



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

EXTRAKCE A KLASIFIKACE SÍŇOVÉ AKTIVITY Z INTRAKARDIÁLNÍCH ELEKTROGRAMŮ

EXTRACTION AND CLASSIFICATION OF ATRIAL ACTIVITY USING MULTI-SITE INTRACARDIAC
ELECTROGRAMS

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Žaneta Martinů

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jakub Hejč

BRNO 2021



Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Žaneta Martinů

ID: 208876

Ročník: 3

Akademický rok: 2020/21

NÁZEV TÉMATU:

Extrakce a klasifikace síňové aktivity z intrakardiálních elektrogramů

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s principy arytmogeneze supraventrikulárních tachykardií a jejich projevy v intrakardiálních záznamech. Dále se seznamte se základními principy zpracování elektrokardiografických signálů a vypracujte literární rešerši na toto téma. 2) Provedte analýzu dostupných intrakardiálních dat a na jejím základě navrhnete vhodný postup pro předzpracování signálů. 3) Implementujte algoritmy pro extrakci síňové aktivity z intrakardiálních signálů. Funkci algoritmů ověřte. 4) Rozšiřte algoritmus o automatické rozpoznání typu síňového rytmu. 5) Vyhodnoťte úspěšnost algoritmu a podrobně diskutujte dosažené výsledky.

DOPORUČENÁ LITERATURA:

[1] SORNMO L. and LAGUNA P. Bioelectrical signal processing and neurological applications. Academic Press; 1st edition, 2005, 688 s., ISBN: 978-0124375529.

[2] ZIAD F. I., Miller J. M. and ZIPES D. P. Clinical Arrhythmology and Electrophysiology: A Companion to Braunwald's Heart Disease. Elsevier 3rd Edition, 2019, 1120 s., ISBN: 9780323523561.

Termín zadání: 8.2.2021

Termín odevzdání: 28.5.2021

Vedoucí práce: Ing. Jakub Hejč

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

Cílem této práce je seznámit čtenáře s arytmogenezí supraventrikulárních tachykardií zaměřenou na projevy v intrakardiálních záznamech. Dále semestrální práce pojednává o základních metodách analýzy elektrokardiografických signálů. Praktická část obsahuje extrakci síňové aktivity a klasifikaci síňového rytmu s možností implementace těchto metod v prostředí MATLAB. Z vhodně předzpracovaných dat je extrahována síňová aktivita. Na extrakci síňové aktivity navazuje klasifikace síňového rytmu pomocí metody K-means.

Klíčová slova

Supraventrikulární tachykardie, intrakardiální záznamy, síňová aktivita předzpracování signálu, klasifikace, shlukování, K-means.

Abstract

The aim of this thesis is to acquaint the reader with the origin of supraventricular, mainly their manifestations in intracardiac electrograms. There are described basic methods of analysis of electrocardiographic records. Practical part contains extraction of atrial activity and classification of atrial rate in MATLAB program. Atrial activity is extracted from preprocessed data. The extraction of atrial activity is followed by the classification of atrial rhythm using the K-means method.

Keywords

Supraventricular tachycardia, intracardiac electrograms, atrial activity, signal processing, classification, clustering, K-means.

Bibliografická citace:

- [1] SORNMO L. and LAGUNA P. Bioelectrical signal processing and neurological applications. Academic Press; 1 st edition, 2005, 688 s., ISBN: 978-0124375529.
- [2] ZIAD F. I., Miller J. M. and ZIPES D. P. Clinical Arrhythmology and Electrophysiology: A Companion to Braunwald's Heart Disease. Elsevier 3rd Edition, 2019, 1120 s., ISBN: 9780323523561.

Prohlášení

„Prohlašuji, že svou bakalářskou práci na téma Extrakce a klasifikace síňové aktivity z intrakardiálních elektrogramů jsem vypracovala samostatně pod vedením vedoucího bakalářské 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 autorka uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědoma 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:

.....
podpis autora

Poděkování

Ráda bych poděkovala vedoucímu mé bakalářské práce Ing. Jakubu Hejčovi za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

V Brně dne:

.....
podpis autora

Obsah

1.	Úvod	14
2.	Arytmogeneze supraventrikulárních tachykardií	15
2.1	Dělení podle mechanismus vzniku.....	15
2.2	Nejčastější typy supraventrikulárních tachykardií	16
2.2.1	Fibrilace síní	16
2.2.2	Flutter síní	17
2.2.3	Síňová tachykardie.....	18
2.2.4	AV uzlová reentry tachykardie (AVNRT).....	20
3.	Principy zpracování elektrokardiografických signálů	22
3.1	Základy filtrace FIR a IIR	23
3.2	Základní typy rušení.....	24
4.	Data	26
5.	Extrakce síňové aktivity	27
5.1	Odhad výkonových spekter.....	27
5.2	Lineární filtrace	30
5.3	Nelineární filtrace.....	32
5.4	Výběr příznaků pro extrakci.....	35
5.5	Detekce píků.....	37
5.6	Vymezení síňové aktivity.....	39
5.7	Metrika hodnocení	40
5.8	Zhodnocení dosažených výsledků.....	41
5.9	Diskuse	45
6.	Klasifikace síňového rytmu.....	46
6.1	Výběr příznaků pro klasifikaci.....	47
6.1.1	Příznaky odvozené z převodu na komory	47
6.1.2	Napěťové příznaky.....	51
6.1.3	Příznaky odvozené z časové aktivace síní	51
6.1.4	Complex Correlation Measure	53
6.1.5	Variabilita síňového rytmu	54
6.2	Standardizace příznaků	54
6.3	Selekce příznaků	55

6.4	Metoda K-means	56
6.5	Metoda analýzy siluet shluků.....	57
6.6	Analýza výsledných shluků.....	59
6.7	Zhodnocení výsledků klasifikace	64
6.8	Diskuse.....	68
7.	Závěr.....	69

Seznam symbolů a zkratek

Zkratky:

bpm	...	stahy za minutu
SVT	...	supraventrikulární tachykardie
FIR	...	konečná impulsní charakteristika
IIR	...	nekonečná impulsní charakteristika
LP	...	dolní propust
HP	...	horní propust
BP	...	pásmová propust
AV	...	atrio-ventrikulární
SA	...	sino-atriální
AVNRT	...	atrio-ventrikulární uzlová reentry tachykardie
AF	...	fibrilace síní
CS	...	koronární sinus
EKG	...	elektrokardiogram
FT	...	Fourierova transformace
DFT	...	diskrétní Fourierova transformace
FFT	...	rychlá Fourierova transformace
JSON	...	JavaScriptový objektový zápis
PCA	...	analýza hlavních komponent
PC	...	hlavní komponenta
DSC	...	Diceův koeficient podobnosti
TP	...	pravdivě pozitivní
FP	...	falešně pozitivní
TN	...	pravdivě negativní
FN	...	falešně negativní
RMSSD	...	odmocnina průměru kvadrátů diferencí sousedních intervalů NN
CCM	...	Complex Correlation Measure

