VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

DETEKCE ARYTMIÍ V EKG

ECG ARRHYTHMIA DETECTION

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE — Tomáš Šoltés

AUTHOR

VEDOUCÍ PRÁCE — Ing. Petra Novotná

SUPERVISOR

BRNO 2023

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Tomáš Šoltés ***ID:*** 230327

Ročník: 3 ***Akademický rok:*** 2022/23

NÁZEV TÉMATU:

Detekce arytmií v EKG

POKYNY PRO VYPRACOVÁNÍ:

1) Nastudujte a popište fyziologii často se vyskytujících arytmií v EKG, zaměřte se na komorové extrasystoly (KES), blokády Tawarových ramének (LBBB, RBBB) a rozdíly mezi nimi. 2) Nastudujte a popište současné metody detekce KES, LBBB a RBBB. Prostudujte jak konvenční přístupy, tak současné metody strojového a hlubokého učení. 3) Seznamte se s poskytnutými daty z databáze na ÚBMI a veřejně dostupných databází a proveďte jejich analýzu. Na základě této analýzy a vybrané detekční metody proveďte potřebné předzpracování dat (filtrace, odvození příznaků, vyhodnocení příznaků, redukce dimenzionallity,...). 4) Vybranou detekční metodu podrobně popište, navrhněte způsob její realizace a ve vhodném implementačním prostředí ji realizujte. 5) Metodu detekce vybraných arytmií optimalizujte, otestujte a porovnejte a vyhodnoťte její přínosy a nedostatky. 6) Dosažené výsledky podrobně diskutujte.

DOPORUČENÁ LITERATURA:

[1] LUZ, Eduardo José da S., William Robson SCHWARTZ, Guillermo CÁMARA-CHÁVEZ a David MENOTTI. ECG-based heartbeat classification for arrhythmia detection: A survey. Computer Methods and Programs in Biomedicine. 2016, (127), 144-164. DOI: 10.1016/j.cmpb.2015.12.008. ISSN 01692607

[2] GOLDBERGER, Ary L., Zachary D. GOLDBERGER a Alexei SHVILKIN. Goldberger's clinical electrocardiography: a simplified approach. 9th edition. Philadephia: Elsevier, 2018. ISBN 978-0-323-40169-2

Termín zadání: 6.2.2023 ***Termín odevzdání:*** 14.8.2023

Vedoucí práce: Ing. Petra Novotná

doc. Ing. Jana Kolářová, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

Bakalářská práce popisuje často se vyskytující vybrané arytmie (resp. komorové extrasystoly a blokády Tawarových ramének) a jejich konvenční i moderní detekční metody, včetně metod využívající neuronové sítě. V praktické části jsou realizovány metody pro jednotlivé arytmie: Statistické analýzy QRS komplexů a jejich klasifikaci pomocí metody K-nejbližších sousedů pro blokády Tawarových ramének a komorových extrasystol.

Klíčová slova

arytmie, komorové extrasystoly, komorové, extrasystoly, srdce, EKG, detekce, konvenční metody, moderní metody, neuronové sítě, K-nejbližší sousedé, KNN, QRS komplex, klasifikace, statistická analýza, blokáda Tawarových ramének, LBBB, RBBB

Abstract

This bachelor thesis describes commonly present arrhytmias such as premature ventricular complex, bundle branch blocks and their detection using conventional methods and modern methods, utilising neural networks. Practical part includes: Detection of premature ventricular complexes and detection of bundle branch blocks using statistical analysis of QRS complex and their classification with K-nearest neighbors

Keywords

arrhytmia, Premature ventricular complex, extrasystoles, heart, ECG, detection, conventional methods, modern methods, neural networks, K-nearest neighbors, KNN, QRS complex, classification, statistical analysis, bundle branch blocks, LBBB, RBBB

Bibliografická citace

ŠOLTÉS, Tomáš. Detekce arytmií v EKG. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2022. Vedoucí práce: Ing. Petra Novotná.

Prohlášení autora o původnosti díla

Jméno a příjmení studenta:	*Tomáš Šoltés*
VUT ID studenta:	*230327*
Typ práce:	*Bakalářská práce*
Akademický rok:	*2022/2023*
Téma závěrečné práce:	*Detekce arytmií v EKG*

Prohlašuji, že svou závěrečnou práci jsem vypracoval samostatně pod vedením vedoucí/ho závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

.

V Brně dne: 14. srpna 2023 ----------

podpis autora

Poděkování

Děkuji vedoucímu bakalářské práce Ing. Petře Novotné za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé závěrečné práce.

V Brně dne: 14. srpna 2023 ----------

podpis autora

Obsah

SEZNAM OBRÁZKŮ

SEZNAM TABULEK

1. ÚVOD ... 1

2. ELEKTROKARDIOGRAM (EKG) ... 2

2.1 EKG KŘIVKA ... 4

2.1.1 Vlna P ... 5

2.1.2 PR interval ... 5

2.1.3 QRS komplex ... 5

2.1.4 ST segment ... 5

2.1.5 Vlna T ... 5

3. SRDEČNÍ ARYTMIE ... 6

3.1 KOMOROVÉ EXTRASYSTOLY (KES) ... 7

3.2 BLOKÁDY TAWAROVÝCH RAMÉNEK ... 9

3.2.1 Blokáda levého Tawarova raménka ... 9

3.2.2 Blokáda pravého Tawarova raménka ... 10

4. METODY DETEKCE KOMOROVÝCH EXTRASYSTOL A BLOKÁD TAWAROVÝCH RAMÉNEK ... 12

4.1 DETEKCE KOMOROVÝCH EXTRASYSTOL PODLE RR INTERVALŮ ... 12

4.2 DETEKCE A LOKALIZACE KOMOROVÝCH EXTRASYSTOL POMOCÍ VLNKOVÉ TRANSFORMACE A ENERGIE SIGNÁLU ... 14

4.2.1 Vlnková transformace ... 14

4.2.2 Energie signálu ... 15

4.2.3 Detekce R kmitů ... 15

4.2.4 Analýza energie signálu klouzavým oknem ... 16

4.2.5 Detekce komorových extrasystol ... 17

4.3 DETEKCE KOMOROVÝCH EXTRASYSTOL POMOCÍ HLUBOKÉHO UČENÍ ... 18

4.4 DETEKCE KES VYUŽITÍM VYLEPŠENÉHO ALGORITMU K POROVNÁVÁNÍ VZORCŮ ... 19

4.5 DETEKCE BLOKÁD TAWAROVÝCH RAMÉNEK POMOCÍ EXTRAKCE PŘÍZNAKŮ ... 21

4.5.1 Detekce blokád levého Tawarova ramének ... 21

4.5.2 Detekce blokády pravého Tawarova ramének ... 22

4.6 DETEKCE BLOKÁD KOMBINACÍ GENETICKÉHO ALGORITMU (GA) A UMĚLÉ NEURONOVÉ SÍTĚ (UNN) ... 23

4.6.1 Extrakce příznaků ... 23

4.6.2 Redukce příznaků pomocí genetického algoritmu (GA) ... 24

4.6.3 Klasifikace pomocí UNN-GA ... 25

4.7 DETEKCE BLOKÁDY TAWAROVA RAMÉNKA UŽITÍM STATISTICKÝCH PŘÍZNAKŮ QRS KOMPLEXU A K-NEJBLIŽŠÍCH SOUSEDŮ ... 27

4.8 DETEKCE KOMOROVÝCH EXTRASYSTOL DESKRIPTORŮ HILBERTOVY TRANSFORMACE ... 28

4.9 SYSTÉM DETEKCE KOMOROVÝCH EXTRASYSTOL POMOCÍ NASTAVITELNÉ Q-FAKTOR VLNKOVÉ TRANSFORMACE (TQWT) ... 29

4.10 DETEKCE KES UŽITÍM ZLOMKOVÉ VLNKOVÉ TRANSFORMACE V KOMBINACI S ANALÝZOU HLAVNÍCH KOMPONENT (PCA) ... 30

4.11 DETEKCE LEVÉ BLOKÁDY TAWAROVA RAMÉNKA UŽITÍM DISKRÉTNÍ VLNKOVÉ TRANSFORMACE (MODWT) S MAXIMÁLNÍM PŘEKRYTÍM V KOMBINACI S ADAPTIVNÍM NEURO FUZZY INFERENČNÍM SYSTÉMEM (ANFIS) 31
4.12 DETEKCE BLOKÁD TAWAROVÝCH RAMÉNKA UŽITÍM ADAPTIVNÍ BAKTERIÁLNÍ HLEDACÍ OPTIMALIZACE A UMĚLÉ NEURONOVÉ SÍTĚ 32

5. REALIZACE DETEKČNÍCH METOD 34

5.1 DATABÁZE BTL 34
5.2 PŘEDZPRACOVÁNÍ DAT 35
5.3 DETEKCE KOMOROVÝCH EXTRASYSTOL (KES) 38
5.3.1 Příprava trénovacích dat (KES/sinus V1) 42
5.3.2 Vytvoření klasifikačního modelu KNN 44
5.3.3 Klasifikace testovacích dat 45
5.3.4 Optimalitace metody 45
5.4 DETEKCE BLOKÁD TAWAROVÝCH RAMÉNEK POMOCÍ STATISTICKÉ ANALÝZY QRS KOMPLEXŮ A JEJICH NÁSLEDNÝM KLASIFIKOVÁNÍM POMOCÍ METODY K-NEJBLIŽŠÍCH SOUSEDŮ 47
5.4.1 Vytvoření trénovacích dat 50
5.4.2 Vytvoření klasifikačního modelu KNN 52
5.4.3 Klasifikace testovacích dat 53
5.4.4 Optimalizace metody 53
5.5 ÚSPĚŠNOST REALIZOVANÝCH METOD 54

LITERATURA 60

SEZNAM PŘÍLOH 62

SEZNAM SYMBOLŮ A ZKRATEK 63

SEZNAM OBRÁZKŮ

Obr. 1 Hrudní svody EKG [18] 2
Obr. 2 Základní EKG křivka a její intervaly [19] 4
Obr. 3 Abnormální vlna P před nástupem tachykardie [3] 6
Obr. 4 Příklad KES na vybraných svodech [8] 8
Obr. 5 Vlna S vytvářející zářezy u BLRT [14] 10
Obr. 6 Příklady BPRT na svodech V1 a V6 [15] 11
Obr. 7 Blokové schéma metody (4.2) [21] 15
Obr. 8 Okna RR intervalů, které překročily nastavený práh [21] 16
Obr. 9 EKG signál a jeho distribuce energie [21] 17
Obr. 10 Detekce KES průnikem oken [21] 18
Obr. 11 Schéma metody [25] 19
Obr. 12 Postup rozpoznání KES [27] 20
Obr. 13 Blokové schéma metody 4.4 [22] 23
Obr. 14 Vybrané příznaky [22] 24
Obr. 15 Proces trénování genetického algoritmu (GA) 26
Obr. 16 Vektorkardiogram a) normálního QRS b) KES komplexu [33] 28
Obr. 17 Spektrum fourierovy transformace pro a) normální a b) KES vektorkardiodiagramů [33] 28
Obr. 18 Svazky a) KES a b)normálních signálů po TQWT [34] 29
Obr. 19 Postup Bakteriální hledací optimalizace [37] 32
Obr. 20 Vlastnosti Butterworth filtru typu horní propust 35
Obr. 21 Vlastnosti Butterworth filtru typu pásmová zádrž 36
Obr. 22 Signál před filtrací 36
Obr. 23 Signál po filtraci 37
Obr. 24 Blokové schéma metody detekce KES 38
Obr. 25 Předčasnost jednotlivých tříd metody detekce KES 39
Obr. 26 Kompenzace jednotlivých tříd metody detekce KES 39
Obr. 27 Průměr jednotlivých tříd metody detekce KES 40
Obr. 28 Rozptyl jednotlivých tříd metody detekce KES 40
Obr. 29 Směrodatná odchylka jednotlivých tříd metody detekce KES 41
Obr. 30 Šikmost jednotlivých tříd metody detekce KES 41
Obr. 31 Křivost jednotlivých tříd metody detekce KES 42
Obr. 32 Sinusový rytmus 43
Obr. 33 Morfologie KES 44
Obr. 34 KNN model pro detekci KES 45
Obr. 35 Metoda detekce blokád Tawarových ramének 47
Obr. 36 Průměr jednotlivých tříd 48
Obr. 37 Rozptyl jednotlivých tříd 48
Obr. 38 Směrodatná odchylka jednotlivých tříd 49
Obr. 39 Šikmost jednotlivých tříd 49
Obr. 40 Křivost jednotlivých tříd 50
Obr. 41 Fyziologický QRS komplex 51
Obr. 42 Blokáda levého Tawarova raménka (LBBB) 51
Obr. 43 Blokáda pravého Tawarova raménka (RBBB) 52
Obr. 44 Přehlad KNN modelu 53

SEZNAM TABULEK

Tab. 1 Úspěšnost detekce KES 55
Tab. 2 Úspěšnost detekce BBB 55
Tab. 3 Porovnání detekce BBB vůči jiným metodám 56
Tab. 4 Porovnání detekce KES vůči jiným metodám 56

1. ÚVOD

Kardiovaskulární systém patří mezi nejvýznamnější ústrojí lidského těla. Je odpovědné za přísun kyslíku a dalších významných živin do všech částí lidského těla a zároveň i odvod oxidu uhličitého a dalších odpadních látek. Hlavním centrem celého systému je srdce (cor). Srdce je dynamické, neúnavné, přesně nastavitelné dvojité čerpadlo, které zajišťuje oběh krve v celém těle. Síla srdce vychází z jeho komor (ventrikulus), jejichž stěny jsou tvořeny silnou svalovinou myokardu. Při svém stahu vypuzují krev do aorty a malého krevního oběhu. Nad komorami leží předsíně (atrium). Mají tenčí stěny a fungují spíše jako pasivní rezervoáry pro krev. Každý úder srdce má 2 fáze. V první fázi (diastole) je srdeční svalovina ochablá a srdce se plní krví, při druhé fázi (systole) se stáhne a vypudí krev. Celý cyklus trvá méně než jednu sekundu. Během života je srce schopno vykonat i více než tři miliardy cyklů. [1]

Srdce není dokonalé, a proto dochází i k poruchám. Mezi tyto poruchy se řadí i arytmie, které jsou cílem zájmu této bakalářské práce. Při arytmii se srdeční rytmus neobvykle zpomaluje, zrychluje nebo je nepravidelný. V normálním případě pokyn ke stahu srdce vzniká v buňkách tzv. pace-makeru SA uzlu, uloženého v horní části pravé předsíně. Vzniklé elektrické vzruchy jsou šířeny svalovinou předsíně a vyvolají stah. Tyto signály jsou poté přepojovány v AV uzlu a jsou dále šířeny vlákny převodního systému mezikomorovým septem do silné svaloviny komor. Podle místa poruch převodu elektrického vzruchu rozlišujeme různé typy arytmií. [1]

Tato bakalářská práce je zaměřena na metody detekce komorových extrasystol (KES), blokád Tawarových ramének (BLRT/LBBB – levé raménko, BRRT/RBBB – pravé raménko) ze záznamu elektrokardiografu (EKG). Následně budou realizována metoda detekce komorových extrasystol kombinací pomocí metody RR intervalů z kapitoly 4.1 a metody popsané v kapitole 4.7. Dále bude realizována metoda detekce blokád Tawarových ramének podle metody zmíněné v části 4.7.

2. ELEKTROKARDIOGRAM (EKG)

Elektrokardiogram (zkráceně EKG) je záznam elektrické činnosti srdce, jenž je získán neinvazivně (z povrchu těla) pomocí Ag/AgCl elektrod. Tato modalita má významný klinický dopad na detekci a vyhodnocení závažnosti kardiovaskulárních chorob. [2] [3] [4]

Konvenční přístroj na měření EKG se skládá ze 12 svodů, rozdělených do dvou skupin (končetinové svody a hrudní svody). Končetinové svody se dále kategorizují na bipolární končetinové svody (I, II, II) a unipolární svody (aVL, aVF, aVR). Hrudní svody zahrnují svody V1 až V6.

Končetinové svody zaznamenávají aktivitu srdce ve vertikální ploše a hrudní svody v ploše horizontální. [4]

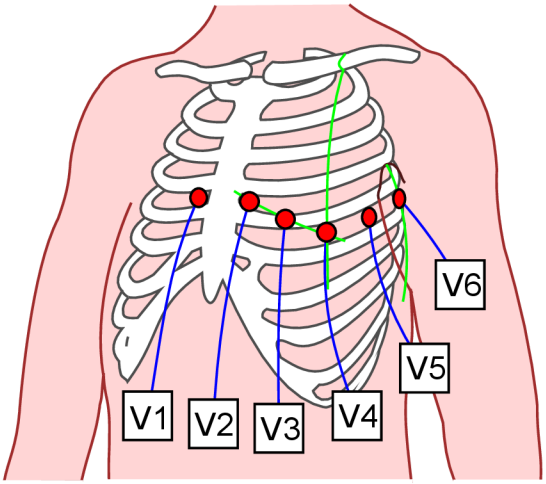

Obr. 1 Hrudní svody EKG [18]

Tři bipolární a tři unipolární svody jsou získány ze tří končetinových elektrod (levá horní končetina, pravá horní končetina a levá dolní končetina – zemnící elektroda).

Bipolární svody zobrazují rozdíl potenciálů mezi dvěma ze tří elektrod:

- Svod I: pravá horní končetina – levá horní končetina
- Svod II: pravá horní končetina – levá dolní končetina
- Svod III: levá dolní končetina – levá horní končetina

Unipolární svody zobrazují rozdíl potenciálů jedné elektrody a odhadu nulového potenciálu (derivované ze zbývajících dvou elektrod). Tyto svody jsou také známy jako augmentované svody. Jedná se o:

- aVR svod: pravá horní končetina
- aVL svod: levá horní končetina
- aVF svod: levá dolní končetina

Hrudní svody jsou unipolární a zobrazují rozdíl potenciálů vybrané hrudní elektrody vůči nulovému potenciálu (derivovaného z průměru potenciálů končetinových elektrod). [5]

2.1 EKG křivka

EKG přístroj zpracovává signál získaný z povrchu těla za pomocí elektrod a tvoří grafickou reprezentaci elektrické aktivity srdce pacienta.

Základní vzor EKG křivky:

- Elektrická aktivita směřovaná k elektrodě způsobuje pozitivní odchylku.
- Elektrická aktivita směřovaná od svodu způsobuje negativní odchylku.
- Odchylky depolarizace a repolarizace jsou vzájemně opačné.

Základní EKG křivka se skládá z vlny P, QRS komplexu a vlny T (Obr.2).

