Hilbertova transformace. Po stisknutí tlačítka s konkrétním názvem metody dojde k aplikování metody na předzpracovaný signál a její následné vykreslení. Po kliknutí na tlačítko *Detekce vln S1* dojde na právě načteném signálu k detekci S1 peaků a jejich porovnání s referenčními peaky z načtených anotací. Kromě vykreslování signálu GUI obsahuje tlačítko, které slouží ke statistickému vyhodnocení. Po stisknutí tlačítka *Bland-Altman* se vykreslí Bland-Altmanův graf a vypočte se $\pm 1,96$ směrodatná odchylka a průměr. Po stisknutí tlačítka *Statistika* se provede výpočet dalších parametrů, které se nachází v bloku *Statistika*, viz obrázek 7.4. Pomocí tlačítka *Tepová frekvence*, se vykreslí tepová frekvence dle anotací a dle výsledků z aktuálně použité metody. Dále je možné v GUI vykreslit frekvenční spektrum a spektrogram.

Statistika	
n	911
TP	911
FP	0
FN	0
Se (%)	100
PPV (%)	100
ACC (%)	100
F1 (%)	100
±1,96 SD (bmp)	7.08
Průměr	0.13

Obrázek 7.4 Blok s vypočtenou statistikou pro jednotlivé parametry.

Pokud uživatel nenačte žádný signál a zkusí provést libovolnou metodu, zobrazí se varovná hláška upozorňující uživatele na to, aby prvně načel signál. Další tlačítko je *Ukončit*, které slouží k vypnutí celého programu a tlačítko *Reset*, které slouží k obnovení celého GUI do výchozí podoby.

Součástí experimentální práce bylo vytvoření i dalšího GUI, které slouží k upravení referenčních anotací, viz obrázek 7.5. R kmity na těchto EKG signálech byly ve většině případů pomocí R detektoru detekovány dobře a toto GUI bylo použito jen jako ověření, že je možné opravdu objektivně verifikovat úspěšnost testovaných metod. Toto prostředí umožňuje načíst signál a pomocí detektoru vykreslit jednotlivé R vlny. Dále umožňuje jednotlivé peaky zkontrolovat, zda použitý R detektor neudělal chybu a popřípadě peak upravit, přidat nebo odebrat. Také možnost posun o peak doleva i doprava, případně posun v časové ose. Výsledné peaky lze uložit a použít pro další zpracování v hlavním uživatelském prostředí.

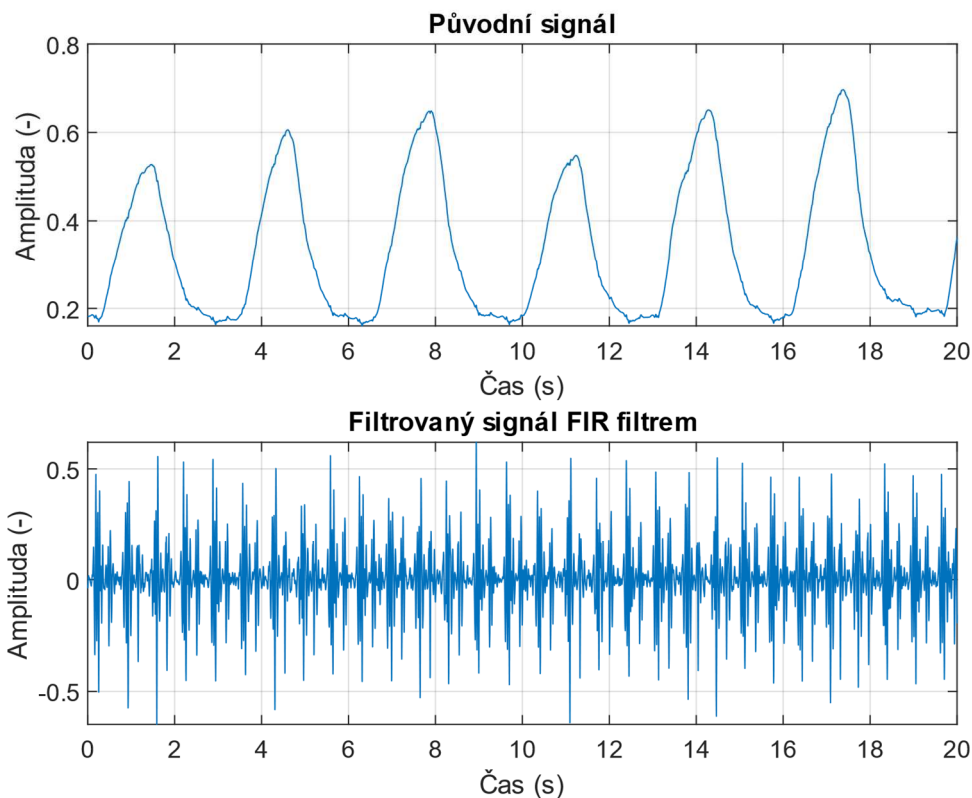


Obrázek 7.5 GUI, které slouží ke kontrole a případné úpravě referenčních anotací

V tomto GUI je možné pomocí tlačítka *Načtení dat* načíst signál a předem detekované referenční anotace. Po načtení signálu se vykreslí jednotlivé grafy, první slouží pro detekci R kmitů a druhý zobrazuje variabilitu srdeční frekvence. V rámci toho GUI je možné se pomocí tlačítek *Index +1* a *Index -1* posouvat po jednotlivých R kmitěch směrem dopředu a dozadu. Pomocí tlačítek *+20 s* a *-20 s* je možné měnit časové okno o 20 sekund směrem doprava a doleva. Pomocí tlačítek *S1 vlevo* a *S1 vpravo* je možné peak posunout o daný časový úsek, defaultní hodnota je zde nastavena na 0,2 s. Po stisknutí tlačítka *Max* dojde ke skoku na maximální peak, který se v oblasti nachází. Tlačítko *Smazat peak* slouží pro odstranění peaku a tlačítko *Přidat peak* slouží naopak k jeho přidání tam, kde se zrovna nacházíme. *Reset peaků* poté znamená smazání peaků upravených uživatelem do původních hodnot načteného souboru anotací. Výsledné upravené anotace je možné uložit do souboru pomocí tlačítka *Uložit*. Tlačítko *Reset* představuje smazání načteného signálu a nastavení GUI do defaultní podoby a tlačítko *Ukončit* zavře celý program. Pokud uživatel nevybere na začátku žádný signál, objeví se varovná hláška, která uživatele upozorní na to, že by měl signál načíst. Stejně tak je uživatel upozorněn, pokud se snaží nastavit mínusový index peaku, který začíná na hodnotě 1 nebo přejít mimo časovou osu.

7.4 Předzpracování signálu

Aby bylo možné s naměřeným signálem pracovat, je nezbytné ho nejprve upravit. Toto předzpracování bylo provedeno pomocí FIR filtru typu pásmová propust s nastavením dolní propustí 10 Hz a horní propustí 100 Hz a řádem filtru 1000. Signál zpracovaný pomocí FIR filtru je znázorněn na obrázku 7.6.



Obrázek 7.6 Původní signál a filtrovaný signál pomocí FIR filtru pro záznam male_3.


7.5 Vlnková transformace

V této metodě je na předzpracovaný signál aplikovaná vlnková transformace. Pro tuto metodu byly testovány různé vlnky a jejich parametry a jako nejvhodnější se ukázala kombinace vlnky typu `coif5` s úrovní rozkladu 6.

Tabulka 2 Výpočet statistických parametrů pro WT pro všechny záznamy.