Seznam obrázků

Obr. 2-1: Ukázka EKG záznamu s výskytem fibrilace síní. [2]	16
Obr. 2-2: Dva unipolární fibrilační elektrogramy zaznamenané z epikardiální stěny pravé síně během elektricky indukovaného a perzistentního AF. Čísla označují místní délky cyklu AF v milisekundách. [18].....	17
Obr. 2-3: Ukázka EKG záznamu s výskytem flutteru síní s převodem 4:1. [2]	17
Obr. 2-4: Intrakardiální elektrogram s výskytem flutteru síní s převodem na komory v poměru 2:1. [15]	18
Obr. 2-5: Ukázka EKG síňové tachykardie. [2].....	19
Obr. 2-6: Pravosíňová tachykardie se srdečním cyklem 350 ms s 2:1 AV blokádou produkující srdeční cyklus 700 ms. [15].....	19
Obr. 2-7 Ukázka tří svodů EKG s výskytem AVNRT a pseudo S vlnou (A). [3]	20
Obr. 2-8: Záznam intrakardiálních elektrogramů pro AVNRT. [15].....	21
Obr. 3-1: Blokový diagram obecného zpracování dat.	22
Obr. 3-2: Srovnání frekvenční odezvy filtrů FIR a IIR 12. řádu, plná čára zobrazuje frekvenční charakteristiky ideálního pásmového filtru. [14].....	24
Obr. 3-3: Různé typy rušení EKG, (a) drift nulové linie, (b) rušení pohybu elektrod, (c) EMG rušení, (d) ovlivnění modulace signálu respirací. [3]	25
Obr. 5-1: Blokové schéma odhadu výkonového spektra.	27
Obr. 5-2: Frekvenční spektrum síňové aktivity.	29
Obr. 5-3: Frekvenční spektrum komorové aktivity.	29
Obr. 5-4: Útlum filtru ve frekvenčním pásmu (modře) v dB.....	31
Obr. 5-5: Ukázka filtrace Butterworthovým filtrem signálu 00003B.json.	32
Obr. 5-6: Obálka vytvořená umocňováním původního signálu 00005E.json svodu CS1.....	33
Obr. 5-7: Blokové schéma tvorby obálky signálu.	33
Obr. 5-8: Obálka vytvořená Hilbertovou transformací signálu 00005E.json svodu CS1 bez zvýraznění umocněním.....	34
Obr. 5-9: Obálka vytvořená Hilbertovou transformací signálu 00005E.json svodu CS1 se zvýrazněním umocněním.....	34

Obr. 5-10: Průměrování jednotlivých svodů a metoda PCA pro získání jednodimenzionálního signálu z více svodů.	36
Obr. 5-11: Průběh prahové hodnoty signálu 000013.json.	38
Obr. 5-12: Ukázka výběru plochy pod křivkou pomocí prahové hodnoty.	39
Obr. 5-13: Výsledné hodnocení signálu 00000D.json s Dice skóre 0,9139.	42
Obr. 5-14: Výsledné hodnocení signálu 00004F.json s Dice skóre 0,7291.	42
Obr. 5-15: Výsledné hodnocení signálu 000043.json s Dice skóre 0.	43
Obr. 5-16: Šíření impulzu síněmi záznamu 000043.json.	43
Obr. 5-17: Neúspěšná detekce píků obálky signálu 000028.json.	44
Obr. 5-18: Výsledné hodnocení signálu 000063.json s Dice skóre 0,2007.	44
Obr. 6-1: Blokové schéma postupu klasifikace rytmu.	46
Obr. 6-2: Frekvenční charakteristika navrhnutého filtru pásmové propusti (modře) v dB.	48
Obr. 6-3: Detekce píků komorové aktivity signálu 00000D.json.	49
Obr. 6-4: Velikost intervalů QP a PQ v signálu 000003.json.	49
Obr. 6-5: Ukázka poměru převodu P:Q na signálu 000030.json.	50
Obr. 6-6: Ukázka šíření vlny sinusového rytmu v CS svodech.	52
Obr. 6-7: Ukázka šíření vlny charakterizované jako AVNRT v CS svodech.	52
Obr. 6-8: Ukázka Poincarého mapy pro signál 000055.json.	53
Obr. 6-9: Zobrazení Pearsonova korelačního koeficientu mezi jednotlivými příznaky.	55
Obr. 6-10: Výsledné průměrné hodnoty siluety shlukování do k shluků.	58
Obr. 6-11: Výsledné hodnoty siluety shlukování do čtyř shluků.	59
Obr. 6-12: Zobrazení shluků K-means pomocí hlavních komponent.	60
Obr. 6-13: Zobrazení vztahů parametrů intervalů PQ a QP.	61
Obr. 6-14: Zobrazení vztahů parametrů intervalů CS5 a CS3.	62
Obr. 6-15: Zařazení jednotlivých cyklů záznamu 000019.json do shluků.	62
Obr. 6-16: Zobrazení vztahů parametrů intervalů A a RMSSD.	63
Obr. 6-17: Zařazení jednotlivých cyklů záznamu 000010.json do shluků.	64
Obr. 6-18: Zařazení jednotlivých cyklů záznamu 000009.json do shluků.	65
Obr. 6-19: Zařazení jednotlivých cyklů záznamu 000026.json do shluků.	65
Obr. 6-20: Zařazení jednotlivých cyklů záznamu 000030.json do shluků.	66

Obr. 6-21: Zařazení jednotlivých cyklů záznamu 00000B.json do shluků.....	67
Obr. 6-22: Zařazení jednotlivých cyklů záznamu 000016.json (nahore) a záznamu 000018.json (dole) do shluků.....	67

Seznam tabulek

Tab. 5-1: Parametry pro návrh filtru.	30
Tab. 5-2: Parametry pro návrh filtru.	31
Tab. 5-3: Parametry navrhnutého filtru.	31
Tab. 5-4: Míra zastoupení variability v první hlavní komponentě a v druhé hlavní komponentě.	37
Tab. 5-5: Výsledné hodnocení.	41
Tab. 5-6: Výsledné hodnocení vybraných souborů.	41
Tab. 6-1: Parametry pro návrh filtru.	47
Tab. 6-2: Parametry pro návrh filtru.	47
Tab. 6-3: Hodnoty poměrů síní a komor pro vybrané signály.	51
Tab. 6-4: Výsledky shlukování do čtyř shluků.	58
Tab. 7-1: Výsledná Dice skóre pro jednotlivé objekty.	74

1. Úvod

Ablace pravidelných supraventrikulárních tachykardií (SVT) se pohybují na předních místech četnosti zákroků. Tyto zákroky mohou být až život zachraňující. Povrchové elektrokardiografické vyšetření (EKG) je jednou ze základních diagnostických metod. Avšak pro správné určení mechanismu a původu supraventrikulárních tachykardií může být nedostatečné. K vyšetření se poté volí vyšetření z intrakardiálních záznamů, ze svodů zavedených katetrem na místo určení. Manuální klasifikace morfologie, rytmu a jiných příznaků z intrakardiálních záznamů je velmi zdoluhavá a často subjektivní. Automatická klasifikace je tedy velmi potřebným nástrojem.

V první části semestrální práce je rozebíraná teorie arytmogeneze supraventrikulárních tachykardií a obecné metody pro klasifikaci elektrokardiografických záznamů. Dále následuje praktická část, která se skládá z extrakce síňové aktivity a klasifikace rytmu.