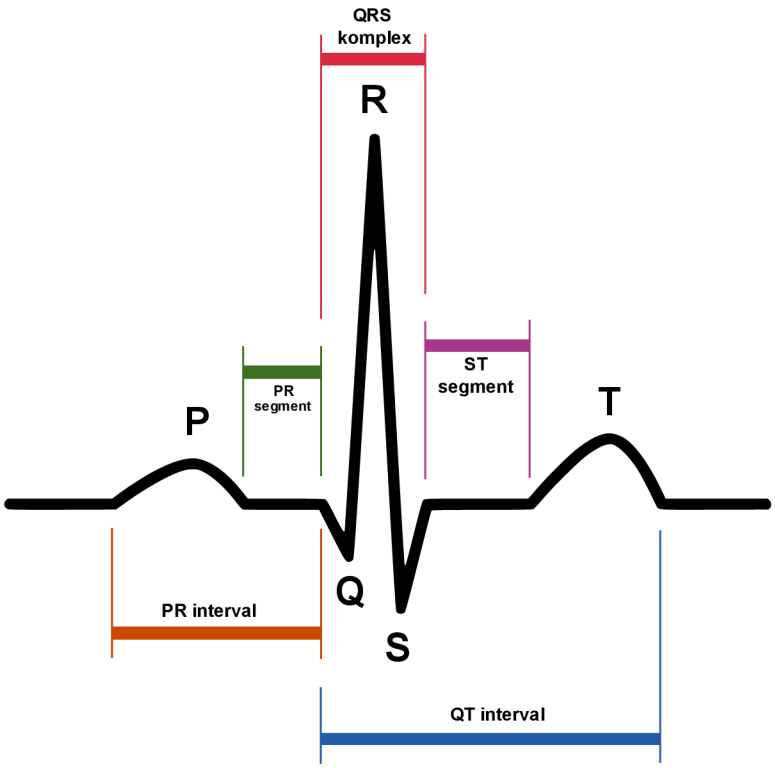

Obr. 2 Základní EKG křivka a její intervaly [19]

2.1.1 Vlna P

Reprezentuje depolarizaci síní. Fyziologicky má amplitudu vlny 0,25 mV a délku 0,11s. Vlna P ve svodu I a II je pozitivní. [5]

2.1.2 PR interval

Časový interval mezi P vlnou a QRS komplexem. Fyziologické hodnoty nepřesahují rozmezí 0,12-0,2s. [5]

2.1.3 QRS komplex

Celý komplex QRS reprezentuje depolarizaci komor a zároveň i repolarizaci síní.

Q vlna odpovídá depolarizaci mezikomorového septa, R vlna odpovídá depolarizaci hlavní masy komor – nejvyšší výchylka a S vlna značí konečnou depolarizaci komor. Délka QRS komplexu fyziologicky není větší než 0,12s. [5]

2.1.4 ST segment

Časový interval mezi koncem QRS komplexu a začátkem vlny T. Značí dobu nulového potenciálu mezi depolarizací a repolarizací komor. [5]

2.1.5 Vlna T

Reprezentuje repolarizaci komor. Fyziologicky je konkordantní – má stejnou polaritu jako nejvyšší kmit QRS komplexu ve svodech I, II a III. V opačném případě je vlna diskordantní a patologická. [5]

3. SRDEČNÍ ARYTMIE

Arytmie se mohou definovat jako porucha fyziologického srdečního rytmu. Arytmie mohou být asymptomatické (nevykazují příznaky) nebo mohou způsobovat palpitaci (nepříjemně vnímané údery srdce), porucha hydrodynamiky (proudění krve v kardiovaskulárním systému). K dalším projevům mohou být synkopy, dušnost, pocit nepohodlí vycházející z hrudníku nebo srdeční zástava. [2]

Mechanismy vzniků arytmií jsou rozděleny do dvou základních kategorií:

1) <u>Abnormální formace impulsu (např. fokální aktivita):</u>

Abnormální formace impulzu může být způsobena expresí ektopických pacemakerů. Tyto pacemakery se nacházejí mimo SA uzel a mohou způsobovat spontánní depolarizaci myokardu. [3]

2) <u>Poruchy šíření vzruchu (např. reentry):</u>

Reentry je cirkulární propagace impulzu po 2 a více propojených drahách s různou vodivostní charakteristikou a refrakterní dobou (doba, během které není možné zahájit další aktivitu). Za běžných podmínek může reentry způsobovat kontinuální cirkulaci aktivační vlny, která ve výsledku může způsobit tachyarytmii.

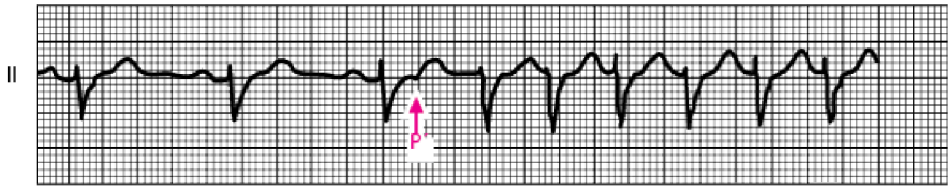

Obr. 3 Abnormální vlna P před nástupem tachykardie [3]

Diagnostika arytmií se opírá o EKG vyšetření. K vyšetření je nutné 12 svodové EKG nebo záznam rytmu získaného v době projevů příznaků.

Ke klíčovým diagnostickým znakům patří:

- Tempo a pravidelnost síňové aktivace
- Tempo a pravidelnost komorové aktivace
- Vztahy mezi jednotlivými aktivacemi

Nepravidelné aktivační signály jsou klasifikovány jako pravidelně nepravidelné nebo nepravidelně nepravidelné (bez detekovatelného vzorce).

Léčba detekovaných arytmií záleží na symptomech a rizicích detekované arytmie. Pokud je arytmie bez příznaků a bez vážných rizik, poté nemusí být léčena. U symptomatických arytmií, které ohrožují pacienta na životě, je léčba prováděna farmakologicky, kardioverzní defibrilací, kardiostimulátory, umělými pacemakery nebo ablační operací.

3.1 Komorové extrasystoly (KES)

Komorové extrasystoly (KES) jsou předčasné depolarizace myokardu začínající v srdeční komoře (v Purkyňových vláknech) místo v SA uzlu.

Komorové extrasystoly mohou nastat buď izolovaně nebo s určitou pravidelností. Podle počtu kontinuálních komorových extrasystol se rozděluje na:

- Dvě komorové extrasystoly = duplet
- Tři komorové extrasystoly = triplet
- Tři a vice KES = komorová tachykardie

převzato z [6]

Komorové extrasystoly se vyskytují s prevalencí 1-4% ze standardního 12 svodového EKG. [7] V převážné majoritě případů, komorové extrasystoly nemají známý původ a mohou nastat spontánně. K nejběžnějším etiologiím patří nadměrná konzumace kofeinu, katecholaminu, nadměrné hladiny stresu a elektrolytické abnormality (nízká hladina draslíku a hořčíku a vysoká hladina vápníku). Alkohol, tabák i nedostatek spánku mají také spojitost s výskytem KES. [6]

K patofyziologickým důvodům k výskytu komorových extrasystol patří ektopická (mimo obvyklé místo) nodální aktivita. Tato možnost ukazuje na schopnost ektopických pacemakerových buněk nést podprahový potenciál, který při elektrické aktivitě srdce může způsobit ektopický srdeční cyklus.

Druhý patofyziologický důvod je reentry šíření impulzu, kdy dochází k bloku jedné z drah Purkyňových vláken a další dráha má sníženou vodivost. Tyto stavy mohou způsobit ektopické šíření na post-blokové dráze. [6]

Na molekulární úrovni dochází k několika změnám, které mohou vytvářet vhodné prostředí pro spontánní depolarizace komorového myokardu. K těmto změnám patří hypokalémie, hypomagnesémie, nadměrná hladina vápníku a katecholaminů. [6]

Znaky komorové extrasystoly (KES) na elektrokardiogramu (EKG):

- široký QRS komplex (nad 0,12 s) s abnormální morfologií,
- předčasný výskyt (mimo pravidelnost sinusového rytmu),
- diskordantní ST úsek a vlna T,
- KES je následována plnou kompenzační pauzou.

KES se mohou klasifikovat na:

- Unifokální = z jednoho ektopického fokusu; KES jsou identické
- Multifokální = z více ektopických fokusů; různá morfologie QRS při KES

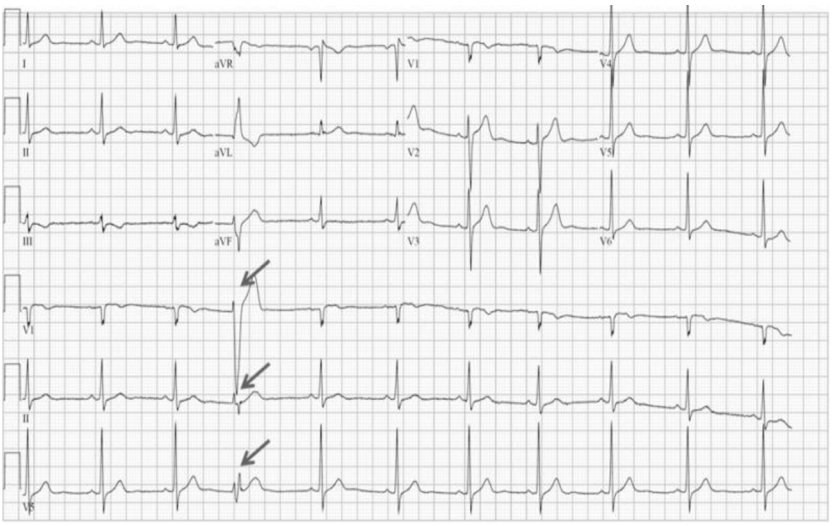

Obr. 4 Příklad KES na vybraných svodech [8]

převzato z [8]

3.2 Blokády Tawarových ramének

3.2.1 Blokáda levého Tawarova raménka

Blokáda levého Tawarova raménka (BLRT, LBBB) je následek anatomické a funkční poruchy v levém raménku.

Komorová depolarizace standardně začíná v mezikomorovém septu. Depolarizace septa začíná v jeho levé části a směřuje k pravé části a produkuje malé R kmity ve svodu V1, V2 a malé Q vlny ve svodu V5 a V6. V případě blokády levého Tawarova raménka dochází k depolarizaci septa impulzy z pravé komory. Malé R (svody V1-V2) a Q (svody V5-V6) kmity jsou redukovány nebo chybějící. Depolarizace je pomalu šířena ke stěně levé komory a vektor depolarizace je dále šířen doleva. Toto způsobí širokou vlnu S ve svodech V1 a V2 (QS komplex, pokud r vlna chybí) a širokou, neforemnou R vlnu ve svodech V5-V6. Vlny R mohou mít na vrcholu zářezy. [13]

Protože je depolarizace levé komory abnormální, repolarizace bude také abnormální a sekundární změny ST úseku jsou vždy přítomné. U levé blokády je očekávána deprese ST úseku a inverze T vlny ve svodech V5,V6,I a aVL. Zároveň svody V1-V3 zobrazují elevaci ST úseku a vysoké R vlny. [13]

Základní kritéria Blokády levého Tavarowa raménka (BLRT, LBBB):

- Doba trvání QRS komplexu je delší než 0,12s.
- Svody V1-V2 vykazují hlubokou a širokou vlnu S. Malá R vlna chybí nebo je menší než normální.
- V případě absence R vlny je přítomen QS komplex ve svodu V1. Ve svodu V1 může mít vlna S zářezy a připomínat písmeno “W“, tato vlastnost však není vždy přítomná.
- Ve svodech V5-V6 je široká, netaktní, pozitivní vlna R s možnými zářezy.
- Svody I a aVL jsou podobné svodům V5 a V6,
- ST-T změny: Svody V5, V6, I a aVL zobrazují inverzi vlny T a depresi ST úseku.
- svody V1-V3 vykazují elevaci ST úseku a pozitivní T vlny.
- Deviace srdeční osy směřuje doleva.

Obr. 5 Vlna S vytvářející zářezy u BLRT [14]

převzato z [14]

3.2.2 Blokáda pravého Tawarova raménka

Blokáda pravého Tawarova raménka (BPRT, RBBB) nastává v případě změny nebo přerušení převodního systému srdečního v oblasti His-Purkyňova systému.

V případě RBBB je levá komora aktivována normálně a počáteční část QRS, korelující k septální depolarizaci, je stejná s fyziologickou. Aktivace pravé komory je opožděná (depolarizace je šířena z levé komory pomalu přes septum). Tato opožděná aktivace produkuje sekundární R´ vlny v hrudních svodech a širokou, nezřetelnou vlnu S v končetinových svodech. Normální aktivace levé komory znamená nezměněnou/normální osu srdeční. [15]

Mezi hlavní kritéria RBBB patří:

- Délka QRS je delší nebo rovna 0,12s.
- Ve svodech V1 a V2 se vyskytuje RSR' komplex.
- Ve svodech I a V6 trvá vlna S déle než vlna R nebo vlna S je delší než 40ms.
- Ve svodech V5 a V6 je vlna R normální.
- Ve svodu V1 je vlna R delší než 50ms.
- Vlna T bývá diskordantní vůči QRS komplexu.

Obr. 6 Příklady BPRT na svodech V1 a V6 [15]

4. METODY DETEKCE KOMOROVÝCH EXTRASYSTOL A BLOKÁD TAWAROVÝCH RAMÉNEK

V této části jsou popsány vybrané dostupné metody detekcí komorových extrasystol a blokád Tawarových ramének. Jsou zde popsány jak konvenční přístupy, tak i přístupy využívající strojového učení a neuronových sítí.

4.1 Detekce komorových extrasystol podle RR intervalů

První vybraná konvenční metoda je detekce komorových extrasystol (KES) pomocí RR intervalů, extrahovaných ze záznamu EKG. Tato metoda bude zároveň realizována v praktické části této práce.

Hlavním krokem vybrané metody je extrakce vybraných příznaků charakterizující komorové extrasystoly. [9] Prvním krokem je zvýraznění QRS komplexů pomocí filtrace EKG signálu pásmovou propustí. Po filtraci následuje umocnění daného signálu, které vede ke zvýraznění QRS komplexů. Výsledné polohy QRS komplexů jsou dány určením extrémů (maxim) v daném záznamu. [10]

Komorové extrasystoly začínají předčasným pulzem, což znamená, že RR interval mezi KES a předchozím normálním cyklem je kratší než průměrná vzájemná vzdálenost RR kmitů. Tento předčasný nástup je následován kompenzační pauzou, která může být spojována s fluktuací vůči normální vzdálenosti mezi následnými srdečními cykly. [9]

K výpočtu předčasného nástupu a kompenzační pauzy byla získána průměrná vzdálenost všech RR intervalů v záznamu a hodnoty byly vypočítány dle rovnic

$$Předčasnost = \frac{(avgRRdist - RRbeat)}{avgRRdist}, \tag{4.1}$$

$$Kompenzační\, pauza = \frac{(RRbeat1 - avgRRdist)}{avgRRdist}, \tag{4.2}$$

kde avgRRdist představuje průměrnou hodnotu RR intervalu, RRbeat odpovídá RR intervalu mezi normálním cyklem a KES a RRbeat1 odpovídá RR intervalu mezi KES a následujícím cyklem.

Metoda byla autory testována na veřejně dostupné databázi arytmií MIT-BIH dostupné ze stránek PhysioNet (https://www.physionet.org) [9]. Ve vybraných záznamech EKG bylo přítomno 41869 normálních cyklů a 6327 komorových extrasystol (KES)

Autory dané metody bylo empiricky zjištěno, že normální sinusové cykly mají hodnoty blízké nule (resp. -0,048 a -0,027; pro danou práci), zatímco průměrné hodnoty pro KES byly mezi 0,265 a 0,203 (pro danou práci). [9]

K výhodám výše zmíněné metody patří její jednoduchost. Je výpočetně nenáročná a vyžaduje pouze vzdáleností R kmitů v záznamu. Algoritmus využívá pouze dva příznaky (předčasnost a kompenzační pauza). Z tohoto důvodu algoritmus selhává při detekci bigeminálních kupletů (párů) komorových extrasystol nebo v případě výskytu komorové tachykardie. Algoritmus může také zaměnit síňové extrasystoly za komorové. [9]

4.2 Detekce a lokalizace komorových extrasystol pomocí vlnkové transformace a energie signálu

4.2.1 Vlnková transformace

Vlnková transormace je zobrazení signálu na množině bázových funkcí (vlnek), které jsou derivovány z vyšší bázové funkce (mateřská vlnka) kontrakčními a dilatačními operátory. Tato transformace je založená na konvoluci signálu z dilatovaným filtrem. Vlnková analýza rozděluje signál na jeho frekvenční části a je závislá na mateřské vlnce. [21]

Obecná transformační funkce vlnkové transformace je definován rovnicí

$$x(a,b) = \int_{-\infty}^{\infty} x(t)\varphi_{a,b}(t)dt\,, \tag{4.3}$$

kde x(t) představuje signál pro zpracování a φ(t) odpovídá vlnkové funkci.

Vlnková funkce φ ve spojité transformaci (CWT) je dána rovnicí

$$\varphi_{a,b}(t) = \left(\frac{1}{\sqrt{a}}\right) * \varphi\left(\frac{t-b}{a}\right), \tag{4.4}$$

kde a,b jsou dilatační a kontrakční parametry a φ je mateřská vlnka.

V diskrétní transformaci (DWT) je vlnková funkce φ popsána vztahem

$$\varphi \mathrm{m,n(x)} = \frac{1}{\sqrt{a_0^m}}\varphi\left(\frac{x}{a_0^m} - nb_0\right), \tag{4.5}$$

kde m je frekveční měřítko, koeficienty a,b představují dilatační a kontrakční parametry a n je časové posunutí.

4.2.2 Energie signálu

Energie signálu může být odhadnuta plochou pod křivkou, která také může mít i zápornou část. Tato část také přispívá stejnou měrou jako kladná část signálu se stejnou velikostí. Energie signálu může být tedy vypočítána buď umocněním signálu nebo pomocí jeho absolutní hodnoty a následné nalezení plochy pod křivkou. [21]

Energie spojitého signálu x(t) v časovém intervalu $t_1 < t < t_2$ je dána vztahem

$$E = \int_{t1}^{t2} |x(t)|^2 \, dt \, . \tag{4.6}$$

kde t_1 a $< t_2$ představují konce časového úseku a x(t) odpovídá signálu v čase t.

Energie diskrétního signálu x(n) v časovém intervalu $n_1 < n < n_2$ je dána vztahem

$$E = \sum_{n=n1}^{n2} |x(n)|^2 \, . \tag{4.7}$$

kde n_1 a $< n_2$ představují vzorky na koncích intervalu a x(n) představuje signál ve vzorku n.

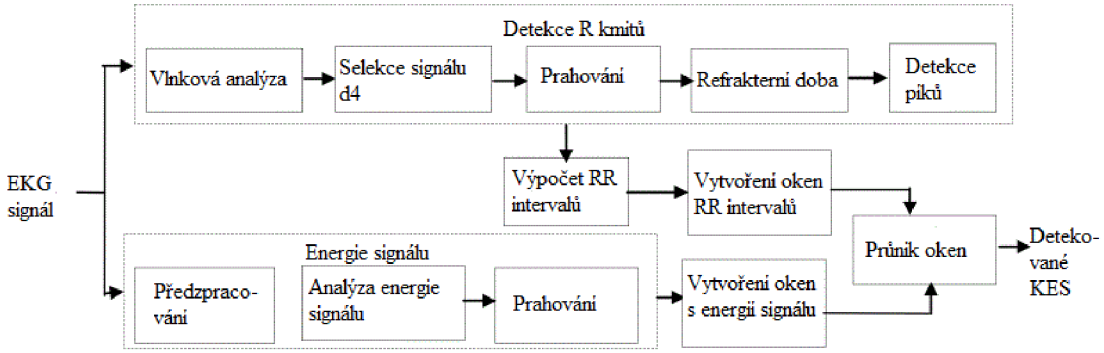

Obr. 7 Blokové schéma metody (4.2) [21]

4.2.3 Detekce R kmitů

EKG signál je rozložen na 8 úrovní použitím db6 vlnky, jejíž morfologie je podobná QRS komplexu a dále je provedena energetická, frekvenční analýza a vzájemná korelace všech získaných rozložených signálů pro výběr relevantního koeficientu

detailu pro detekci R kmitů. V těchto analýzách bylo zjištěno, že koeficient detailu (d4) získaný po rozkladu má maximální energii a nejvyšší hodnotu koeficientu vzájemné korelace. Vybraný signál d4 prochází prahováním, aby byla většina nechtěných vrcholů EKG eliminována, a dále je aplikována refrakterní doba 200 milisekund pro detekci skutečných vrcholů.