Záznamy	TP	FP	FN	n	ACC (%)	SE (%)	PPV (%)	F1 (%)
Female 1	617	207	169	786	62,13	78,5	74,88	76,65
Female 2	686	83	60	746	82,75	91,96	89,21	90,56
Female 3	686	7	3	689	98,56	99,56	98,99	99,27
Female 4	698	21	14	712	95,23	98,03	97,08	97,55
Female 5	759	10	8	767	97,68	98,96	98,7	98,83
Male 1	801	37	36	837	91,65	95,7	95,58	95,64
Male 2	866	3	3	869	99,31	99,65	99,65	99,65
Male 3	911	0	0	911	100	100	100	100
Male 4	949	1	0	949	99,89	100	99,89	99,94
Male 5	998	0	1	999	99,9	99,9	100	99,95
Male 6	978	1	0	978	99,9	100	99,9	99,95

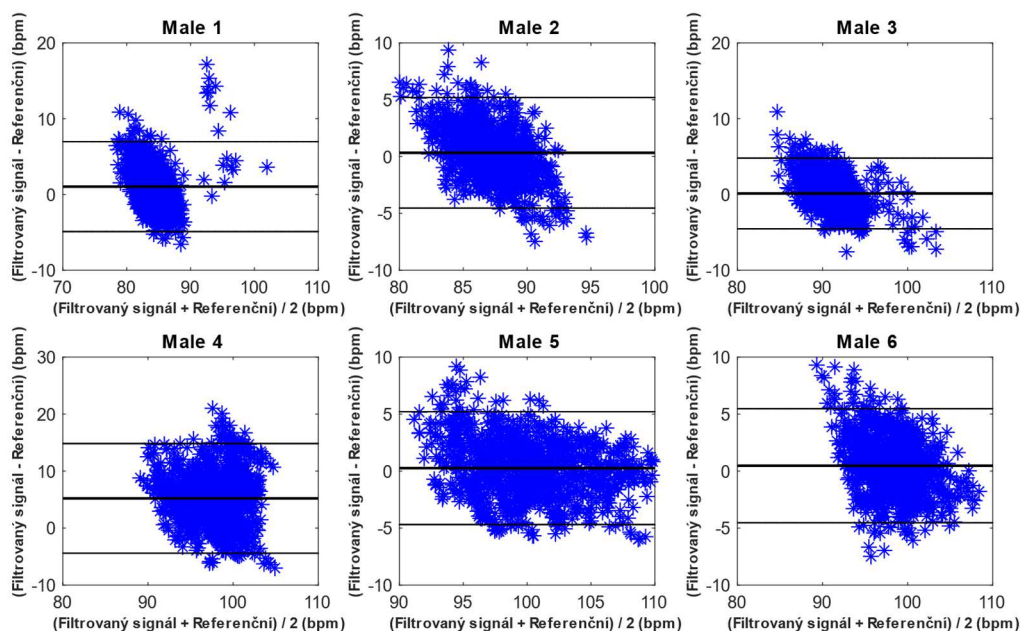
Z výsledků je patrné, že pro signál Female 1 tato metoda nelze považovat za úspěšnou. U signálu Female 2 sice dosáhl parametr ACC hodnoty 82,75 %, stále ovšem metodu nemůžeme považovat za úspěšnou, neboť minimální požadovaná hodnota úspěšnosti je 95 %. Pokud se u toho signálu podíváme na parametr n, můžeme vidět, že dle referenčních anotací tento signál obsahuje 746 peaků neboli počet tepů v záznamu. Parametry FP a FN zde poté ukazují že celkem 143 těchto peaků bylo chybně detekováno. Toto platí i pro další ženské záznamy a pokud tyto porovnáme s těmi mužskými, tak vidíme, že ty mužské dopadly poměrně daleko lépe. U zbývajících signálů tato metoda byla úspěšnější, mimo jiné dosáhla statistické přesnosti 100 % u signálu Male 3. Pokud budeme brát v potaz jenom mužské signály, tak tato metoda hodnocení signálu byla úspěšná.



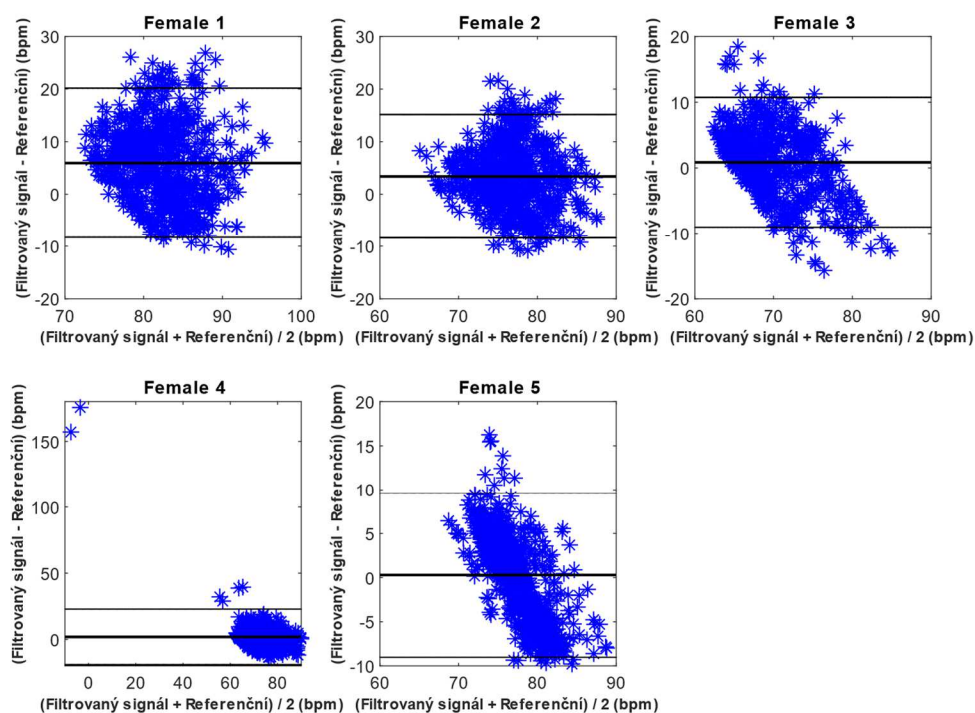
Obrázek 7.7 Signály zpracované pomocí vlnkové transformace pro záznam male_3.

Další část testování byla provedena pomocí Bland-Altmanových grafů, kde se porovnávaly odhadnuté HR křivky a referenční HR křivky. Sestrojení těchto grafů proběhlo stejným způsobem, který je důkladně popsán v kapitole Statistické vyhodnocení.

Na obrázku 7.8 jsou zobrazeny Bland-Altmanovy grafy pro všechny mužské signály. Grafy pro ženské signály jsou poté zobrazeny na obrázku 7.9.



Obrázek 7.8 Blant-Altmanovy grafy pro signály Male 1 až 6.



Obrázek 7.9 Blant-Altmanovy grafy pro signály Female 1 až 5.

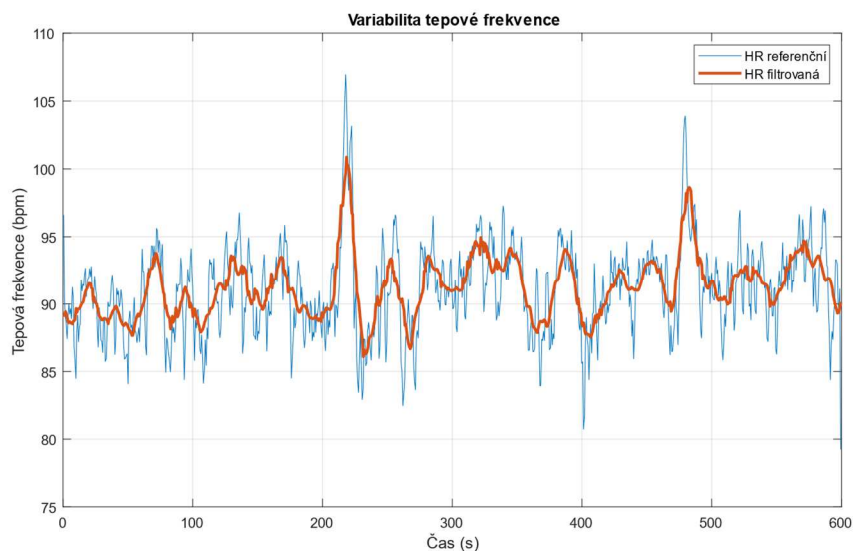
Střední hodnoty pro jednotlivé signály byly zaznamenány do Tabulky 3. Důležitým bodem, který je třeba v tabulce sledovat je, zda se střední hodnota μ blíží 0. Pokud tato střední hodnota nabývá velkých jak kladných, tak záporných hodnot, znamená to, velký rozdíl mezi křivkami odhadnutými a křivkami referenčními. Podobný jev je možné sledovat i u hodnot $1,96\sigma$, kde hranice úspěšnosti se nachází v rozmezí -5 až 5 bpm.

Tabulka 3 Zaznamenané střední hodnoty μ a hodnoty $1,96\sigma$ u metody WT.

