



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 ATRIÁLNÍCH FIBRILACÍ METODAMI V ČASOVÉ OBLASTI

ATRIAL FIBRILLATION DETECTION USING TIME-DOMAIN METHODS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Maroš Sámel

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Oto Janoušek, Ph.D.

BRNO 2019

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Maroš Sámel

ID: 171282

Ročník: 3

Akademický rok: 2018/19

NÁZEV TÉMATU:

Detekce atriálních fibrilací metodami v časové oblasti

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou detekce atriálních fibrilací metodami založenými na analýze komorového rytmu. 2) Proveďte literární rešerši těch metod, které lze aplikovat na krátkodobé úseky elektrokardiogramu a které využívají kvantifikátory v časové a/nebo geometrické oblasti. 3) Porovnejte vlastnosti těchto metod, vyberte si jednu z nich a zdůvodněte její výběr. 4) Implementujte vybranou metodu v prostředí Matlab. 5) Na anotovaných elektrokardiogramech z databáze UBMI ověřte detekční schopnosti realizované metody. 6) Statisticky zpracujte výsledky a interpretujte jejich význam. 7) Zhodnoťte reálnou úspěšnost metody a srovnajte dosažené výsledky s teoretickou úspěšností vybrané metody i s teoretickou úspěšností ostatních metod zahrnutých v literární rešerši.

DOPORUČENÁ LITERATURA:

[1] SAHOO, Sujit Kumar, Wenmiao LU, Sintiani Dewi TEDDY, Desok KIM, et al. Detection of atrial fibrillation from non-episodic ECG data: a review of methods. In 33rd Annual International Conference of the IEEE EMBS, Boston, USA, 2011, s. 4992-4995.

[2] CLIFFORD, Gari D, Francisco AZUAJE a Patrick MCSHARRY. Advanced methods and tools for ECG data analysis. Boston: Artech House, 2006, 384 s. ISBN 1-58053-966-1.

Termín zadání: 4.2.2019

Termín odevzdání: 24.5.2019

Vedoucí práce: Ing. Oto Janoušek, Ph.D.

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

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

Účelom tejto práce je zoznámenie sa s problematikou atriálnych fibrilácií, jej porozumenie a následné spracovanie metód detekcie atriálnych fibrilácií založených na analýze komorového rytmu. Metódy spracované v tejto práci sú: metóda mediánov, metódy založené na histogramoch (na základe výpočtu variančného koeficientu a porovnaní histogramov hustôt RR a Δ RR intervalov s SDH), metóda využívajúca RdR mapu, metóda využívajúca komplexity RR intervalov a metódy detekcie založené na štatistických rozloženiach pomocou Gaussovského rozloženia a Laplaceovej funkcie.

Praktická časť je zameraná na porovnanie spomínaných metód a výber tej najvhodnejšej – zvolená bola metóda mediánov. Nasleduje jej realizácia v prostredí Matlab, a testovanie na reálnych dátach nami zvolenej databázy. V závere sa vyhodnotí jej reálna úspešnosť a porovná s teoretickými predpokladmi ostatných metód. Nami zostrojený algoritmus detekcie atriálnych fibrilácií založený na metóde mediánov dosiahol výborné výsledky, najvyššia obdržaná hodnota špecificity bola 93,976%, senzitivity 89,182% a AUC (plocha pod krivkou) 0,973.

Kľúčové slová

Atriálne fibrilácie, elektrokardiografia, R hrot, krátkodobé RR intervaly, špecificita, senzitivita.

Abstract

The purpose of this work is to get better understanding of the problems of atrial fibrillation followed by the processing methods for detection of atrial fibrillation based on an analysis of the ventricular rhythm. Methods that are described: method of medians, methods based on histograms (using coefficient of variation and density histograms of RR and Δ RR intervals), method using RdR map, method using complexity of RR intervals and methods based on a statistical framework by Gaussian distribution and Laplace function

The practical part of this work is focused on comparing these methods and selecting the best one – method of medians is the chosen one. This is followed by implementation of this method in the Matlab and testing it on the real data from a selected database. In the end, the detection ability of our method is evaluated and compared with the theoretical detection abilities of the other methods. Our algorithm for detection of atrial fibrillations, based on the median method, achieved excellent results with the highest value of specificity obtained at 93,976%, sensitivity at 89,182% and AUC (area under the curve) at 0,973.

Keywords

Atrial fibrillation, electrocardiography, R peak, short term RR intervals, specificity, sensitivity.

Bibliografická citácia:

SÁMEL, M. *Detekce atriálních fibrilací metodami v časové oblasti*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2018. 46 s. Vedúci bakalárskej práce: Ing. Oto Janoušek, Ph.D.

Prehlásenie

„Prehlasujem, že svoju záverečnú prácu na tému, Detekce atriálních fibrilací metodami v časové oblasti, som vypracoval samostatne pod vedením vedúceho bakalárskej práce s použitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autor uvedenej záverečnej práce som neporušil autorské práva tretích osôb, najmä som nezasiahol nedovoleným spôsobom do cudzích autorských práv osobnostných a som si plne vedomý následkov porušenia ustanovenia § 11 a nasledujúceho autorského zákona č. 121/2000 Sb., vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovení časti druhej, hlavy VI. diel 4 Trestného zákonníku č. 40/2009 Sb.

V Brne dňa 24.5.2019

.....
podpis autora

Pod'akovanie

Ďakujem vedúcemu bakalárskej práce Ing. Otovi Janouškovi, Ph.D., za účinnú metodickú, pedagogickú a odbornú pomoc a ďalšie cenné rady pri spracovaní mojej bakalárskej práce.

V Brne dňa 24.5.2019

.....
podpis autora

OBSAH

ÚVOD	1
1 TEORETICKÁ ČASŤ	2
1.1 Srdce	2
1.1.1 Prevodový systém srdca	2
1.1.2 Elektrokardiografia (EKG).....	4
1.2 Atriálne fibrilácie	6
1.2.1 Patofyziológia a mechanizmus vzniku AFIB.....	7
1.2.2 Klasifikácie atriálnych fibrilácií a ich liečba	8
1.3 Metódy detekcie atriálnych fibrilácií	10
1.3.1 Metóda mediánov	10
1.3.2 Metódy založené na histogramoch.....	12
1.3.3 Metóda využívajúca RdR mapu	14
1.3.4 Metóda využívajúca komplexity RR intervalov	15
1.3.5 Metódy detekcie založené na štatistických rozloženiach	18
1.4 Porovnanie detektorov atriálnych fibrilácií	20
2 PRAKTICKÁ ČASŤ	23
2.1 Databáza ÚBMI	23
2.2 Vybraná metóda detekcie atriálnych fibrilácií – metóda mediánov	24
2.2.1 Hodnotenie detekčnej schopnosti detektoru	28
2.3 Porovnanie detektorov AFIB so zestrojeným detektorom.....	36
3 Záver	40
Bibliografia	42
Zoznam použitých skratiek	45
Zoznam príloh.....	46

Zoznam obrázkov

Obrázok 1: Šírenie elektrických vzruchov v srdci, prevzaté z [22]	3
Obrázok 2: EKG krivka s popisom jednotlivých častí, prevzaté z [1].....	4
Obrázok 3: Prevalencia AFIB v jednotlivých vekových skupinách podľa štúdie ATRIA, prevzaté z [23]	7
Obrázok 4: AFIB s nepravidelne nepravidelným komorovým rytmom, prevzaté z [4]	8
Obrázok 5: Vývojový diagram krokov daného algoritmu, popis častí uvedený v texte vyššie, prevzaté a preložené z [15].....	11
Obrázok 6: Bodový diagram RR intervalov (v ms) a dRR intervalov (v ms). Vľavo diagram A - signalizuje AFIB, vpravo - B signalizuje sínusový rytmus, prevzaté z [17].....	14
Obrázok 7: Výsledky v jednotlivých častiach algoritmu: (a) Originálny signál s anotáciou RR intervalov. (b) Výpočet RMSSD/MeanRR, (c) TPR, (d) Shannonova entropia zobrazená spolu s optimalizovaným prahom, (e) zobrazenie detekcie, prevzaté z [19].....	17
Obrázok 8: Histogram normalizovaných RR intervalov (so strednou hodnotou 0) s nanesením Gaussovej a Laplaceovej funkcie, prevzaté a preložené z [20]	19
Obrázok 9: Reprézntácia matice "matrix" v prostredí Matlab.	25
Obrázok 10: Zostrojená ROC krivka pre dĺžku okna „buffer“=3 a všetky AFIB.	30
Obrázok 11: Zostrojená ROC krivka pre dĺžku okna „buffer“=4 a všetky AFIB.	30
Obrázok 12: Zostrojená ROC krivka pre dĺžku okna „buffer“=5 a všetky AFIB.	31
Obrázok 13: Zostrojená ROC krivka pre dĺžku okna „buffer“=6 a všetky AFIB.	31
Obrázok 14: Zostrojená ROC krivka pre dĺžku okna „buffer“=7 a všetky AFIB.	32
Obrázok 15: Zostrojená ROC krivka pre dĺžku okna „buffer“=3 a čisté AFIB.	32
Obrázok 16: Zostrojená ROC krivka pre dĺžku okna „buffer“=4 a čisté AFIB.	33
Obrázok 17: Zostrojená ROC krivka pre dĺžku okna „buffer“=5 a čisté AFIB.	33
Obrázok 18: Zostrojená ROC krivka pre dĺžku okna „buffer“=6 a čisté AFIB.	34
Obrázok 19: Zostrojená ROC krivka pre dĺžku okna „buffer“=7 a čisté AFIB.	34

Zoznam tabuliek

Tabuľka 1: Detekčná schopnosť detektoru s použitím Gaussovej funkcie (L1) a Laplaceovej funkcie (L2) na daných databázach, prevzaté a preložené z [20].....	20
Tabuľka 2: Tabuľka parametrov vybraných detektorov.....	20
Tabuľka 3: Štatistické vyhodnotenie detektoru pre rôzne dĺžky okien "buffer" a všetky AFIB.....	35
Tabuľka 4: Štatistické vyhodnotenie detektoru pre rôzne dĺžky okien "buffer" a čisté AFIB.....	35
Tabuľka 5: Reálne úspešnosti nami vyhotoveného detektoru metódy mediánov a jeho teoretické predpoklady úspešností.....	37
Tabuľka 6: Zhrnutie reálnej úspešnosti nami vyhotoveného detektoru spolu s ostatnými detektormi vhodnými na detekciu pre krátkodobé úseky EKG.....	38

ÚVOD

Atriálne fibrilácie (ďalej označované len ako AFIB) sa stali v posledných rokoch predmetom zvýšeného záujmu, pretože sa jedná o najrozšírenejšiu srdcovú arytmiu. Je dôležité zaoberať sa touto problematikou, aby sme ich mohli efektívne liečiť a predchádzať im. Pomoc pri boji s AFIB ponúkajú automatizované metódy na ich detekciu a dopyt po týchto metódach stále narastá. Táto práca sa zaoberá práve týmito metódami.

V prvej, teoretickej kapitole, sú priblížené poznatky potrebné k pochopeniu fungovania orgánu srdca a jeho prevodového systému. Tieto znalosti pomohli lepšie pochopiť mechanizmus vzniku AFIB a jeho prejavy na EKG krivke čo viedlo k výberu správnych metód, ktoré sa dajú aplikovať na detekciu AFIB pre krátkodobé úseky EKG. Následne sú vyhl'adané a vybrané vhodné metódy na detekciu AFIB založené na analýze komorového rytmu. Na základe určených parametrov sa tieto metódy porovnali a bola vybraná najvhodnejšia z nich, s ktorou sa ďalej pracovalo.

V druhej, praktickej časti, je realizovaná vybraná metóda v prostredí Matlab, popísané jej fungovanie a overenie jej detekčnej schopnosti na vybranom sete dát. V rámci vybraného setu dát, sa vybraná metóda aplikuje na signály obsahujúce fyziologický, sínusový rytmus, v zmesi s AFIB (buď čisté AFIB, bez iných arytmií, alebo tiež v zmesi s inými arytmiami).

Neskôr sa vyhodnotila, zo získaných výsledkov, jej reálna úspešnosť detekcie AFIB a porovнала s teoretickými úspešnosťami detekcie ostatných metód, ktoré sú rozobraté v prvej, teoretickej kapitole. Na záver je zhodnotenie celkovej úspešnosti realizácie nášho detektoru a popísanie návrhov na vylepšenie tejto metódy.