V další fázi jsou vypočítány intervaly po sobě jdoucích píků a na závěr je vytvořeno okno, které značí RR interval, který překročil 75% maximální hodnoty RR intervalu.

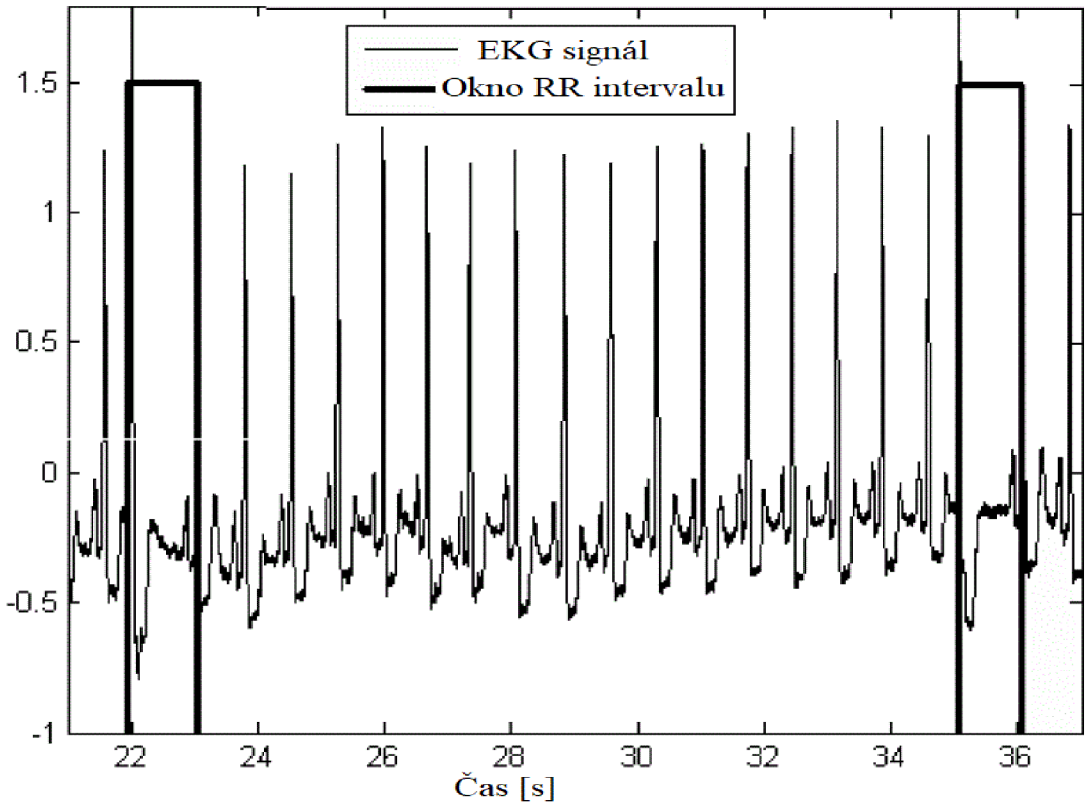

Obr. 8 Okna RR intervalů, které překročily nastavený práh [21]

4.2.4 Analýza energie signálu klouzavým oknem

Před samotnou detekcí je důležitá filtrace signálu od nízkofrekvenčních artefaktů. Zkoumaný signál je filtrován Butterworth horní propustí čtrvtého řádu s hraniční frekvencí 2 Hz.

Filtrovaný signál je poté analyzován za pomocí klouzavého okna o délce 600 milisekund. Pokud délka signálu není dělitelná délkou okna, pak je signál prodloužen nulovými hodnotami, aby bylo možné vypočítat energii posledního okna.

Části signálu s nižšími hodnotami energie jsou odstraněny nastavením práhu 60% maximální hodnoty energie. Výsledkem jsou okna mezi dvěmi sekcemi signálu, které mohou odpovídat výskytu komorové extrasystoly.

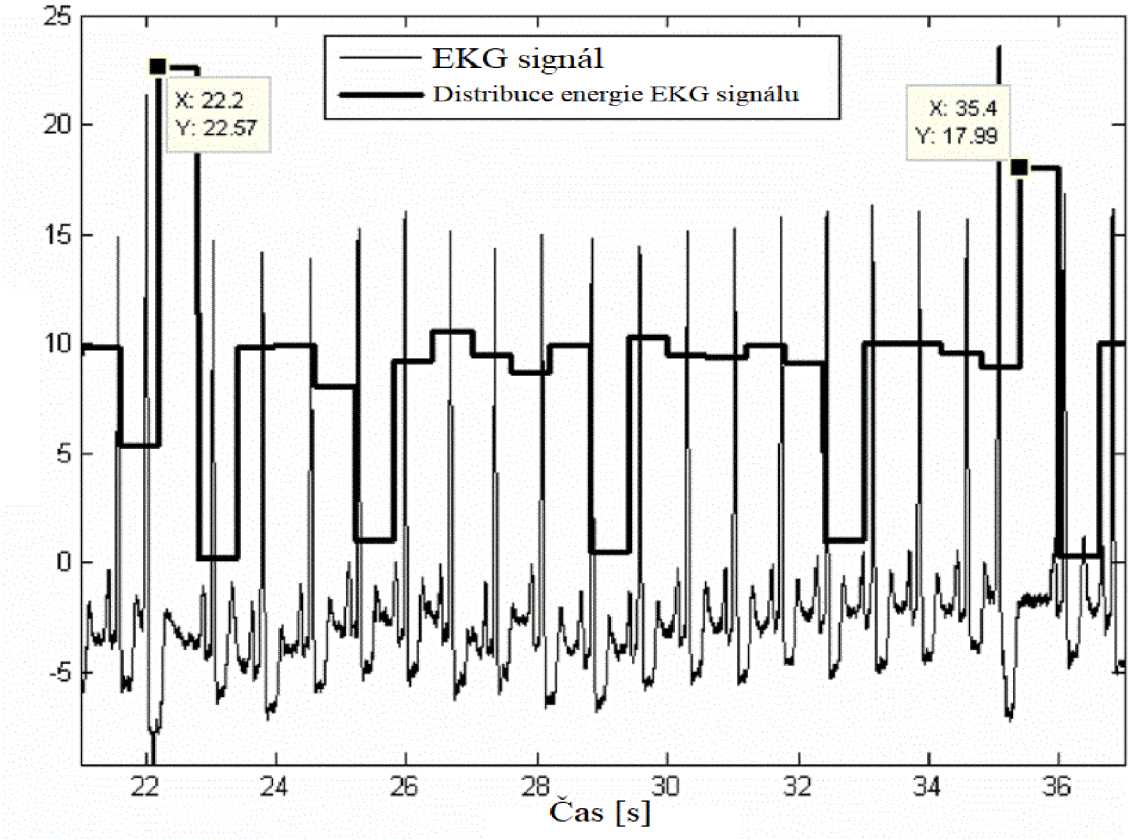

Obr. 9 EKG signál a jeho distribuce energie [21]

4.2.5 Detekce komorových extrasystol

Za skutečnou detekci a lokalizaci komorových extrasystol je považován průnik oken RR intervalu a energii. Okno RR intevalu je superponováno přes energetické okna je získáno průnikové ekno, které značí skutečný počet a polohy komorových extrasystol.

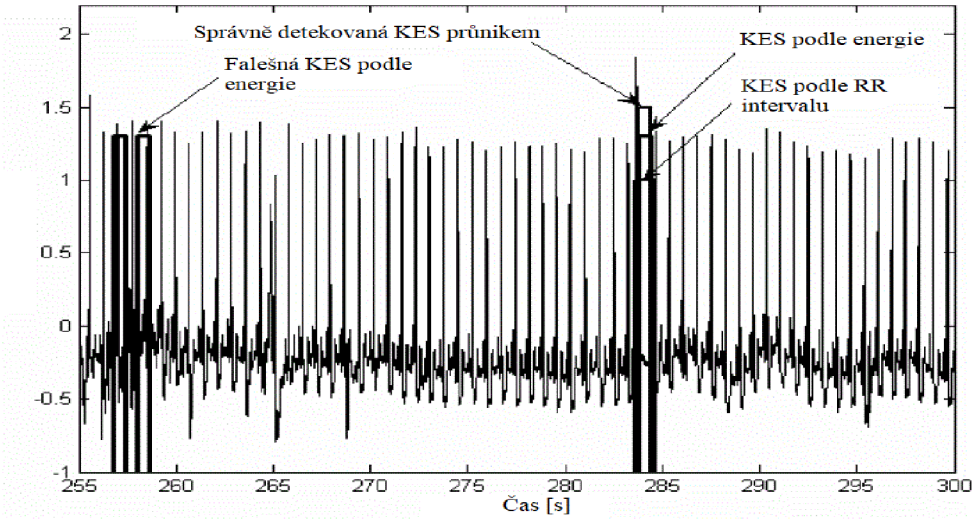

Obr. 10 Detekce KES průnikem oken [21]

Metoda byla jejímy autory testována na veřejně dostupné databázi arytmií MIT-BIH dostupné ze stránek PhysioNet (https://www.physionet.org) [21] s úspěšností 86,48%.

[21]

4.3 Detekce komorových extrasystol pomocí hlubokého učení

Tato detekce komorových exstrasystol se skládá z extrakce příznaků a klasifikace QRS komplexů. Cílem extrakce je detekce tří různých charakteristických částí QRS komplexu. QRS komplex obsahuje důležité informace, které mohou být využity k detekci KES.

V této metodě je použit Pan-Tompkinsův algoritmus k detekci QRS komplexů, poté jsou extrahovány 4 příznaky: velikost R kmitu, RR interval, QRS doba, komorová aktivační doba a velikosti Q a S vlny. Tyto příznaky jsou použity ke klasifikaci, pro kterou je vytvořena hluboká neuronová síť se 6 vstupy a 2 výstupy.

Síť je optimalizována kombinací hodnot K v K-násobné křížové validaci, architektury skryté vrstvy, metody inicializace vah, metody regularizace, počtu trénovacích kroků, rychlostí učení, typy aktivačních funkcí a optimalizátoru. [25]

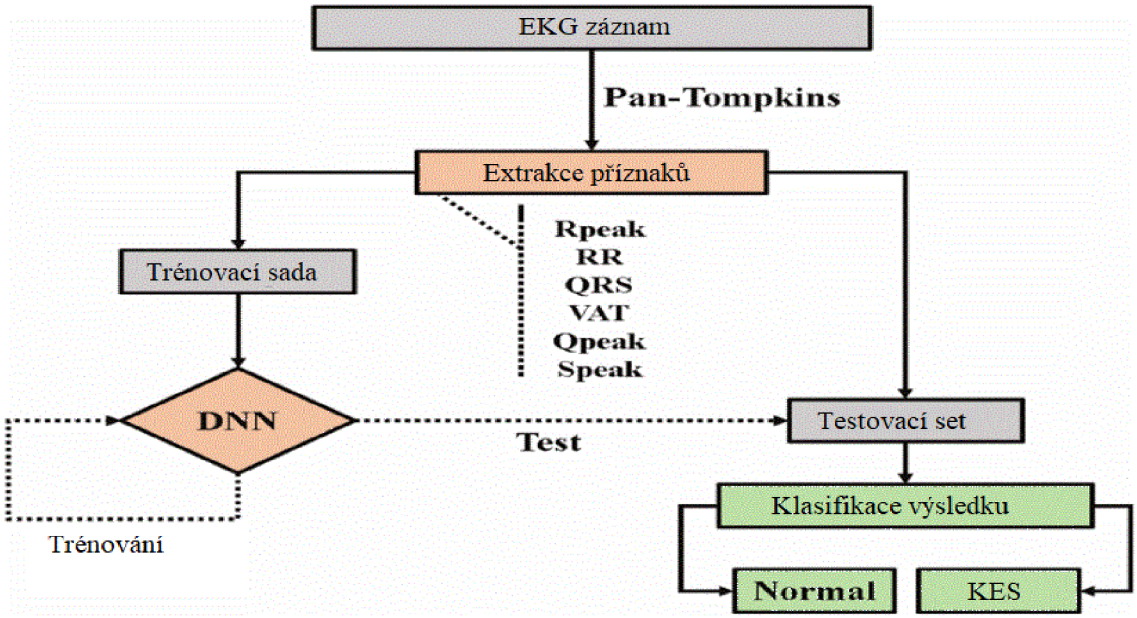

Obr. 11 Schéma metody [25]

4.4 Detekce KES využitím vylepšeného algoritmu k porovnávání vzorců

Metoda se skládá ze 4 částí: Předzpracování, detekci R kmitů, extrakci hlavních příznaků EKG a detekce komorových extrasystol. V předzpracovací části je signál filtrován tak, aby byly zachovány přesná morfologie EKG signálu. R kmity jsou detekovány pomocí vhodného detektoru (např. užitím vlnkové transformace z kapitoly 4.2.1).

Ze záznamu EKG jsou dále extrahovány příznaky potřebné k detekci KES. Mezi vybrané příznaky patří RR interval, délka QRS komplexu, amplituda R kmitu, detekce vlny T. K extrakci příznaků je signál EKG segmentován na jednotlivé cykly s rozsahem 0.25s před R kmitem a 0.44s za R kmitem.

Samotná detekce komorových extrasystol je založená na korelaci jednotlivých rytmů se šablonou (segment s fyziologickými parametry).

[27]

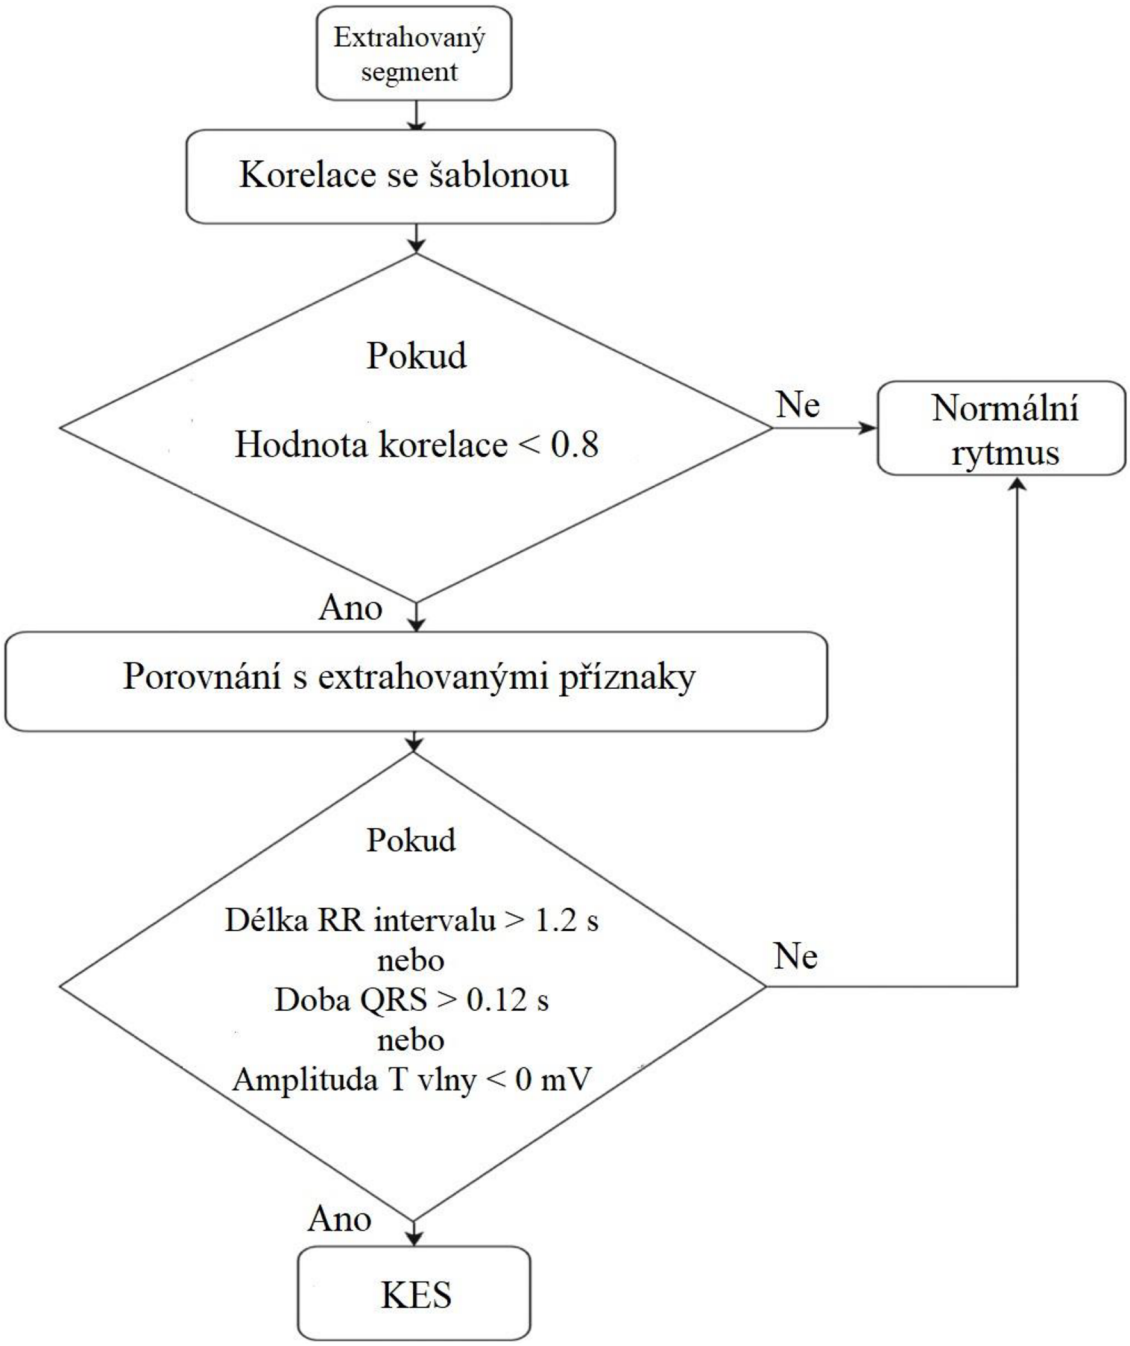

Obr. 12 Postup rozpoznání KES [27]

4.5 Detekce blokád Tawarových ramének pomocí extrakce příznaků

Důvodem k celému procesu extrakce příznaků je selekce a zachování relevantních informací z původního signálu. Vlna R je detekována využitím digitálních filtrů a následnou detekcí maxima.

Intervaly QRS, PR a QT jsou vypočítány hledáním počátečních a konečných bodů vln. Po získání polohy R vlny je vytvořeno okno, ve kterém jsou hledány maxima a minima. Detekce je poté určena analýzou parametrů dle níže zmíněných kritérií.

4.5.1 Detekce blokád levého Tawarova ramének

Pro vyhodnocení BLRT jsou potřeba pouze svody V6 a V1. Svod V6 je zpracován pro detekci dominantní nebo zářezovou vlnu (tvar "M"), dobu QRS komplexu a směr vlny T. [14] Mezi kritérie detekce patří:

- Dominantní vlna R je detekována zjišťováním vyšší hodnoty, než je hodnota vlny S, mezi vlnami S a Q.
- Doba QRS je vypočítaná rozdílem mezi začátkem vlny Q a koncem vlny S. Měla by být větší než 0,12s.
- Pro detekci vlny R ve tvaru "M" je vypočítán rozdíl mezi současnou hodnotou a hodnotou předchozí. Pokud jsou rozdíly větší než 0, pak se jedná o normální vlnu R. V opačném případě se jedná o zářezovou vlnu R.
- Pokud je hodnota vlny T menší než nula, pak je vlna T opačná k vlně QRS

Svod V1 je zpracován pro zjištění dominantní nezřetelné vlny S, doby QRS a směru vlny T. Ke kritériím detekce patří [14]:

- Dominantní vlna S je detekována kontrolováním každého bodu mezi vlnami Q a S.
- Doba QRS je vypočítána pomocí diference mezi začátkem vlny Q a koncem vlny S.
- Pokud je hodnota vlny T pozitivní, pak směr vlny T je opačný vůči QRS komplexu

4.5.2 Detekce blokády pravého Tawarova ramének

K detekci BPRT je potřeba pouze svodů V6 a V1.