Záznam	μ (bpm)	$1,96\sigma$
Female 1	5,93	14,24
Female 2	3,38	11,78
Female 3	0,85	9,88
Female 4	6,16	22,58
Female 5	0,29	9,31
Male 1	1,03	5,93
Male 2	0,33	4,86
Male 3	0,13	4,67
Male 4	5,21	9,62
Male 5	0,26	4,95
Male 6	0,47	5

V této tabulce lze vidět, že střední hodnoty se nejvíce blížily 0 pro signály Female 3, Female 5, Male 2, Male 3, Male 5 a Male 6. Pro signály Female 3 a Female 5 se ovšem hodnota $1,96\sigma$ nacházela mimo stanovené rozmezí, a tudíž ji nemůžeme považovat za úspěšnou.

Jako další srovnávací bod je vizuální srovnání přesnosti extrakce signálu použitou metodou. Toto srovnání je provedeno vykreslením křivek HR extrahovaných pomocí metod a křivek referenčních HR. Tyto křivky pro záznam Male 3 je možné vidět na obrázku 7.10.



Obrázek 7.10 Srovnání referenčních a extrahovaných křivek HR pro záznam Male 3 u metody WT.

Z tohoto grafu je patrné, že použitá metoda dokázala poměrně přesně vyextrahovat HR křivku vzhledem k referenční.

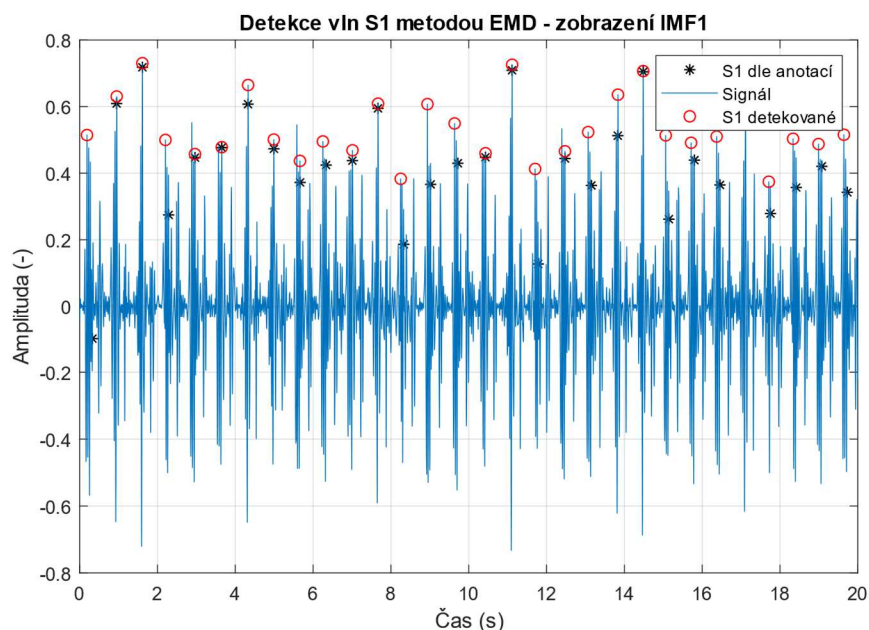
7.6 Empirická modální dekompozice

Jako další metoda pro testování signálu byla vybrána metoda EMD. Tato metoda předzpracovaný signál rozkládá na jednotlivé oscilační funkce IMF. Následně byla vybrána nejvhodnější IMF a s ní provedené statistické výpočty. V rámci GUI je možné nastavit vykreslení až 10 IMF, s tím, že pro naše zpracování byla použita IMF1, jelikož u dalších došlo již k poměrně velkému rozkladu signálu.

Tabulka 4 Výpočet statistických parametrů pro metodu EMD pro všechny záznamy.

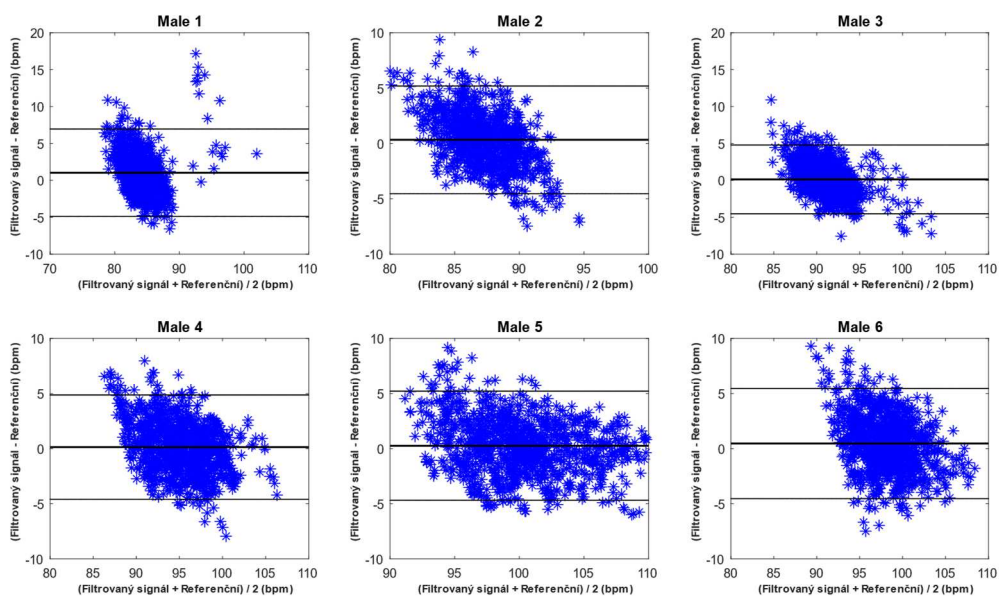
Záznamy	TP	FP	FN	n	ACC (%)	SE (%)	PPV (%)	F1 (%)
Female 1	563	269	223	786	53,36	71,63	67,67	69,59
Female 2	655	114	91	746	76,16	87,8	85,18	86,47
Female 3	675	27	14	689	94,27	97,97	96,15	97,05
Female 4	690	33	22	712	92,62	96,91	95,44	96,17
Female 5	756	12	11	767	97,05	98,57	98,44	98,5
Male 1	827	8	10	837	97,87	98,81	99,04	98,92
Male 2	869	1	0	869	99,89	100	99,89	99,94
Male 3	910	1	1	911	99,78	99,89	99,89	99,89
Male 4	949	1	0	949	99,89	100	99,89	99,94
Male 5	996	1	3	999	99,6	99,7	99,9	99,8
Male 6	978	1	0	978	99,9	100	99,9	99,95

Z výsledků je patrné, že podobně jako u WT, ani pro tuto metodu nemůžeme extrakci signálu Female 1 považovat za úspěšnou, i když oproti WT dopadla u parametru ACC procentuálně lépe. Opět, pokud porovnáme parametry FP a FN ve vztahu k hodnotě počtu peaků n, tak lze stále u ženských signálů zpozorovat nedostatky, ačkoliv oproti metodě WT došlo k mírnému zlepšení. K mírnému zlepšení došlo i u mužských signálů, kde hodnota parametru ACC pro signál Male 1 zde vyšla 97,87 %, kdežto u metody WT jenom 91,65 %. Pro ostatní signály se tato metoda pohybuje u žen kolem 97 % a u mužů kolem 99 %, což znamená, že extrakce touto metodou byla úspěšná.