1 TEORETICKÁ ČASŤ

1.1 Srdce

Srdce je motorom obehovej sústavy. Pracuje ako tlakovo-objemová pumpa, ktorá je rozdelená na dve, v sérii zapojené, nezávislé podjednotky – ľavá a pravá podjednotka. Každá z týchto častí je tvorená predsieňou a komorou, ktoré sú od seba oddelené chlopňovým aparátom. Srdce je neustále zaťažované, vháňa do obehovej sústavy približne 4,7 litra krvi za minútu. Do pravej predsieni je vedená žilná krv, ktorá je následne čerpaná pravou komorou. Odtiaľ je ďalej vedená do malého pľúcneho obehu, kde sa okyslí a priteká do ľavej predsieni a následne do ľavej komory. Tu začína distribúcia krvi veľkým telovým obehom do tela. [21]

Srdce funguje na báze dvoch zložiek – elektrickej a mechanickej. Tieto zložky sú úzko prepojené a jedna na druhej závislé. Depolarizácia (zmena polarizácie membránového napätia) a repolarizácia (vrátenie hodnôt membránového napätia do pôvodného stavu) sú dva elektrické deje, ktoré sa mechanicky prejavujú stiahnutím, alebo uvoľnením myokardu (systola a diastola). Z pohľadu analýzy vzniku, šírenia a detekcie AFIB sa budeme ďalej venovať výhradne elektrickej zložke srdca, pretože AFIB sú patofyziologickým prejavom práve tejto zložky. [1]

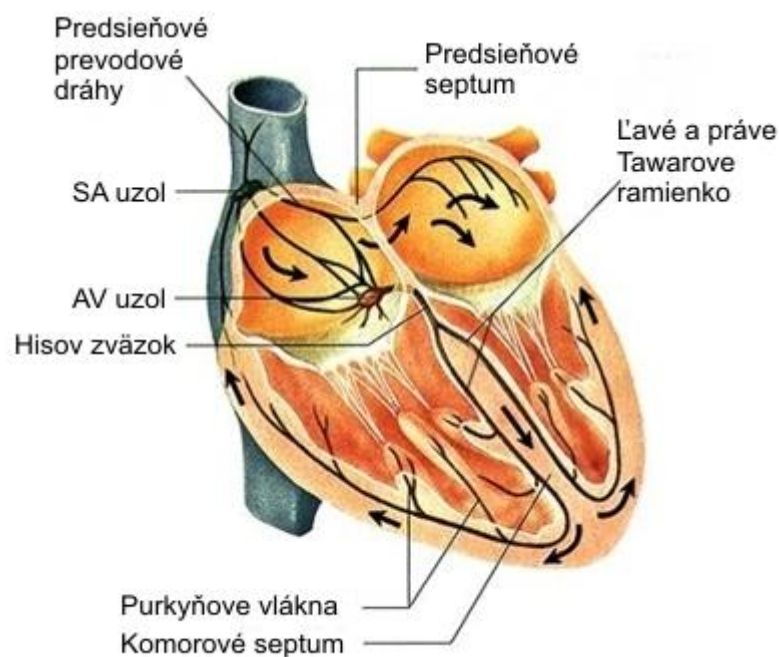
1.1.1 Prevodový systém srdca

Táto podkapitola sa bude venovať popisu vzniku a vedenia vzruchov (elektrických signálov) v srdci za fyziologických podmienok. Porozumenie šíreniu vzruchov v srdci a ich následná reprezentácia formou EKG krivky, čítanie tejto krivky a jej vyhodnocovanie sú základným kameňmi k pochopeniu vzniku akýchkoľvek fibrilácií. Nasledujúce kapitoly nám umožnia lepšie pochopiť vznik fibrilácií, v našom prípade AFIB, a priblížia problematiku patofyziologických zmien prevodného systému srdca a ich prejav na EKG krivke. [1]

V srdci sa vyskytujú časti, ktoré sa prednostne špecializujú na tvorbu a prenos elektrického signálu: sinoatriálny uzol (ďalej len SA uzol – nachádza sa v pravej predsieni), preferenčné predsieňové dráhy ústiace do

atrioventrikulárneho uzlu (ďalej len AV uzol), Hisovho zväzku, Tawarovho ramienka (pravé a ľavé) a Purkyňove vlákna. [2]

Aby mohlo dôjsť k mechanickému stiahnutiu myokardu, v SA uzle musí vzniknúť podnet na jeho podráždenie. SA uzol teda predstavuje pacemaker (z angl. „udávateľ rytmu“) pre srdce. Tieto podnety vznikajú s frekvenciou 60-100 za minútu a z SA uzlu sú po svalovine predsiení vedené preferenčnými dráhami až k AV uzlu. Ďalej putujú cez Hisov zväzok a oboma jeho Tawarovými ramienkami až do Purkyňových vlákien. Tie prenášajú akčné potenciály až k myokardu komôr, ktorý sa kontrahuje (vizualizácia prevodu je na obrázku 1). [3]




Obrázok 1: Šírenie elektrických vzručov v srdci, prevzaté z [22]

Srdcovú frekvenciu určuje miesto s najvyššou frekvenciou depolarizácií. Za fyziologického fungovania to je spomínaný SA uzol, avšak ak sa v predsieňach nachádza patologický fokus, ktorý predbieha SA uzol a generuje podnety na vznik depolarizácií, stáva sa udavačom tempa (spolu s SA uzlom) a tým sa zvýši srdcová frekvencia, stane sa nepravidelná a chaotická (bližší popis v kapitole 1.2.1.). [3]

1.1.2 Elektrokardiografia (EKG)

EKG krivka (obrázok 2) slúži na meranie a zobrazovanie elektrickej aktivity myokardu v čase a je snímaná elektródami z povrchu tela. Analýza EKG záznamu je najdôležitejšou diagnostickou metódou pre detekciu AFIB. Porozumieť jednotlivým častiam EKG krivky, vedieť s ňou pracovať a vyhodnocovať ju je nevyhnutné pre bližšiu analýzu signálov, ktoré môžu obsahovať AFIB. [4]



Obrázok 2: EKG krivka s popisom jednotlivých častí, prevzaté z [1]

P vlna

Depolarizácia predsiení sa na EKG zobrazí P vlnou, ktorá fyziologicky predchádza každému QRS komplexu, od ktorého je oddelená PQ intervalom. Depolarizácia predsiení vzniká v sínusovom uzle a smeruje do AV uzlu smerom k dolným končatinám a preto sa na EKG P vlna zobrazuje ako pozitívna v zvodoch zameraných na dolnú časť srdca (napríklad zvody II, III a aVF) a naopak negatívne sa zobrazuje pre zvod zameraný na hornú časť srdca (aVR). [5]

Absencia P vlny naznačuje abnormálnu činnosť srdca a môžu symbolizovať vznik AFIB. V našej práci sa avšak budeme zaoberať detekciou AFIB len na základe RR intervalov, pretože absencia P vlny, prípadné nahradenie týchto vln f vlnami (fibrilačnými vlnami), je, čo sa týka automatizovaných algoritmov, veľmi zložitá a taktiež aj nepresná (z dôvodu veľkej variácie P vlny). Detektory AFIB využívajú rôznu morfológiu P vlny prevažne len ako pomocný faktor pri detekcii. [4]

PQ interval

Tento interval je meraný od vzniku P vlny až po začiatok vzniku QRS komplexu a odpovedá dobe od konca depolarizácie predsiení až po začiatok depolarizácie komôr. Doba trvania tohto intervalu je 0,12-0,21 s. [4]

QRS komplex

Najvýraznejšou zložkou EKG krivky je QRS komplex, ktorý zobrazuje elektrické vektory počas depolarizácie komôr. Amplitúda tejto krivky je oveľa väčšia ako amplitúda P vlny a to z dôvodu, že svalovina komôr je oveľa robustnejšia ako svalovina predsiení. QRS komplex predstavuje šírenie vzruchu od AV uzlu cez Hisov zväzok, ktorý je ďalej rozdelený na pravé a ľavé Tawarové ramienko až ku Purkyňovým vláknam. Prevod vzruchov v komorovej svalovine je cez tento systém veľmi rýchly, doba QRS komplexu trvá do 0,11 s. Predĺženie ($\geq 0,12$ s) tohto komplexu môže značiť vznik AFIB. QRS komplex môže mať 3 typy kmitov:

- kmit Q – začiatok QRS komplexu avšak môže aj chýbať, je to prvý negatívny kmit,
- kmit R – zobrazuje každý pozitívny kmit komplexu,
- kmit S – negatívne kmity nasledujúce po R kmite. [5]

RR interval

RR interval je časový úsek medzi dvomi hrotmi susedných R kmitov v QRS komplexoch. Sú to momenty, kedy sú komory kompletne depolarizované. RR intervaly sa používajú aj na výpočet srdcovej frekvencie (počet komorových systol za minútu). Ak je rytmus RR intervalov nepravidelne nepravidelný (dĺžky RR intervalov sa vo veľkej miere menia), signalizuje to AFIB (viď. kapitola 1.2.1.). [4], [5]

ST segment

Je úsek medzi koncom QRS komplexu a začiatkom vlny T. Tento segment nám symbolizuje dobu repolarizácie a depolarizácie komôr. Patologické zmeny ST

segmentu, dynamika T vlny sa mení v EKG krivke, signalizuje často závažné srdcové stavy ako ischémie, alebo infarkt myokardu. [5]


T vlna

Vlna T symbolizuje repolarizáciu komôr pred ďalším sťahom srdca. Táto vlna je najvariabilnejšia v EKG krivke (môže mať rôzne tvary a dĺžky), ale má rovnakú polaritu ako QRS komplex. Za vlnou T môžeme registrovať aj vlnu U, ktorej pôvod nie je úplne jasný, predpokladá sa, že je výsledkom repolarizácie Purkyňových vlákien. [5]

1.2 Atriálne fibrilácie

Atriálne fibrilácie sú najčastejšie vyskytujúcou sa poruchou srdcového rytmu 21. storočia. Ich výskyt sa odhaduje približne na 1-2% populácie, pričom toto číslo sa nepretržite zvyšuje. Toto číslo zrejme nie je ani presné, pretože AFIB môžu prebiehať asymptomaticky a jedinec nemusí vôbec registrovať žiadne príznaky, alebo ich nepovažuje za dôležité. [6]

Prevalencia (percentuálny výskyt) AFIB veľmi výrazne narastá s vekom, u ľudí vo veku 40-50 rokov je približne 0,5%, kdežto u ľudí nad 80 rokov je výskyt odhadovaný približne na 10% (ako zobrazuje Obr. 3). U človeka staršieho ako 40 rokov je šanca na výskyt AFIB počas jeho života až 25%, na čo poukázali výsledky Framinghamskej štúdie [8], nárast tohto čísla je do budúcnosti predpokladaný. [7]



Obrázok 3: Prevalencia AFIB v jednotlivých vekových skupinách podľa štúdie ATRIA, prevzaté z [23]

AFIB sú ako arytmia zodpovedné až za 1/3 všetkých hospitalizácií pre poruchy srdcového rytmu. AFIB síce nie sú priamo život ohrozujúce, avšak kvalita života u postihnutých jedincov je nižšia a výrazne sa znižuje s rozsiahlosťou a dobou, kedy jedinec trpí AFIB. Navyše tým, že AFIB môžu prebiehať asymptomaticky, prvým prejavom týchto fibrilácií môže byť až cievna mozgová príhoda (postihnutí jedinci AFIB majú až 5x vyššiu tendenciu na výskyt mozgovo cievnej príhody, ako jedinci bez AFIB), iné tromboembolické komplikácie, alebo aj zlyhanie srdca, čo môže mať za následok smrť. Preto AFIB nepriamo zvyšujú morbiditu aj mortalitu pacientov. [6], [7]

Z týchto dôvodov je potrebné vyvíjať metódy na včasnú detekciu AFIB, najmä u rizikových pacientov trpiacich napríklad hypertenziou, diabetom, alebo tých, čo už prekonalí cievnu mozgovú príhodu (tendencia na vznik AFIB je u týchto rizikových pacientov vyššia). [7]


1.2.1 Patofyziológia a mechanizmus vzniku AFIB

Mechanizmus vzniku AFIB je komplikovaný a dôvodom vzniku môže byť viacero faktorov. AFIB sú charakterizované chaotickou a neusporiadanou elektrickou aktivitou v predsieňach v náhodných miestach, bez daného pacemakeru, s následnou stratou mechanickej kontrakcie srdca. Je to dané

vznikom patologických fokusov, ktoré tvoria mikro re-entry okruhy (dochádza ku krúženiu vzruchu po funkčne, či anatomicky definovanej dráhe) a predbiehajú SA uzol. [6]

Prevod impulzov cez AV uzol do komôr je náhodný, AV uzol nedokáže previesť všetky vzruchy z predsiení (ak by mohol, došlo by k fibrilácii komôr – na ochranu má refraktérnu periódu. Je to doba, za ktorú AV uzol nedokáže po prenesení impulzu prenášať iné impulzy). Niektoré impulzy sú úplne zablokované, iné zase len čiastočne prepustené. To má za následok, že nie vždy sa aktivujú komory a teda môžu spomaliť, alebo úplne zablokovať prevod ďalších vzruchov. Táto nepravidelnosť komorového rytmu sa na EKG krivke prejaví nepravidelne nepravidelnými RR intervalmi (môžeme pozorovať na obrázku 4) a je spôsobená štruktúrnymi, alebo elektrickými zmenami v predsieňach. Tento jav berieme ako hlavnú známku a indikátor AFIB. [6]

Ďalšou známkou AFIB je vysoká frekvencia predsieňových depolarizácií (vlny P na EKG) o hodnote 350-600/min. Tieto vlny voláme aj f vlny (fibrilačné vlny) a sú typické pre AFIB, avšak v našej práci budeme rozoberať metódy detekcie AFIB založené na nepravidelnosti RR intervalov, pretože tento indikátor nám s určitosťou indikuje prítomnosť AFIB a je hlavným prejavom AF. [6]



Obrázok 4: AFIB s nepravidelne nepravidelným komorovým rytmom, prevzaté z [4]

1.2.2 Klasifikácie atriálnych fibrilácií a ich liečba

O AFIB môžeme povedať, že sú veľmi špecifickou arytmiou, pretože krátko po vzniku AFIB u jedincov dochádza k zmenám elektrofyziologických vlastností predsieňovej svaloviny srdca, jej mechanickej funkcie a štruktúry, čo má za následok jednoduchšie udržanie AFIB v srdci a podmieňuje ďalšie vznikanie AFIB.