Svod V6 je zpracován pro detekci dominatní, nezřetelné vlny S, QRS doby a směru vlny T. Mezi kritéria patří:

- Doba QRS komplexu je delší než 0,12s
- Hodnota vlny T je větší než 0 (nedochází k inverzi vlny T).

Svod V1 je zpracován pro detekci nezřetelné nebo zářezové vlny R, doby QRS a směru vlny T. Kritéria detekce jsou:

- Doba QRS komplexu je delší než 0,12s
- Dominantní vlna R je detekována zjišťováním každého bodu mezi vlnou Q a vlnou S, který je větší než hodnota maxima vlny S.
- Zářezová vlna R je detekována počtem procházení nulovou linií mezi vlnou Q a vlnou S. Počet průchodů musí být větší nebo roven 3.
- Pokud je hodnota vlny R menší než nula, pak se jedná on inverzi vlny T.

Metoda poskytuje jednoduchý a efektivní detekční algoritmus založena na extrakci příznaků. Efektivita detekce záleží na správné extrakci PQRST bodů. Efektivita algormitu může být vylepšena užitím statistiky vyššího řádu a metodou podpůrných vektorů. [17]

převzato z [17]

4.6 Detekce blokád kombinací genetického algoritmu (GA) a umělé neuronové sítě (UNN)

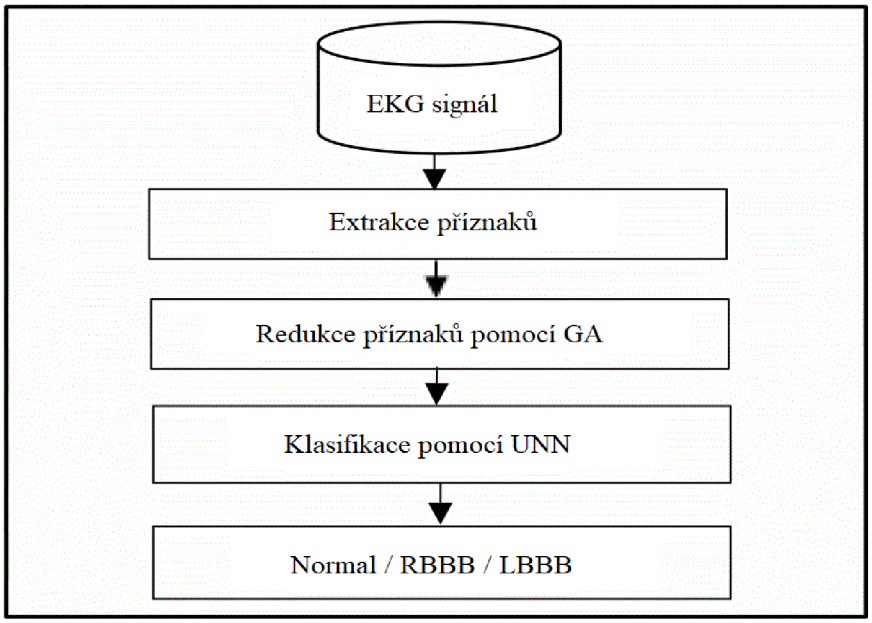

Obr. 13 Blokové schéma metody 4.4 [22]

4.6.1 Extrakce příznaků

Ze záznamu EKG bylo vybráno 19 dočasných příznaků včetně PR, PQ, RR a PT intervalu a tři morfologických příznaků. Mezi další příznaky patří QR, ST, RS intervaly a jejich rozdílové hodnoty, např. V(Q)-V(S). Morfologické znaky zahrnují minima a maxima každé vlny EKG signálu po normalizaci dle vzorce

$$f(t) = \frac{t(i) - \min(t)}{\max(t) - \min(t)}, \tag{4.8}$$

kde t(i) je hodnota v řadě a min,max představují minima a maxima řady.

Všechny příznaky pro jednotlivé cykly byly roztřízené do separátních vektorů jako N, LBBB nebo RBBB.

Příznak	Popis	Příznak	Popis
1	V(R1)	8	V(R2)-V(R1)
2	V(S)	9	X(R1)-X(S)
3	X(T)	10	X(S)-X(T)
4	V(P)	11	X(P)-X(T)
5	X(Q)	12	X(P)-X(Q)
6	X(R2)	13	X(Q)-X(R2)
7	V(R2)		

Obr. 14 Vybrané příznaky [22]

4.6.2 Redukce příznaků pomocí genetického algoritmu (GA)

GA je optimalizační technika, která replikuje přirozené přežití nejsilnějších, kde jsou podmnožiny funkcí s nejlepším výkonem zahrnuty do generování nových podmnožin funkcí. [22]

Další generace podskupin si zachovává příznivé vlastnosti, zatímco nepříznivé vlastnosti jsou vynechány, což vede k progresivní evoluci druhů. [22]

GA iteruje a vyvíjí populaci vytvářením nové populace na každém kroku prostřednictvím výběru, rekombinace, mutace, a nakonec aplikace fitness funkce. Proces výběru přímo vybírá podmnožiny prvků, které tvoří současnou populaci. Každá podmnožina (chromozom) je hodnocena pomocí fitness funkce. V rámci každé podmnožiny, křížení nebo rekombinace vytváří novou podmnožinu příznaků. Mutace je aplikovaná na každou podmnožinu příznaku za účelem vytvoření upravených podmnožin. Fitness funkce pak měří kvalitu řešení vyjádřenou jako procento správně klasifikovaných jedinců. [22]

4.6.3 Klasifikace pomocí UNN-GA

V dané metodě byla použitá kaskádová dopředná neuronová síť (CFNN), která byla trénována se zpětným šířením chyb podobně jako dopředné sítě, ale zahrnuje váhové spojení ze vstupu do každé vrstvy a z každé vrstvy do následných vrstev.

Síť byla trénována nepřetržitým procesem pře nastavováním vah a prahových hodnot, aby se chyba sítě snížila na předem nastavené minimum 1 % nebo aby se zastavila při předem nastaveném počtu cyklů. Poté byly pro předpovědi předány načtené vzorky nebo testovací data trénované síti, aby se inferencí získaly výsledky predikce.

GA byl použit k optimalizaci vstupních vlastností UNN pro získání menších a efektivnějších vstupů.

Data v GA byla reprezentována n-bitovými binárními vektory. Vyhledávací prostor tedy odpovídá booleově prostoru o velikosti n.
Klasifikační systém je popsán na obrázku 2 níže, který zdůrazňuje optimalizaci GA. [22]

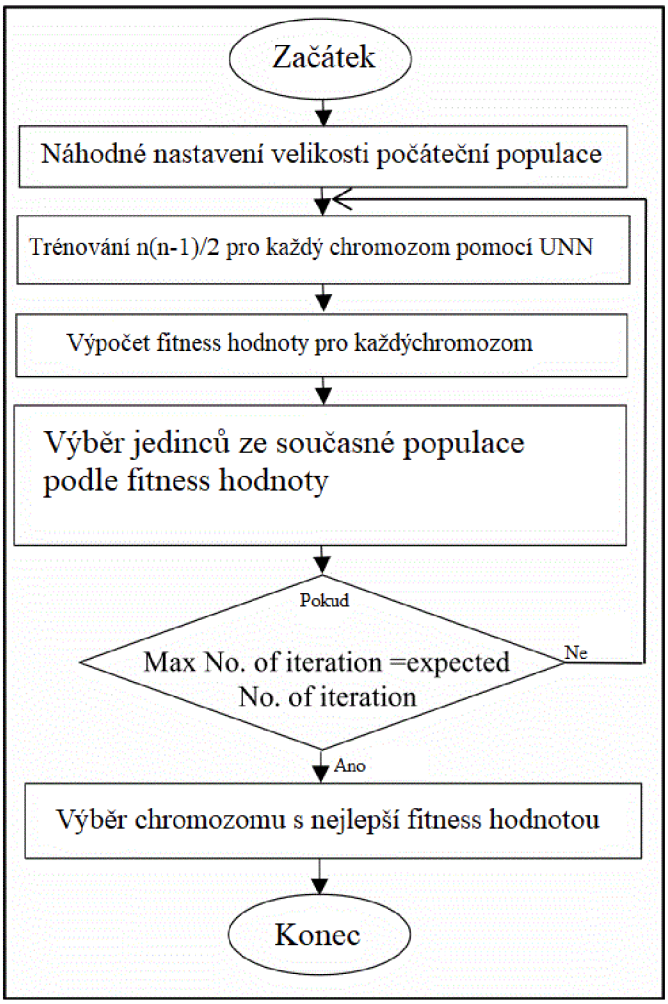

Obr. 15 Proces trénování genetického algoritmu (GA)

Metoda byla testována na veřejně dostupné databázi arytmií MIT-BIH dostupné ze stránek PhysioNet [29]. Polovina záznamů byla využita pro trénování a druhá polovina pro vyhodnocení. [22]

Metoda využivající genetický algoritmus (GA) a umělou neuronovou síť (UNN, ANN) poskytuje vysokou přesnost i u zašuměných dat.

4.7 Detekce blokády Tawarova raménka užitím statistických příznaků QRS komplexu a K-nejbližších sousedů

Metoda využívá změn QRS komplexů způsobených blokádami Tawarových ramének a tedy i změn jejich statistických příznaků. [28]

Z QRS komplexu byly extrahovány tyto statistické příznaky:

$$průměr = \frac{\sum_n x[i]}{N}, \tag{4.9}$$

$$rozptyl = \frac{\sum\left(x_i - mean(x)\right)^2}{n-1}, \tag{4.10}$$

$$směrodatná\ odchylka = \sqrt{\frac{\sum\left(x_i - mean(x)\right)^2}{N}}, \tag{4.11}$$

$$koeficient\ špičatosti = \frac{\mu_4}{\sigma^4}, \tag{4.12}$$

$$koeficient\ šikmosti = \frac{\mu_3}{\sigma^3}, \tag{4.13}$$

kde x[i] a x_i jsou prvky v sekvenci, N je velikost sekvence, n je počet prvků, mean(x) je průměr všech hodnot v sekvenci, μ_4 představuje čtvrtý centrální moment, μ_3 představuje třetí centrální moment a σ představuje směrodatnou odchylku.

Vybrané příznaky jsou následně klasifikovány podle klasifikační metody K-nejbližších sousedů. Metoda K-nejbližších sousedů je jednoduchá metoda strojového učení s učitelem, která nevyžaduje trénovaní, a při které mohou být testovací data klasifikovány pomocí trénovacích dat (prediktorů) a jejich příslušných tříd. Daný algoritmus vyhledá, pomocí zvolené distanční metriky, K nejbližších sousedů a testovací data jsou poté přiřazena do třídy, kam patří majorita z nalezených nejbližších sousedů. [28] Postup a užití dané metody je rozebráno v praktické části 5.4.

4.8 Detekce komorových extrasystol deskriptorů Hilbertovy transformace

Metoda spočívá ve vytvoření syntetického vektorkardiogramu z EKG záznamu, který je následně analyzován pomocí Fourierova deskriptoru pro rozpoznání komorových extrasystol [33]. Postup metody spočívá ve 2 krocích:

1) Hilbertova transformace EKG záznamu a vytvoření syntetických vektorkardiodiagramů z QRS komplexů s danými tvary:

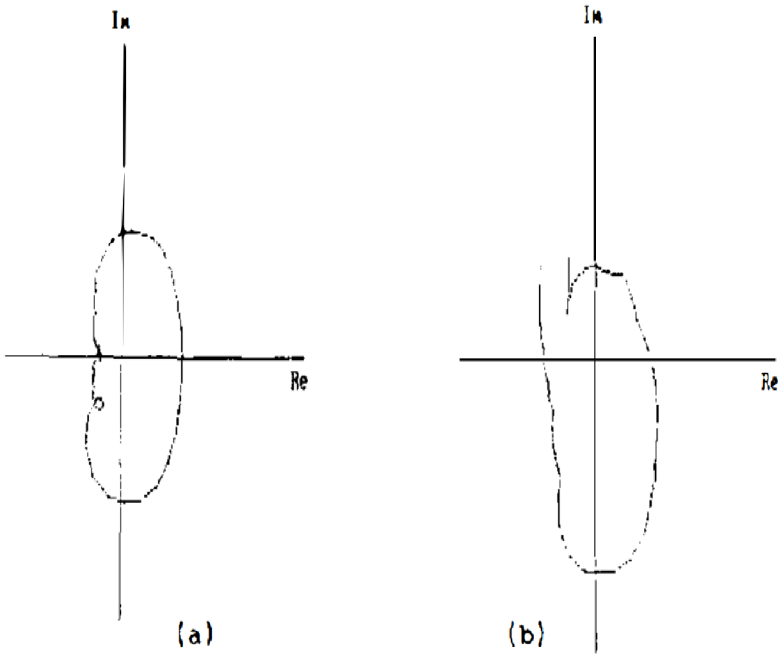

Obr. 16 Vektorkardiogram a) normálního QRS b) KES komplexu [33]

2) Analýza vektorkardiodiagramů pomocí rychlé fourierovy transformace a vykreslení spektra:

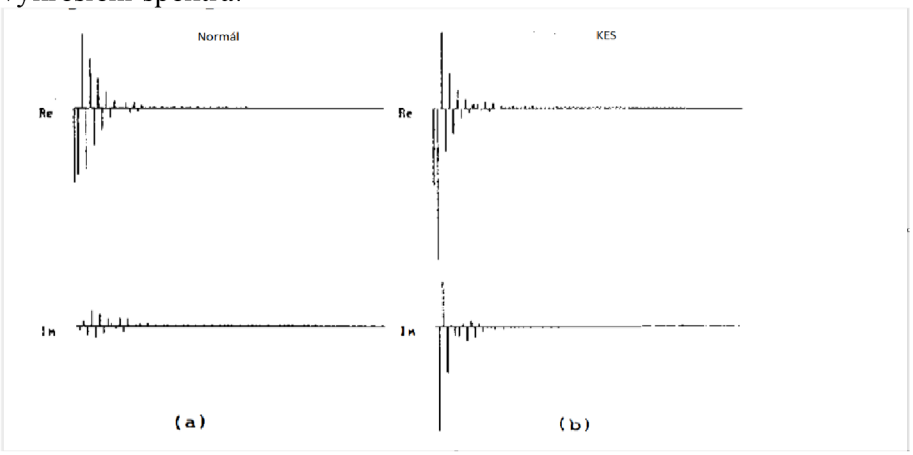

Obr. 17 Spektrum fourierovy transformace pro a) normální a b) KES vektorkardiodiagramů [33]

4.9 Systém detekce komorových extrasystol pomocí nastavitelné Q-faktor vlnkové transformace (TQWT)

V této metodě jsou nejprve filtrovány EKG záznamy pomocí kombinace pásmových zádrží a propustí pro očištění od veškerého rušení. Následně byla provedena dekompozice signálu pomocí TQWT, která je závislá na Q faktoru, redundance R a úroveň dekompozice J. Signál byl podle této analýzy rozložen na 5 svazků [34]:

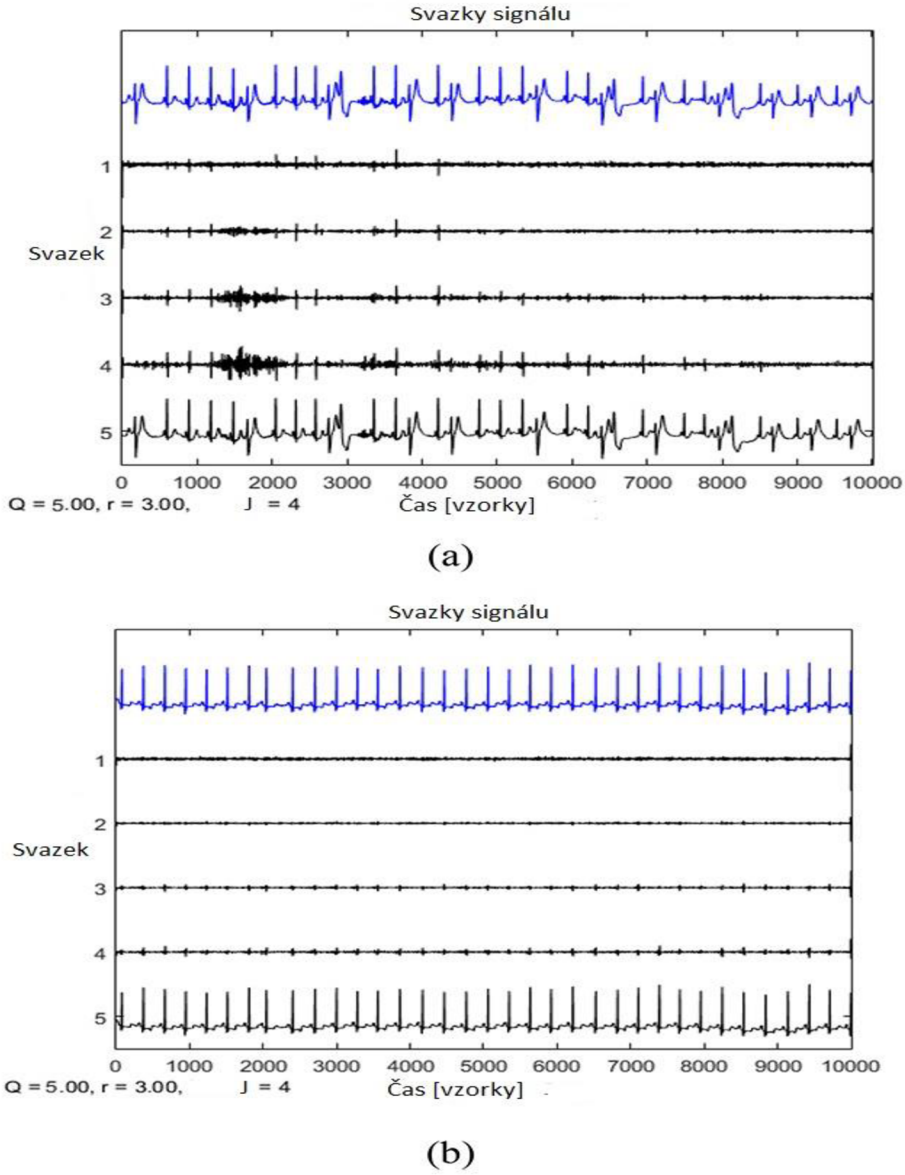

Obr. 18 Svazky a) KES a b) normálních signálů po TQWT [34]

Z daných podsvazků byly extrahováno 9 statistických příznaků QRS komplexů (minimum, maximum, kvadratický průměr, průměr, mezikvartilní rozsah, směrodatná ochylka, šikmost a křivost). Všechny příznaky nemusí být vhodné pro analýzu, a proto

byly extrahované příznaky podrobeny analýze variance (ANOVA). Výsledný počet příznaků je na závěr použit a použity ke klasifikaci pomocí metod strojového učení: metody pomocných vektorů, K-nejbližších sousedů nebo umělé neuronové sítě. [34]

Autory dosažená celková úspěšnost dosahuje 97,81 %. [34]

4.10 Detekce KES užitím zlomkové vlnkové transformace v kombinaci s analýzou hlavních komponent (PCA)

V této metodě je signál nejprve předzpracován pomocí frakční vlnkové transformace, jejíž α-řád je definován pomocí rovnice

$$W_x^{\alpha}(p,q) = \int_{-\infty}^{\infty} x(t)\varphi_{\alpha,p,q}^{*}(t)dt, \tag{4.14}$$

kde p,q značí škálu a posun mateřské vlnky v časové doméně a $\varphi_{\alpha,p,q}^{*}$ odpovídá frakční vlnce, která je definována vzorcem:

$$\varphi_{\alpha,p,q}^{*}(t) = e^{-(\frac{j}{2})(t^2-q^2-\left(\frac{t-q}{p}\right)^2)cot\alpha} * \varphi_{p,q}(t), \tag{4.15}$$

kde α představuje úhel rotace.