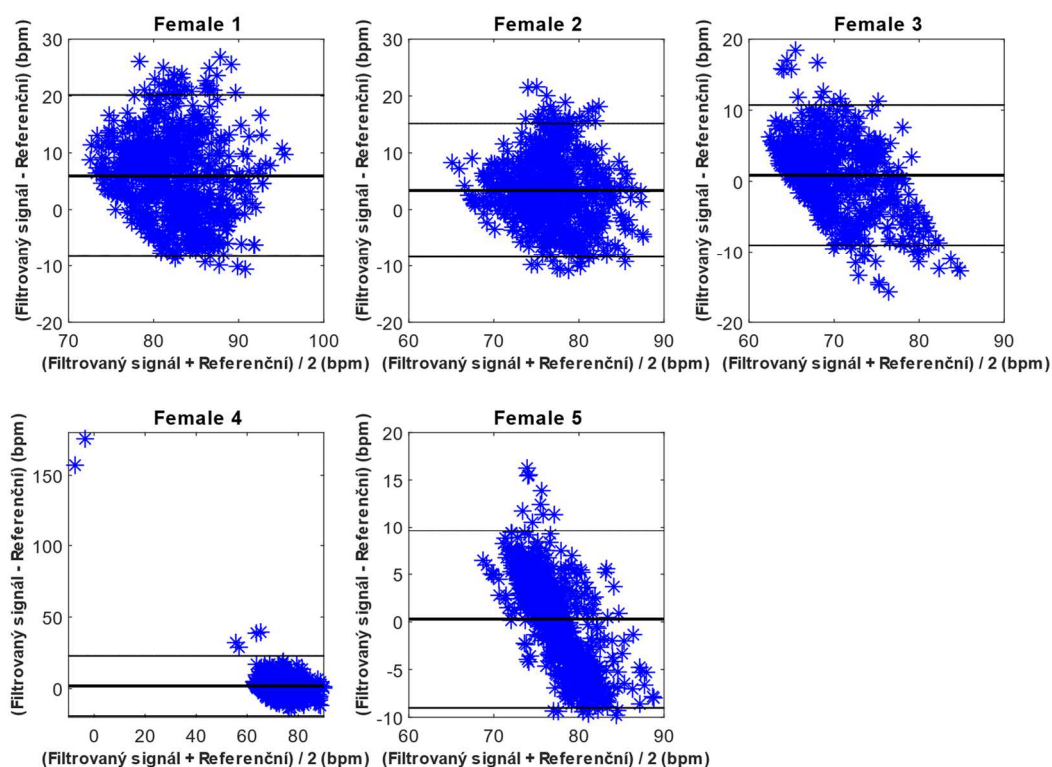


Obrázek 7.11 Signály zpracované pomocí EMD pro záznam Male 3. Vykresleno zobrazení IMF1.

Opět jako u WT další část testování byla provedena pomocí Bland-Altmanových grafů, kde se porovnávaly odhadnuté HR křivky a referenční HR křivky. Sestrojení těchto grafů proběhlo stejným způsobem, který je důkladně popsán v kapitole Statistické vyhodnocení. Na obrázku 7.12 jsou zobrazeny Bland-Altmanovy grafy pro všechny mužské signály. Grafy pro ženské signály jsou poté zobrazeny na obrázku 7.13.



Obrázek 7.12 Bland-Altmanových grafy pro signály Male 1 až 6.



Obrázek 7.13 Blant-Altmanovy grafy pro signály Female 1 až 5.

Střední hodnoty pro jednotlivé signály byly zaznamenána do Tabulky 5. Opět je důležité sledovat, zda se střední hodnota μ blíží 0, hranice úspěšnosti se nachází v rozmezí -0,5 až 0,5 bpm. Dále také sledujeme hodnoty $1,96\sigma$, kde hranice úspěšnosti se nachází v rozmezí -5 až 5 bpm.


Tabulka 5 Zaznamenané střední hodnoty μ a hodnoty $1,96\sigma$ u metody EMD.

Záznam	μ (bpm)	$1,96\sigma$
Female 1	7,15	14,7
Female 2	3,47	11,51
Female 3	2,21	11,82
Female 4	2,4	22,14
Female 5	0,33	9,24
Male 1	0,45	5,82
Male 2	0,53	4,84
Male 3	0,63	4,74
Male 4	0,52	4,82
Male 5	0,41	5,1
Male 6	0,62	5,07

V této tabulce 5 lze vidět, že ženských signálu se střední hodnota přiblížila 0 pouze u signálu Female 5. Mužské signály dopadly o poznání lépe a 0 se blížily téměř všechny. Jelikož ale považujeme

hranici úspěšnosti u středních hodnot v rozmezí $-0,5$ až $0,5$ bpm a hranici $1,96\sigma$ v rozmezí -5 a 5 bpm, můžeme za úspěšnou považovat pouze extrakci i signálů Male 2, Male 3 a Male 4. Za zmínku stojí i signály Male 5 a Male 6, které se téměř hranici úspěšnosti přiblížily.

Jako další srovnávací bod je vizuální srovnání přesnosti extrakce signálu použitou metodou. Toto srovnání je provedeno vykreslením křivek HR extrahovaných pomocí metod a křivek referenčních HR. Tyto křivky pro záznam Male 3 je možné vidět na obrázku 7.14.

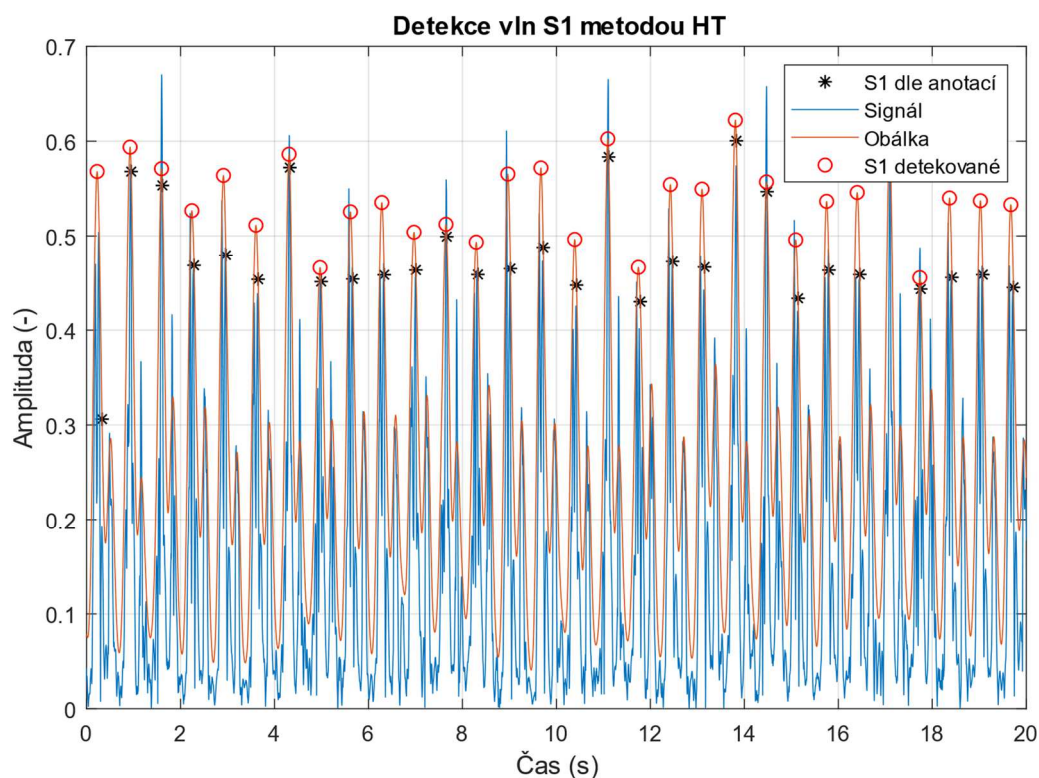


Obrázek 7.14 Srovnání referenčních a extrahovaných křivek HR pro záznam Male 3 u metody EMD.

Z toho grafu je patrné, že podobně jako u metody WT, tak i u této metody se podařilo vyextrahovat HR křivku poměrně přesně vzhledem k referenční HR křivce.

7.7 Hilbertova transformace

Jako další metoda pro testování signálu byla použita Hilbertova transformace. Tato metoda funguje tak, že z předpracovaného signálu je vyfiltrovaná obálka a na této obálce je poté prováděná S1 detekce a statistické výpočty.