AFIB môžeme klasifikovať na základe mnohých aspektov, ale Česká kardiologická spoločnosť od roku 2011 [9] a Európska kardiologická spoločnosť

od roku 2010 [10] sa zhodli, že je najdôležitejšie klasifikovať AFIB z pohľadu dĺžky jej trvania u pacienta (je to dôležitý aspekt pri nastavení postupu liečby):

- prvá diagnostikovaná AFIB – prvé zaznamenanie AFIB, ktoré nám neumožňuje jej zaradenie. Môže sa jednať o ojedinelú epizódu, alebo opakujúcu sa - recidivujúcu AFIB. V tomto prípade treba najskôr vylúčiť prechodné príčiny a liečiteľné ochorenia (napríklad akútny infarkt myokardu, hypertyreóza, pľúcna embólia, ...),
- paroxysmálna AFIB – jedná sa o 2 a viac epizód AFIB, ktoré končia spontánne (bez liečby) behom 48 hodín. Ak AFIB trvajú viac ako 48 hodín, dochádza k remodelácií predsiení a spontánne ukončenie AFIB je málo pravdepodobné, v tom prípade treba začať s liečbou formou antiarytmík (lieky ovplyvňujúce srdcovú kontraktilitu a hemodynamiku [11]),
- perzistujúca AFIB – arytmia trvajúca dlhšie ako 7 dní, ktorá sa už spontánne neukončí. Predsiene sa začali remodelovať, mení sa ich štruktúra a vytvára sa substrát na udržiavanie AFIB – remodeláciou vzniká prostredie v srdci podporujúce ďalší vznik AFIB. Na ukončenie epizódy je nutné nasadiť medikamentóznou liečbu, alebo elektrickú kardioverziu (snaha o navodenie normálneho, sinusového rytmu pomocou elektrického výboja),
- dlhodobo perzistujúca AFIB – označuje epizódu trvajúcu viac ako 1 rok. Stále možnosť nápravy srdcového rytmu (sínusového rytmu) formou elektrickej ablácie („vypálenie“ mikro re-entry fokusov),
- permanentná AFIB – termín popisujúci stav, kedy pacient aj lekár akceptujú permanentnú prítomnosť arytmie v tele pacienta bez prerušení, predošlé pokusy o nápravu kardioverziou, antiarytmikami, alebo abláciou zlyhali. Sínusový rytmus už nie je možné navrátiť. [6]

Napriek tomu, že terapia AFIB existuje, až u 50% pacientov, táto arytmia progresuje z paroxysmálnej formy až do perzistujúcej, prípadne chronickej formy behom 10-tich rokov [12]. Opakované epizódy AFIB podnecujú opakované štrukturálne, mechanické a elektrofyziologické zmeny v predsieňach, čím sa tvorí

ideálne prostredie pre vznik ďalších AFIB. U pacientov s progresujúcou formou je pozorovaný väčší počet kardiovaskulárnych príhod a taktiež vyšší počet hospitalizácií. [13]

1.3 Metódy detekcie atriálnych fibrilácií

Nepravidelnú dĺžku RR intervalov považujeme za najpresnejší indikátor prítomnosti AFIB v EKG signáli, preto nasledujúce metódy popísané v tejto kapitole budú pracovať na základe nepravidelnej dĺžky RR intervalov. Nepravidelná dĺžka RR intervalov je daná rýchlou a chaotickou predsieňovou elektrickou aktivitou s frekvenciou 350-600/min. Táto elektrická aktivita má za následok stratu efektívnej kontrakcie predsiení. AV uzol nedokáže previesť všetky tieto predsieňové vzruchy, niektoré z nich blokuje, iné do AV uzlu ani neprejdú a teda komorový rytmus neodpovedá tomu predsieňovému na EKG sa nám zobrazia nepravidelne rozmiestnené QRS komplexy. [6]

1.3.1 Metóda mediánov

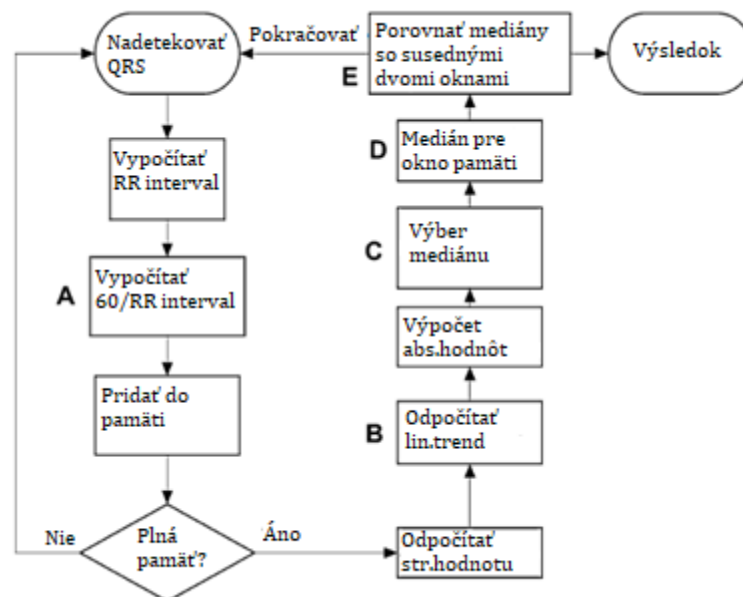
Táto metóda pracuje na porovnaní mediánov zo susedných segmentov, na ktoré bol signál rozdelený a následnom roztriedení podľa prahovej hodnoty mediánu na segmenty obsahujúce AFIB, alebo sínusový rytmus. V tejto metóde, ako aj v ostatných, potrebujeme najskôr detekovať QRS komplexy a teda hlavne R vlny, ak v daných dátach už vopred nie sú anotované. Táto metóda je, ako autor *Linker D.T.* popisuje, najúčinnějšía pri práci s krátkodobými úsekmi EKG (v tomto prípade sa jedná o segmenty dĺžky 21 detekovaných RR intervalov a menej). Táto metóda bola autorom testovaná na segmentoch dlhých 7 až 101 RR intervalov. Pre výrazne dlhšie úseky EKG (segmenty o 101 a viac RR intervalov) táto metóda stráca na schopnosti správnej detekcie AFIB, avšak stále je použiteľná s pomerne dobrými výsledkami. [15]

Algoritmus tejto metódy funguje tak, že po úspešnom detekovaní QRS komplexov vo zvolenom segmente (dĺžky týchto okien by mali byť rovnaké pre dané segmenty), vypočítame dĺžku RR intervalov, ktoré následne prevedieme na hodnoty lokálnych srdečných rytmov tým, že vydáme číslo 60 hodnotami RR

intervalov pre každý RR interval v segmente (bod A v obrázku 5). Tieto hodnoty sa následne uložia do pamäte na základe predom zvolenej dĺžky okna segmentu (veľkosti pamäte). [15]

Po naplnení pamäte, zistíme strednú hodnotu a vypočítame lineárny trend zo všetkých RR intervalov pre daný segment a tieto hodnoty odpočítame od každého jedného RR intervalu (bod B v obrázku 5). Potom zoradíme absolútne hodnoty týchto RR intervalov a vyberieme z nich medián (bod C v obrázku 5). [15]

Na záver porovnáme medián z tohto segmentu signálu, tak ako aj predošlého a nasledujúceho segmentu signálu, z týchto troch hodnôt vyberieme medián (bod E v obrázku 5). Tento medián je výsledná hodnota pre nami zvolený segment a ak prekračuje predom zvolený prah (bližšie informácie k voľbe prahu nie sú autorom uvedené), daný segment signálu, s ktorým pracujeme označujeme za segment obsahujúci AFIB. [15]



Obrázok 5: Vývojový diagram krokov daného algoritmu, popis častí uvedený v texte vyššie, prevzaté a preložené z [15]

Metóda mediánov bola testovaná na segmentoch dlhých 7 až 101 RR intervalov. Daná metóda vykazuje skvelé výsledky pre krátkodobé úseky EKG. Detekčná schopnosť algoritmu pracuje so senzitivitou 98,7% a špecificitou 98% pre segmenty o dĺžke 19 RR intervalov. Pri dĺžke 7 RR intervalov tieto hodnoty minimálne klesnú, napriek tomu stále ostávajú okolo 98% (práve pre dĺžky týchto

úsekov sú autorom zverejnené štatistické vyhodnotenia algoritmu. Autor popisuje dĺžku okna 19 a menej RR intervalov za zlomovú, kedy detekčná schopnosť výrazne presahuje ostatné algoritmy na detekciu AFIB). [15]

1.3.2 Metódy založené na histogramoch

Detekčnej časti nasledujúcich dvoch metód predchádza najskôr zložité predspracovanie dát. Aby sme tieto metódy mohli využiť, potrebujeme zostrojiť štandardizované histogramy hustoty (z angl. „Standard Density Histograms“, ďalej značené len ako SDH), ktoré poslúžia ako šablóny obsahujúce AFIB, pre ďalšie spracovanie. Tieto histogramy sú zostrojené z úsekov signálov z databázy MIT-BIH o ktorých vieme, že obsahujú AFIB. Autori *Tateno K. a Glass L.*, píše o rozdelení SDH v segmentoch po 50 srdečných úderoch do 16-tich skupín podľa ich strednej hodnoty (úseky 350-399 ms, 400-449ms, 450-499 ms, ...), avšak to sa javí ako problémové, pretože toľko veľa skupín s tak malým krokom je nevyužiteľné, keďže nám stačí mať 350-600, maximálne 650 ms (pri AFIB je chaotická predsieňová aktivita s frekvenciou 350-600/min). [16]

1.3.2.1 Metóda založená na výpočte variačného koeficientu

Táto metóda, ako popisujú autori *Taento K. a Glass L.*, je vhodnejšia a úspešnejšia pre segmenty, ktorých dĺžka okna je väčšia - približne 100 RR intervalov. Zvolíme segmenty, v ktorých po detekcii RR intervalov, vypočítame časové rozdiely medzi dvomi úspešne detekovanými RR intervalmi označené ako ΔRR intervaly. Z hodnôt RR intervalov vypočítame variačný koeficient, podľa vzorca:

$$v_x = \frac{s_x}{\bar{x}}, \quad (1.1)$$

kde v_x je variačný koeficient, s_x je smerodatná odchýlka RR intervalov a \bar{x} je aritmetický priemer RR intervalov v danom segmente. Pre ΔRR intervaly platí rovnaký vzorec s obmenou, že smerodatnú odchýlku vypočítame z ΔRR intervalov, aritmetický priemer ostáva pre RR intervaly (pre ΔRR intervaly sú histogramy symetrické a teda aritmetický priemer by bol vždy približne 0). Pri AFIB sú

variačné koeficienty pre RR a Δ RR intervaly takmer konštantné, tieto koeficienty porovnáme so štandardizovanými variančnými koeficientami (získame ich rovnakým vzorcom ako v_x avšak z SDH). Ak hodnoty variančných koeficientov prekročia hodnotu predom zvoleného prahu, môžeme hovoriť, že v danom segmente došlo k AFIB. [16]

Tento algoritmus vykazuje rozdielne výsledky pri práci s RR a Δ RR intervalmi. Ukázalo sa, že test založený na detekcii RR intervalov a následnou prácou s nimi má senzitivitu asi 86,6% a špecificitu približne 84,3%, s prahom zvoleným $R_{v_x} = 35\%$. Test založený na výpočte variančného koeficientu pre Δ RR intervaloch sa ukázal ako menej spoľahlivý, so špecificitou a senzitivitou rovnou 84%. Zvýšenie hodnoty prahu zlepšuje senzitivitu, ale zároveň znižuje špecificitu. [16]

1.3.2.2 Porovnanie histogramov hutot RR a Δ RR intervalov s SDH

V tejto metóde porovnáme histogramy hustoty pre RR a Δ RR intervaly a porovnáme so SDH pre RR a Δ RR intervaly pomocou Kolmogorov-Smirnovho testu (ďalej len K-S test). V tomto teste porovnáme maximálnu vzdialenosť medzi týmito kumulatívnymi distribúciami. Ak by sa tieto distribúcie zhodovali a vzdialenosť medzi nimi by bola minimálna, môžeme povedať, že v testovanom segmente sa nachádza AFIB (tzn. histogramy testovaných dát by boli zhodné so šablónami histogramov pre AFIB). [16]

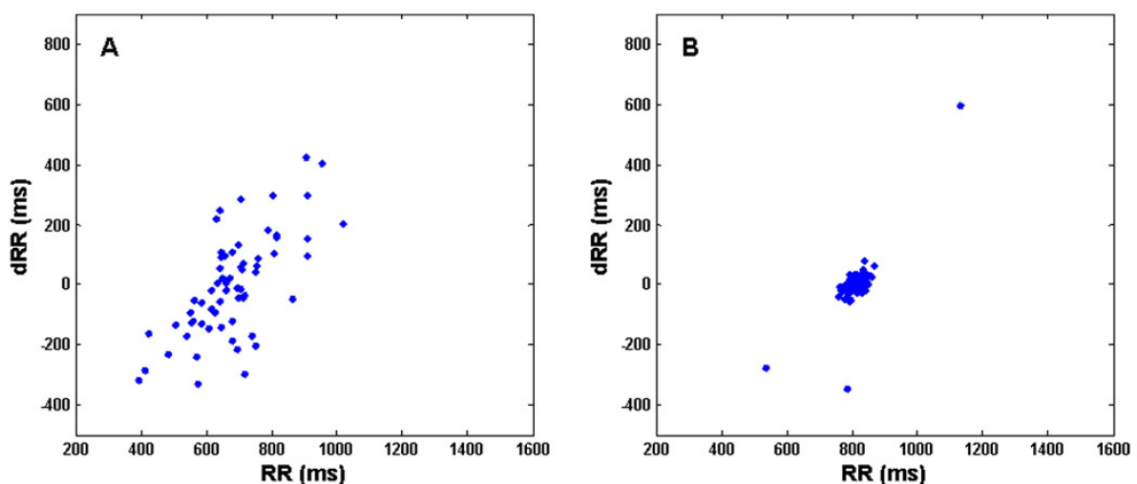
Úspešnosť tohto testu je taktiež rozdielna pri práci s RR, alebo Δ RR intervalmi. Pre RR intervaly bola úspešnosť testu horšia, ako u metódy založenej na výpočte variančného koeficientu využívajúcej RR intervaly. Avšak pri využívaní nadetekovaných Δ RR intervalov sa ukázala metóda K-S testu úspešnejšia, ako metóda variančného koeficientu. K-S test vykazoval najlepšie výsledky pri dĺžke segmentu 100 vzorkou. Špecificita K-S testu pre Δ RR intervaly bola 97,2% a senzitivita 94,4%. Nevýhodou tohto testu je ale to, že pri krátkodobých segmentoch sa výrazne zníži úspešnosť tejto metódy a často označuje záznamy bez AFIB ako patologické, teda kde AFIB vyskytuje. [16]