Praktická část začíná předzpracováním elektrogramu a extrakcí síňové aktivity. Kroky předzpracování jsou spektrální analýza jednotlivých aktivit a následná filtrace. Práci uzavírá diskuse, ve které je zhodnocen postup extrakce síňové aktivity pomocí kvantitativních i kvalitativních kritérií.

Na extrakci síňové aktivity navazuje klasifikace síňového rytmu. Ze získaných příznaků je provedena selekce příznaků na základě Pearsonova korelačního koeficientu. Dále je provedeno shlukování jednotlivých síňových stahů pomocí metody K-means. Jednotlivé shluky jsou na základě analýzy klasifikovány dle rytmu.

2. Arytmogeneze supraventrikulárních tachykardií

Převodní systém srdeční nabývá schopnosti generovat elektrické impulzy, je schopný rozvádět elektrické vzruchy díky vysoké vodivosti. Důsledkem koordinovaného a efektivního vedení vzruchů dochází ke kontrakci srdeční svaloviny. Srdeční automacie je schopnost srdce generovat, rozvádět elektrické impulzy převodním systémem a následně udávat rytmus kontrakcí svaloviny. Sinoatriální uzel (SA) má roli hlavního srdečního pacemakeru, který za normálních podmínek udává rytmus 60–100 bpm. Srdce bije podle ložiska nejvyšších frekvencí. Důsledkem různých patologií může být udávány rychlejší rytmus než sinusový, na který bude svalovina srdce reagovat. [1]

Pro tachykardii je typický rytmus nad 100 bpm. Supraventrikulární tachykardie mají původ vzniku v síňové oblasti srdce (sinoatriální uzel, srdeční svalovina síní, atrioventrikulární uzel, velké cévy připojené k síním). Můžeme je dělit na síňové tachykardie, kdy rytmus vzniká v oblasti síní, a na nodální tachykardie, kdy rytmus vzniká v AV junkci – atrioventrikulárním uzlu. [3] Impulzy přes AV uzel rychle přechází na komory a vytváří tak úzký QRS komplex (<0,12 s). SVT jsou tvořeny jedním ze tří mechanismů: reentry, zvýšená automacie nebo spouštěcí aktivita. [2]

2.1 Dělení podle mechanismus vzniku

Mezi mechanismy vzniku supraventrikulárních tachykardií patří 3 hlavní mechanismy, těmi jsou reentry, zvýšená automacie a spouštěcí aktivita.

Reentry je opakované šíření impulzu přes elektricky oddělené cesty, které mohou být oddělené anatomickou bariérou. Jedno rameno je tvořeno fyziologicky převodním systémem srdečním, druhá přídavná dráha způsobuje návrat impulzu zpět. [3] Je potřebná jiná rychlost šíření mezi rameny, jinak by došlo k zániku reentry. Spouštěcím mechanismem je extrasystola. [2] Reentry je případem atrioventrikulární reentrantní tachykardie (AVRT), atrioventrikulární nodální reentrantní tachykardie (AVNRT), paroxysmální supraventrikulární tachykardie (PSVT) nebo síňového flutteru. [4]

Zvýšená automacie označuje jev, kdy skupina buněk vykazuje patologické změny v klidovém membránovém potenciálu. Vykazují-li schopnost rychlé depolarizace, mohou snadno vytvořit dominantní srdeční rytmus. [3] Arytmie způsobené zvýšenou automacií zahrnují sinusovou tachykardii, síňovou tachykardii a junkční nebo nodální tachykardii. [4]

Spouštěcí aktivita je způsobena dodatečnými depolarizacemi bezprostředně po buněčné repolarizaci, které mohou mít za následek extrasystoly a trvalé tachyarytmie. Aktivace může nastat jako reakce na zvýšení intracelulárního vápníku (např. srdečními glykosidy) a je mechanismem přibližně 30 % fokálních síňových tachykardií. [3] Spouštěcí aktivita se podílí i na zahájení fibrilace síní. Arytmie způsobené spouštěcí aktivitou zahrnují paroxysmální supraventrikulární tachykardii (PSVT). [4]

2.2 Nejčastější typy supraventrikulárních tachykardií

Nejčastěji se vyskytující supraventrikulární tachykardie jsou AV uzlová reentry tachykardie (AVNRT), flutter síní, síňová tachykardie a síňová fibrilace. V této podkapitole se zaměříme na popis zmíněných nejčastěji se vyskytujících arytmií a objasníme jejich vliv na intrakardiální záznamy. Mezi další příklady SVT patří sinusová tachykardie, AV reentry tachykardie (AVRT), permanentní junkční reciproční tachykardie (PJRT) a další. [2]

Klinické kardiální elektrofyziologické techniky, zahrnující intrakardiální snímání a elektrickou stimulaci, mají velký význam při stanovování mechanismu srdečních arytmií. Vedou k lepším interpretacím povrchových EKG, ale i hrají zásadní roli při terapii tachykardií. Povrchové EKG má omezení v diagnostice takových komplexních tachykardií a invazivních elektrofyziologické studie mohou mít v této souvislosti důležitý význam. Např. u pacientů s SVT se přítomnost substrátu pro reentry, jako je doplňková dráha, může projevit abnormální intrakardiální aktivační sekvencí buď síňového nebo komorového elektrogramu. [15]

2.2.1 Fibrilace síní


Supraventrikulární arytmií fibrilace síní (*AF – Atrial Fibrillation*) charakterizuje nepravidelná aktivita síní, která je v rozmezí 400–700 bpm s navazující nepravidelnou komorovou odezvou. [5] K vytvoření fibrilace síní je zapotřebí alespoň 10 mikro-reentry okruhů (depolarizačních ložisek) v oblasti síní. Spouštěcím mechanismem jsou nejčastěji síňové extrasystoly. Síňové depolarizace na EKG s danou frekvencí jsou označovány jako vlna f. Na EKG na Obr. 2-1 lze vidět přítomnost f vln a nepravidelný výskyt QRS komplexů. [2]



Obr. 2-1: Ukázka EKG záznamu s výskytem fibrilace síní. [2]

Na Obr. 2-2 jsou znázorněny dva unipolární elektrogramy zaznamenané z epikardiálního povrchu pravé síně u pacientů s akutně indukovanou AF (a) a chronickou AF (b). Fibrilační elektrogramy vykazují jasné morfologické variace a nepravidelné délky cyklu mezi rytmy.


Během akutního AF má většina fibrilačních potenciálů vysokou amplitudu a vykazuje jedinou negativní výchylku během cyklu, jak lze vidět na Obr. 2-2 (a). Během chronické AF, který je zobrazen na elektrogramu na Obr. 2-2 (b) se délka cyklu poněkud prodlužuje a je nepravidelnější. Dvojité potenciály a mírná frakcionace, které jsou výsledkem disociace a otáčení fibrilačních vln, jsou vidět častěji. [18]



Obr. 2-2: Dva unipolární fibrilační elektrogramy zaznamenané z epikardiální stěny pravé síně během elektricky indukovaného a perzistentního AF. Čísla označují místní délky cyklu AF v milisekundách. [18]


2.2.2 Flutter síní

Flutter síní se řadí k arytmiím způsobeným makro-reentry. Impulz krouží s rychlostí 200–400 bpm. Reentry okruh vzniká v pravé síni kolem trikuspidální chlopně. Oběh může vést po směru i proti směru hodinových ručiček. Forma, jež vede proti směru hodinových ručiček, je běžnější a vede k negativnímu pilovému vlnovému vzoru ve svodech II, III, aVR s pozitivní vlnou ve V1. Význačný je také pravidelnou aktivitou komor. [3] Nejčastější převod impulsu mezi síněmi na komory je v poměru 2:1. Jasně viditelný pilový vzor je zobrazen na Obr. 2-3, poměr přenosu impulsu mezi síněmi a komorami je zde v poměru 4:1 [2].