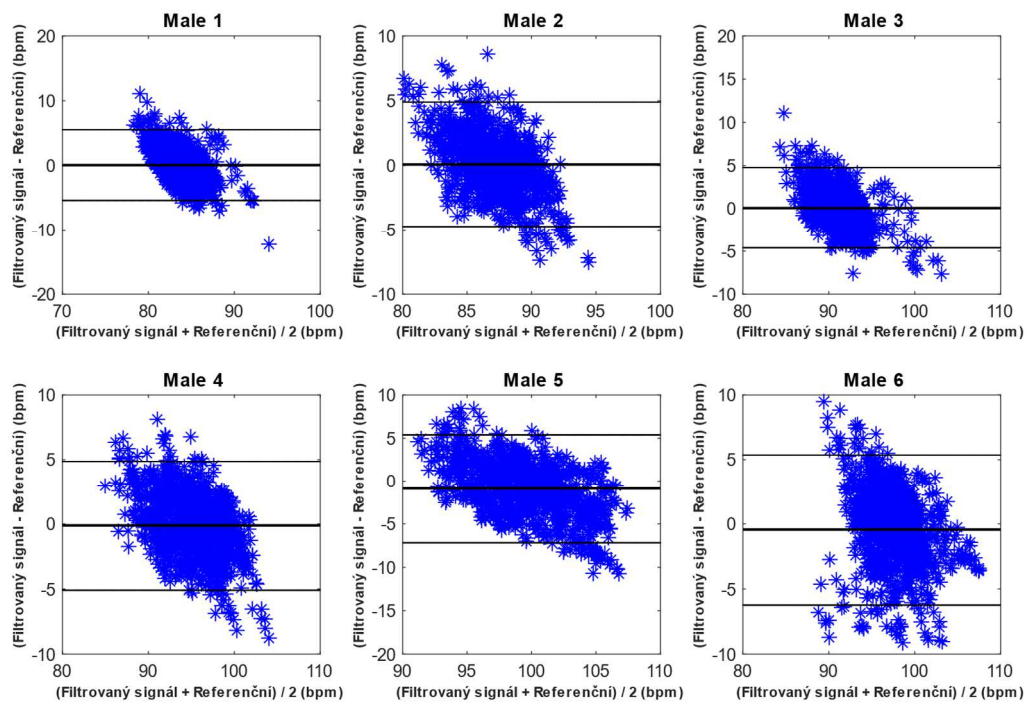
Obrázek 7.15 Vyfiltrována obálka získání pomocí metody HT pro signál Male 3.

Tabulka 5 Výpočet statistických parametrů pro metodu HT pro všechny záznamy.

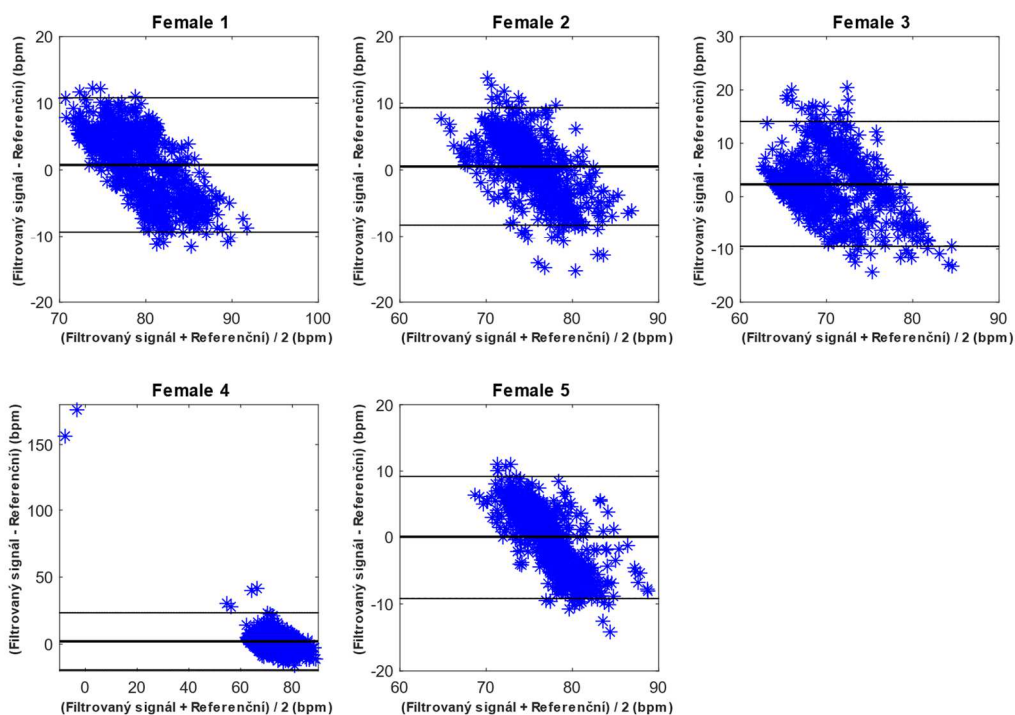
Záznamy	TP	FP	FN	n	ACC (%)	SE (%)	PPV (%)	F1 (%)
Female 1	671	115	115	786	74,47	85,37	85,37	85,37
Female 2	648	97	98	746	76,87	86,86	86,98	86,92
Female 3	653	43	34	687	89,45	95,05	93,82	94,43
Female 4	659	55	53	712	85,92	92,56	92,3	92,43
Female 5	744	21	23	767	94,42	97	97,25	97,12
Male 1	836	0	1	837	99,88	99,88	100	99,94
Male 2	869	0	0	869	100	100	100	100
Male 3	909	2	2	911	99,56	99,78	99,78	99,78
Male 4	943	4	6	949	98,95	99,37	99,58	99,47
Male 5	969	17	30	999	95,37	97	98,28	97,64
Male 6	960	11	18	978	97,07	98,16	98,87	98,51

Z výsledků je patrné, že podobně jako u předchozích metod dopadly mužské signály lépe než ty ženské. Pokud srovnáme tuto celkově tuto metodu s těmi předchozími, tak tato metoda dopadla pro ženské signály nejhůř ze všech, i když signál Female 1 zde dopadl ze všech metod nejlépe. Při porovnání parametrů FP a FN můžeme upozorovat, že nejen u ženských signálů, ale i mužských signálů Male 5 a Male 6 došlo k horší detekci než u metod předchozích.

Opět jako u předchozích metod další část testování byla provedena pomocí Bland-Altmanových grafů, kde se porovnávaly odhadnuté HR křivky a referenční HR křivky. Sestrojení těchto grafů proběhlo stejným způsobem, který je důkladně popsán v kapitole Statistické vyhodnocení. Bland-Altmanovy grafy pro mužské a ženské signály můžeme vidět na obrázku 7.16 a 7.17.



Obrázek 7.16 Bland-Altmanovy grafy pro signály Male 1 až 6.



Obrázek 7.17 Bland-Altmanovy grafy pro signály Female 1 až 5

Střední hodnoty pro jednotlivé signály byly zaznamenána do Tabulky 6.


Tabulka 6 Zaznamenané střední hodnoty μ a hodnoty $1,96\sigma$ u metody EMD.

Záznam	μ (bpm)	$1,96\sigma$
Female 1	0,75	10,08
Female 2	0,52	8,81
Female 3	2,3	11,8
Female 4	2,8	21,37
Female 5	0,01	9,2
Male 1	0,06	5,46
Male 2	0,08	4,81
Male 3	0,07	4,69
Male 4	-0,12	4,98
Male 5	-0,9	6,28
Male 6	-0,44	5,8

V Tabulce 6 lze vidět, že u ženských signálu hranici úspěšnosti u střední hodnoty překonal pouze signál Female 5. Signály Female 1 a Female 2 se této hranici přiblížily ale i tak je považujeme za neúspěšné. U hodnotícího parametru $1,96\sigma$ považujeme hranici úspěšnosti v rozmezí -5 a 5 bpm a do tohoto rozmezí se nedostal ani jeden ženský signál. Pro tyto signály tedy můžeme tuto metodu

považovat za nevhodnou a neúspěšnou. Mužské signály dopadly poměrně lépe, hranici úspěšnosti u středních hodnot překonaly všechny signály kromě Male 5. U hodnotící parametru $1,96\sigma$ se do rozmezí úspěšnosti vešly signály Male 2, Male 3, Male 4.

Jako další srovnávací bod je vizuální srovnání přesnosti extrakce signálu použitou metodou. Toto srovnání je provedeno vykreslením křivek HR extrahovaných pomocí metod a křivek referenčních HR. Tyto křivky pro záznam Male 3 je možné vidět na obrázku 7.18.




Obrázek 7.18 Srovnání referenčních a extrahovaných křivek HR pro záznam Male 3 u metody HT.

Z tohoto obrázku je patrné, že podobně jako u předchozích metod, i zde vykreslené HR křivka přesně odpovídá HR křivce referenční.


7.8 Diskuse

Výsledky získané pomocí použitých metod ukazují, že jsou pro většinu testovacích záznamů velmi účinné. Pro některé signály je jejich efektivita horší. Jako příklad je níže zobrazena HR křivka pro signále Female 1, který u všech testovacích metod dopadl nejhůře. Na obrázku 7.19 je zobrazena HR odhadnutá křivka pro signál Female 1, který je vyextrahován pomocí metody WT a také HR referenční křivka, která je získaná z referenčních anotací pro stejný záznam.




Obrázek 7.19 Odhadnutá HR křivka pro signál Female 1 vyextrahován pomocí metody WT.