1.3.3 Metóda využívajúca RdR mapu

Táto metóda využíva kvantifikátory v geometrickej oblasti, a to konkrétne bodový (korelačný) diagram, ktorý porovnáva dve premenné pre vybraný segment signálu. Na horizontálnej ose x zobrazujeme dĺžku susedných RR intervalov a na vertikálnej ose y zobrazuje časové zmeny medzi RR intervalmi, označované ako hodnoty dRR, podľa vzorca:

$$dRR_i = RR_i - RR_{i-1}, \quad (1.2)$$

kde i je index daného RR intervalu. Bodový diagram je následne zostrojený z týchto hodnôt. Každý bod v grafe predstavuje jednu dvojicu RR intervalov spolu s dRR hodnotou, počet bodov v grafe teda udáva dĺžku okna segmentu. Signál obsahujúci AFIB bude mať náhodne rozložené body na diagrame (je vidieť na obrázku 6). Pre vyčíslenie tohto výsledku, RdR mapa je rozdelená na 2D mriežku s rozlíšením 25 ms (každá jedna bunka grafu je veľká 25 ms). V grafe hľadáme bunky, ktoré obsahujú aspoň 1 bod na grafe (nazývané „zaplnené bunky“ z angl. „nonempty cell“). AFIB detekujeme vtedy, ak počet zaplnených buniek presiahne nami zvolený prah (prah odvodíme od ROC krivky – z angl. „Receiver Operating Characteristic“). [17]



Obrázok 6: Bodový diagram RR intervalov (v ms) a dRR intervalov (v ms). Vľavo diagram A - signalizuje AFIB, vpravo - B signalizuje sínusový rytmus, prevzaté z [17]

Táto metóda využívala 4 rôzne databázy dát na porovnanie úspešnosti detekcie a to MIT-BIH (databáza AFIB, databáza arytmií, databáza sínusového

rytmu, databáza sínusového rytmu s RR intervalmi). Signály týchto databáz boli rozdelené na segmenty o dĺžkach 32, 64 a 128 RR intervalov. Senzitivita a špecificita pre okno dĺžky 32 RR je 94,4% a 92,6%, pre okno dĺžky 64 RR je 95,8% a 94,3% a pre okno dĺžky 128 RR je 95,9% a 95,4%. Vidíme, že oba tieto parametre sa s dĺžkou okna mierne zvyšujú. Táto metóda vykazuje veľmi dobré výsledky aj pre krátkodobé úseky signálov. [17]

1.3.4 Metóda využívajúca komplexity RR intervalov

Táto metóda je zhluk viacerých postupov, ktoré nám štatisticky pomáhajú určiť, či sa v danom segmente nachádza AFIB. Je to zhluk troch algoritmov. [18]

Prvým komponentom tohto algoritmu je odhad náhodnosti RR intervalov pomocou neparametrického testu. Tento test vyjadruje mieru náhodnosti dát meniacich sa v čase. Každý RR interval je porovnaný s dvomi susednými (predchádzajúci a nasledujúci) a ak je jeho hodnota rozdielna od týchto dvoch, RR interval je označený za náhodný (nepravidelný), napríklad:

$$(RR(n) - RR(n - 1)) \cdot (RR(n) - RR(n + 1)) > 0, \quad (1.3)$$

kde n je index daného RR intervalu, ktorého náhodnosť (nepravidelnosť) sa snažíme zistiť (príklad RR intervalov je na obrázku 7, bod a). Výsledné náhodné body sú normalizované podľa dĺžky segmentu. Ak množstvo náhodných bodov (označené ako TPR a zobrazené v obrázku 7, bod c) spadá do nami preddefinovaného prahu, označeného ako $TprThresh$, poukazuje to na neperiodicitu signálu a vynechávanie sínusového rytmu. [18], [19]

Druhým krokom tohto algoritmu je výpočet priemeru kvadratického rozdielu po sebe idúcich RR intervalov, podľa vzorca

$$RMSSD = \sqrt{\frac{1}{l-1} \sum_{j=1}^{l-1} (a(j+1) - a(j))^2}, \quad (1.4)$$

kde j udáva index RR intervalu v segmente, l je počet RR intervalov daného segmentu. Ak hodnoty $RMSSD$ prekročia hranicu prahu, segment definujeme ako segment s možným obsahom AFIB. Prah (zobrazený v obrázku 7, bod b) vyjadríme vzorcom

$$RmsThresh = \frac{RMSSD}{MeanRR}, \quad (1.5)$$

kde $MeanRR$ je aritmetický priemer RR intervalov daného segmentu, vyjadrený vzorcom

$$MeanRR = \frac{1}{n} \sum_{i=1}^n a_i, \quad (1.6)$$

kde n je počet všetkých RR intervalov a $\sum_{i=1}^n a_i$ vyjadruje súčet všetkých RR intervalov. Takto zadefinovaný prah je účinnejší ako menší prah pre každé $RMSSD$, ostáva konštantný pre všetky segmenty a kompenzuje falošnú detekciu AFIB.

Treťou časťou algoritmu je výpočet Shannonovej entropie. Ide o koreláciu vzorov v daných segmentoch signálov. Algoritmus využíva histogram zobrazujúci dĺžky RR intervalov. Na začiatok sa zbavíme 8 najkratších RR intervalov a 8 najdlhších intervalov daného segmentu, pretože tieto hodnoty sú považované za odľahlé extrémny a pôsobia rušivo. Histogram je rozdelený aspoň na 16 stĺpcov rovnakej šírky, ohraničené minimálnou hodnotou RR intervalov na jednej strane a maximálnou hodnotou RR intervalov na druhej strane. Pre každý stĺpec histogramu vypočítame rozdelenie pravdepodobností podľa vzorca


$$p(i) = \frac{N_{stĺpec(i)}}{l - N_{rušivé h.}}, \quad (1.7)$$

kde $p(i)$ je rozdelenie pravdepodobnosti i -tého stĺpca, $N_{stĺpec(i)}$ je počet R vln v i -tom stĺpci, l je celkový počet RR intervalov od ktorých je odpočítaný celkový počet extrémnych hodnôt (v tomto prípade ich je 16). Shannonovú entropiu (zobrazené na obrázku 7, bod d) pre náš segment následne vypočítame ako

$$SE = - \sum_{i=1}^{16} p(i) \frac{\log p(i)}{\log(\frac{1}{16})}. \quad (1.8)$$

Hodnoty Shannonovej entropie pre daný segment následne porovnáme s predom zvoleným prahom (označený ako $SeThresh$ – je vyobrazený v obrázku 7, bod d a jeho výsledok v tom istom obrázku v bode e).

Pre úplnú funkčnosť tohto detektoru AFIB, musíme ešte odfiltrovať extrasystoly, ktoré môžu byť aj u zdravých jedincov a môžu byť falošne detekované ako AFIB. Odfiltrujeme ich zmazaním RR intervalov 1% najkratších a najdlhších RR intervalov. [18], [19]



Obrázok 7: Výsledky v jednotlivých častiach algoritmu: (a) Originálny signál s anotáciou RR intervalov. (b) Výpočet RMSSD/MeanRR, (c) TPR, (d) Shannonova entropia zobrazená spolu s optimalizovaným prahom, (e) zobrazenie detekcie, prevzaté z [19]

Daný algoritmus nadetkuje AFIB v prípade, že sme odfiltrovali extrasystoly a platí nasledujúce: ak $RMSSD > RmsThresh$ a TPR spadá do $TprThresh$ a $SE > SeThresh$. Autori Dash S. a kolektív otestovali daný detektor na dvoch databázach (MIT-BIH databáza AFIB a MIT-BIH databáza arytmií). Pre prvú z databáz mal detektor senzitivitu 94,4% a špecificitu 95,1%. [18], [19]

V prípade druhej databázy boli AFIB kamuflované aj inými arytmiami, detektor si mierne zhoršil detekčnú schopnosť a to na senzitivitu 90,2% a špecificitu 91,2%. Tieto výsledky sú dostačujúce, avšak boli dosiahnuté na dlhých

segmentoch EKG a pri skrátení okna segmentu sa detekčná schopnosť zhoršuje. [18], [19]

1.3.5 Metódy detekcie založené na štatistických rozloženiach

V týchto metódach detekujeme AFIB na základe zostrojených, normalizovaných histogramov zobrazujúcich nadetekované RR intervaly v daných segmentoch. Normalizáciu zavádzame z dôvodu čitateľnejšieho zobrazenia hodnôt na histograme a úpravu extrémnych hodnôt. Normalizáciou prepočítavame a upravujeme hodnoty tak, aby spadali do nami žiadaného intervalu hodnôt. Obe metódy predpokladajú, že stredné hodnoty, okolo ktorých bude pravdepodobnostné rozloženie orientované budú nulové. Na dané histogramy segmentov následne aplikujeme jednu z dvoch pravdepodobnostných funkcií hustoty: Gaussova a Laplaceova funkcia. Na detekciu AFIB nám následne pomôže Neyman-Pearsonové rozhodovacie kritérium. [20]

Pomocou náhodnej veličiny x zostrojíme histogram normalizovaných hodnôt RR intervalov, vzorec pre túto veličinu je

$$x_i = \frac{(RR_i - RR_{i-1})}{\overline{RR}_i}, \quad (1.9)$$

kde i je index i -tého RR_i intervalu, a \overline{RR}_i je priemer vyjadrený vzťahom

$$\overline{RR}_i = 0,9 \cdot \overline{RR}_{i-1} + 0,1 \cdot RR_i. \quad (1.10)$$

Na histogram náhodnej premennej x aplikujeme jednu z dvoch pravdepodobnostných funkcií: Gaussova (označená ako P_G), alebo Laplaceova (označená ako P_L) – zobrazené na obrázku 8:

$$P_G(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}}, \quad (1.11)$$


$$P_L(x) = \frac{1}{2b} e^{-\frac{|x|}{b}}, \quad (1.12)$$

kde σ a b sú parametre pravdepodobnostných funkcií. Následne aplikujeme Neyman – Pearsonové rozhodovacie kritérium, ktoré v zjednodušenej forme pre Gaussovú a Laplaceovo rozloženie vyzerá

$$L_G(x) = \sum_{i=1}^N x_i^2 > \gamma_1, \quad (1.13)$$

$$L_P(x) = \sum_{i=1}^N |x_i| > \gamma_2, \quad (1.14)$$

kde N zodpovedá hodnote dĺžky zvoleného segmentu a γ_1, γ_2 sú predvolené prahové hodnoty, prekročenie týchto hodnôt značí AFIB.



Obrázok 8: Histogram normalizovaných RR intervalov (so strednou hodnotou 0) s nanesením Gaussovej a Laplaceovej funkcie, prevzaté a preložené z [20]

Táto metóda je citlivá na lokálne extrémne hodnoty, preto je dôležité ich odstrániť (princíp prahovania – hodnoty väčšie/menšie ako prah odstránime).

Metódy sme testovali na troch databázach: MIT-BIH (databáza arytmií), MIT-BIH AFIB (databáza AFIB) a Drager Medical AFIB database (databáza arytmií vypracovaná Draegerovou klinikou). Použitie Laplaceovej pravdepodobnostnej funkcie nám vykazuje lepšie výsledky a presnejšiu detekciu AFIB ako Gaussova funkcia. Metódy boli testované na segmentoch dlhých 30 R hrotov a teda 29 RR intervalov a segmenty sa neprekrývali. Usudzujeme teda, že metóda funguje presnejšie na krátkodobé úseky EKG, avšak na záznamy dlhé 10 sekúnd a menej je nižšie. [20]

Tabuľka 1: Detekčná schopnosť detektoru s použitím Gaussovej funkcie (L1) a Laplaceovej funkcie (L2) na daných databázach, prevzaté a preložené z [20]

Databáza	Gaussova funkcia L ₁ Senzitivita Se [%]	Laplaceova funkcia L ₂ Senzitivita Se [%]
MIT databáza arytmií	90	92
MIT databáza AFIB	88	89
Databáza kliniky Draeger pre AFIB	86	87

1.4 Porovnanie detektorov atriálnych fibrilácií

V tejto podkapitole si zhrnieme uvedené parametre jednotlivých detektorov (vidieť v tabuľke 2).

Tabuľka 2: Tabuľka parametrov vybraných detektorov.

Metóda, autor	Rozdelenie	Dĺžka okna [počet RR intervalov]	Detaily	Špecifická [%]	Senzitivita [%]	Poznámky
Metóda mediánov, David T.Linker [15]		19		98	98,7	Vhodné pre krátkodobé EKG. Horšia detekčná schopnosť pre dlhé úseky EKG.
		7		≈ 98	≈ 98	
Metódy založené na histogramoch, Taento K., Glass L. [16]	Výpočet variančného koeficientu	100	Práca výhradne s RR intervalmi	84,3	86,6	Zložité predspracovanie dát – tvorba šablón obsahujúce AFIB. Vhodné pre dlhé úseky EKG.
			Práca s Δ RR intervalmi	84	84	
	Porovnanie histogramov hustôt RR a Δ RR intervalov s SDH	100	Využíva K-S test a RR intervaly	Neuvedené, nižšia ako pre variančný koeficient	Neuvedené, nižšia ako pre variančný koeficient	Zložité predspracovanie dát – tvorba šablón obsahujúce AFIB. Vhodné pre dlhé úseky EKG – pre krátke úseky EKG výrazne horšia detekčná schopnosť.
			Využíva K-S test a Δ RR intervaly	97,2	94,4	

Metóda využívajúca RdR mapu, <i>Lian J., Wang L., Muessig D.</i> [17]	Využitie kvantifikátorov v geometrickej oblasti	32		92,6	94,4	Detekčná schopnosť narastá s dĺžkou okna, vhodné ale aj na kratšie úseky EKG.
		64		94,3	95,8	
		128		95,4	95,9	
Metóda využívajúca komplexity RR intervalov, <i>Dash S. a kolektív</i> [18],[19]		neuvedené (popísané len ako detektor vhodný pre dlhé úseky EKG)		95,1 (databáza MIT-BIH pre AFIB) 91,2 (databáza MIT-BIH arytmií-AFIB kamuflované aj inými arytmiami)	94,4 (databáza MIT-BIH pre AFIB) 90,2 (databáza MIT-BIH arytmií-AFIB kamuflované aj inými arytmiami)	Zhluk troch algoritmov. Potrebne odfiltrovať extrasystoly - extrémny. Odstraňovanie extrémov môže viesť k nepresným výsledkom. Detekčná schopnosť klesá so zväčšujúcim sa oknom segmentu.
Metódy detekcie založené na štatistických rozloženiach, <i>Ghodratti A., Marinello S.</i> [20]	Pomocou Gaussovského rozloženia	29			90 (databáza MIT-BIH arytmií) 88 (databáza MIT-BIH AFIB) 86 (databáza klinky Draeger)	Vhodné na krátke úseky EKG. Avšak úseky dlhé okolo 10s výrazne zvýšili chybovosť detektoru.
	Pomocou Laplaceovej funkcie	29			92 (databáza MIT-BIH arytmií) 89 (databáza MIT-BIH AFIB) 87 (databáza klinky Draeger)	