Obr. 2-3: Ukázka EKG záznamu s výskytem flutteru síní s převodem 4:1. [2]

Na Obr. 2-4 je zaznamenána kavotrikuspidální blokáda šíje během radiofrekvenční ablace pro síňový flutter. Do pravé síně je zavedený dvacetipolární Halo katetr (H 1-20). Ten zaznamenává aktivaci z okolí trikuspidálního mezikruží během stimulace z katetru koronárního sinu (CS). V prvních dvou srdečních cyklech je aktivace kolem prstence ve směru hodinových ručiček i proti směru hodinových ručiček, což je naznačeno šipkami. Během třetí doby je aktivace pouze proti směru hodinových ručiček, což indikuje blokování šíje značící flutter síní s převodem na komory v poměru 2:1. [15]



Obr. 2-4: Intrakardiální elektrogram s výskytem flutteru síní s převodem na komory v poměru 2:1. [15]


2.2.3 Síňová tachykardie

Síňová tachykardie značí rychlý abnormální rytmus přesahující 100 bpm. Elektrické impulzy vycházející z jednoho místa v oblasti síně neodpovídají sinusovému rytmu. Mechanismus původu a šíření impulzu je nejčastěji klasifikován jako zvýšená automacie. Původ elektrických impulzů se nenachází v sinoatriálním uzlu, ale v jednom ložisku ve tkáni srdečních síní. [8] Na EKG na Obr. 2-5 můžeme vidět odlišné vlny P od P vln sinusového rytmu. [2]



Obr. 2-5: Ukázka EKG síňové tachykardie. [2]


Pokud je tachykardie přetrvávající, je upřednostňovanou technikou mapování aktivace pomocí vychýleného mapovacího katetru s odklonitelnou špičkou. Technika využívá P vlnu jako pevný referenční bod a unipolární záznam hledající komplex QS v místě ohniska. Multipolární katetry umístěné v příslušných částech síně mohou významně pomoci této technice. Jakmile je fokus považován za identifikovaný, lze k potvrzení použít mapování „strháváním“ (*entrainment mapping*). Dále lze pro identifikaci síňové tachykardie v elektrogramu použít techniky kardiostimulace a následného porovnání stimulovaných P vln s P vlnami danými tachykardií. Na Obr. 2-6 je patrná odpověď V–A–A–V při vedení síňové tachykardie přes AV uzel, protože poslední stržená vlna A bude následně blokovat dopředně vedení v AV uzlu. [15]



Obr. 2-6: Pravosíňová tachykardie se srdečním cyklem 350 ms s 2:1 AV blokádou produkující srdeční cyklus 700 ms. [15]


2.2.4 AV uzlová reentry tachykardie (AVNRT)

Jedná se o nejčastěji vyskytující se paroxysmální (záchvatovitou) SVT. Pacienti s AVNRT (*Atrioventricular Nodal Reentrant Tachycardia*) prokazují duální atrioventrikulární uzlové vstupy s různými elektrofyziologickými vlastnostmi, které působí jako dvě končetiny reentrantního okruhu. Jedná se o rychlou a pomalou cestu. Typickou formou je pomalá–rychlá AVNRT (*slow–fast AVNRT*). Dochází k dopřednému vedení pomalou cestou a zpětnému rychlou cestou. Atypickými druhy jsou pomalá–pomalá (*slow–slow*) nebo rychlá–pomalá (*fast–slow*) AVNRT. Na EKG můžeme nalézt pseudo–S vlny. Na Obr. 2-7 je taková pseudo–S vlna naznačena bodem A. [3]



Obr. 2-7 Ukázka tří svodů EKG s výskytem AVNRT a pseudo S vlnou (A). [3]

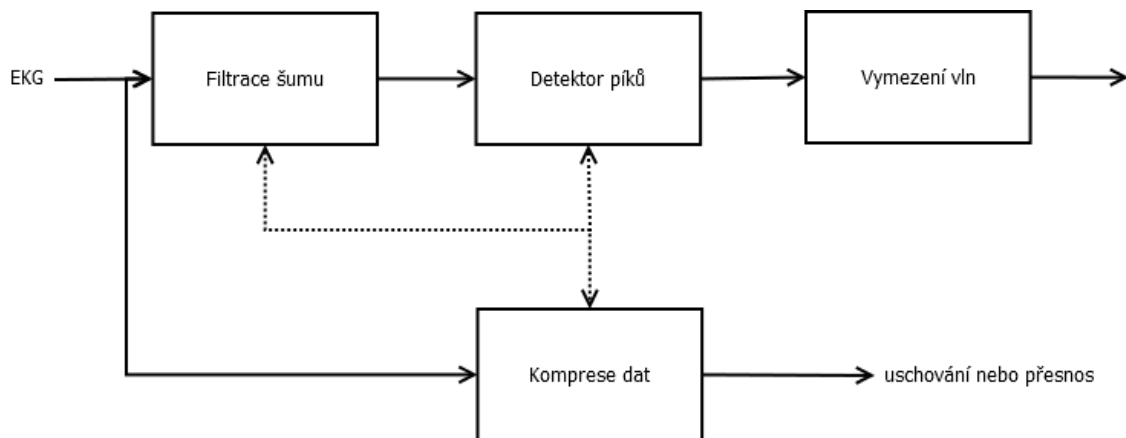
U 70 % pacientů s AVNRT bude během snímání elektrogramu viditelná změna v AH vedení. AH vedení je vedení od začátku kmitu A do začátku kmitu H (norma: 50–130 ms). AH vedení odpovídá době vedení AV uzlem v elektrogramu Hisova svazku. Minimální prodloužení je 50 ms. Pro diagnostiku je nejprve nutné zkrátit interval A1A2 o 10–20 ms. Tato skutečnost je naznačena na Obr. 2-8. Typická AVNRT slow–fast se skládá z dlouhého intervalu AH a synchronního síňového a komorového vedení s krátkým intervalem VA. Přítomnost bloku větve svazku způsobí prodloužení HV vedení a zpoždění komorových elektrogramů v závislosti na tom, které větve svazku jsou ovlivněny. Délka cyklu ovlivněna nebude. HV vedení je doba vedení Hisovým–Purkyňovým svazkem a Purkyňovými vlákny (norma: 35–55 ms). Aktivace síní by během AVNRT měla probíhat pravidelně. Atypická AVNRT slow–fast vede k dlouhému intervalu RP na povrchovém elektrogramu s odpovídajícími změnami intrakardiálního elektrogramu. [15]



Obr. 2-8: Záznam intrakardiálních elektrogramů pro AVNRT. [15]

3. Principy zpracování elektrokardiografických signálů

Zpracování elektrokardiografických signálů je nezbytným krokem k následné analýze dat a identifikacím arytmií. Na Obr. 3-1 můžeme vidět jednoduchý algoritmus zobrazený na blokovém diagramu pro zpracování elektrokardiografických signálů. Výstup horní větve schématu je podmíněný signál s informací o časovém výskytu dané vlny (píku), začátku a konce každé vlny. [12]



Obr. 3-1: Blokový diagram obecného zpracování dat.