Na obrázku 7.20 je vyznačená oblast, kde HR křivka shodovala s HR křivkou referenční.



Obrázek 7.20 Odhadnutá HR křivka pro signále Female 1 vyextrahován pomocí metody WT pro část signálu, kde odhadnutá HR křivka odpovídá referenční HR křivce.


Na obrázku 7.21 lze vidět odhadnutá HR křivka, která se výrazně odchylovala od té referenční.



Obrázek 7.21 Odhadnutá HR křivka pro signál Female 1 vyextrahován pomocí metody WT pro část signálu, ve kterém se odhadnutá křivka výrazně odchylovala od té referenční.

Z těchto ukávek je patrné, že kvalita extrakce signálu je závislá na kvalitě samotných vstupních signálů. Konkrétně na příkladě signálu Female 1 kvalitu původního vstupního signálu zaručit nemůžeme. Tento signál byl nesprávně naměřen a tím pádem metoda WT nebyla schopná tento signál správně zpracovat. Z toho vyplývá, že pro tento signál u všech použitých metod byly hodnoty parametrů TP, v poměru k celkovému počtu kmitů, velmi nízké. Tím pádem byly hodnoty parametrů FP a FN velmi vysoké a parametr ACC dosáhl v průměru pro všechny použité metody hodnoty 61,8 %, což nelze považovat za úspěch.

Pokud vstupní signál porovnáme s kvalitním signálem, viz obrázek 7.22, na kterém je zobrazena odhadnutá HR křivka pro signál Male 3. Na tomto obrázku můžeme pozorovat, že odhadnutá HR křivka odpovídá referenční, a i již na první pohled signál vypadá kvalitněji. Toto je statisticky podloženo v Tabulce 3, kde můžeme zpozorovat, že parametr ACC pro tento signál dosáhl hodnoty 100 %. To znamená, že parametry FP a FN rovnaly nule.



Obrázek 7.22 Odhadnutá a referenční HR křivka pro signál Male 3.

Tabulka 7 Souhrnné srovnání metod

Záznam	EMD			WT			HT		
	μ (bpm)	1.96 σ	ACC (%)	μ (bpm)	1.96 σ	ACC (%)	μ (bpm)	1.96 σ	ACC (%)
Female 1	0,75	10,08	53,36	5,93	14,24	62,13	7,15	14,70	74,47
Female 2	0,52	8,81	76,16	3,38	11,78	82,75	3,47	11,51	76,87
Female 3	2,30	11,80	94,27	0,85	9,88	98,56	2,21	11,82	89,45
Female 4	2,80	21,37	92,62	6,16	22,58	95,23	2,40	22,14	85,92
Female 5	0,01	9,20	97,05	0,29	9,31	97,68	0,33	9,24	94,42
Male 1	0,06	5,46	97,87	1,03	5,93	91,65	0,45	5,82	99,88
Male 2	0,08	4,81	99,89	0,33	4,86	99,31	0,53	4,84	100,00
Male 3	0,07	4,69	99,78	0,13	4,67	100,00	0,63	4,74	99,56
Male 4	-0,12	4,98	99,89	5,21	9,62	99,89	0,52	4,82	98,95
Male 5	-0,90	6,28	99,60	0,26	4,95	99,90	0,41	5,10	95,37
Male 6	-0,44	5,80	99,90	0,47	5,00	99,90	0,62	5,07	97,07
Průměr	0,47	8,48	91,85	2,19	9,35	93,36	1,70	9,07	92,00

V Tabulce 7 je zobrazen přehled statistických parametrů všech metod. Střední hodnota vychází nejbližší nule u metody EMD, stejně tak má metoda EMD v průměru i nejmenší směrodatnou odchylku. Vlnková transformace naopak byla lepší v porovnání parametrů ACC, nejvýrazněji u Female 1 a 2.

Tato diplomová práce se zabývala extrakcí a analýzou FKG signálu. Při zpracovávání jednotlivých metod vyšlo najevo, že úspěšnost metody přímo souvisí s kvalitou signálu. Jak můžeme vidět na obrázku 7.19, tento signál nedosahoval dostatečné kvality, a tudíž ani použité metody úspěšně být nemohly. Pokud porovnáme ženské signály a mužské signály, tak je patrné, že mužské signály byly

kvalitnější, což lze vidět i na statistické analýze pro každou metodu. Zde mužské signály dosahovaly přesnosti nad 95 %, oproti tomu přesnost ženských signálu byla nižší.

Závěr

V zadání diplomové práce bylo stanoveno 5 hlavních cílů. Všechny cíle této práce byly splněny a níže jsou podrobně popsány a zhodnoceny.

Prvním bodem zadání byl popis základních principů šíření světla v optických vláknech, optická vlákna a funkce Mach-Zehnderova interferometru. Tento cíl byl naplněn v kapitolách 2, 3 a 4. Kapitola 2 se zabývala optickými vlákny, jejich dělením a principem šíření světla uvnitř vlákna. Další pojednávala o interferometrii. Jsou zde popsány vlastnosti interference, koherence a v poslední podkapitole princip interferometrů. Kapitola 4 se zabývala senzory z optických vláken. Speciální podkapitola je věnována Mach-Zehnderově interferometru, což je senzor, pomocí kterého se měřila data pro experimentální část.

Druhým bodem bylo prostudování a výběr různých metod extrakce požadovaného signálu pro následnou analýzu. Tento bod byl splněn provedením rešerše, která se zaměřovala na popis různých metod extrakce jak EKG, tak FKG signálu. Tyto metody byly rozděleny do kapitol dle jejich principu – metody vlnkové transformace, neuronových sítí, slepé separace zdrojů a další. Součástí rešerše bylo i zhodnocení vybraných metod podle daných kritérií. U nich se hodnotila jejich náročnost, přesnost a prediktivita. Toto vedlo k výběru vhodných metod, pomocí kterých se vstupní signál hodnotil. Byly vybrány metody vlnkové transformace, empirická modální dekompozice a Hilbertova transformace. V následujících kapitolách byly tyto vybrané metody matematicky popsány.

Třetím bodem byl návrh a realizace SW aplikace pro zobrazení, úpravu a analýzu signálu, naměřeného pomocí mřížkových senzorů ve vývojovém prostředí Matlab. Tento bod byl splněn naprogramováním aplikace v prostředí Matlab. V kapitole 7.3, kde je aplikace důkladně popsána, jsou objasněny její funkce a to, jak se s ní pracuje.

Předposledním bodem bylo ověření funkcionality SW aplikace pomocí vhodné metody, srovnání vůči vhodné referenci a analýza výsledků. Tento cíl byl splněn v kapitole 7, kde se provádělo experimentování s vyextrahovanými daty. Realizace těchto experimentů byla provedena v aplikaci Matlab 2018a. Jednotlivé hodnotící metody mají vlastní kapitolu, kde byly pro dané signály zhodnoceny statistickými výpočty. Byla pozouzena úspěšnost detekování S1 kmitů u každého signálu vůči anotacím, převzatých z referenčního EKG signálu. Dále byly pro každou metodu vykresleny Bland-Altmanovy grafy, vypočítána směrodatná odchylka a střední hodnota. Pro tyto parametry bylo nastaveno rozmezí, do kterého se vyextrahovaný signál musel vejít, aby mohla metoda být považována za úspěšnou. Poslední hodnocení probíhalo vizuálně vykreslením odhadnuté HR křivky a referenční křivky.

Posledním bodem bylo provedení diskuse dosažených výsledků. Tento cíl byl splněn v kapitole 7.8. Jak bylo zmíněno výše, jednotlivé metody byly hodnoceny jak statisticky, tak pomocí vykreslení Bland-Altmanových grafů, provedení výpočtů střední hodnoty a směrodatné odchylky. Dále byly pro jednotlivé metody vykresleny odhadnuté HR křivky vůči HR křivkám referenčním.

Výsledky experimentů dokazují, že použité hodnotící metody byly úspěšné. Vlnková transformace dosahovala parametru přesnosti ACC větší než 90 % pro 9 z 11 testovaných signálů. Pro signály Female 1 a Female 2 tato metoda dosahovala parametru ACC 61,13 % a 82,75 %, tudíž se

pro tyto signály nedala považovat za úspěšnou. Důvodem byla pravděpodobně nižší kvalita použitého signálu.