Aby sme mohli nami vybrané detektory porovnať a zistiť, ako veľmi boli úspešné, používali sme na ich hodnotenie dva hlavné štatistické údaje: špecificita a senzitivita. Senzitivita v našom prípade popisuje úspešnosť nadetekovaných

AFIB s tým, že táto hodnota býva negatívne ovplyvnená falošne, negatívne nadetekovanými hodnotami (hodnoty, ktoré detektor nevykazuje ako AFIB, avšak v realite sú AFIB). Špecifická metóda vyjadruje schopnosť algoritmu vyselektovať prípady, u ktorých nenastáva AFIB. Táto hodnota vykazuje nižšie výsledky, ak zvolený detektor detekuje falošne pozitívne hodnoty (hodnoty označené ako AFIB, ale reálne nimi nie sú). Čím vyššie hodnoty týchto dvoch parametrov, tým lepšia je detekčná schopnosť detektoru. [14]

Ďalším dôležitým parametrom pre nami vybraný, najvhodnejší detektor bola správne zvolená dĺžka okna. Keďže v práci sme sa mali zamerať na detekciu AFIB pre krátkodobé úseky EKG signálov, predpokladáme výber najvhodnejšieho detektoru na základe čo najmenšej dĺžky okna. Väčšina uvedených detektorov pracuje presnejšie na dlhých úsekoch EKG. Ako použiteľné pre našu prácu sa javia najviac metóda mediánov, metóda využívajúce RdR mapu a metódy detekcie založené na štatistických rozloženiach. Avšak treba poznamenať, že u druhej metódy, využívajúcej RdR mapu, vieme, že jej detekčná schopnosť sa so zmenšujúcim oknom znižuje a teda pre veľmi krátke úseky EKG môže byť dosť nepresná a pre tretiu metódu, založenú na štatistických rozloženiach zase vieme, že pre úseky EKG signálov dlhé okolo 10s sa chybovosť detekcie výrazne zvýšila.

Preto si na základe vyššie uvedených poznatkov pre ďalšie spracovanie tejto bakalárskej práce vyberáme metódu mediánov, ktorá sa javí ako vhodný adept pre spracovanie krátkych úsekov EKG s výbornou detekčnou úspešnosťou, ktorá je lepšia aj oproti metóde využívajúcej RdR mapu. Špecifická metódy mediánov je 98% a senzitivita 98,7% pri 19 RR intervaloch a pri 7 RR intervaloch je špecifická a senzitivita približne rovná $\approx 98\%$.

2 PRAKTICKÁ ČASŤ

Cieľom praktickej časti bakalárskej práce je implementovať nami vybraný algoritmus detektoru v prostredí Matlab. Na základe teoretických poznatkov sme zistili, že najvhodnejšou metódou na spracovanie našej bakalárskej témy bude algoritmus od autora *Linker D.T.*, metóda mediánov. Táto metóda je vhodná na spracovanie krátkodobých úsekov EKG, mala by vykazovať vysoké hodnoty špecificity a senzitivity pre tieto EKG úseky. [15]

Následne otestujeme náš algoritmus spracovaný v prostredí Matlab na anotovaných elektrokardiogramoch z databáze ÚBMI (popis databázy v kapitole 2.1) a overíme jeho detekčnú schopnosť.

Potom štatisticky spracujeme výsledky, interpretujeme ich význam a zhodnotíme reálnu úspešnosť nami vyhotoveného detektoru. Túto úspešnosť porovnáme s teoretickou úspešnosťou nami vybraného detektoru, ale aj s ostatnými, popisovanými metódami (kapitoly 1.3 a 1.4).

2.1 Databáza ÚBMI

Detekčnú schopnosť nášho algoritmu, ako aj správne fungovanie sme otestovali na databáze elektrokardiogramov, ktoré boli zhotovené Ústavom biomedicínskeho inžinierstva na Vysokom učení technickom v Brne. Táto databáza obsahovala dva súbory typu Microsoft Access Table Shortcut (s príponou .mat) a dali sa jednoducho otvoriť v programe Microsoft Access a tak isto načítať priamo do programovacieho rozhrania Matlab. Databáza predstavovala anotované 10 sekundové úseky signálov EKG namerané štandardným 12 zvodovým EKG, z toho 8 zvodov bolo nameraných (6 hrudných a 2 končatinové) a 4 dopočítané. Jednalo sa o kľudové EKG. Súbory boli pomenované BTL_data (.mat) a BTL_qrs (.mat).

Prvý súbor, BTL_data (.mat) je bunkové pole rozmeru 6884x4, teda 6884 riadkov, kde každý riadok obsahoval 4 stĺpce. Prvý stĺpec uvádzal názov každého signálu (napríklad „EB0000018570.mat“), druhý stĺpec obsahoval priamo dané 10 sekundové signály EKG. Tretí stĺpec popisoval bližšie rôzne patofyziológie (arytmie) vyskytujúce sa na obraze EKG krivky. Posledný, štvrtý stĺpec, obsahoval

v skratke rozdelenie príslušného signálu podľa toho, či sa jednalo o fyziologický (sínusový rytmus), alebo patofyziologický rytmus (pri jednotlivých poliach popisujúcich buď sínusový rytmus, alebo arytmiický rytmus, je číselná hodnota buď logická 1, alebo 0 – 1 vyjadruje, že daný signál obsahuje danú arytmiu, prípadne sínusový rytmus, 0 znamená, že daná položka sa v signál nenachádza) .

Druhý súbor, BTL_qrs, obsahoval bunkové pole rozmeru 6884x2, teda 6884 riadkov, kde každý riadok obsahoval dva stĺpce. V tomto bunkovom poli boli rovnako, ako v súbore BTL_data (.mat), v prvom stĺpci názvy signálov EKG, sú vedené v rovnakom poradí ako v prvom súbore. Druhé pole obsahovalo anotáciu, súradnice, kde sa nachádzali v daných EKG signáloch R hroty.

Pre náš detektor boli najpodstatnejšie dva údaje – vyselektovať signály, ktoré obsahovali buď fyziologický, sínusový rytmus (značené v štvrtom stĺpci bunky BTL_data ako SR=1), alebo atriálne fibrilácie (značené v rovnakom stĺpci tej istej bunky ako AFIB=1), iné arytmie nás nezaujímali. Následne sme museli vybrať súradnice R hrotov z daných EKG signálov z bunky BTL_data v druhom stĺpci. Pracovali sme so signálmi o dĺžke od 4 R hroty až po 34 R hrotov. Syntézou týchto údajov sme vedeli vyselektovať nami zvolené EKG signály ktoré obsahovali buď atriálne fibrilácie, alebo sínusový rytmus.

2.2 Vybraná metóda detekcie atriálnych fibrilácií – metóda mediánov

V tejto časti podrobne popíšeme vybraný algoritmus a jeho realizáciu. Pre lepšiu vizualizáciu sme vytvorili vývojový diagram popisujúci fungovanie algoritmu (obsiahnutý v prílohe 1). Algoritmus bol zhotovený v prostredí Matlab, konkrétne na verzii Matlab R2018a.

Na začiatok si načítame dáta BTL_qrs a BTL_data príkazom load. Následne si nastavíme inicializačné podmienky, hlavne dĺžku okna RR intervalov v premennej „buffer“ (počet RR intervalov v jednom okne), tieto okná sa behom algoritmu neprekrývajú. Cyklom for si prejdeme štruktúru BTL_data a BTL_qrs riadok po riadku, až do konca štruktúry. Vnoreným cyklom if-elseif vyberieme iba záujmové signály a teda signály obsahujúce čistý sínusový rytmus (v položke BTL_data

v štvrtom stĺpci hľadáme hodnoty SR=1 a ostatné hodnoty rovné 0), alebo signály obsahujúce atriálne fibrilácie (rovnaká položka, hľadáme AFIB = 1). Signály obsahujúce AFIB môžu taktiež obsahovať aj iné arytmie, daný detektor sme zostrojili pre variantu čistých AFIB (len AFIB = 1, iné = 0), ale aj pre variantu AFIB s inými arytmiami (AFIB = 1, iné = 1) . Výsledkom týchto cyklov bude matica s názvom „matrix“, v ktorej budeme mať v prvom riadku hodnoty R hrotov pre príslušné signály EKG, vyňaté z položky BTL_qrs, v druhom stĺpci názov signálu, v treťom stĺpci index, na ktorom riadku sa daný signál nachádza (v oboch položkách). Do štvrtého stĺpca vyjmeme z položky BTL_data maticu, kde zisťujeme, o aký signál sa jedná (SR=1, AFIB=1, iné=1, prípadne 0), do piateho stĺpca budeme neskôr vpisovať výstupy algoritmu detektoru a v šiestom stĺpci bude textové pole obsahujúce slová buď „AFIB“, alebo „SR“, podľa toho, o aký signál sa jedná (všetky kroky vidieť na výsledkovej matici na obrázku 9).

	1	2	3	4	5	6
1	12x1 double	'EB0000018...	1	1x2 struct	0	'SR'
2	12x1 double	'EB0000018...	2	1x2 struct	0	'SR'
3	16x1 double	'EB0000018...	3	1x2 struct	0.0121	'SR'
4	13x1 double	'EB0000018...	4	1x2 struct	0.0072	'SR'
5	12x1 double	'EB0000018...	8	1x2 struct	0.0718	'AFIB'
6	13x1 double	'EB0000018...	9	1x2 struct	0.1037	'AFIB'
7	12x1 double	'EB0000018...	11	1x2 struct	0.0133	'SR'
8	12x1 double	'EB0000018...	12	1x2 struct	0.0275	'SR'
9	14x1 double	'EB0000018...	13	1x2 struct	0.0061	'SR'
10	16x1 double	'EB0000018...	22	1x2 struct	0.0029	'SR'
11	15x1 double	'EB0000018...	23	1x2 struct	0.0073	'SR'
12	13x1 double	'EB0000018...	27	1x2 struct	0.0471	'SR'
13	13x1 double	'EB0000018...	32	1x2 struct	0.0223	'SR'

Obrázok 9: Reprezentácia matice "matrix" v prostredí Matlab.

Z celkového počtu 6884 signálov EKG extrahovali presne 3021 signálov, ktoré obsahovali buď čistý sínusový rytmus (SR=1, ostatné=0), alebo obsahovali AFIB (AFIB=1, prípadne iné=1, okrem SR=1 – pri AFIB nikdy nedosiahneme sínusový rytmus a preto tieto položky majú vždy SR=0). Z množstva 3021 signálov sme zistili, že 2468 je obsahujúcich čistý sínusový rytmus (len SR=1) a 249

obsahuje čisté AFIB (AFIB=1, iné=0) a 304 AFIB v zmesi s inými arytmiami (AFIB=1, iné=1). Postup je obsiahnutý v prílohe 1, v bode A, na obrázku vývojového diagramu. Dokopy teda signál obsahoval 553 AFIB.

Nasleduje vyhotovenie samotného detektoru. Detektor sme sa snažili zostrojiť podľa autora metódy mediánov, *Linker D.T.* Samotný detektor začína cyklom for a while, ktoré prechádzajú maticu „matrix“ od začiatku a cykly sa ukončia, keď prejdú celú maticu (body B a C na obrázku vývojového diagramu v prílohe). Celý detektor pracuje na základe nami zvolenej inicializačnej podmienky dĺžky okna (v programe pomenované ako „buffer“). Najskôr potrebujeme vypočítať dĺžku RR intervalov pre vyselektované signály – keďže metóda pracuje na základe nepravidelnej dĺžky RR intervalov. V bode D na obrázku prílohy 1 si pomocou indexu rozdelíme signál na okná, podľa ich zvolenej dĺžky, okná sa neprekrývajú. Cyklus while vždy momentálne pracuje s jedným oknom a realizuje v ňom všetky výpočty pre dané okno, po dokončení výpočtov pre toto okno sa okno v signáli posúva (značené ako posun okna v prílohe 1 „ $i=i+1$ “).

Vnorený cyklus for ,v cykle while, (bod E v obrázku prílohy 1) nám rozdelí signál podľa dĺžky okna. RR intervaly v ňom dostaneme tak, že v matici „matrix“ si z prvého stĺpca vyberieme hodnoty lokácií R hrotov a postupne ich jednu od druhej odčítavame, s inicializačným indexom $i=1$ a inkrementom $+1$. To znamená, že vždy vyberie súradnice prvého R hrotu daného okna signálu a od neho odpočíta súradnice druhého R hrotu toho istého okna signálu. Hneď potom priamo vypočítame pre tento RR interval jeho absolútnu hodnotu (súradnice R hrotov narastajú a keďže odpočítavame R hrot s indexom $i+1$ od R hrotu s indexom i , viedlo by to k záporným hodnotám RR intervalov, preto aplikujeme túto absolútnu hodnotu). Následne vypočítame pre tento jeden RR interval hodnotu lokálneho srdcového rytmu tak, že číslo 60 vydělíme hodnotou RR intervalu (bod F v prílohe 1). Potom sa vrátíme na začiatok tohto cyklu for, inkrementom $+1$ sa posunieme na súradnice druhého R hrotu. Pomocou druhého R hrotu a tretieho, vypočítame ďalší RR interval, spolu s absolútnou hodnotou a hodnotou lokálneho srdcového rytmu (bod F v prílohe 1). Tieto výpočty pokračujú až do naplnenia dĺžky okna, po naplnení sa cyklus for pre dané okno ukončí.