Filtrace se skládá z lineární a nelineární filtrace. Cílem je odstranění driftu nulové linie, síťového brumu a aktivity svalů. Základními typy rušení se budeme zabývat v podkapitole 3.1. Důležitá je správnost určení, do jaké míry je výstup filtru ovlivněn vlivem vstupující aktivity. Periodické vlny jsou nežádoucími vlnami s vysokou amplitudou. Lineární, časově nezávislý filtr je více senzitivní na tyto impulzy, přesto se může někdy jevit výhodnější využití nelineárních struktur. Správná **detekce vln (píků)** představuje stěžejní krok pro následnou analýzu dat a ovlivní výsledky daného systému. **Vymezení vln** je důležitým krokem pro zpracovávání elektrografických signálů. Pro diagnostiku je esenciální využití informací o amplitudě a trvání jedné vlny. Návrh je často založen na principu, že amplituda je dosahuje nízkých hodnot v krajních bodech vlny. Tato nízká amplituda je i ve většině případů skrytá pod signálem šumu. Značné úspory dat, kapacity paměti a času přenosu lze dosáhnout využitím různých typů redundance. Každý vzorek může být reprezentován méně bity než v původním signálu. **Použití komprese dat** je přijatelné, pouze pokud jsou v rekonstruovaném signálu zachovány požadované diagnostické informace. Zpracovávání elektrokardiografického signálu je obvykle doprovázeno **následnou analýzou**, která často pracuje s morfologií a rytmem vln. Pro charakteristiku morfologie vln se používá extrakce vlastností. Mezi hlavní vlastnosti vlny patří délka a amplituda vlny. Doplnující vlastnosti jsou vyžadovány pro rozdělení signálu do daných skupin. Doplnujícími vlastnostmi mohou být oblast,

polarita, strmost vln (heuristické prvky) nebo korelační koeficienty vzniklé porovnáváním se šablonou. Analýza rytmu vln počítá s intervaly mezi každou vlnou a následující vlnou. Rozsah využití analýzy rytmu je závislý na aplikaci. Pro klidovou EKG je možné využít analýzy rytmu pouze pro komplikované a trvalé arytmie z důvodu délky záznamu. Na kontinuální měření EKG můžou být pomocí analýzy rytmu zachyceny život ohrožující přechodné arytmie. [12]

3.1 Základy filtrace FIR a IIR

Lineární filtrace slouží k úpravě signálu, při níž se některé jeho složky potlačí nebo odstraní, zatímco jiné jsou tak relativně zdůrazněny. Vlastnosti filtrů se nejčastěji definují prostřednictvím jeho frekvenční charakteristiky. Lineární filtraci můžeme rozdělit na pásmové filtry, filtry s obecnými (resp. regulovatelnými) charakteristikami, fázové korektory a tvarovače signálu. Pásmová filtrace slouží k výběru určitého frekvenčního pásma (frekvenčních pásem), nebo naopak potlačení. Hlavními typy frekvenčních charakteristik pásmové filtrace jsou: dolní propust (LP), horní propust (HP), pásmová propust (BP) a pásmová zadrž. [6]

Základní vlastností FIR filtrů je konečná impulsní charakteristika. Výstupem takového filtru je konečná diskretní konvoluce s impulsní charakteristikou:

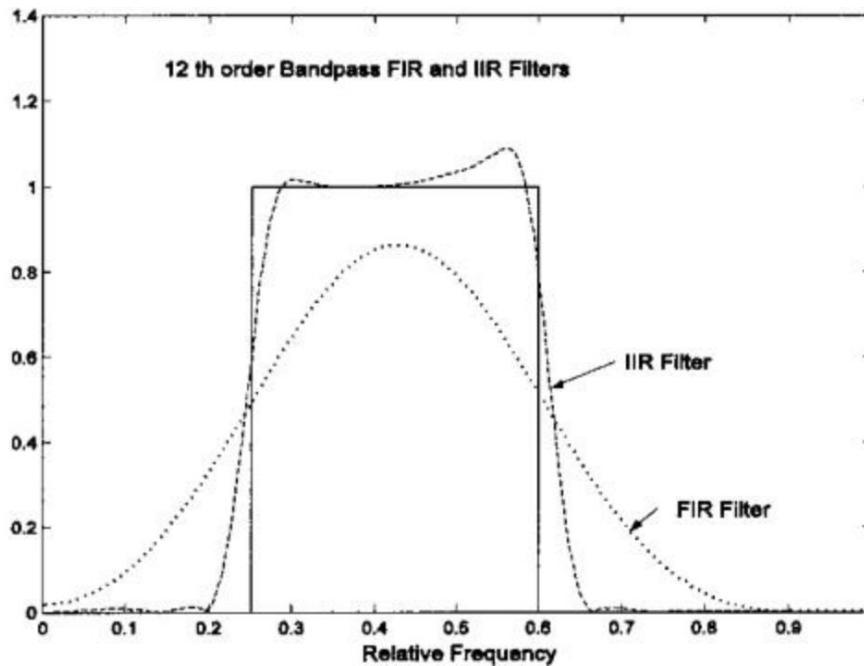
$$y_n = \sum_{k=0}^{N-1} x_{n-k} h_k, \quad k \in \langle 0, N-1 \rangle. \quad (3.1)$$

Přenosová funkce impulsní charakteristiky má významné pouze nulové body. FIR filtry můžeme nazvat absolutně stabilní díky násobnému pólu ve středu jednotkové kružnice. Frekvenční charakteristika filtru je periodická, jako pro každé diskretní systémy. FIR filtry mohou mít přesně lineární fázovou charakteristiku, pokud je jejich impulsní charakteristika symetrická nebo antisymetrická. [6]

Lineární filtry s nekonečnou impulsní charakteristikou neboli IIR filtry jsou realizovány lineárními obecně rekursivními systémy s diferenční rovnicí:

$$y_n = \sum_{i=0}^r L_i x_{n-i} - \sum_{i=1}^m K_i y_{n-i}, \quad (3.2)$$

kde L_i jsou koeficienty nerekursivní části systému a K_i rekursivní části systému. IIR filtry jsou oproti FIR filtrům koncepčně složitější, avšak realizačně jednodušší a pro srovnatelné vlastnosti vyžadují výrazně menší výpočetní výkon. [6]



Obr. 3-2: Srovnání frekvenční odezvy filtrů FIR a IIR 12. řádu, plná čára zobrazuje frekvenční charakteristiky ideálního pásmového filtru. [14]


Tato skutečnost je zobrazena na Obr. 3-2, kdy je použit stejný řád filtru FIR a IIR. IIR filtr vykazuje strmější charakteristiku a užší propustné pásmo. Avšak rekursivita umožňuje nestabilitu. Vždy při návrhu filtru je nutné otázku stability analyzovat. Při výpočtech může docházet ke kumulaci zaokrouhlovací chyby, následnému vzniku mrtvých pásem a mezních cyklů. [6]

3.2 Základní typy rušení

Mezi základní typy rušení patří síťový brum, drift nulové linie a signály rušení z EMG. Další rušení může být způsobeno např. pohybem elektrod nebo modulací signálu dechem.