Metoda EMD poté dosáhla mírně výsledků lepších, kde pro 5 signálů byla hodnota ACC > 99%. Hodnot parametru ACC > 90 % poté dosáhlo 9 z 11 signálů. U signálu Female 1 došlo k mírnému zhoršení a hodnota parametru ACC byla 53,36 %, také došlo ke zhoršení parametru ACC na hodnotu 76,16 % u Female2. Hodnocení metody EMD bylo provedeno na vyextrahovaném signálu IMF1, kde destrukce signálu je menší. Pokud byla použita IMF vyššího řádu, parametry přesnosti nabývaly menších hodnot a nešla zaručit úspěšnost použité metody. Jako nevýhodu této metody můžeme zmínit náročnost metody, kdy rozklad většího signálu může trvat oproti ostatním použitým metodám výrazně delší dobu s velmi podobnou přesností jako další použité hodnotící metody.

Poslední použitou metodou pro hodnocení byla Hilbertova transformace. Tato metoda z použitých hodnotících metod nejhorší. Hodnot parametru ACC > 90 % poté dosáhlo pouze 7 z 11 signálů. Menší úspěšnosti této metody bylo možné zpozorovat i na Bland-Altmanových grafech, výpočtech středních hodnot a $\pm 1,96$ směrodatné odchylky. Do nastavených rozmezí úspěšnosti se dostaly jen 3 signály z 11. Ostatní signály byly mimo hranici úspěšnosti, a proto byla tato metoda považována za tu nejméně vhodnou.

Bibliografie

- [1] The heart: All you need to know. *Medical News Today* [online]. 2020 [cit. 2020-12-03]. Dostupné z: <https://www.medicalnewstoday.com/articles/320565>
- [2] Cardiovascular system (heart) anatomy. *HealthEngine* [online]. 2006 [cit. 2020-12-03]. Dostupné z: <https://healthengine.com.au/info/cardiovascular-system-heart>
- [3] The Heartbeat. *Biology Pages* [online]. 2011 [cit. 2020-12-03]. Dostupné z: <https://www.biology-pages.info/H/Heart.html>
- [4] ZHANG, Gus a Weiguo ZHANG. Heart rate, lifespan, and mortality risk. *Ageing Research Reviews* [online]. 2009, **8**(1), 52-60 [cit. 2020-12-03]. ISSN 15681637. Dostupné z: doi:10.1016/j.arr.2008.10.001
- [5] COSTANZO, Linda S. *Physiology*. Sixth edition. Philadelphia: Elsevier, 2018. ISBN 9780323478816.
- [6] Heart Rate Variability: An Indicator of Self-Regulatory Capacity, Autonomic Function and Health. *Heartmath* [online]. 2020 [cit. 2020-12-03]. Dostupné z: <https://www.heartmath.org/research/science-of-the-heart/heart-rate-variability/>
- [7] SHAFFER, Fred a J. GINSBERG. An Overview of Heart Rate Variability Metrics and Norms. *Frontiers in Public Health* [online]. 2017, **5** [cit. 2020-12-03]. ISSN 2296-2565. Dostupné z: doi:10.3389/fpubh.2017.00258
- [8] *Fiber optic sensors: an introduction for engineers and scientists*. 2nd ed. Editor Eric UDD, editor William B. SPILLMAN. Hoboken: Wiley, 2011. ISBN 978-0-470-12684-4.
- [9] PENG, Gang-Ding. *Handbook of Optical Fibers* [online]. Singapore: Springer Singapore, 2019 [cit. 2020-12-01]. ISBN 978-981-10-7086-0.
- [10] KROHN, David, Trevor MACDOUGALL a Alexis MENDEZ. *Fiber optic sensors : fundamentals and applications* [online]. Fourth edition. Bellingham, Washington 98227-0010 USA: Society of Photo-Optical Instrumentation Engineers (SPIE), 2014 [cit. 2020-11-01]. ISBN 9781628411812. Dostupné z: <https://www.spiedigitallibrary.org/ebooks/PM/Fiber-Optic-Sensors-Fundamentals-and-Applications-Fourth-Edition/eISBN-9781628411812/10.1117/3.1002910>
- [11] YU, Francis a Shizhuo YIN. *Fiber optic sensors*. New York: Marcel Dekker, 2002. Optical engineering (Marcel Dekker, Inc.), v. 76. ISBN isbn0-8247-0732-x.

- [12] DONNIE, Jones. *Navy Electricity and Electronics Training Series: Modul 24: Introduction to Fiber Optics*. 1998 Edition. Washington, DC: NAVAL EDUCATION AND TRAINING PROFESSIONAL DEVELOPMENT AND TECHNOLOGY CENTER, 1998. ISBN 0504-LP-026-8470.
- [13] Studijní materiály: Optika. *Přírodovědecká fakulta Univerzita Palackého: Katedra optiky* [online]. Olomouc, 2008 [cit. 2020-11-08]. Dostupné z: <http://apfyz.upol.cz/ucebnice/down/optika.pdf>
- [14] HARIHARAN, P. *Basics of interferometry*. 2nd ed. Boston: Elsevier Academic Press, 2007. ISBN 978-0-12-373589-8.
- [15] EDITED BY IVAN PADRON. *Interferometry - Research and Applications in Science and Technology*. Second Edition. InTech, 2012. ISBN 978-953-51-0403-2.
- [16] HARIHARAN, P. *Optical interferometry*. 2nd ed. Boston: Academic Press, 2003. ISBN 9780123116307.
- [17] Coherence. *RP Photonics Encyclopedy* [online]. 2005 [cit. 2020-11-27]. Dostupné z: <https://www.rp-photonics.com/coherence.html>
- [18] NOLTE, David D. *Optical Interferometry for Biology and Medicine* [online]. New York, NY: Springer New York, 2012 [cit. 2020-11-13]. ISBN 978-1-4614-0889-5. Dostupné z: doi:10.1007/978-1-4614-0890-1
- [19] FAJKUS, Marcel, Jan NEDOMA, Radek MARTINEK, Vladimír VASINEK, Homer NAZERAN a Petr SÍSKA. A Non-Invasive Multichannel Hybrid Fiber-Optic Sensor System for Vital Sign Monitoring. *Sensors* [online]. 2017, **17**(12) [cit. 2020-12-02]. ISSN 1424-8220. Dostupné z: doi:10.3390/s17010111
- [20] MARTINEK, Radek, Jan NEDOMA, Marcel FAJKUS et al. A Phonocardiographic-Based Fiber-Optic Sensor and Adaptive Filtering System for Noninvasive Continuous Fetal Heart Rate Monitoring. *Sensors* [online]. 2017, **17**(4) [cit. 2021-04-28]. ISSN 1424-8220. Dostupné z: doi:10.3390/s17040890
- [21] MARTINEK, Radek, Radana KAHANKOVÁ, Jan NEDOMA, Marcel FAJKUS, Homer NAZERAN a Jana NOWAKOVÁ. Adaptive Signal Processing of Fetal PCG Recorded by Interferometric Sensor. KRÖMER, Pavel, Enrique ALBA, Jeng-Shyang PAN a Václav SNÁŠEL, ed., Pavel KRÖMER, Enrique ALBA, Jeng-Shyang PAN, Václav SNÁŠEL. *Proceedings of the Fourth Euro-China Conference on Intelligent Data Analysis and Applications* [online]. Cham: Springer International Publishing, 2018, s. 235-243 [cit. 2021-04-28]. Advances in Intelligent Systems and Computing. ISBN 978-3-319-68526-7. Dostupné z: doi:10.1007/978-3-319-68527-4_26