Po naplnení jedného okna signálu pokračujeme bodom G na obrázku prílohy 1, výpočtom strednej hodnoty okna a lineárnym trendom, ich hodnoty odpočítame od hodnôt RR intervalov v segmente – týmto popisujeme ako sa jednotlivé hodnoty RR intervalov vzdávajú od ideálnych hodnôt RR intervalov, ktoré by definovali sínusový rytmus (pri sínusovom rytme sú diferencie medzi jednotlivými RR intervalmi veľmi malé). Na záver zoradíme absolútne hodnoty týchto RR intervalov a vyberieme z nich medián pre dané jedno okno signálu, uložíme ho do matice „median_first_level“ (bod G v prílohe 1). Metóda mediánov pracuje, ale na porovnávaní mediánov so susednými dvomi oknami (vidieť v bode E, obrázok 5, kapitola 1.3.1). My sme modifikovali tento postup a v našom prípade budeme porovnávať mediány z prvého okna s nasledujúcimi dvomi, nie susednými dvomi. Preto potrebujeme naplniť maticu „median_first_level“ aspoň tromi hodnotami. To docielime cyklom while (bod C v prílohe 1.). Celý cyklus sa opakuje od bodu C, to znamená, že posúvame okno o jeho predom zvolenú dĺžku a všetky výpočty opakujeme pre ďalšie R hroty v signáli. Opakujeme do bodu F (v prílohe 1) do momentu, kedy matica „median_first_level“ nebude obsahovať aspoň tri hodnoty na porovnanie (bod H v prílohe 1). V prípade obdržania troch hodnôt, tieto mediány z troch okien porovnáme a vyberieme z nich medián, túto hodnotu zapíšeme do matice „matrix_median“. Avšak cyklus while (bod C v prílohe 1) nemusí byť ukončený, stále môže obsahovať R hroty s ktorými sme nepracovali. Preto tento cyklus pokračuje ďalej, získavame ďalšie mediány v matici „median_first_level“ a následne aj matici „matrix_median“. Vždy po získaní nového mediánu v matici „median_first_level“ sú porovnávané posledné tri mediány z tejto matice (bod G v prílohe 1) a zapísané do matice „matrix_median“. Cyklus na záver, keď prejde jeden celý signál, vyberie maximálnu hodnotu z matice „matrix_median“ (maximálna hodnota mediánu predpokladá najväčšiu šancu prítomnosti AFIB v signáli – bod I v prílohe 1). Pri SR by sa mali mediány od seba pre daný signál minimálne odlišovať, avšak pri AFIB predpokladáme vyšší medián, preto nám stačí vybrať maximum). Táto hodnota sa zapíše do piateho stĺpca matice „matrix“. Týmto sme prešli jeden signál cyklu for (bod B v prílohe 1) a cyklus pokračuje vybraním druhého signálu.

Keď sa naplní piaty stĺpec matice „matrix“, pre všetky signály, zoradíme túto maticu podľa veľkosti mediánov od najnižšej hodnoty mediánu po najvyššiu. Týmto predpokladáme zoradenie nízkych hodnôt mediánov ako sínusový rytmus a AFIB predpokladáme mať vyššie hodnoty mediánov (bod J v prílohe 1).

2.2.1 Hodnotenie detekčnej schopnosti detektoru

Na zistenie detekčnej schopnosti nami zostrojeného detektoru AFIB sme použili rovnaké kritéria, ako pri porovnávaní detektorov a výbere najvhodnejšieho detektoru, pre našu prácu (popísané v kapitole 1.4.). Týmto kritériami sú senzitivita a špecificita. Senzitivita (Se) nám udáva schopnosť detektoru správne detekovať AFIB a špecificita (Sp) zase naopak, schopnosť detektoru správne vytriediť signály s fyziologickým, sínusovým rytmom:

$$Se = \frac{TP}{TP+FN}, \quad (2.1)$$

$$Sp = \frac{TN}{TN+FP}, \quad (2.2)$$

kde TP je hodnota správne nadetekovaných AFIB, TN je hodnota správne nadetekovaných SR, FP sú signály, ktoré detektor určil ako obsahujúce AFIB, avšak v realite sú fyziologické, obsahujúce SR a hodnota FN sú signály obsahujúce AFIB, avšak našim detektorom sú označené ako signály so SR.

Taktiež na celkové zhodnotenie sme využili prvok AUC (z angl. „Area under the curve“ – plocha pod krivkou), ktorý vyjadruje schopnosť detektoru správne rozlíšiť prvky AFIB od SR (obsahuje hodnoty v intervale od 0 do 1, čím vyššia hodnota, tým väčšia je oblasť pod krivkou a teda aj detekčná schopnosť je lepšia).

Aby sme mohli tieto kritéria správne určiť, potrebovali sme najskôr zostrojiť ROC krivku (z angl. „Receiver operating characteristic“). Je to nástroj, ktorý určuje, ako sa náš detektor správa pri menení prahových hodnôt a aká je jeho úspešnosť detekcie pre rôzne prahy. Pri zostrojovaní ROC krivky sme najskôr vo for cykle prechádzali maticu „sorted_matrix“. Ako prahové hodnoty nám slúžia hodnoty mediánov z piateho stĺpca tejto matice. Preto vyberieme prvý medián tejto matice ako prvú prahovú hodnotu. Hodnoty väčšie, alebo rovné prahovej hodnote sú považované detektorom za AFIB, hodnoty pod prahovou hodnotu sú označené detektorom ako SR a zisťujeme, na koľko sa počet týchto označených

AFIB a SR zhoduje s realitou. Týmto dostaneme prvky TP, TN, FP, FN. Tieto prvky pre prvý medián uložíme do matice „*statistic_matrix*“ do prvého riadka. Do toho istého riadka uložíme aj hodnoty TPR (z angl. „true positive rate“) a FPR (z angl. „false positive rate“), ktoré nám slúžia na zostrojenie samotnej ROC krivky:

$$TPR = \frac{TP}{TP+FN} = Se, \quad (2.3)$$

$$FPR = \frac{FP}{FP+TN}. \quad (2.4)$$

Na realizáciu tejto krivky použijeme hodnotu FPR ako x-ové súradnice a hodnota TPR nám určí hodnotu súradnice pre osu y. Týmto vznikne jeden bod na ROC krivke. Cyklus for takto prejde všetky hodnoty mediánov (prahov) a pre každý vykreslí jeden bod s vypočítanými TPR a FPR.

Aby sme zistili, na ktorej prahovej hodnote pracuje detektor s najlepšou úspešnosťou detekcie, do siedmeho stĺpca matice „*statistic_matrix*“ vypočítame pre každú prahovú hodnotu Youdenov J index:


$$J = Se + Sp - 1 = \frac{TP}{TP+FN} + \frac{TN}{TN+FP} - 1. \quad (2.5)$$

Tento index sumarizuje celkovú detekčnú schopnosť detektoru. Naberá hodnôt na intervale od 0 do 1, kde pre hodnoty rovné 1 indikuje, že detektor nedetekoval žiadne FP a FN prvky a teda funguje perfektne. Vybratím maximálnej hodnoty Youdenovho J indexu pre všetky prahy dostaneme jeden prah, pre ktorý náš detektor funguje najlepšie, má najlepšie detekčné schopnosti.

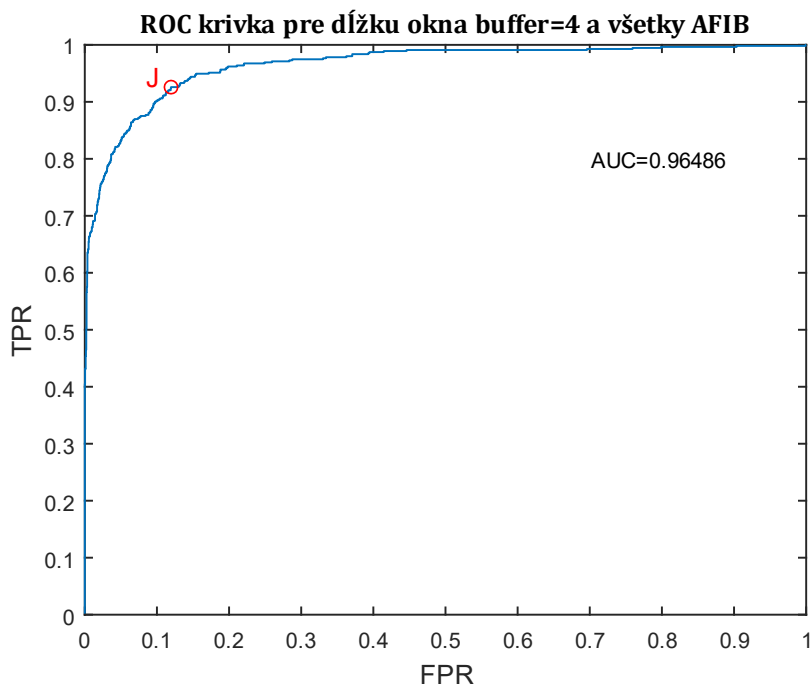
Na záver vypočítame prvok AUC (vyjadrujúci obsah plochy pod ROC krivkou). Toto číslo vyjadruje celkovú schopnosť detektoru rozlíšiť AFIB od SR.

Aby sme sa uistili, že detektor funguje univerzálne a správne, otestovali sme ho na rôznych dĺžkach okien „buffer“ a zostrojili sme ho pre detekciu signálov obsahujúcich SR spolu so signálmi obsahujúcimi čisté AFIB (AFIB=1) v zmesi spolu s inými arytmiami (v súbore dát BTL.data, štvrtý stĺpec, AFIB=1, iné sa môže rovnať tiež 1, SR=1 – popísané v kapitole 2.2). Táto varianta je popísaná v tabuľke 2 (pod obrázkami 10-19) a je ďalej značená ako „všetky AFIB“. Takisto sme detektor zostrojili aj pre výhradne čisté AFIB a SR (v súbore dát BTL.data, štvrtý stĺpec AFIB=1, iné=0, SR=1 – popísané v kapitole 2.2), táto varianta je popísaná v tabuľke 3 a ďalej označená ako „čisté AFIB“.


ROC krivky sme pre všetky prahové hodnoty spolu s vyznačením AUC a Youdenovho J indexu zobrazili pre oba spôsoby spracovania na obrázkoch 10 až 19.




Obrázok 10: Zostrojená ROC krivka pre dĺžku okna „buffer“=3 a všetky AFIB.



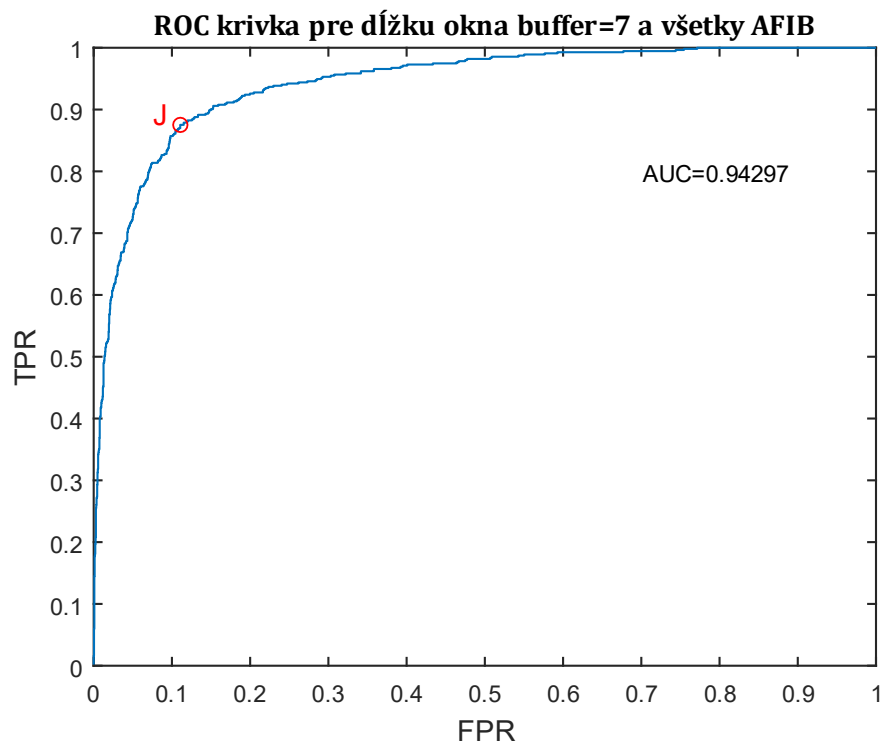
Obrázok 11: Zostrojená ROC krivka pre dĺžku okna „buffer“=4 a všetky AFIB.




Obrázok 12: Zostrojená ROC krivka pre dĺžku okna „buffer“=5 a všetky AFIB.




Obrázok 13: Zostrojená ROC krivka pre dĺžku okna „buffer“=6 a všetky AFIB.



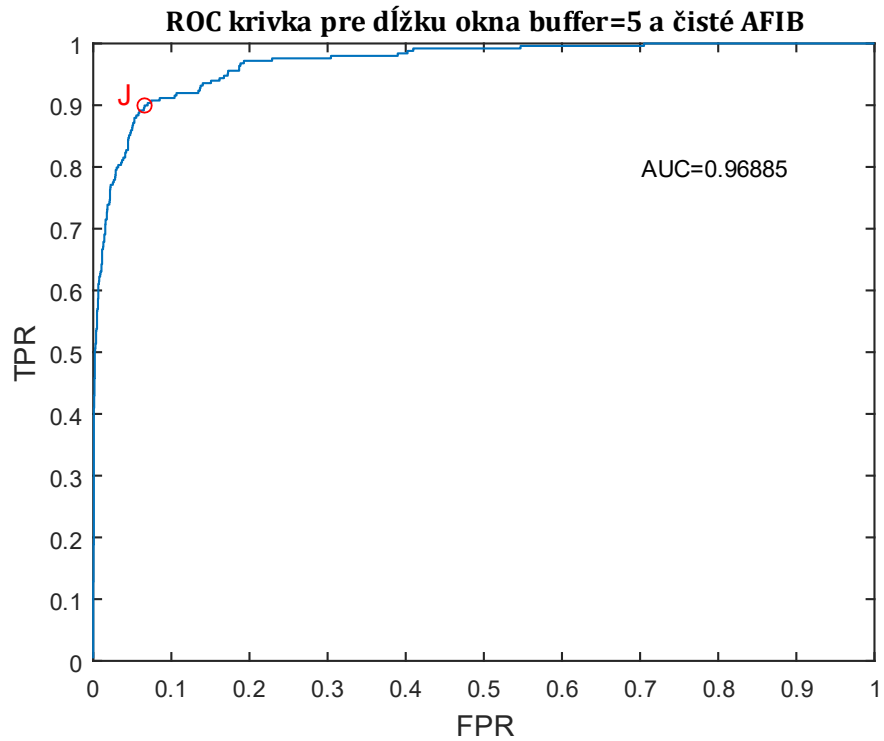
Obrázok 14: Zostrojená ROC krivka pre dĺžku okna „buffer“=7 a všetky AFIB.