Elektromagnetické pole sítě způsobuje rušení, které je charakterizované sinusovým průběhem o frekvenci 50 nebo 60 Hz. Dané rušení se nazývá síťový brum. Frekvence může být doprovázena rušením jejích vyšších harmonických frekvencí. Pro odstranění síťového rušení je vhodný FIR filtr druhého řádu s dvěma nulovými body na jednotkové kružnici překrývajícími 50 (resp. 60) Hz. Další metodou je návrh filtru IIR s dvěma póly svírající stejný úhel jako nulové body s poloměrem z intervalu (0,1). Oproti FIR filtru IIR filtr nepotlačuje okolní frekvence. [13]

Drift nulové linie je efekt, kdy osa x není rovná, ale můžeme na ni vidět výkyvy nahoru a dolu. Toto rušení může být způsobeno pomalými pohyby pacienta nebo dýcháním. Rušení je ve frekvenčním rozsahu do 0,5 Hz. Přímé řešení driftu izoliny je využití ideálního filtru horní propusti. FIR filtr by měl dosahovat řádu $2L + 1$ (L stojí za délku impulsní charakteristiky filtru) pro získání dostačujícího rozumného kompromisu mezi útlumem nepropustného pásma a šířkou přechodového pásma. Lze využít i vlnkové transformace k odstranění driftu izoliny. [13]



Obr. 3-3: Různé typy rušení EKG, (a) drift nulové linie, (b) rušení pohybu elektrod, (c) EMG rušení, (d) ovlivnění modulace signálu respirační. [3]

Přítomnost svalového šumu představuje velký problém, protože křivky s nízkou amplitudou mohou signál EKG úplně zakrýt. Tyto signály je možné naměřit pomocí elektromyografie. Narozdíl od síťového brumu a driftu izoliny nelze využít úzkopásmový filtr, ale je potřeba rozvinout komplexnější řešení problému. Odstranění myopotenciálů může probíhat klouzavým průměrem nebo složitějšími metodami odvozenými od této techniky. [13]

4. Data

Poskytnutá databáze k analýze dat se skládá ze 100 souborů ve formátu JSON (*JavaScript Object Notation* – JavaScriptový objektový zápis). Jedná se o textový datový formát, který je nezávislý na jazyce. V prostředí MATLAB je možné nejprve soubory načíst pomocí funkce *fileread*, následně ze souboru vytvořit datovou strukturu pomocí funkce *jsondecode*. Načtením dat získáme struktury obsahující 6 objektů: *id*, *patient*, *measurement*, *diagnosis*, *data* a *annotation*.

V objektu *id* nalezneme identifikační kód. Objekt *patient* kvůli anonymitě pacientů neposkytuje data o pacientovi.

Objekt *measurement* nám udává informace o měření a naměřených datech. Data byla naměřena pomocí přístroje EP WorkMate 4.2. Jejich vzorkovací frekvence je 2000 Hz, vzorky signálů jsou udávány v milivoltech s rozlišením 0,1 mikrovolt. Vyčteme zde i informaci o počtu naměřených svodů a délce signálu

Objekt *data* obsahuje naměřené signály jako řádkový vektor. Každý záznam obsahuje 19 nasnímaných signálů, 12 signálů z povrchového EKG a 7 intrakardiálních signálů. Intrakardiální signály tvoří signály z elektrod umístěných v koronárním sinu (CS5, CS4, CS3, CS2 a CS1) a v Hisově svazku (HIS2 a HIS1).

Další objekt je *diagnosis*. Obsahuje informaci o typu rytmu. Pokud má pacient supraventrikulární arytmii, je zde uveden typ arytmie. Pokud pacientovi nebyla diagnostikována supraventrikulární arytmie, je k němu přiřazen sinusový rytmus. Databázi můžeme rozdělit do tří klasifikačních tříd: sinusový rytmus, supraventrikulární tachykardie a kombinovaný rytmus (kombinace sinusového rytmu a SVT).

Posledním objektem je *annotation*. *Annotation* obsahuje dva prvky, a to *atrial_onset* a *atrial_offset*. *Atrial_onset* obsahuje indexy, které určují začátky síňové aktivity. Zatímco *atrial_offset* obsahuje indexy, které určují konce síňové aktivity. Tyto prvky budou sloužit k vyhodnocení výsledků extrakce síňové aktivity, kterými se bude zabývat podkapitola 5.8.

5. Extrakce síňové aktivity

5.1 Odhad výkonových spekter

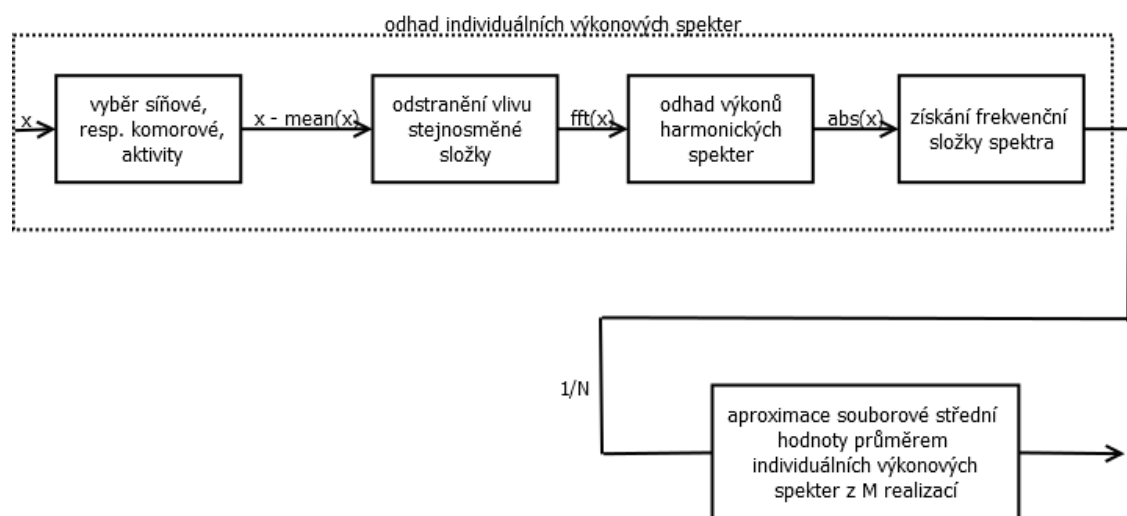
U deterministických signálů provádíme odhad výkonu harmonických spekter pro vyjádření signálu jako aditivní směsi harmonických složek. Pro digitální signály je možno aplikovat DFT pro získání frekvenční složky. [6] Digitální signály jsou signály zaznamenané v diskretních časových okamžicích a v diskretních úrovních amplitudy se vzorkovací frekvencí. [7]

Diskrétní Fourierovou transformací (*DFT, Discrete Fourier Transformation*) provádíme odhad výkonového spektra. U deterministických signálů získáváme amplitudy a počáteční fáze harmonických složek signálu. U náhodných signálů se jedná o odhad výkonů harmonických složek. Tedy nezískáváme fázové informace. DFT poskytne periodické frekvenční spektrum v rozsahu od 0 Hz po hodnotu poloviny vzorkovací frekvence. DFT může být přesnou formou výpočtu Fourierovy řady periodického signálu: [6]

$$F(k\Omega) = \sum_{n=0}^{N-1} f_n e^{-jk\Omega nT}, \quad \Omega = \frac{2\pi}{NT} \quad (5.1)$$

kde $k\Omega$ je z intervalu $\langle 0, \omega_{vz} - \Omega \rangle$.