Příznaky silně závisí na zvolené arytmii, a proto je pro extrakci použi Yule-Walkerův autoregresivní modelovací technika. Následně jsou pomocí PCA analýzy detekovány R kmity. V PCA analýze má první hlavní komponenta největší varianci, která poukazuje na maximální variabilitu nabízenou v originálních komponentech. Úspěšnost dané metody je vyhodnocena pomocí SNR (poměr signál-šum), střední kvadratická chyba a přesnost detekce. [35]

Úspěšnost této metody dosáhla 99,89 % pro databázi MIT-BIH [29] [35].

4.11 Detekce levé blokády Tawarova raménka užitím diskrétní vlnkové transformace (MODWT) s maximálním překrytím v kombinaci s adaptivním neuro fuzzy inferenčním systémem (ANFIS)

V této metodě jsou data předzpracovány pomocí Butterworth filtrů typu pásmová zádrž a pásmová propust. V další části jsou QRS komplexy extrahovány pomocí různých metod detekce R kmitu a ke každému QRS komplexu je vytvořeno okno o délce 180 ms. [36]

Dále jsou extrahovány příznaky pomocí MODWT. MODWT je neortogonální verze diskrétní vlnkové transformace, která, na rozdíl od standardní diskrétní vlnkové transformace, zachovává podvzorkovaná data. Vstupní signál LBBB QRS komplexů je podroben MODWT dekompozici a jsou vytvořeny dekompoziční úrovně D1 až D11 a A11, kde Dx značí koeficienty detailu a A11 je koeficient rozsahu. Z daných dekompozicí nejsou všechny koeficienty klinicky významné, a proto byly podrobeny klinickému pozorování a statistickému t-testu. Na závěr metody byla pro klasifikaci použita metoda adaptivního neuro fuzzy inferenčního systému (ANFIS) podle definovaných pravidel. Pro daný systém byly zvoleny parametry D2, D3, D4, šikmost a křivost, které byly normalizovány na škálu <0,1> a následně rozděleny do dvou tříd (normální a LBBB). Úspěšnost klasifikace je vypočítána pomocí F-skóre. [36]

Autory údávaná úspěšnost je 99,88 % a F-skóre je rovno 0.999. [36]

4.12 Detekce blokád Tawarových raménka užitím adaptivní bakteriální hledací optimalizace a umělé neuronové sítě

V této metodě jsou data nejprve předzpracována pomocí Sgolay FIR filtru, pro odstranění posunu nulové linie a vyhlazení. Následně byly jednotlivé QRS komplexy segmentovány. V následné části byla užita Bakteriální hledací optimalizace (BFO), která je inspirovaná v hledací aktivitě E. coli bakterií, protože maximalizuje přísun energie za jednotku času hledání. Hlavními operačními kroky jsou: Chemtaxe, rojení a reprodukce. Postup BFO je popsán na vývojém diagramu obr.19 [37]:

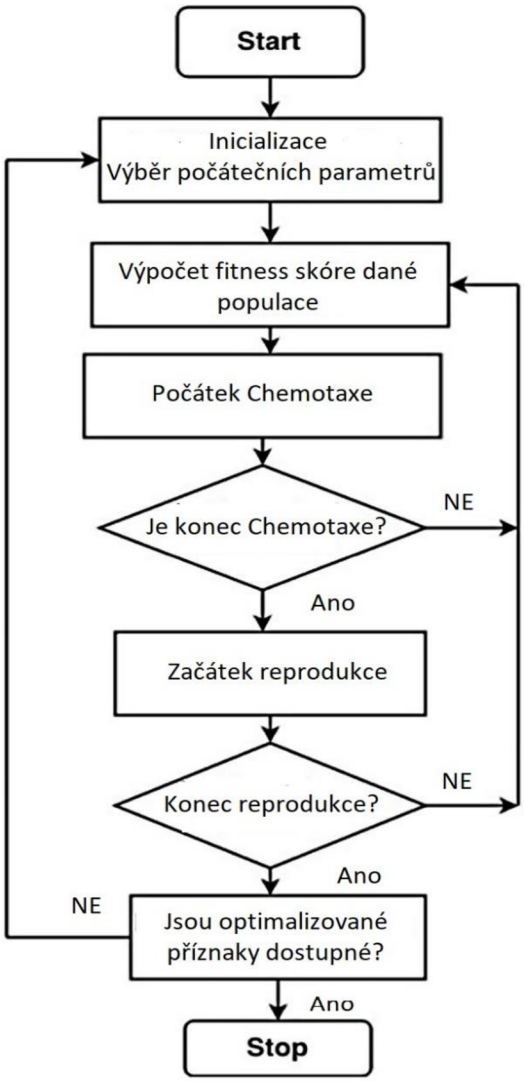

Obr. 19 Postup Bakteriální hledací optimalizace [37]

Data byly následně klasifikovány pomocí Levenberg-Marquardtovy neuronové sítě se zpětnou propagací chyby. K testování modelu je použit skalární konjugační gradient.

Trénování a testování dané sítě bylo provedeno pomocí 12 692 QRS komplexů s nastaveným počtem iterací 1 000 a střední kvadratickou odchylkou menší než 0.001.

Dle autorů, daná metoda dosáhla senzitivity 98,5 %, specificity 96,2% a celkové přesnosti 96,1 % [37]

5. REALIZACE DETEKČNÍCH METOD

V praktické části jsou realizovány metody detekce již zmíněných v částech 4.1 a 4.7, tedy detekce komorových extrasystol kombinací metod z kapitol 4.1, 4.7 a detekce blokád Tawarových ramének pomocí statistické analýzy QRS komplexů a jejich následné klasifikování pomocí metody K-nejbližších sousedů.

V této části je zároveň realizován detektor R kmitů na bázi umocnění filtrovaného signálu a jeho úspěšnost byla porovnána s polohami R kmitů již přítomnými v použité databázi.

5.1 Databáze BTL

K testování algoritmu byla využita databáze BTL_dataq. Databáze obsahuje 6884 nefiltrovaných EKG záznamů pacientů s buď normálním nebo abnormálním EKG.

Struktura databáze je složena ze 4 částí/sloupců. První části je název pacienta (např. EB0000018570), druhá je složena z 8 svodů (končetinové svody II, III a hrudní V1-V6), třetí značí přítomnost pozorovaných vlastností/arytmií pomocí binárních hodnot (1 = pozitivní, 0 = negativní) a poslední část značí již zjištěné polohy QRS komplexů v jednotlivých záznamech EKG.

Vzorkovací frekvence všech záznamů je 500 Hz.

Pro detekci přítomnosti komorových extrasystol (KES) a ověření úspěšnosti byly použity svody II ze 300 různých záznamů. Pro detekci blokád byly zpracovány svody V1 ze záznamů obsahujících jak fyziologické QRS komplexy, tak i QRS komplexy s blokádami Tawarových ramének.

5.2 Předzpracování dat

V rámci předzpracování dat byl brán zřetel na zachování tvaru QRS komplexu. K filtraci byl použit butterworth filtr k odstranění síťového šumu a posunu nulové linie a mediánový filtr pro vyhlazení výsledného signálu. [30] [31]

Pro odstranění driftu of nulové linie a síťového rušení byly použity dva butterworth filtry 4. řádu (horní propust a pásmová zádrž). Oba filtry byly realizovaný přes MATLAB funkci butter() a aplikovány funkcí filtfilt().

Pro filtr typu horní propust byla vybrána hraniční frekvence 0.5 Hz. Sítťové rušení se nachází při frekvenci 50 Hz, proto bylo, pro druhý filtr, zvoleno rozmezí frekvencí 45-55Hz. [31]

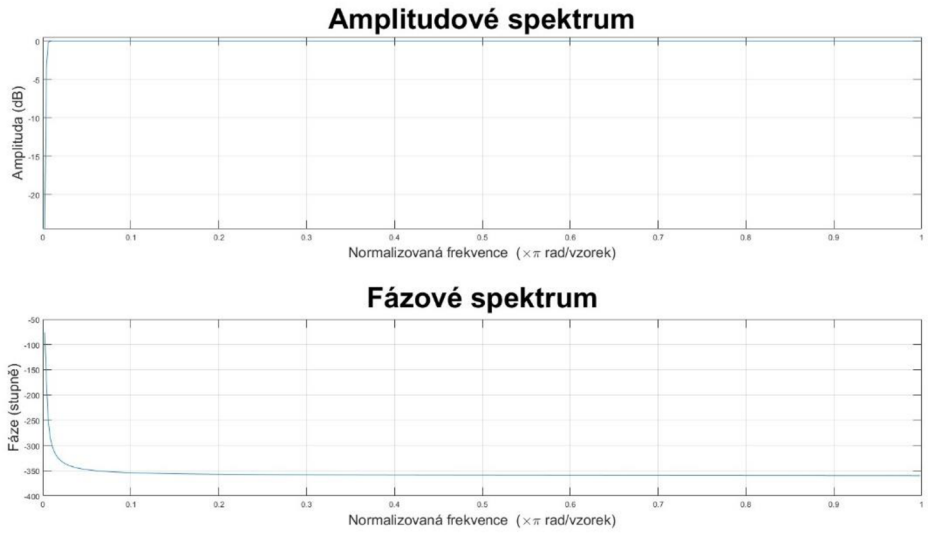

Obr. 20 Vlastnosti Butterworth filtru typu horní propust

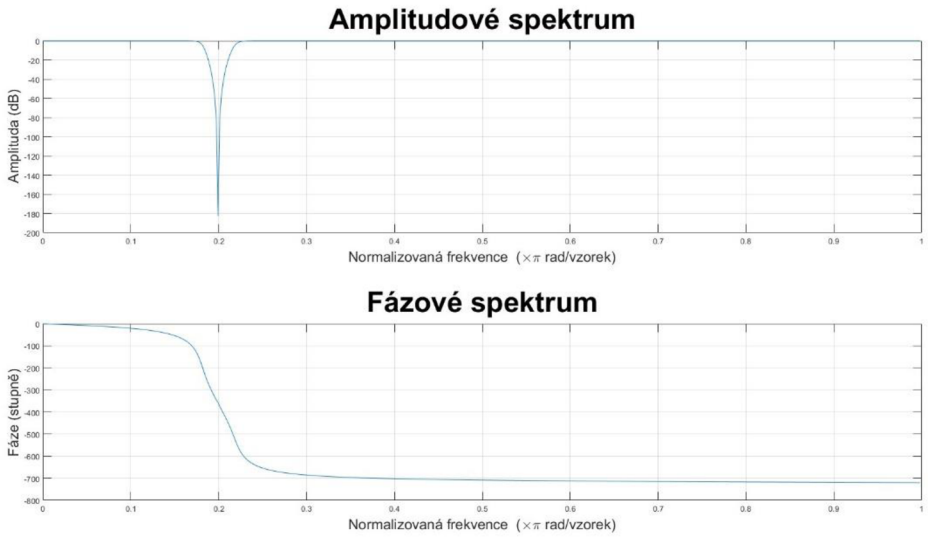

Obr. 21 Vlastnosti Butterworth filtru typu pásmová zádrž

Reziduální šum byl redukován pomocí mediánového filtru s délkou okna 10. [30] Daná délka okna byla určena empiricky, jako vhodná pro danou aplikaci. K vytvoření filtru byla použita MATLAB funkce medfilt1().

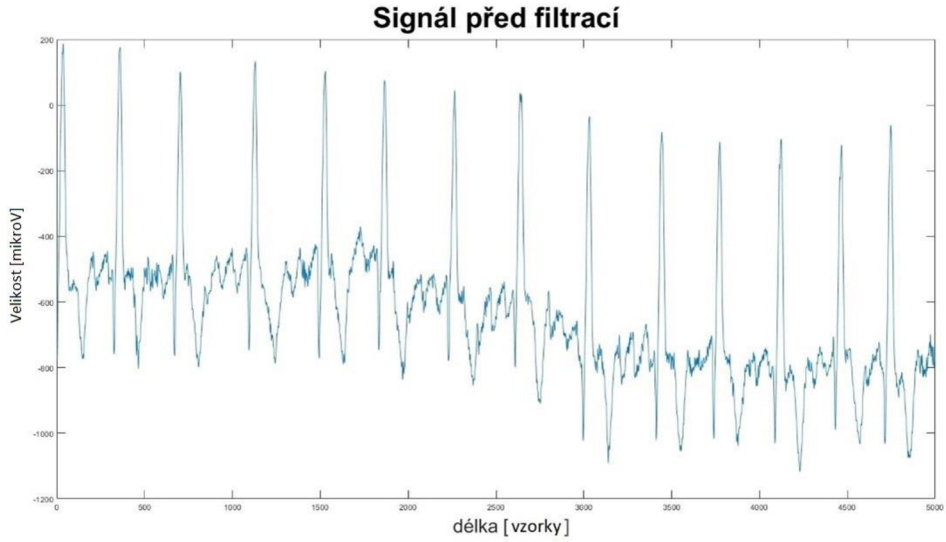

Obr. 22 Signál před filtrací

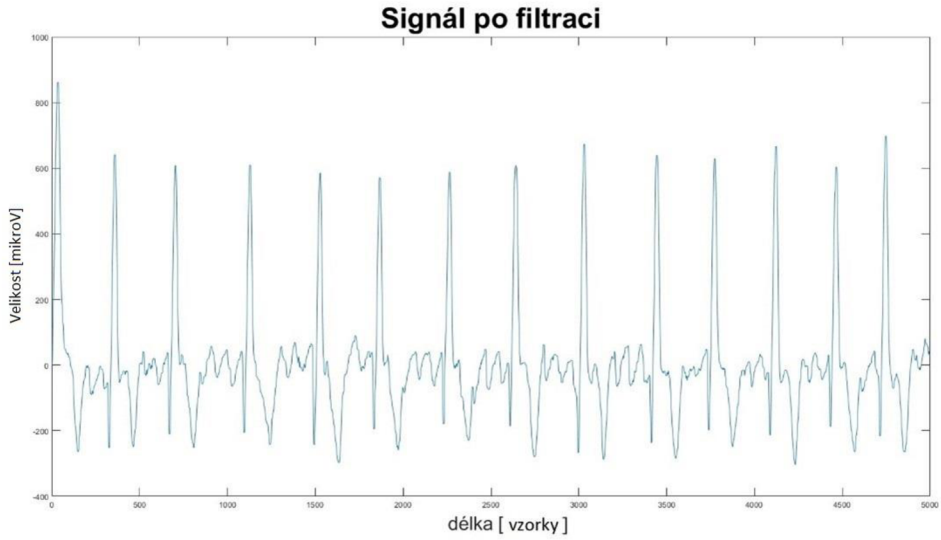

Obr. 23 Signál po filtraci

5.3 Detekce komorových extrasystol (KES)

Jako metoda detekce komorových extrasystol byla použita kombinace metod z kapitol 4.1 a 4.7, tedy metoda popsaná v kapitole 4.7 a obohacená o předčasnost a kompenzační pauzu z kapitoly 4.1. Daná kombinace byla poté použita pro detekci komorových extrasystol (KES). Podmínkou správného fungování modelu a detekce je anotace všech QRS komplexů včetně KES komplexů.

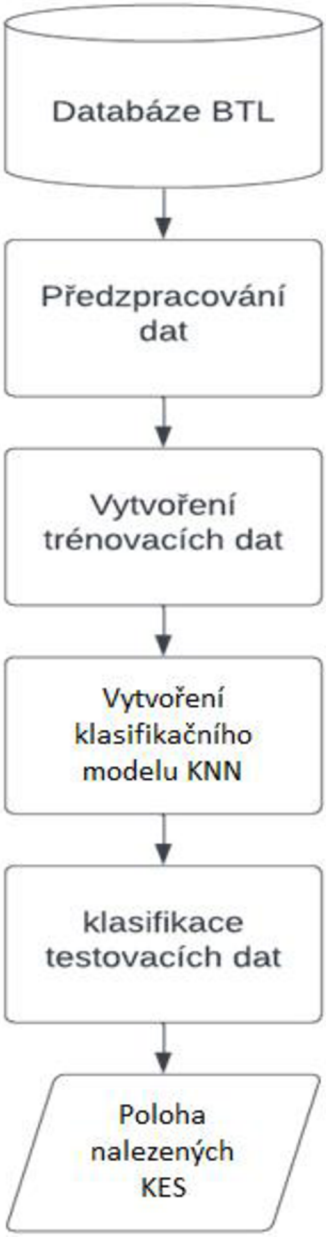

Obr. 24 Blokové schéma metody detekce KES

Změny morfologie mezi fyziologickým QRS komplexem a KES jsou výrazné, a proto lze pozorovat změnu v jejich parametrech. Jako parametry byly zvoleny: Předčasnost, Kompenzace, Průměr, Rozptyl, Směrodatná odchylka, Šikmost a Křivost. Rozdíl v daných parametrech lze vizualizovat pomocí box-plot grafů:

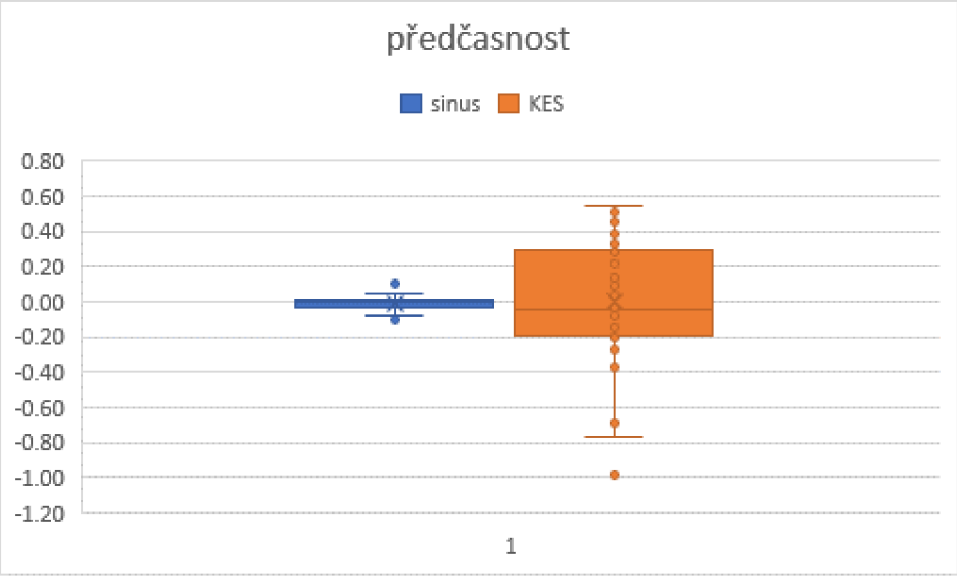

Obr. 25 Předčasnost jednotlivých tříd metody detekce KES

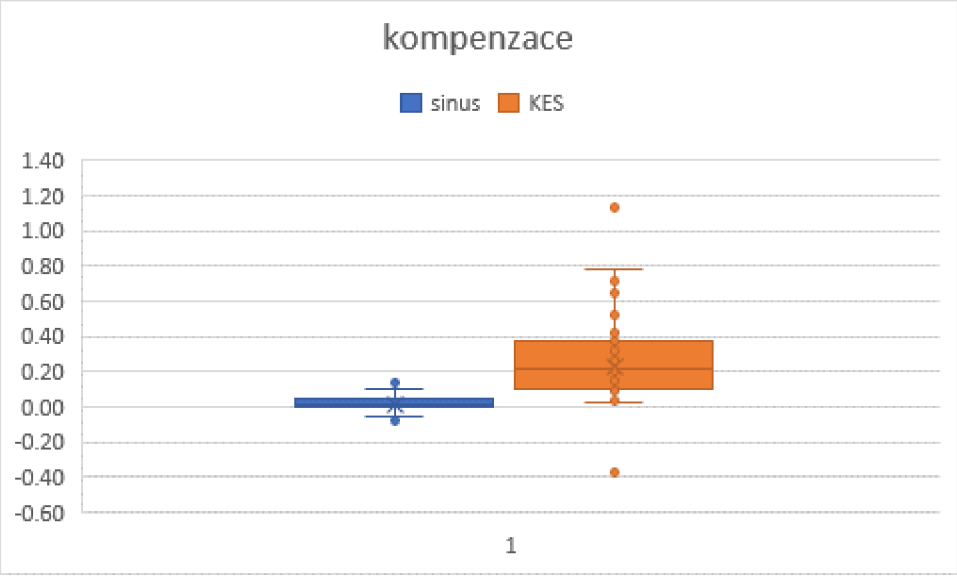

Obr. 26 Kompenzace jednotlivých tříd metody detekce KES

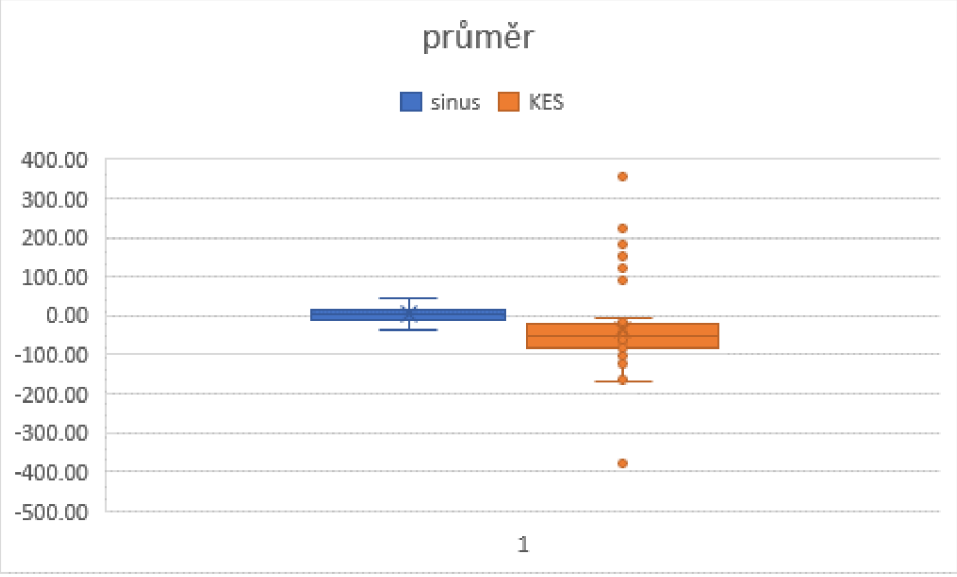

Obr. 27 Průměr jednotlivých tříd metody detekce KES

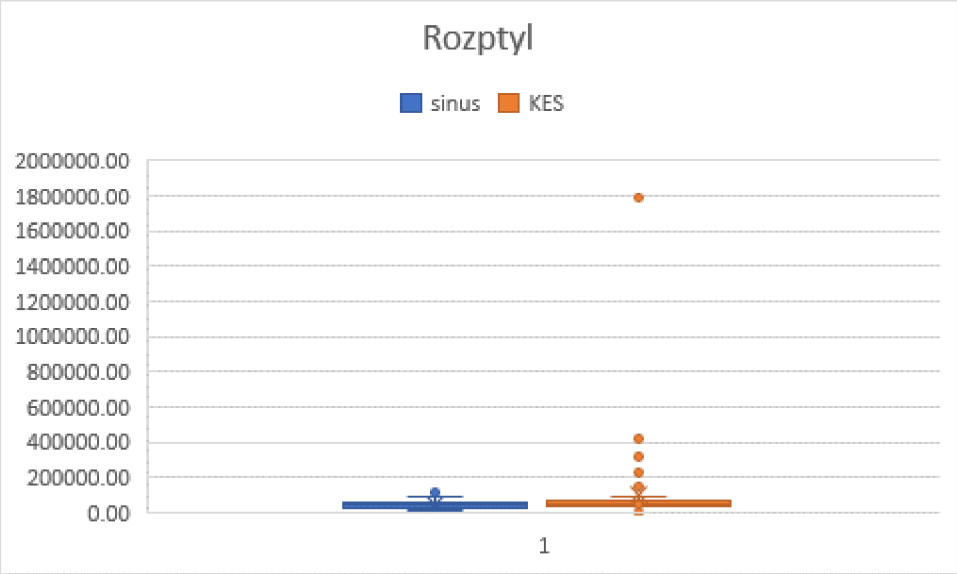

Obr. 28 Rozptyl jednotlivých tříd metody detekce KES

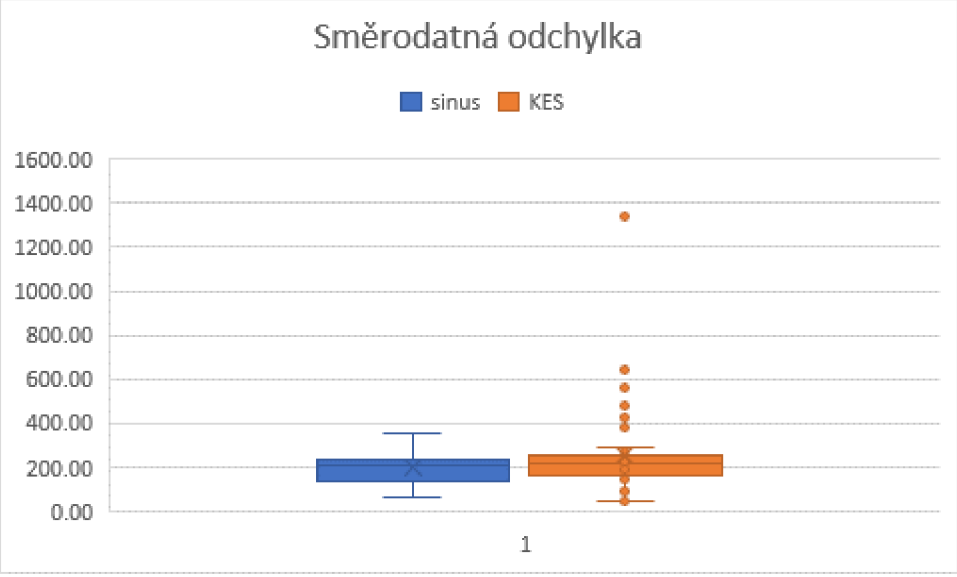

Obr. 29 Směrodatná odchylka jednotlivých tříd metody detekce KES

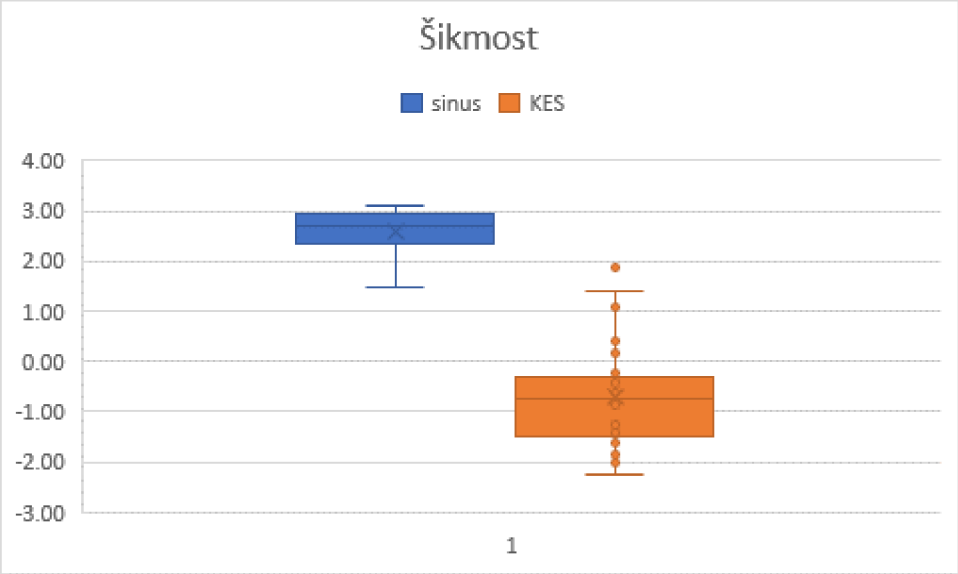

Obr. 30 Šikmost jednotlivých tříd metody detekce KES

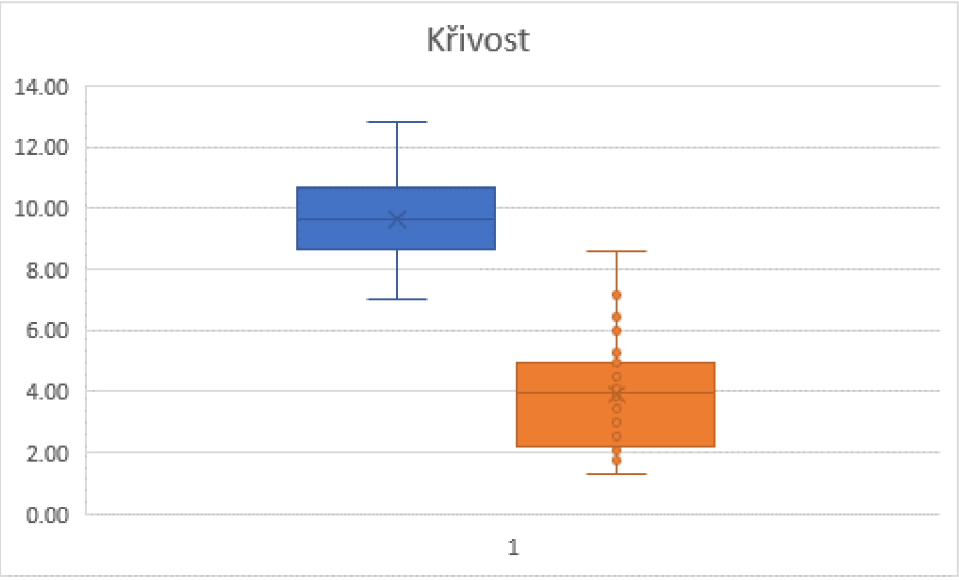

Obr. 31 Křivost jednotlivých tříd metody detekce KES

Z vizualizace parametrů je zřejmé, že rozptyl a směrodatná odchylka se překrývají, a měly by být nevhodné pro správné rozlišení. Předčasnost a kompenzace se také překrývají, ale majorita hodnot pro fyziologický rytmus je velmi blízký 0 a KES hodnoty se pohybuji nad +/- 0.1. Parametry a data byly optimalizovány v kapitole 5.3.4.

Pro trénovací a testovací data byl použit svod

5.3.1 Příprava trénovacích dat (KES/sinus V1)

Trénovací data byly vybrány ze 100 vzorových QRS oken o délce 160ms (Patologická délka QRS komplexu přesahuje 0.12s). Vybraná okna představují fyziologický sinusový rytmus a KES v poměru 1:1, tedy 50 oken pro sinus a 50 oken pro KES. Dané QRS komplexy byly podrobeny analýze zmíněné v kapitole 4.7, byly přiřazeny odpovídající klasifikace a následně seskupeny do datového typu table. Vzniklá tabulka byla uložena do .csv souboru pro snadnější přístup v případě vytvoření separátního MATLAB skriptu nebo pro jiný typ analýzy, využívající stejný formát dat.

Morfologie QRS komplexů pro vybrané třídy:

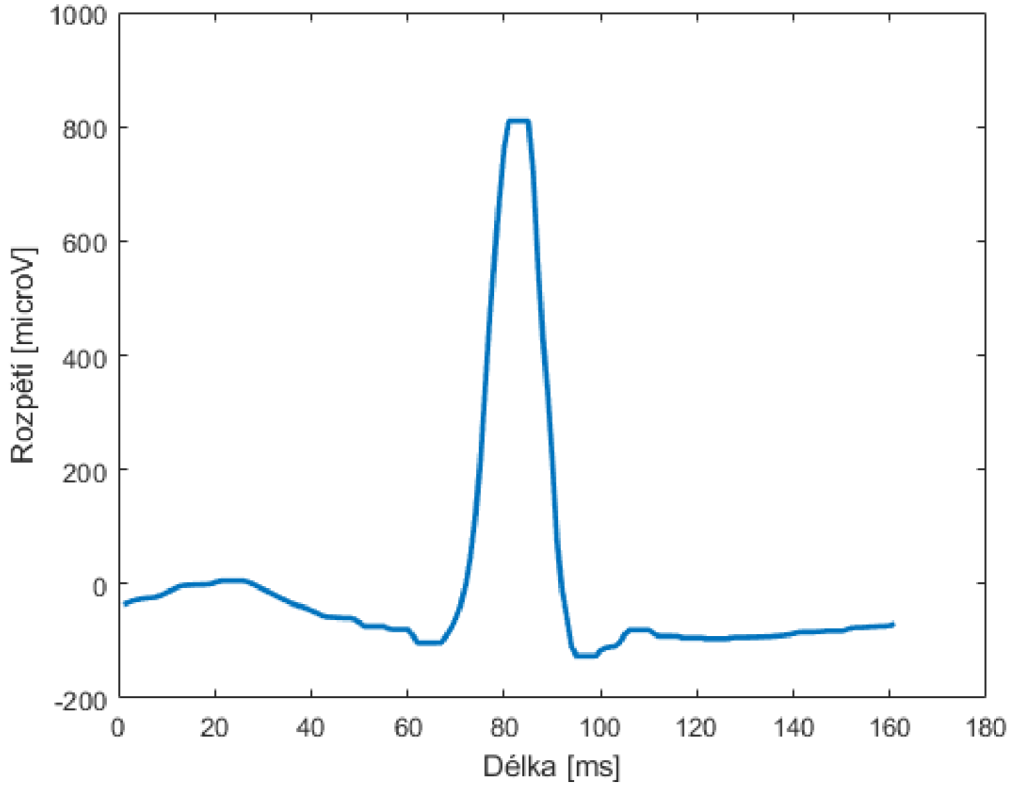

Obr. 32 Sinusový rytmus

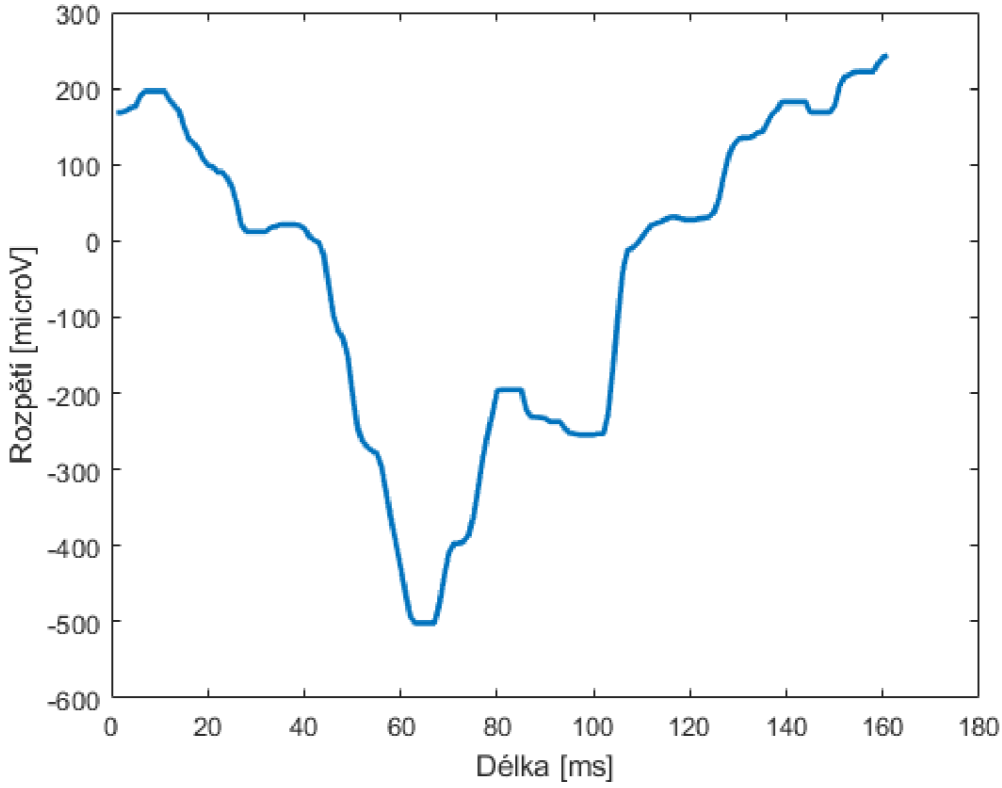

Obr. 33 Morfologie KES

5.3.2 Vytvoření klasifikačního modelu KNN

K vytvoření samotného klasifikačního modelu byl použit MATLAB nástroj fitcknn(), který dle ručně zadaných parametrů vytvoří již připravený klasifikační model KNN. Využité trénovací a testovací data jsou samotným modelem také standardizovány. [32]

Pro vybraný model byly zvoleny následující parametry:

- Počet sousedů: 1-3-5
- Distanční metoda: Euklidovská (po optimalizaci => Mahalanobovská)
- Prediktory: předčasnost, kompenzace, průměr, rozptyl, směrodatná odchylka, šikmost a křivost (odpovídá názvům Var1 až Var7; po optimalizaci: předčasnost, kompenzace, průměr, šikmost, které odpovídají Var1 až Var4)
- Odpověď/Klasifikační třídy: sinus/KES
- počet pozorování: velikost trénovací databáze
- standardizace dat: Ano

```
ClassificationKNN
         PredictorNames: {'Var1'  'Var2'  'Var3'  'Var4'  'Var5'  'Var6'  'Var7'}
           ResponseName: 'Y'
  CategoricalPredictors: []
             ClassNames: {'KES'  'sinus'}
         ScoreTransform: 'none'
        NumObservations: 100
               Distance: 'mahalanobis'
           NumNeighbors: 5
```

Obr. 34 KNN model pro detekci KES

5.3.3 Klasifikace testovacích dat

Pro testovaní bylo použito 2000 QRS komplexů z různých záznamů z části databáze (1000 sinus, 1000 KES), která nebyla použita pro vytvoření trénovacího datasetu, aby nedošlo k overfittingu nových testovacích dat. Vybrané QRS komplexy byly podrobeny analýze statistických parametrů z kapitoly 4.7, 4.1 a pomocí funkce predict() byly klasifikovány k příslušným třídám.

Podmínkou správné klasifikace je správná anotace všech QRS komplexů, včetně KES komplexů i při vytváření testovacích dat

5.3.4 Optimalitace metody

Optimalizace samotné metody probíhala systematicky v referenci na zdrojové práce z kapitol 4.1 a 4.7. Samotný model KNN byl optimalizován testováním jiných metrik a počtu sousedů. Následně byla optimalizována samotná trénovací a testovací data pomocí PCA analýzy a pomocí vizuálního pozorování rozložení hodnot v box-plot grafech z úvodu kapitoly 5.3.

Podle reference z práce [28] byly pro optimalizaci samotného KNN modelu uváženy celkově 4 metriky: Euklidovská, City-block, Kosinova a Mahalanobovská a 3 počty sousedů (k): 1, 3 a 5. Následně byly redukován počet použitých metrik na Euklidovskou a Mahalanobovskou vzdálenost, která jsou nejpoužívanější pro klasifikační úlohy KNN. City-block vzdálenost je vhodná na data, která mají vysokou dimenzionalitu, která není přítomna u realizované metody KNN pro BBB, kde je pouze 5 základních příznaků.