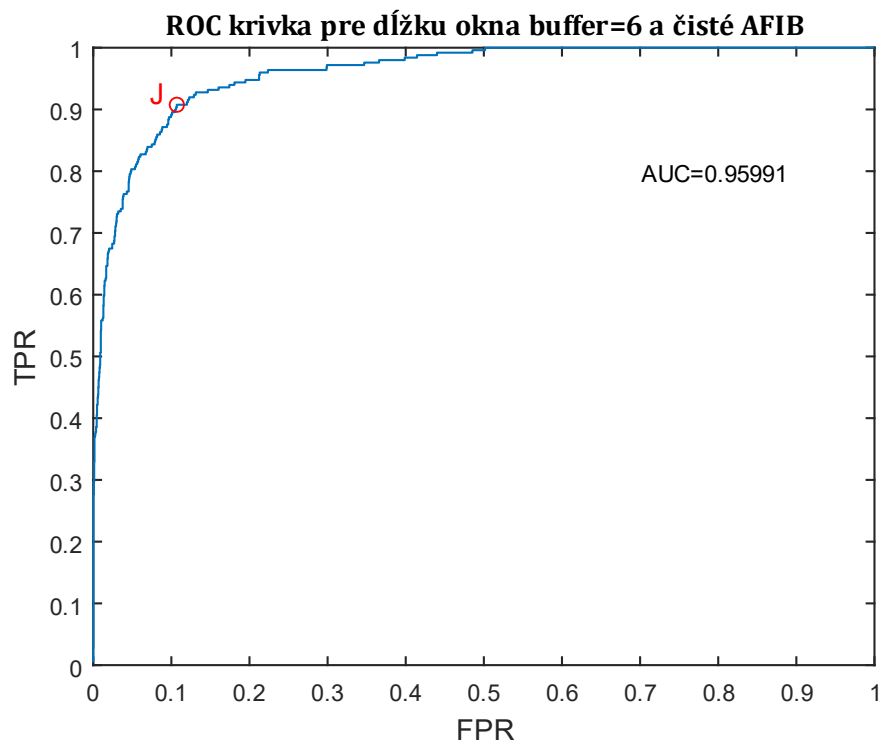
Obrázok 15: Zostrojená ROC krivka pre dĺžku okna „buffer“=3 a čisté AFIB.



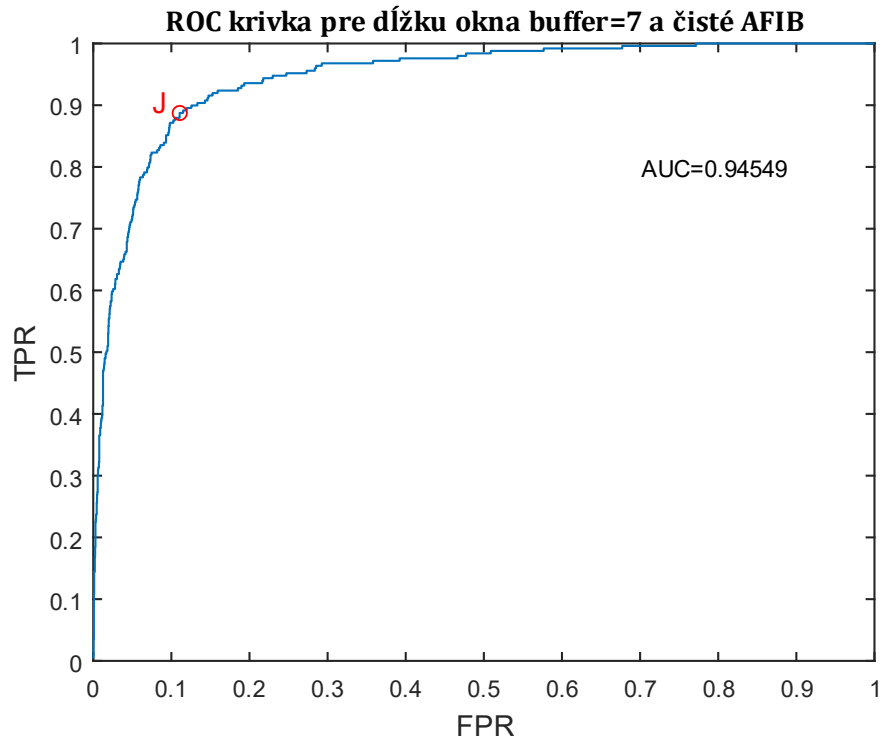
Obrázok 16: Zostrojená ROC krivka pre dĺžku okna „buffer“=4 a čisté AFIB.



Obrázok 17: Zostrojená ROC krivka pre dĺžku okna „buffer“=5 a čisté AFIB.



Obrázok 18: Zostrojená ROC krivka pre dĺžku okna „buffer“=6 a čisté AFIB.



Obrázok 19: Zostrojená ROC krivka pre dĺžku okna „buffer“=7 a čisté AFIB.

Tabuľka 3: Štatistické vyhodnotenie detektoru pre rôzne dĺžky okien "buffer" a všetky AFIB.

Dĺžka okna "buffer" [počet RR intervalov]	Sp [%]	Se [%]	AUC	Prahová hodnota vybraného mediánu
<u>3</u>	<u>91,863</u>	<u>91,572</u>	<u>0,9654</u>	0,0328
4	92,586	88,047	0,9649	0,0191
5	88,608	93,030	0,9613	0,0204
6	89,512	89,303	0,9541	0,0177
7	87,523	88,938	0,9430	0,0213

Tabuľka 4: Štatistické vyhodnotenie detektoru pre rôzne dĺžky okien "buffer" a čisté AFIB.

Dĺžka okna "buffer" [počet RR intervalov]	Sp [%]	Se [%]	AUC	Prahová hodnota vybraného mediánu
3	91,566	91,815	0,9718	0,0330
<u>4</u>	<u>93,976</u>	<u>89,182</u>	<u>0,9730</u>	0,0200
5	86,960	93,436	0,9689	0,0210
6	90,763	89,303	0,9600	0,0170
7	88,755	88,938	0,9450	0,0213

Dĺžky okna pre detektor sme volili v rozmedzí od 3 do 7 RR intervalov. Minimálna hodnota dĺžky okna musí byť 3 RR intervaly, pretože pri voľbe dĺžky okna o 2 RR intervaloch, by detektor nefungoval správne, miesto mediánov by robil priemery z okien. Maximálna dĺžka okna je zvolená 7 RR intervalov. Vidíme, že hodnota AUC v oboch tabuľkách (tabuľka 2 a 3) klesá so zväčšujúcim sa oknom a preto pri predĺžení okna očakávame horšie detekčné vlastnosti, to je spôsobené najmä tým, že testovacia databáza (z kapitoly 2.1) nám poskytovala veľmi krátke úseky EKG signálov, dlhé 10 sekúnd, ktoré obsahovali od 3 RR intervalov do 33 RR intervalov a preto pre signály s malým počtom RR intervalov nemusel pracovať správne a je v nich väčšia šanca detekčnej chybovosti. Taktiež môžeme povedať, že detektor pracuje lepšie so signálmi obsahujúcimi výhradne čisté AFIB bez iných, ostatných arytmií. Jeho detekčná schopnosť je mierne vyššia pri porovnávaní

rovnakých dĺžok okien s detektorom pre všetky AFIB. Najlepšiu detekčnú schopnosť má algoritmus pri dĺžke okna „buffer“ = 4 RR intervaly a práci s čistými AFIB, s hodnotou senzitivity $Se = 89,182\%$ a špecificiy $Sp = 93,976\%$ a teda algoritmus dobre roztriedil prvky so SR, avšak hodnoty Se je nižšia a teda viacero AFIB označil za SR. Hodnota AUC pre túto dĺžku okna je, $AUC = 0,9730$ (v tabuľke 4), čo považujeme za veľmi vysoké číslo a teda môžeme povedať, že algoritmus dobre pretriedil signály s AFIB od SR.

Pre signály obsahujúce všetky AFIB, spolu s rôznymi inými arytmiami, algoritmus vykazuje najlepšiu detekčnú schopnosť pri dĺžke okna „buffer“ = 3 RR intervaly. Senzitivita pre toto okno je $Se = 91,572\%$, špecificita $Sp = 91,863\%$ a $AUC = 0,9654$ (vidieť v tabuľke 3).

2.3 Porovnanie detektorov AFIB so zostrojeným detektorom

V nasledujúcej kapitole porovnáme reálnu úspešnosť nášho detektoru s teoretickými predpokladmi, ktoré sme zhrnuli v tabuľke 2 v kapitole 1.4.

Dôležité je poznamenať, že teoretické hodnoty detekčných schopností nami vybraných detektorov (z kapitoly 1.3 a 1.4) pracujú za predpokladu stálej dĺžky okna „buffer“. To znamená, že signál je rozdelený na určitý počet okien a tieto okná, obsahujú všetky rovnaký počet RR intervalov (= dĺžka okna „buffer“). Avšak nami spracované dáta obsahovali len 10 sekundové záznamy EKG o hodnotách od 3 RR intervalov až po 33 RR intervalov (popísane v kapitole 2.1) a teda algoritmus v niektorých prípadoch nemusel fungovať správne, bol ovplyvnený rôznorodou hodnotou R hrotov v EKG signáloch. Veľmi krátke signály tak negatívne ovplyvnili detekčnú schopnosť.

Tabuľka 5: Reálne úspešnosti nami vyhotoveného detektoru metódy mediánov a jeho teoretické predpoklady úspešnosti.

Metóda	Dĺžka okna "buffer" [počet RR intervalov]	Sp [%]	Se [%]	AUC
Naše spracovanie metódy mediánov	3 – čisté AFIB	91,566	91,815	0,9718
	<u>4 – čisté AFIB</u>	<u>93,976</u>	<u>89,182</u>	<u>0,9730</u>
	7 – čisté AFIB	88,755	88,938	0,9450
	3 – všetky AFIB	91,863	91,572	0,9654
	4 – všetky AFIB	92,586	88,047	0,9649
	7 – všetky AFIB	88,755	88,938	0,9450
Teoretický predpoklad - metóda mediánov, <i>Linker,D.T.</i> [15]	19	98	98,7	0,9966 pre bližšie nedefinovaný počet RR intervalov
	7	≈ 98	≈ 98	

Naše spracovanie metódy mediánov má na prvý pohľad horšie štatistické výsledky, ako metóda mediánov od *Linker.D.T.* [15] Avšak pri pohľade na AUC je vidieť, že tieto rozdiely sú minimálne, líšia sa približne o dve stotiny a oba vyhotovené detektory považujeme za detektory s veľmi vysokou detekčnou schopnosťou.

Dôležité je ale poznamenať, že na základe teoretických poznatkov o metóde mediánov vieme, že jej detekčná schopnosť je ideálna pri dĺžke okna o 19 RR intervaloch a klesá so znižujúcim sa oknom po hraničnú hodnotu 7 RR intervalov, kde je síce stále Se a Sp ≈ 98%, avšak pre okná menšie ako 7 RR intervalov predpokladáme prudší pokles oboch hodnôt Se a Sp. Nášmu algoritmu klesala detekčná schopnosť so zväčšujúcim sa oknom a preto pri porovnaní teoretických predpokladov s našim spracovaním vidíme, že teoretické, očakávané predpoklady detekcie nie sú rovnaké s praktickými. Rozdiely medzi teoretickou Se

a Sp a praktickými je takmer 10%, avšak hodnota Se a Sp pre náš detektor je preto nižšia, lebo je negatívne ovplyvnená nerovnomernosťou dĺžky testovacích dát.

Ďalšou vhodnou metódou aj na spracovanie krátkych úsekov EKG signálov bola metóda využívajúca kvantifikátory v geometrickej oblasti, konkrétne metóda využívajúca RdR mapu od *Lian J., Wang L., Muessig D.* [17] a metódy založené na štatistických rozloženiach od *Ghodratti A., Marinello S.* [20] Ich porovnanie s našim detektorom je v tabuľke 6:

Tabuľka 6: Zhrnutie reálnej úspešnosti nami vyhotoveného detektoru spolu s ostatnými detektormi vhodnými na detekciu pre krátkodobé úseky EKG.

Metóda	Dĺžka okna "buffer" [počet RR intervalov]	Sp [%]	Se [%]	Poznámky
Naše spracovanie metódy mediánov	3 – čisté AFIB	91,566	91,815	
	4 – čisté AFIB	<u>93,976</u>	<u>89,182</u>	
	3 – všetky AFIB	91,863	91,572	
	4 – všetky AFIB	92,586	88,047	
Metóda využívajúca RdR mapu, <i>Lian J., Wang L., Muessig D.</i> [17]	32	92,6	94,4	Detekčná schopnosť klesá so znižujúcim sa oknom.
Metódy detekcie založené na štatistických rozdeleniach, <i>Ghodratti A., Marinello S.</i> [20]	29 – Gaussovské rozloženie		90	Detekčná schopnosť výrazne znížená pre EKG signály o dĺžke 10s.
	29 – Laplaceova funkcia		92	

Najlepšie detekčné vlastnosti nášho algoritmu sú pri zvolenej dĺžke okna 4 RR intervaly a pri práci výhradne s čistým AFIB, bez iných arytmií. Hodnota špecificity Sp je dokonca vyššia, ako u metódy využívajúcej RdR mapu, hodnoty špecificity pre metódy detekcie založenej na štatistických rozloženiach nemáme. Avšak hodnota Senzitivity, Se, je nižšia pre náš detektore ako u oboch vybraných

metód, avšak len minimálne. Napriek tomu môžeme ale povedať, že nami zhotovený algoritmus pracuje lepšie na nami zvolenom sete dát (popísané v kapitole 2.1) ako ostatné dva algoritmy, pretože vieme, že u metódy využívajúcej RdR mapu detekčná schopnosť klesá so zmenšujúcim sa oknom a štatistické výsledky Sp a Se pre okno 32 RR intervalov nie je pre nás smerodajné, pretože naše dáta obsahovali poväčšine ani nie polovičný počet RR intervalov pre dané signály EKG, ako v prípade metódy RdR mapy. Pri metóde detekcie na základe štatistických rozdelení zase vieme, že jej detekčná schopnosť je výrazne nižšia pre EKG signály o dĺžke 10 sekúnd a preto môžeme povedať, že na náš set dát by bola takmer nepoužiteľná (v našej práci využívame výhradne 10 sekundové úseky EKG signálov – popis kapitola 2.1).