DFT tedy poskytuje přesné vzorky spektra konečného a navzorkovaného signálu. Často využívaný algoritmus pro danou operaci je rychlá Fourierova transformace (*FFT – Fast Fourier Transformation*). [7]



Obr. 5-1: Blokové schéma odhadu výkonového spektra.

Na základě daných znalostí jsem provedla odhad individuálních výkonových spekter z pěti sad svodů trénovacích dat po pěti svodech CS5, CS4, CS3, CS2 a CS1. Pět náhodně vybraných sad svodů považuji za dostatečné, při přidání dalších sad svodů nedocházelo k markantní změně výsledného spektra ani přílišného posunu maxim spekter.

Pro upravené signály byl uskutečněn odhad individuálních výkonových spekter dle blokového schématu na Obr. 5-1. Požadovaným výstupem daného algoritmu jsou výsledná spektra síňové aktivity srdce a komorové aktivity srdce. Vstupem jsou signály ze svodů CS5, CS4, CS3, CS2 a CS1. Mechanicky byla na každém souboru svodů označena, dle znalostí průběhů EKG, místa se zmíněnými aktivitami, síňovou a komorovou aktivitou.

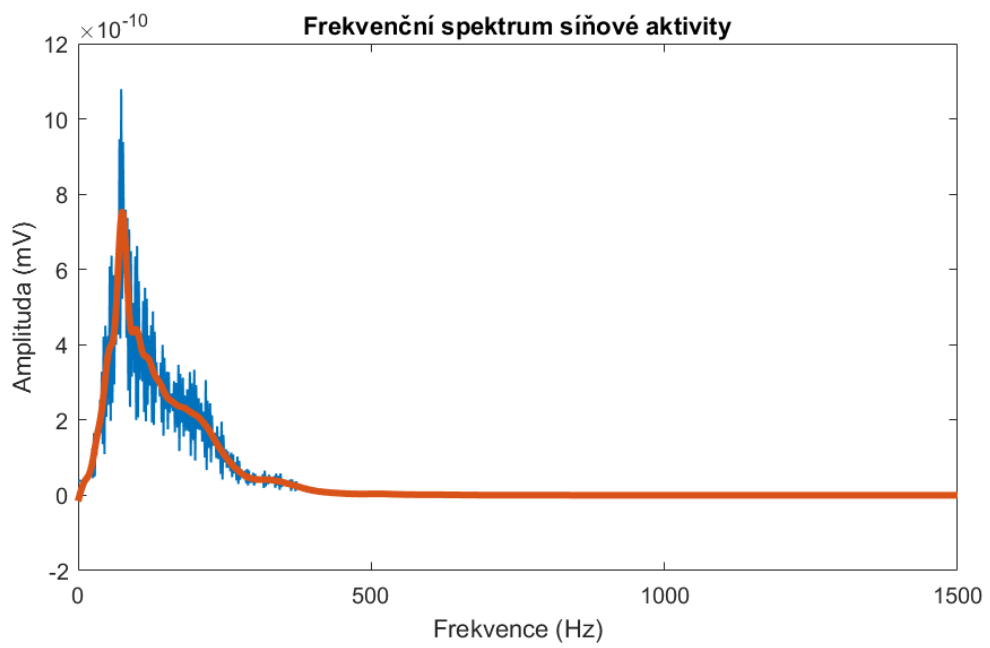
Odhad výkonu harmonických spekter byl implementován za pomoci funkce $fft(X, n)$. X udává matici vstupních signálů, na kterých proběhne Fourierova transformace každého sloupce, a n udává počet prvků výstupu. Volila jsem n rovné fvz (2000 Hz), tedy výsledné spektrum je realizované s frekvenčním rozlišením 1 Hz.

Pro každou aktivitu zvlášť byla zpřůměrována frekvenční spektra všech zpracovaných svodů aproximací souborové střední hodnoty průměrem individuálních výkonových spekter z M realizací: [6]


$$S_{ff}(\omega) = E_w \left\{ \frac{1}{N} |F_w(\omega)|^2 \right\} \approx \frac{1}{M} \sum_{w_i=w_1}^{w_M} \frac{1}{N} |F_{w_i}(\omega)|^2. \quad (5.2)$$

Získali jsme dvě výsledná frekvenční spektra, a to spektrum pro síňovou aktivitu a spektrum pro komorovou aktivitu.

Výkonová spektra nám slouží k analýze frekvenčního rozložení pro dané aktivity. Obě spektra pro síňovou a komorovou aktivitu v záznamech jsou vykreslena na Obr. 5-2 a Obr. 5-3. Z Obr. 5-2 je zřejmé, že energie síňové aktivity dosahuje maxima v rozmezí 50–70 Hz s vrcholem kolem frekvence 70 Hz. Energie komorové aktivity (Obr. 5-3) dosahuje maxima v rozmezí frekvencí 5–40 Hz s vrcholem kolem 20 Hz, je však ve svém maximu zhruba o 1 řád nižší než maximální energie síňové aktivity. Výkonové spektrum komorové aktivity dále obsahuje významnou energetickou složku v oblasti 60–70 Hz, tato oblast se však již frekvenčně překrývá se síňovou aktivitou. Z frekvenční analýzy vyplývá, že komorovou složku bude možné alespoň částečně potlačit pomocí lineárního filtru typu horní propust s mezní frekvencí v oblasti kolem 50 Hz. Návrhem vhodného filtru se zabývá podkapitola 5.2.



Obr. 5-2: Frekvencní spektrum síňové aktivity.



Obr. 5-3: Frekvencní spektrum komorové aktivity.

5.2 Lineární filtrace

Lineární filtrace se často navrhuje formou pásmové propusti. Získáme tak potřebnou spektrální složku, kterou můžeme dále zpracovávat. [12] Pásmová propust je navržena tak, aby propouštěla oblast zájmu. Nehledáme periodicitu síňové aktivity mimo dané pásmo. [7] Na základě analýzy frekvenčního spektra na Obr. 5-2 a Obr. 5-3 zvolíme lineární filtr horní propusti, který bude pro následnou analýzu vhodnější. Vyhnete se tak určování druhé mezní frekvence propustného pásma, která by mohla zavádět zkreslení. Spektrum komorové aktivity nabývá přibližně mezi frekvencemi 250–1000 Hz nulových hodnot, tedy nepotřebujeme v těchto frekvencích potlačovat komorovou aktivitu. Z toho důvodu není nutné navrhovat pásmovou propust a určovat druhou mezní frekvenci filtru. Dle analýzy spektra z podkapitoly 5.1 tak můžeme navrhnout filtr horní propusti s mezní frekvencí 50 Hz pro zvýraznění síňové aktivity a útlum komorové aktivity.