Kosinova vzdálenost je užita pro detekci podobnosti v analýze textu (detekce plagiátorství atd.). [38]

V další fázi bylo rozdělení dat vizuálně ověřeno vykreslením box-plotů, ze kterých je patrné, že většina hodnot rozptylu a směrodatné odchylky jsou, mimo odlehlé hodnoty, skoro totožné. Tato podobnost by mohla mít negativní vliv nebo by byla neužitečná pro detekci KES. Proto byly dané proměnné odstraněny z testovaní modelu KNN:

V poslední fázi byly vstupní proměnné dat redukovány pomocí PCA analýzy, pro urychlení klasifikace modelů a odstranění proměnných, které mají velmi malý vliv na rozlišitelnost arytmií. Data byly normalizovány a testovány pomocí MATLAB funkce pca(). Výstupní proměnná dané funkce "explained" představuje poměr rozptylů jednotlivých komponent vůči celkovému rozptylu dat. Suma rozptylů dat vysvětluje 100% rozptylu, kde předčasnost vysvětluje 44.16%, kompenzace 21.339%, průměr 17.281%, šikmost 14.246% a křivost 2.974% celkového rozptylu.

Pro redukci dat bylo vybráno rozmezí 95-99% rozptylu, teda malý vliv na rozlišitelnost arytmií. Křivost má nejmenší zastoupení celkového rozptylu, a proto byla data redukovaná na pouze 4 příznaky (předčasnost, kompenzace, průměr a šikmost) s celkovým vysvětleným rozptylem 97,026%

5.4 Detekce blokád Tawarových ramének pomocí statistické analýzy QRS komplexů a jejich následným klasifikováním pomocí metody K-nejbližších sousedů

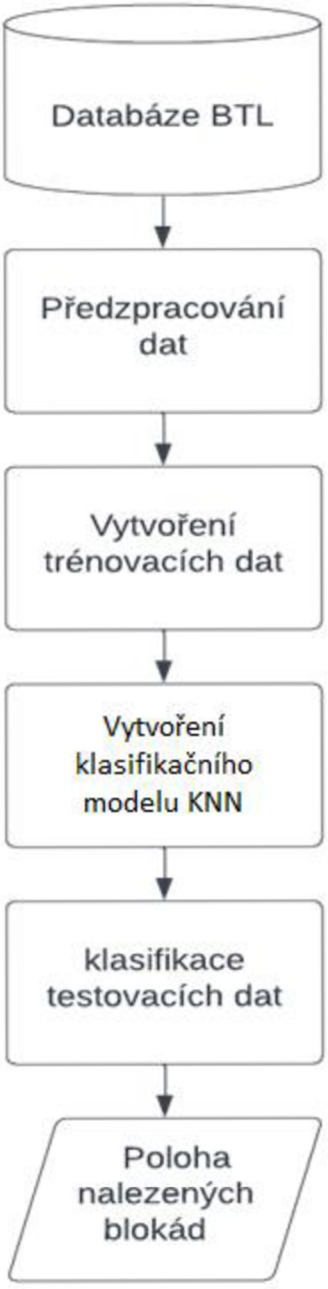

Obr. 35 Metoda detekce blokád Tawarových ramének

V práci [28] již bylo zmíněno, že při přítomnosti blokád Tawarových ramének dochází k velké změně v morfologii QRS komplexu (kap. 3.2). Tyto změny se projeví na statistických parametrech QRS komplexu a lze tedy, s kombinací s klasifikační metodou KNN, použít pro detekci jednotlivých blokád.

Vizualizace změn statistických paramterů pomocí boxplot grafů:

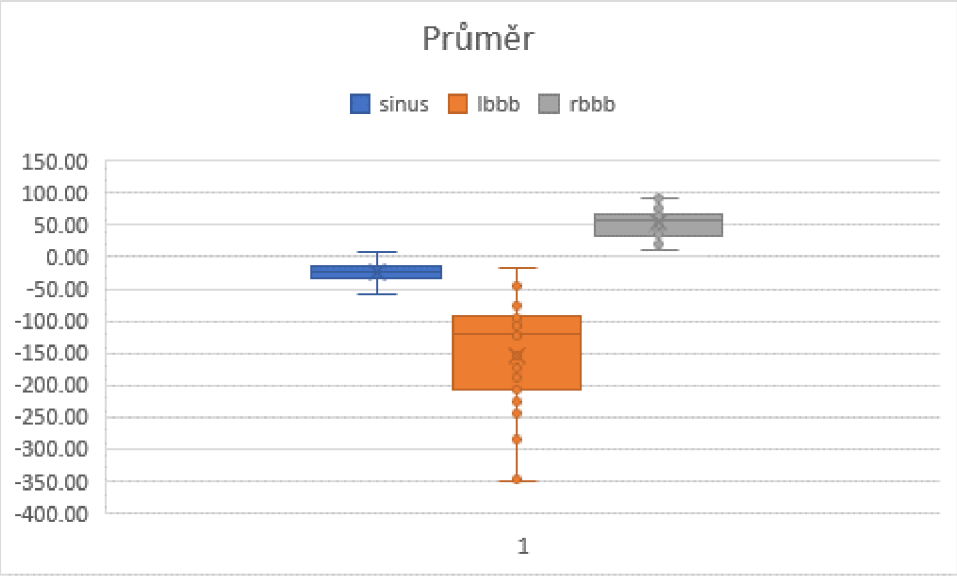

Obr. 36 Průměr jednotlivých tříd

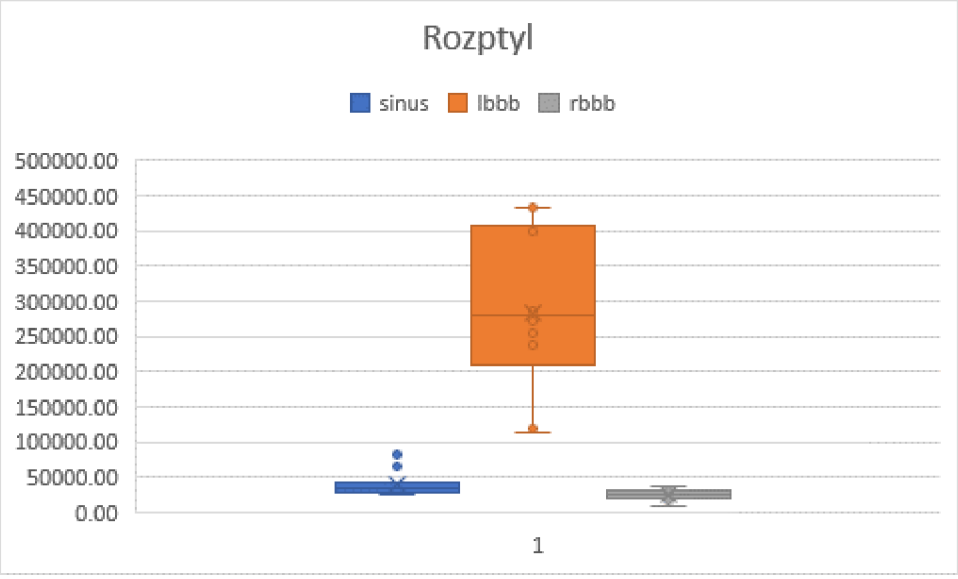

Obr. 37 Rozptyl jednotlivých tříd

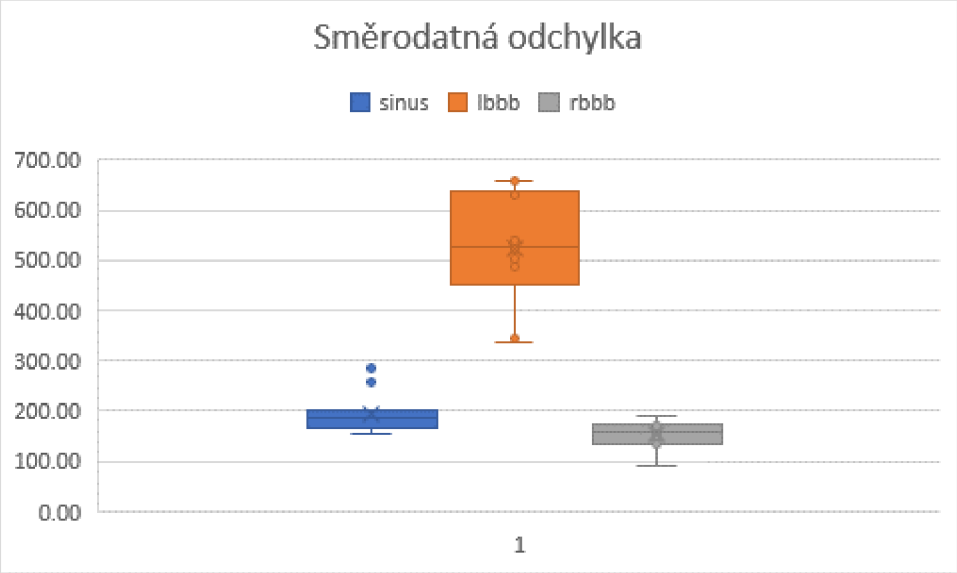

Obr. 38 Směrodatná odchylka jednotlivých tříd

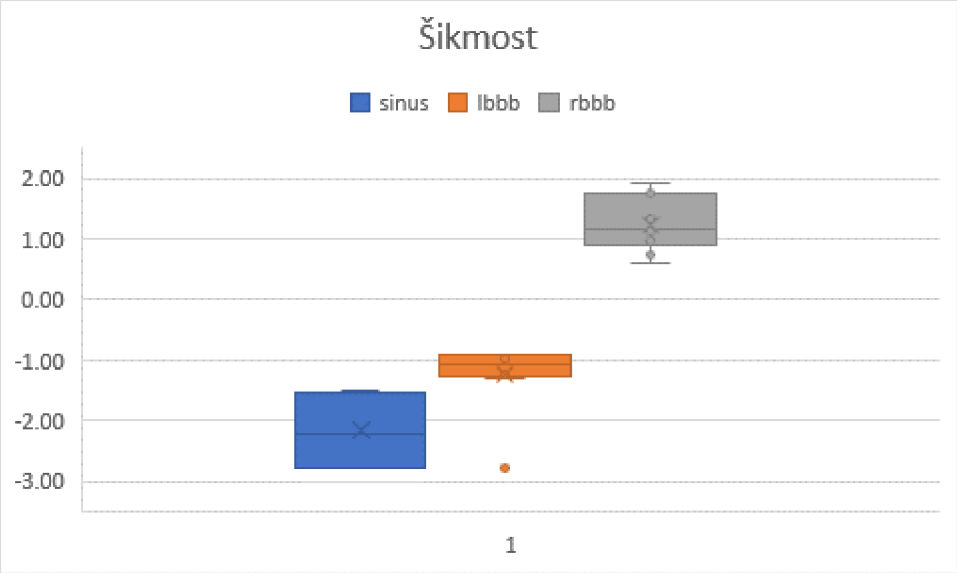

Obr. 39 Šikmost jednotlivých tříd

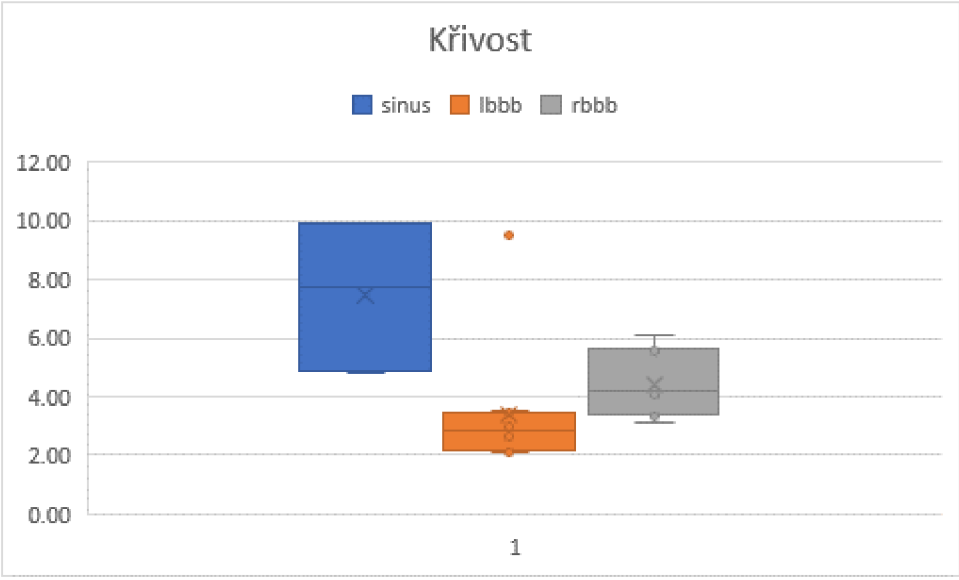

Obr. 40 Křivost jednotlivých tříd

Z databáze BTL_dataq byly použity filtrované EKG záznamy ze svodu V1, kde jsou dané změny morfologie nejvýraznější.

5.4.1 Vytvoření trénovacích dat

Z databáze bylo ručně vybráno 160 oken o délce 0.16s (délka abnormálního QRS komplexu > 0.11s), reprezentující vzorové morfologie QRS komplexů pro sinusový rytmus, LBBB, RBBB a jiné. Dané QRS komplexy byly podrobeny analýze zmíněné v kapitole 4.7, byly přiřazeny odpovídající klasifikace a následně seskupeny do datového typu table. Vzniklá tabulka byla uložena do .csv souboru pro snadnější přístup v případě vytvoření separátního MATLAB skriptu nebo pro jiný typ analýzy, využívající stejný formát dat.

Morfologie jednotlivých analyzovaných QRS komplexů:

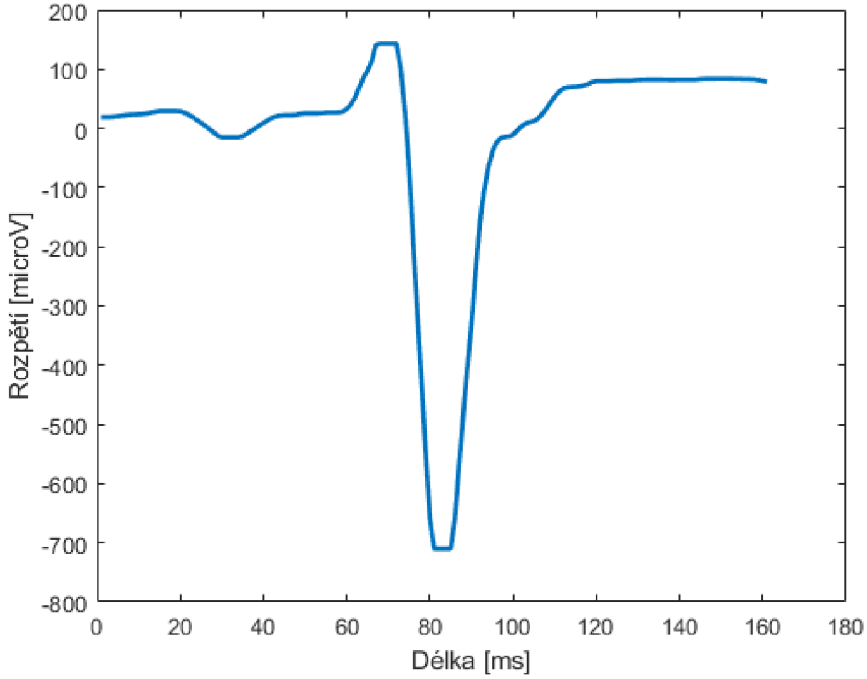

Obr. 41 Fyziologický QRS komplex

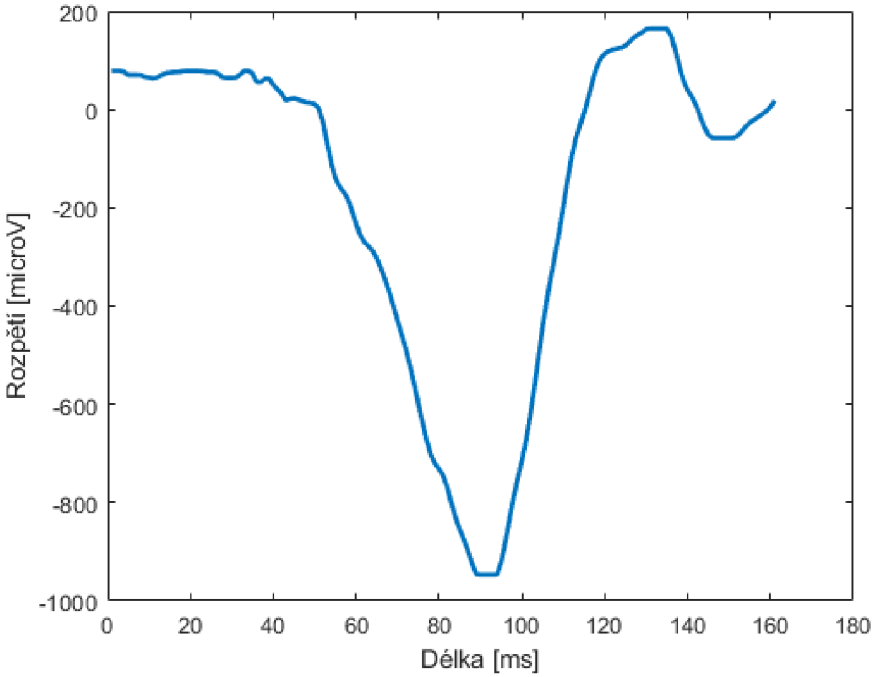

Obr. 42 Blokáda levého Tawarova raménka (LBBB)

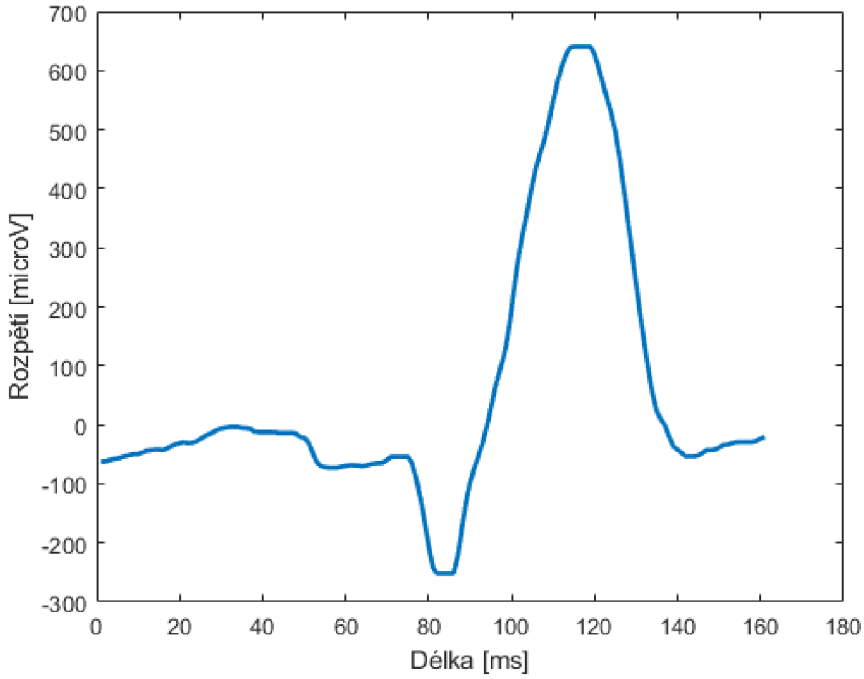

Obr. 43 Blokáda pravého Tawarova raménka (RBBB)

5.4.2 Vytvoření klasifikačního modelu KNN

K vytvoření samotného klasifikačního modelu byl použit MATLAB nástroj fitcknn(), který dle ručně zadaných parametrů vytvoří již připravený klasifikační model KNN. Využité trénovací a testovací data jsou samotným modelem také standardizovány. [32]

Pro vybraný model byly zvoleny následující parametry:

- Počet sousedů: 1-3-5
- Distanční metoda: Euklidovská (po optimalizaci => Mahalanobovská)
- Prediktory: průměr, rozptyl, směrodatná odchylka, šikmost a křivost (odpovídá názvům Var1 až Var5; po optimalizaci Var1 až Var4)
- Odpověď/Klasifikační třídy: sinus/lbbb/rbbb/jiné
- počet pozorování: velikost trénovací databáze
- standardizace dat: Ano

```
ClassificationKNN
         PredictorNames: {'Var1'  'Var2'  'Var3'  'Var4'}
           ResponseName: 'Y'
  CategoricalPredictors: []
             ClassNames: {'jiny'  'lbbb'  'rbbb'  'sinus'}
         ScoreTransform: 'none'
        NumObservations: 160
                Distance: 'mahalanobis'
           NumNeighbors: 3
```

Obr. 44 Přehlad KNN modelu

Vytvořený model a trénovací data byla dále podrobena optimalizaci, která je popsána v kapitole 5.4.4.