Porovnávať náš detektor so zvyšnými metódami zvolenými v kapitolách 1.3 a 1.4, metódy založené na histogramoch a metóda využívajúca komplexity RR intervalov, nie je potrebné, pretože všetky metódy sú vhodné pre dlhé úseky EKG signálov a pre naše spracovanie by neboli vhodné.

3 ZÁVER

Nepravidelná dĺžka RR intervalov je považovaná za najpresnejší indikátor prítomnosti AFIB v EKG signáli, preto všetky popísané detektory v tejto práci fungovali na základe porovnávania veľkosti RR intervalov v rámci určitých segmentov, okien. Každý z detektorov pracoval na inom princípe, na základe iných kritérií a na základe rôznych dĺžok okien. Výsledkom bolo vždy porovnanie s predom stanovenou prahovou hodnotou, prípadne porovnanie s predom vyhotoveným templátom, ktorý predstavoval signály obsahujúce AFIB.

Detekčné schopnosti jednotlivých metód boli porovnané na základe štatistických údajov: senzitivita (Se) a špecificita (Sp), ale taktiež AUC. Navyše veľkú úlohu zohral aj údaj o tom, pre ako dlhé úseky EKG sú jednotlivé algoritmy vhodné – v našom prípade sa pracovalo s krátkodobými úsekmi EKG. Detektory boli porovnané v kapitole 1.4 na základe týchto údajov.

Najlepšie detekčné schopnosti zo všetkých porovnaných metód mala metóda mediánov, ktoré navyše vyhovovala aj jej zameraním sa práve na tieto krátkodobé úseky EKG (popísaná v kapitole 1.3.1). Jej následné vyhotovenie bolo prevedené v rozhraní Matlab na verzii R2018a, a funkčnosť bola otestovaná na dátach z databázy ÚBMI (popis v kapitole 2.1). Detektor bol vyhotovený pre detekciu AFIB z 10 sekundových EKG signálov z tejto databázy a jeho detekčná schopnosť bola porovnaná pre signály obsahujúce čisté AFIB a SR, ale aj pre signály obsahujúce SR a čisté AFIB v zmesi s inými arytmiami (popísané v kapitolách 2.1 a 2.2).

Na základe vyhotovených ROC kriviek (popis v kapitole 2.2.1) pre dĺžky okien 3 až 7 RR intervalov sa vypočítali štatistické parametre, ktoré boli neskôr porovnané na zhodnotenie úspešnosti detekcie AFIB. Treba ale poznamenať, že pri zostrojovaní týchto ROC kriviek bolo viditeľné to, že hodnoty prahov, (podľa ktorých sú signály väčšie ako prah označené za AFIB a menšie ako prah označené za SR), nie sú konštantné a pre oba spôsoby vypracovania nášho detektoru (pre čisté a pre všetky AFIB) sa menia pri zmene dĺžky okna. Táto nestálosť prahových hodnôt pre rôzne dĺžky okien by mohla byť problémom najmä pri práci s neanotovanými dátami.

Zhotovený detektor vykazuje najlepšie detekčné vlastnosti pri zvolenej dĺžke okna 3 RR intervaly pre všetky AFIB a SR, so $Sp=91,863\%$, $Se=91,572\%$ a $AUC=0,9654$ a pre signály obsahujúce výhradne čisté AFIB (bez prímiesí iných arytmií) a SR, $Sp=93,976\%$, $Se=89,182\%$ a $AUC=0,9730$. Detektor dosahuje lepšie výsledky pri práci výhradne s čistým AFIB, čo je spôsobené najmä tým, že iné arytmie môžu taktiež ovplyvňovať dĺžky RR intervalov a teda detekciu AFIB negatívne ovplyvniť. Navyše detektor porovnávajúci čisté AFIB a SR pracoval len s 249-timi signálmi obsahujúcimi AFIB z celkového počtu 553 (popis v kapitole 2.2) a teda bol testovaný ani nie na polovici dát, ako detektor pre signály obsahujúci všetky AFIB a SR. Tento fakt mohol taktiež negatívne ovplyvniť detekčnú schopnosť nášho detektoru.

Pri porovnaní nášho detektoru, pre oba spôsoby detekcie, s jeho teoretickými predpokladmi sú dosiahnuté nižšie hodnoty Sp a Se . Tieto hodnoty sú nižšie približne o 5% a AUC sa líšilo o necelé dve stotiny. Pri porovnaní rovnakých dĺžok okien „buffer“=7 RR intervalov tento rozdiel stúpol takmer až na 10%, pretože s rastúcou dĺžkou okna „buffer“ nášmu detektoru klesala detekčná schopnosť. Treba ale poznamenať, že testovací set dát pre náš detektor obsahoval veľmi rôznorodé signály EKG o rôznych dĺžkach (popis v kapitole 2.1) od 3 RR intervalov až po 33 RR intervalov. Toto sa javí veľkou nevýhodou, ktorá mohla do veľkej miery negatívne ovplyvniť štatistické výsledky nášho detektoru, keďže v prípade ostatných, vybraných metód (z kapitol 1.3 a 1.4) bolo vysvetlené, že dané detektory fungujú výhradne na fixných, konštantných dĺžkach okien, ktoré sa počas detekcie nemenia. V prípade nášho detektoru signály o veľmi malých hodnotách RR intervalov mohli spôsobiť to, že algoritmus nepracoval správne vo výpočtovej časti, napríklad pri vypočítaní a porovnávaní jednotlivých mediánov.

Analýzou dosiahnutých výsledkov sa dá ale konštatovať, že výber metódy na spracovanie tejto bakalárskej témy bol vhodný, jeho spracovanie sa podarilo a štatistická reprezentácia výsledkov formou špecificity, senzitivity a AUC dosiahla skvelých výsledkov.

BIBLIOGRAFIA

1. SILBERNAGL, Stefan a Agamemnon DESPOPOULOS: *Atlas fyziologie člověka*. 6. vyd., zcela přeprac. a rozš., Vyd. 3. české. Praha: Grada, 2004. ISBN 80-247-0630-X.
2. BULÍKOVÁ, Táňa: *EKG pre záchranárov nekladológov*. Praha: Grada, 2014. ISBN 978-80-247-5308-9.
3. LANGMEIER, Miloš: *Základy lékařské fyziologie*. Praha: Grada, 2009. ISBN 978-80-247-2526-0.
4. BENNETT, David H.: *Srdeční arytmie: praktické poznámky k interpretaci a léčbě*. Praha: Grada, 2014. ISBN 978-80-247-5134-4.
5. HAMPTON, John R.: *EKG stručně, jasně, přehledně*. Praha: Grada, 2013. ISBN 978-80-247-4246-5.
6. KAUTZNER, Josef: *Fibrilace síní v běžné praxi*. Praha: Maxdorf, c2012. Jessenius. ISBN 978-80-7345-270-4.
7. TÁBORSKÝ, Miloš: *Fibrilace síní: novinky v léčbě 2013*. Praha: Axonite CZ, 2013. Asclepius. ISBN 978-80-904899-3-6.
8. LLOYD-JONES, Donald M., Thomas J. WANG, Eric P. LEIP, et al. Lifetime Risk for Development of Atrial Fibrillation. *Circulation* [online]. 2004, **110**(9), 1042-1046 [cit. 2018-12-03]. DOI: 10.1161/01.CIR.0000140263.20897.42. ISSN 0009-7322.
9. ČIHÁK R, HEINC P (2004). Doporučení pro léčbu pacientů s fibrilací síní [Recommendations for the management of patients with atrial fibrillation]. *Cor Vasa*. 46: K67–K77 (in Czech).
10. CAMM, A. J., P. KIRCHHOF, G. Y. H. LIP, et al. Guidelines for the management of atrial fibrillation: The Task Force for the Management of Atrial Fibrillation of the European Society of Cardiology (ESC). *European Heart Journal* [online]. 2010, **31**(19), 2369-2429 [cit. 2018-12-05]. DOI: 10.1093/eurheartj/ehq278. ISSN 0195-668X.
11. HYNIE, Sixtus. *Farmakologie v kostce*. 2., přeprac. vyd. V Praze: Triton, 2001. ISBN 80-7254-181-1.

12. WILBER, David J. Pursuing Sinus Rhythm in Patients With Persistent Atrial Fibrillation. *Journal of the American College of Cardiology*[online]. 2009, **54**(9), 796-798 [cit. 2018-12-15]. DOI: 10.1016/j.jacc.2009.04.073. ISSN 07351097.
13. DE VOS, Cees B., Ron PISTERS, Robby NIEUWLAAT, et al. Progression From Paroxysmal to Persistent Atrial Fibrillation. *Journal of the American College of Cardiology* [online]. 2010, **55**(8), 725-731 [cit. 2018-11-03]. DOI: 10.1016/j.jacc.2009.11.040. ISSN 07351097.
14. LANG, Thomas A. a Michelle SECIC. *How to report statistics in medicine: annotated guidelines for authors, editors, and reviewers*. 2nd ed. New York: American College of Physicians, c 2006. ISBN 1-930513-69-0.
15. LINKER, David T. Accurate, Automated Detection of Atrial Fibrillation in Ambulatory Recordings. *Cardiovascular Engineering and Technology* [online]. 2016, **7**(2), 182-189 [cit. 2018-11-26]. DOI: 10.1007/s13239-016-0256-z. ISSN 1869-408X.
16. TATENO, K. a L. GLASS. Automatic detection of atrial fibrillation using the coefficient of variation and density histograms of RR and Δ RR intervals. *Medical & Biological Engineering & Computing* [online]. 2001, **39**(6), 664-671 [cit. 2018-11-26]. DOI: 10.1007/BF02345439. ISSN 0140-0118.
17. LIAN, Jie, Lian WANG a Dirk MUESSIG. A Simple Method to Detect Atrial Fibrillation Using RR Intervals. *The American Journal of Cardiology* [online]. 2011, **107**(10), 1494-1497 [cit. 2018-11-26]. DOI: 10.1016/j.amjcard.2011.01.028. ISSN 00029149.
18. KENNEDY, Alan, Dewar D FINLAY, Daniel GULDENRING, Raymond BOND a James MCLAUGHLIN. The accuracy of beat-interval based algorithms for detecting atrial fibrillation. In: *2015 Computing in Cardiology Conference (CinC)* [online]. IEEE, 2015, 2015, s. 893-896 [cit. 2018-11-26]. DOI: 10.1109/CIC.2015.7411055. ISBN 978-1-5090-0685-4.
19. DASH, S., K. H. CHON, S. LU a E. A. RAEDER. Automatic Real Time Detection of Atrial Fibrillation. *Annals of Biomedical Engineering*[online].

- 2009, **37**(9), 1701-1709 [cit. 2018-01-03]. DOI: 10.1007/s10439-009-9740-z. ISSN 0090-6964.
20. GHODRATI, A. a S. MARINELLO. Statistical analysis of RR interval irregularities for detection of atrial fibrillation. In: *2008 Computers in Cardiology* [online]. IEEE, 2008, 2008, s. 1057-1060 [cit. 2019-01-03]. DOI: 10.1109/CIC.2008.4749227. ISBN 978-1-4244-3706-1.
21. WILHELM, Zdeněk. Stručný přehled fyziologie člověka pro bakalářské studijní programy. 4. vyd. Brno: Masarykova univerzita, 2010. ISBN 978-80-210-5283-3.
22. BLAHÚT, P: *Akčný potenciál a srdce*. [online].[cit. 2018-12-20].Dostupné z <https://www.techmed.sk/akcny-potencial-a-srdce/>
23. GO, Alan S., Elaine M. HYLEK, Kathleen A. PHILLIPS, YuChiao CHANG, Lori E. HENAULT, Joe V. SELBY a Daniel E. SINGER. Prevalence of Diagnosed Atrial Fibrillation in Adults. *JAMA* [online]. 2001, **285**(18) [cit. 2019-01-03]. DOI: 10.1001/jama.285.18.2370. ISSN 0098-7484. Dostupné z: <http://jama.jamanetwork.com/article.aspx?doi=10.1001/jama.285.18.2370>

ZOZNAM POUŽITÝCH SKRATIEK

AFIB - atriálne fibrilácie, fibrilácia predsiení

SR - sínusový rytmus

EKG - elektrokardiografia

CMP - cievna mozgová príhoda

SA uzol - sinoatriálny uzol

AV uzol - atrioventrikulárny uzol

SDH - štandardizované histogramy hustoty

K-S test - Kolmogorov-Smirnov test

Se - senzitivita

Sp - špecificita

AUC - plocha pod krivkou

z angl. - z anglického, z angličtiny

ZOZNAM PRÍLOH

- Príloha 1: Obrázok vývojového diagramu metódy mediánov
- Príloha 2: Priložené DVD (obsahuje elektronickú verziu bakalárskej práce vo formáte PDF pod názvom *Sámel_Maroš_BP.pdf* a realizované algoritmy metódy mediánov v prostredí Matlab R2018a pre všetky, ale aj pre čisté AFIB spolu s ukázkovými dátami v zložke *Sámel_Maroš_prílohy*)