- [31] SAXENA, S., A. SHARMA a S. CHAUDHARY. Data compression and feature extraction of ECG signals. *International Journal of Systems Science* [online]. 1997, **28**(5), 483-498 [cit. 2020-12-19]. ISSN 0020-7721. Dostupné z: doi:10.1080/00207729708929409
- [32] ALEXAKIS, C., H.O. NYONGESA, R. SAATCHI, N.D. HARRIS, C. DAVIES, C. EMERY, R.H. IRELAND a S.R. HELLER. Feature extraction and classification of electrocardiogram (ECG) signals related to hypoglycaemia. In: *Computers in Cardiology, 2003* [online]. IEEE, 2003, s. 537-540 [cit. 2020-12-15]. ISBN 0-7803-8170-X. Dostupné z: doi:10.1109/CIC.2003.1291211
- [33] JEN, K.-K a Y.-R. HWANG. ECG feature extraction and classification using cepstrum and neural networks. *Journal of Medical and Biological Engineering*. 2008, **28**, 31-37.
- [34] YU, S a K. CHOU. Integration of independent component analysis and neural networks for ECG beat classification. *Expert Systems with Applications* [online]. 2008, **34**(4), 2841-2846 [cit. 2020-12-15]. ISSN 09574174. Dostupné z: doi:10.1016/j.eswa.2007.05.006
- [35] SLANINA, Zdenek, Rene JAROS, Radana KAHANKOVA, Radek MARTINEK, Jan NEDOMA, Marcel FAJKUS, Ryszard ROMANIUK a Maciej LINCZUK. Fetal phonocardiography signal processing from abdominal records by non-adaptive methods. In: *Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments 2018* [online]. SPIE, 2018, s. 118- [cit. 2021-04-28]. ISBN 9781510622036. Dostupné z: doi:10.1117/12.2501550
- [36] HE, Taigang, Gari CLIFFORD a Lionel TARASSENKO. Application of independent component analysis in removing artefacts from the electrocardiogram. *Neural Computing and Applications* [online]. 2006, **15**(2), 105-116 [cit. 2020-12-16]. ISSN 0941-0643. Dostupné z: doi:10.1007/s00521-005-0013-y
- [37] BARHATTE, Alka, Rajesh GHONGADE a Sachin TEKALE. Noise analysis of ECG signal using fast ICA. In: *2016 Conference on Advances in Signal Processing (CASP)* [online]. IEEE, 2016, s. 118-122 [cit. 2020-12-16]. ISBN 978-1-5090-0849-0. Dostupné z: doi:10.1109/CASP.2016.7746149
- [38] BRUSER, C., K. STADLTHANNER, S. WAELE a S. LEONHARDT. Adaptive Beat-to-Beat Heart Rate Estimation in Ballistocardiograms. *IEEE Transactions on Information Technology in Biomedicine*. 2011, **15**(5), 778-786. ISSN 1558-0032. Dostupné z: doi:10.1109/TITB.2011.2128337
- [39] JOVIC, Alan a Nikola BOGUNOVIC. Feature Extraction for ECG Time-Series Mining Based on Chaos Theory. In: *2007 29th International Conference on Information*

Technology Interfaces [online]. IEEE, 2007, s. 63-68 [cit. 2020-12-14]. ISBN 953-7138-09-7. ISSN 1330-1012. Dostupné z: doi:10.1109/ITI.2007.4283745

- [40] CHOUHAN, Vinod a S. MEHTA. Detection of QRS Complexes in 12-lead ECG using Adaptive Quantized Threshold. *Int J Comput Sci Network Security*. 2008, **8**.
- [41] CHOUHAN, V.S. a S.S. MEHTA. Total Removal of Baseline Drift from ECG Signal. In: *2007 International Conference on Computing: Theory and Applications (ICCTA'07)* [online]. IEEE, 2007, s. 512-515 [cit. 2020-12-15]. ISBN 0-7695-2770-1. Dostupné z: doi:10.1109/ICCTA.2007.126
- [42] XIAOMIN XU, a YING LIU. ECG QRS Complex Detection Using Slope Vector Waveform (SVW) Algorithm. In: *The 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* [online]. IEEE, 2004, s. 3597-3600 [cit. 2020-12-17]. ISBN 0-7803-8439-3. Dostupné z: doi:10.1109/IEMBS.2004.1404011
- [43] OLVERA, Felipe E. *Electrocardiogram Waveform Feature Extraction Using the Matched Filter* [online]. [cit. 2020-12-17]. Dostupné z: <http://web.cecs.pdx.edu/~ssp/Reports/2006/Olvera.pdf>
- [44] RAMLI, A.B. a P.A. AHMAD. Correlation analysis for abnormal ECG signal features extraction. In: *4th National Conference of Telecommunication Technology, 2003. NCTT 2003 Proceedings* [online]. IEEE, 2003, s. 232-237 [cit. 2020-12-17]. ISBN 0-7803-7773-7. Dostupné z: doi:10.1109/NCTT.2003.1188342
- [45] MARTIS, Roshan, U. ACHARYA a Lim MIN. ECG beat classification using PCA, LDA, ICA and Discrete Wavelet Transform. *Biomedical Signal Processing and Control* [online]. 2013, **8**(5), 437-448 [cit. 2020-12-17]. ISSN 17468094. Dostupné z: doi:10.1016/j.bspc.2013.01.005
- [46] AZIZ, Sumair, Muhammad KHAN, Majed ALHAISONI, Tallha AKRAM a Muhammad ALTAF. Phonocardiogram Signal Processing for Automatic Diagnosis of Congenital Heart Disorders through Fusion of Temporal and Cepstral Features. *Sensors* [online]. 2020, **20**(13) [cit. 2021-04-28]. ISSN 1424-8220. Dostupné z: doi:10.3390/s20133790
- [47] ŠPRAGER, Sebastijan, Denis ĐONLAGIĆ a Damjan ZAZULA. *Estimation of Heart Rate, Respiratory Rate and Motion by using Optical Interferometer as Body Sensor*. 2011. Dostupné z: doi:10.2316/P.2011.759-069
- [48] NEDOMA, Jan, Marcel FAJKUS, Radek MARTINEK, Stanislav KEPAK, Jakub CUBIK, Stanislav ZABKA a Vladimir VASINEK. Comparison of BCG, PCG and ECG signals in application of heart rate monitoring of the human body. In: *2017 40th International Conference on Telecommunications and Signal Processing (TSP)* [online]. IEEE, 2017, s.

420-424 [cit. 2021-04-28]. ISBN 978-1-5090-3982-1. Dostupné z: doi:10.1109/TSP.2017.8076019

- [49] LEI, Yaguo. 2 - *Signal processing and feature extraction*. Butterworth-Heinemann, 2017, s. 17-66. ISBN 978-0-12-811534-3. Dostupné z: doi:<https://doi.org/10.1016/B978-0-12-811534-3.00002-0>
- [50] *IIR Filters and FIR Filters - DIAdem 2018 Help - National Instruments* [online]. [cit. 2021-04-29]. Dostupné z: https://zone.ni.com/reference/en-XX/help/370858P-01/genmaths/genmaths/calc_filterfir_iir/?fbclid=IwAR2Szo7C1fN2OpCj2wJVO0QeGtgU1GOTXvjQ1SfQL-PcYDpd9QSkcZr67yo
- [51] BEHBAHANI, Soroor. A hybrid algorithm for heart sounds segmentation based on phonocardiogram. *Journal of Medical Engineering & Technology* [online]. 2019, **43**(6), 363-377 [cit. 2021-04-29]. ISSN 0309-1902. Dostupné z: doi:10.1080/03091902.2019.1676321
- [52] NASERI, H. a M. R. HOMAEINEZHAD. Detection and Boundary Identification of Phonocardiogram Sounds Using an Expert Frequency-Energy Based Metric. *Annals of Biomedical Engineering* [online]. 2013, **41**(2), 279-292 [cit. 2021-04-29]. ISSN 0090-6964. Dostupné z: doi:10.1007/s10439-012-0645-x

Přílohy

K této práci je přiložen soubor *2021_DOS0139_DP_priloha.zip*, obsahující reálná data naměřená interferometrických senzorem – signály FKG a referenční signály EKG. Dále složka obsahuje GUI pro testování metod a druhé GUI pro kontrolu anotací referenčního signálu. Všechny funkce jsou vytvořeny v programu Matlab R2018a.

Obsah:

- Anotace – složka obsahující referenční EKG data a referenční anotace.
- Data – složka obsahující testovaná data.
- Bland_altman – funkce provádějící Bland-Altmanovu analýzu.
- Detektor_S1 – funkce sloužící k detekci S1 peaků.
- Gui_main – vytvořené GUI pro hodnocení signálů.
- GUI_QRS – vytvořené GUI pro úpravu referenčních anotací.
- metodaHT – funkce sloužící k výpočtu Hilbertovy transformace.
- metodaWT – funkce sloužící k provedení vlnkové transformace.
- Predzpracovani – funkce sloužící k předzpracování reálných dat pomocí FIR filtru.
- S1_max – funkce sloužící k úpravě zobrazení detekovaných S1 peaků.
- Spektrum – funkce sloužící k provedení Fourierovy transformace pro vykreslení amplitudového spektra.
- Stanoveni_TP_FP_FN – funkce sloužící k provedení statistického hodnocení signálu.
- Vline – funkce sloužící k vykreslení svislé osy v bodě indexu pro GUI_QRS.