5.4.3 Klasifikace testovacích dat

Pro testovaní bylo použito 2000 QRS komplexů z různých záznamů z části databáze (500 sinus, 500 LBBB, 500 RBBB a 500 jiné), která nebyla použita pro vytvoření trénovacího datasetu, aby nedošlo k overfittingu nových testovacích dat. Vybrané QRS komplexy byly podrobeny analýze statistických parametrů z kapitoly 4.7 a pomocí funkce predict() byly klasifikovány k příslušným třídám.

5.4.4 Optimalizace metody

Optimalizace samotné metody probíhala systematicky v referenci na zdrojové práce. Samotný model KNN byl optimalizován testováním jiných metrik a počtu sousedů. Následně byla optimalizována samotná trénovací a testovací data pomocí PCA analýzy.

Podle reference z práce [28] byly pro optimalizaci samotného KNN modelu uváženy celkově 4 metriky: Euklidovská, City-block, Kosinova a Mahalanobovská a 3 počty sousedů (k): 1, 3 a 5. Následně byly redukován počet použitých metrik na Euklidovskou a Mahalanobovskou vzdálenost, která jsou nejpoužívanější pro klasifikační úlohy KNN. City-block vzdálenost je vhodná na data, která mají vysokou dimenzionalitu, která není přítomna u realizované metody KNN pro BBB, kde je pouze 5 základních příznaků. Kosinova vzdálenost je užita pro detekci podobnosti v analýze textu (detekce plagiátorství atd.). [38]

V další fázi byly vstupní proměnné dat redukovány pomocí PCA analýzy, pro urychlení klasifikace modelů a odstranění proměnných, které mají velmi malý vliv na rozlišitelnost arytmií. Data byly normalizovány a testovány pomocí MATLAB funkce pca(). Výstupní proměnná dané funkce "explained" představuje poměr rozptylů jednotlivých komponent vůči celkovému rozptylu dat. Suma rozptylů dat vysvětluje 100% rozptylu, kde průměr vysvětluje 45.094%, rozptyl 29.795%, směrodatná odchylka 16.223%, šikmost 7.513% a křivost 1.373% celkového rozptylu.

Pro redukci dat bylo vybráno rozmezí 95-99% rozptylu, teda malý vliv na rozlišitelnost arytmií. Křivost má nejmenší zastoupení celkového rozptylu, a proto byla data redukovaná na pouze 4 příznaky (průměr, rozptyl, směrodatná odchylka a šikmost) s celkovým vysvětleným rozptylem 98,627%

5.5 Úspěšnost realizovaných metod

Obě metody detekcí KES a BBB byly testovány, optimalizovány a jejich úspěšnost byla zapsána do tabulek níže (Tab.1 a Tab.2). Jejich úspěšnost byla vyhodnocena pomocí statistických hodnot parametrů senzitivity a specificity. Senzitivita vyjadřuje úspěšnost pozitivní detekce a je popsaná vzorcem:

$$senzitivita = \frac{počet\ skutečně\ pozitivních}{počet\ skutečně\ poitivních + počet\ falešně\ negativních}\ . \quad (5.1)$$

Specificita vyjadřuje schopnost správně detekovat negativní detekce a je popsaná vzorcem:

$$specificita = \frac{počet\ skutečně\ negativních}{počet\ skutečně\ negativních + počet\ falešně\ pozitivních}\ . \quad (5.2)$$

Pro detekci KES byla nejvyšší úspěšnost dosažena pomocí Euklidovské metriky s počtem sousedů 3, kde celková úspěšnost dosahuje 97,26%. Pro detekci KES byla nejvíce úspěšná Euklidovská metrika s počtem sousedů 5, kde metoda dosáhla celkové úspěšnosti 94,91%.

Detekce komorových extrasystol (KES)				
distanční metrika	počet sousedů	přesnost [%]	senzitivita [%]	specificita [%]
Euklidovská	1	96,32	95,22	97,14
	3	97,26	97,67	96,67
	5	96,08	95,12	97,50
Mahalanobovská	1	96,29	95,65	96,77
	3	95,45	96,15	95,24
	5	94,21	92,86	97,50

Tab. 1 Úspěšnost detekce KES

Detekce blokád tawarových ramének (BBB)				
distanční metrika	počet sousedů	přesnost [%]	senzitivita [%]	specificita [%]
Euklidovská	1	93,37	97,24	87,53
	3	93,92	92,68	95,12
	5	94,91	93,1	96,67
Mahalanobovská	1	90,94	93,54	88,57
	3	91,89	89,62	94,73
	5	92,78	90,91	94,45

Tab.2 Úspěšnost detekce BBB

Realizované metody detekce byly následně porovnány s veřejně dostupnými metodami, využívající jiné nebo podobné metodiky. Detekce BBB byla porovnána s metodami GA-ANN, PCA-ANN [22] a KNN podle analýzy QRS komplexů [28]. Detekce KES byla porovnána s metodami ze zdrojů [25] a [27].

Detekce blokád tawarových ramének (BBB)				
Metoda	přesnost [%]	senzitivita [%]	specificita [%]	reference
Tato práce	94,91	93,1	96,67	
GA-ANN	98,71	98,35	98,71	[22]
PCA-ANN	77,66	55,33	98,2	[22]
KNN	99,05	99,48	99,30	[28]

Tab. 3 Porovnání detekce BBB vůči jiným metodám

Detekce komorových extrasystol (KES)				
metoda	přesnost [%]	senzitivita [%]	specificita [%]	reference
Tato práce	97,26	97,67	96,67	
DNN	99,41	96,08		[25]
ETMA	99.00	90,81	99,4	[27]

Tab. 4 Porovnání detekce KES vůči jiným metodám

Závěr

Tato bakalářská práce se zaměřuje na detekci arytmií ze záznamů elektrokardiogramu (EKG) z databáze BTL_Dataq. Celá bakalářská práce je rozdělena do úvodu a 4 jednotlivých kapitol. V první kapitole jsou popsány a uvedeny charakteristiky elektrokardiogramu (EKG), poloh svodů a základní komponenty EKG křivky. V druhé části jsou popsány základní vlastnosti arytmií a následně vlastnosti vybraných arytmií, tedy komorových extrasystol (KES) a blokád Tawarových ramének (BBB), které jsou oblastí zájmu této bakalářské práce. Ve třetí části jsou popsány jak konvenční přístupy, tak i moderní přístupy využivající strojové učení a neuronové sítě. Z této části byly také vybrány 2 metody, které byly následně realizovány v praktické části v prostředí MATLAB.

První metodou je detekce komorových extrasystol (KES) spojením metod z kapitol 4.1 a 4.7. Metodika spočívá v různé morfologii mezi sinusovým a KES QRS komplexem, jejich statistických parametrů a předčasnosti/kompenzace, která jsou typické pro komorové extrasystoly. Tato vlastnost byla využita pro detekci pomocí metody K-nejbližších sousedů (KNN). Metoda byla realizována a nejvyšší úspěšnosti za užití Euklidovské distanční metriky s počtem sousedů 3, kdy metoda dosáhla senzitivity 97,67%, specificity 96,97% a celkové úspěšnosti 97,26%. Tato metoda byla následně optimalizována změnami parametrů a redukci příznaků pomocí PCA a vizuální analýzy pomocí box-plot grafů. Metoda byl porovnána s ostatními dostupnými metodami. I když metoda měla poměrně vysokou úspěšnost, tak měla celkově menší úspěšnost než porovnávané metody. I přes nízký stupeň úspěšnosti, v porovnání s ostatními metodami, stále dosáhla celkové úspěšnosti 97,26%, tedy dokáže dobře rozpoznat komorové extrasystoly vůči normálním QRS komplexům.

Druhou metodou byla detekce blokád Tawarových ramének (BBB) realizací metody z kapitoly 4.7. Stejně jako metoda detekce KES, využívá změnu statistických parametrů QRS komplexů pro sinus a BBB, které lze použít pro detekci pomocí KNN. Metoda byla realizována a dosáhla nejvyšší úspěšnosti při užití Euklidovské vzdálenosti s počtem sousedů 5, kdy dosáhla senzitivity 93,1%, specificity 96,67% a celkové úspěšnosti 94,91%. Metoda byla optimalizována a porovnána s veřejně dostupnými

metodami. Metoda detekce BBB byla pouze úspěšnější v porovnání s metodou PCA-ANN. Nižší úspěšnost byla způsobena častou falešnou pozitvní či negativní detekcí jiných arytmií, kdy nemusel být výrazný rozdíl statistických parametrů pro sinus, BBB a jiné. Vynechání třídy "jiné" by se mohla velikost zvýšit a rovnat se s porovnanými metodami, které se pouze zaměřují na vybrané arytmie.

Obě metody byly realizovány pomocí klasifikační metody KNN. K výhodám KNN patří snadné pochopení metody, schopnost práce s nelineárními daty a vysoká úspěšnost při dostatku a správném přípravě trénovacích dat. K nevýhodám KNN patří striktní dodržení struktury testovacích a trénovacích dat, kdy nevhodné uspořádání nebo nevhodně přiřazená klasifikace může vést k nesprávné detekci a dále je metoda omezena pouze na vybrané třídy, tedy přítomnost jiných arytmií může vést ke špatné detekci (případ u detekce BBB). Mezi ostatní nevýhody může patřit omezená dimenzionalita dat, nevhodná metrika a paměťová náročnost (model musí zachovat trénovací data při každém spuštění).

I přes výše zmíněné výhody a nevýhody, realizované detekční metody dosáhly úspěšností větších než 90%, tedy více než 90% případů dokáže správně klasifikovat do přiřazených tříd. Dané metody mohou být tedy použity pro klasifikaci záznamů EKG, ale ke klinickému použití je úspěšnost stále malá. Problémem daných metod může být poměrně malá velikost trénovacích dat a úspěšnost by tedy mohla být vyšší. V případě detekce BBB nastal problém, kdy k výběru vzorových záznamů LBBB byla použita většina použité databáze BTL_dataq a nastala by nedostatečná velikost samotných testovacích dat pro LBBB a vznikla možná nehomogenita v testovacím setu. Dále by mohly být další příznaky redukovány pomocí PCA analýzy, ale to by mohlo vést k málému celkovému vysvětlenému rozptylu a úspěšnost by mohla být nižší.

V potenciálních navazujících pracích mohou být tyto detekční metody buď obohaceny, zvětšena trénovací databáze nebo užita jiná klasifikační metoda (např. neuronové sítě).

LITERATURA

[1] PARKER, STEVE. LIDSKÉ TĚLO. V PRAZE: EUROMEDIA GROUP - KNIŽNÍ KLUB, 2007. ISBN 978-80-242-2211-0.

[2] MITCHELL, L.B. Overview of arrhytmias: cardiovascular disorders. MSD Manual Professional Edition.

[3] KLABUNDE, Richard E. Cardiovascular Physiology Concepts. Indianapolis (Indiana): Marian University College of Osteopathic Medicine, 2022.

[4] SATTAR, Y a L CHHABRA. Electrocardiogram. Treasure Island (FL): StatPearls Publishing, 2022.

[5] ASHLEY, EA a J NIEBAUER. Cardiology Explained. London: Remedica, 2004.

[6] FARZAM, K a JR RICHARDS. Premature Ventricular Contraction. Treasure Island (FL): StatPearls Publishing, 2022.

[7] AHN, MS. Current Concepts of Premature Ventricular Contractions. J Lifestyle Med. 2013.

[8] BURNS, Ed a Robert BUTTNER. Premature Ventricular Complex (PVC). Life in the Fast Lane. 2021.

[9] CUESTA, Pedro, María J. LADO, Xosé A. VILA a Raúl ALONSO. Detection of premature ventricular contractions using the RR-interval signal: A simple algorithm for mobile devices. Technology and Health Care. 2014.

[10] LYSÁK, Karel. Metody detekce QRS komplexu. Brno, 2014. Bakalářská práce. VUT FEKT. Vedoucí práce Ing. Lukáš Smítal.

[11] CUESTA, Pedro, María J. LADO, Xosé A. VILA a Raúl ALONSO. Detection of premature ventricular contractions using the RR-interval signal: A simple algorithm for mobile devices. Technology and Health Care. 2014.

[12] PETRYSHAK, Bohdan, Illia KACHKO, Mykola MAKSYMENKO a Oles DOBOSEVYCH. Robust deep learning pipeline for PVC beats localization. Technology and Health Care. 2021.

[13] Left Bundle Branch Block (LBBB): ECG criteria, causes, management. ECG & ECHO. 2020.

[14] BUTTNER, R, E BURNS, R.B. BURNS a E BURNS. Left Bundle Branch Block (LBBB). Life in the Fast Lane. 2022.

[15] BUTTNER, R, E BURNS, R.B. BURNS a E BURNS. Right bundle branch block (RBBB). Life in the Fast Lane. 2022.

[16] HARKNESS, WT a M HICKS. Right Bundle Branch Block. Treasure Island (FL): StatPearls Publishing, 2022.

[17] MANE, Rameshwari S, A N CHEERAN a Priya RANI. Cardiac Arrhythmia Detection By ECG Feature Extraction. International Journal of Engineering Research and Applications. 2013.

[18] Přispěvatelé WikiSkript, Elektrokardiografie (2. LF UK). 2023.

[19] Přispěvatelé WikiSkript, EKG (pediatrie). 2016.

[20] FAJKUS, Jiří. Moderní metody detekce QRS komplexů. Brno, 2010. Bakalářská práce. VUT FEKT (UBMI). Vedoucí práce Ing. Martin Vítek.
[21] PACHAURI, Awadhesh a Manabendra BHUYAN. Wavelet and energy based approach for PVC detection. 2009 International Conference on Emerging Trends in Electronic and Photonic Devices & Systems. 2009.
[22] R. Allami, A. Stranieri, V. Balasubramanian a H. F. Jelinek. Genetic algorithm-neural network wrapper approach for bundle branch block detection. Computing in Cardiology Conference (CinC). 2016.
[23] HARSHITA, Pandey a Tiwari RAJINDER. An Innovative Approach to the Reduction of Noise in ECG Signal through Chebyshev Type 2 Digital Filter. 2013.
[24] Different Types of Chebyshev Filters with Calculations. ELPROCUS: Electronics, projects, focus. 2013.
[25] JUN, Tae Joon, Hyun Ji PARK, Nguyen Hoang MINH, Daeyoung KIM a Young-Hak KIM. Premature Ventricular Contraction Beat Detection with Deep Neural Networks. In: 2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA). 2016.
[26] TERESHCHENKO, Larisa G. a Mark E. JOSEPHSON. Frequency content and characteristics of ventricular conduction. Journal of Electrocardiology. 2015.
[27] MALEK, Abdel Salam, Ashraf ELNAHRAWY, Hamed ANWAR a Mohamed NAEEM. Automated detection of premature ventricular contraction in ECG signals using enhanced template matching algorithm. Biomedical Physics & Engineering Express. 2020.
[28] DEV SHARMA, Lakhan, Ramesh Kumar SUNKARIA a Aman KUMAR. Bundle branch block detection using statistical features of QRS-complex and k-nearest neighbors. 2017 Conference on Information and Communication Technology (CICT). 2017.
[29] https://www.physionet.org
[30] J. -S. Wang, Y. Zhang, P. Zhang a S. -F. Sun. Research on denoising algorithm for ECG signals. Proceedings of the 29th Chinese Control Conference. Beijing, China, 2010.
[31] CHATTERJEE, Shubhojeet, Rini Smita THAKUR, Ram Narayan YADAV, Lalita GUPTA a Deepak Kumar RAGHUVANSHI. Review of noise removal techniques in ECG signals. IET Signal Processing. 2020.
[32] The MathWorks Inc. Fit k-nearest neighbor classifier. Natick, Massachusetts, USA: The MathWorks, 2023
[33] CHANG, W.H., Philippe KANG-PING LIN a SHINN-YIH TSENG. ECG analysis based on Hilbert transform descriptor. Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 1988.

[34] MAZIDI, Mohamad Hadi. Premature Ventricular Contraction (PVC) Detection System Based on Tunable Q-Factor Wavelet Transform. Journal of Biomedical Physics and Engineering. 2022.
[35] GUPTA, Varun a Monika MITTAL. Arrhythmia Detection in ECG Signal Using Fractional Wavelet Transform with Principal Component Analysis. Journal of The Institution of Engineers (India): Series B. 2020.
[36] AL-NAAMI, Bassam, Hossam FRAIHAT, Hamza Abu OWIDA, Khalid AL-HAMAD, Roberto DE FAZIO a Paolo VISCONTI. Automated Detection of Left Bundle Branch Block from ECG Signal Utilizing the Maximal Overlap Discrete Wavelet Transform with ANFIS. Computers. 2022.
[37] KORA, Padmavthi, Sri Rama Krishna KALVA, Hamza Abu OWIDA, Khalid AL-HAMAD, Roberto DE FAZIO a Paolo VISCONTI. Detection of Bundle Branch Block using Adaptive Bacterial Foraging Optimization and Neural Network. Egyptian Informatics Journal. 2017.
[38] SARANG ANIL GOKTE. Most Popular Distance Metrics Used in KNN and When to Use Them. Kdnuggets.com [online].

SEZNAM PŘÍLOH

Příloha A – Realizované algoritmy detekčních metod, včetně trénovacích dat KNN metody jsou uložené v IS VUT v komprimovaném souboru typu zip.

SEZNAM SYMBOLŮ A ZKRATEK

Zkratky:

FEKT	Fakulta elektrotechniky a komunikačních technologií
VUT	Vysoké učení technické v Brně
EKG	Elektrokardiogram
KES	Komorové extrasystoly
BLRT	Blokáda levého Tawarova raménka
LBBB	Left bundle branch block
BPRT	Blokáda pravého Tawarova raménka
RBBB	Right bundle branch block
CWT	spojitá vlnková transformace
DWT	diskrétní vlnková transformace
KNN	K-nejbližších sousedů
TQWT	Nastavitelná Q-faktor vlnková transformace
PCA	Analýza hlavních komponent
SNR	Poměr signál-šum
ANFIS	Adaptivní neuro fuzzy inferenční systém
MODWT	Diskrétní vlnková transformace s maximálním překrytím
PCA	Analýza hlavních komponent
GA	genetický algoritmus
ANN/UNN	umělá neuronová síť
DNN	hluboká neuronová síť
ETMA	Vylepšený algoritmus pro poznávání šablon
BBB	Blokáda Tawarových ramének
BFO	Bakteriální hledací optimalizace