Lineární filtrace byla provedena pomocí Butterworthových filtrů. Metoda návrhu filtru probíhá na základě podobnosti s analogovými filtry. Jedná se o jednoduchý filtr s lineární frekvenční doménou, monotónně se měnící odezvu a maximálně plochou frekvenční odezvou v propustném pásmu a v nepropustném pásmu mířící k nule. [11] V prostředí MATLAB byl Butterworthův filtr navržen pomocí funkce *butter(N, Wn)*. Funkce na základě zadaných parametrů provede návrh Butterworthova filtru N -tého řádu. Do dvou proměnných $[A, B]$ vrátí koeficienty filtru o délce $N+1$, B je numerátor a A je denumerátor. Mezní frekvence Wn je z intervalu $(0, 1)$, kde 1 odpovídá polovině vzorkovací frekvence. Třetí vstupní parametr je potřeba nadefinovat jako *high* pro vytvoření horní propusti. K určení řádu filtru použijeme funkci *buttord*, vstupními parametry nastavujeme vlastnosti filtru. Výstupem této funkce je minimální řád filtrace n a W_n označovaná jako přirozená Butterworthova frekvence.

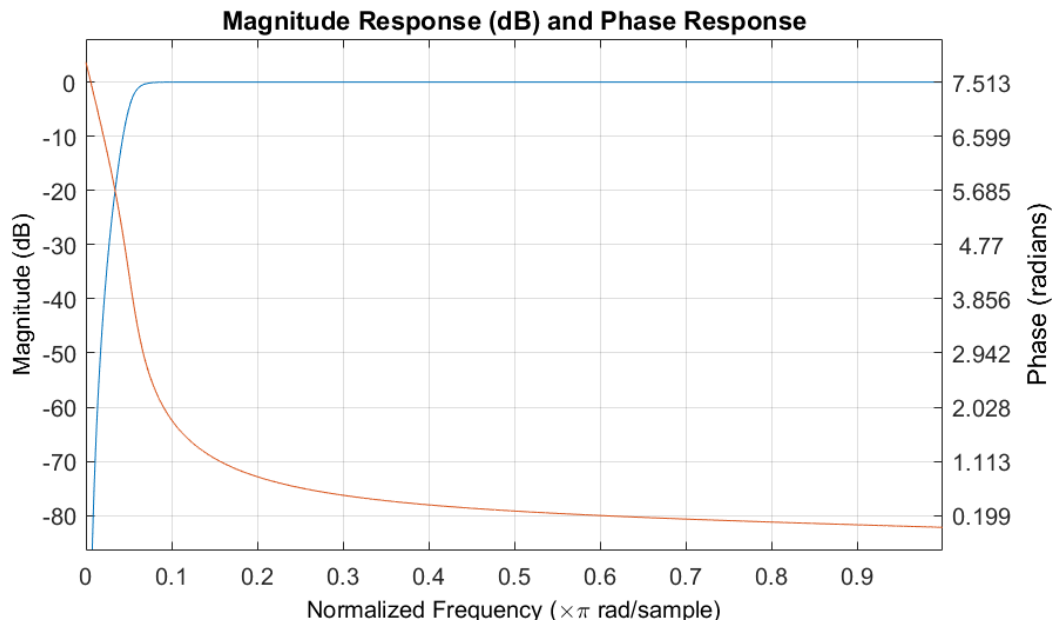
Tab. 5-1: Parametry pro návrh filtru.

	Symbol	Frekvence (Hz)	Normalizovaná frekvence (-)
Hraniční frekvence propustného pásma	W_p	55	0,0550
Hraniční frekvence koncového pásma	W_s	50	0,0500

Určenými parametry vždy volíme mezi strmostí mezi přechodným a nepřechodným pásmem a velikostí útlumu v nepropustném pásmu. Na Obr. 5-4 vidíme návrh Butterworthova filtru, kdy k největšímu útlumu dochází při 0,01 až 0,04 normalizované frekvence (10–40 Hz). V tomto frekvenčním pásmu se nachází i nejvyšší aktivita komor, kterou potřebujeme nejvíce utlumit. Nastavené parametry pro návrh filtru jsou uvedené v Tab. 5-1 a Tab. 5-2.

Tab. 5-2: Parametry pro návrh filtru.

	Symbol	Zvlnění (dB)
Zvlnění propustného pásma	R_p	3
Zvlnění nepropustného pásma	R_s	5

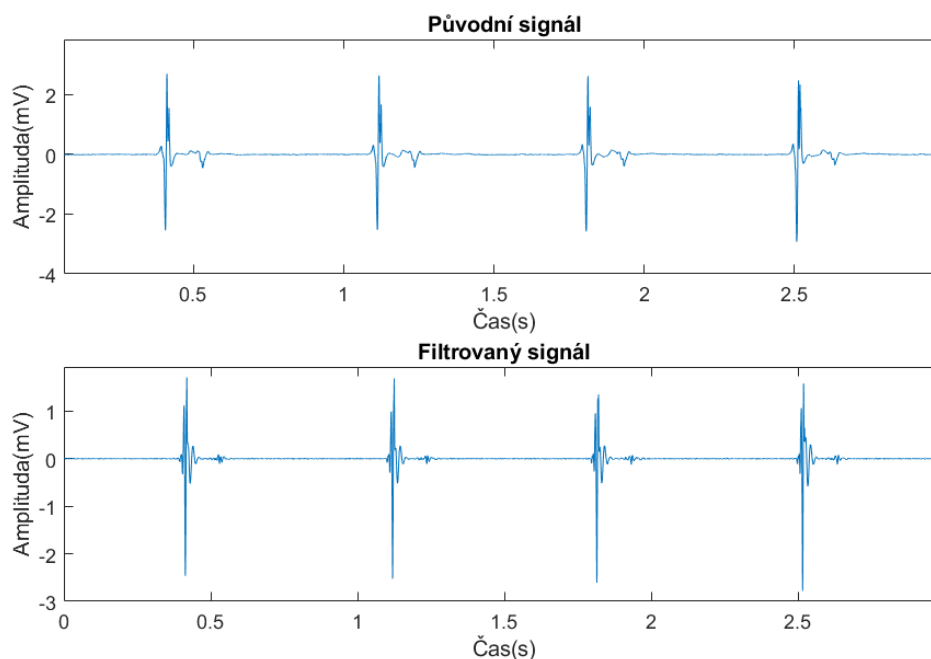


Obr. 5-4: Útlum filtru ve frekvenčním pásmu (modře) v dB.

Pomocí funkce *filter* vyfiltrujeme daný signál. Řád filtrace je n a mezní frekvencí je W_n . Parametry navrhnutého filtru jsou uvedené v Tab. 5-3. Na Obr. 5-5 můžeme vidět značný pokles píků komorové aktivity na filtrovaném signálu oproti původnímu signálu. Z Obr. 5-5 je také vidět, že aktivita síní na filtrovaném signálu je dostatečně zvýrazněna v poměru s komorovou aktivitou.

Tab. 5-3: Parametry navrhnutého filtru.

	Symbol	Hodnota
Minimální řád filtru	n	5
Mezní frekvence	W_n	0,0540 Hz



Obr. 5-5: Ukázka filtrace Butterworthovým filtrem signálu 00003B.json.

5.3 Nelineární filtrace

Nelineární filtrace provádíme pro získání jednoho pozitivního píku pro každou vlnu, kterou chceme detekovat. Jednoduchý způsob je využití druhé mocniny původního signálu. Vytvořenou obálku můžeme vidět na Obr. 5-6. Doporučuje se umocněný signál $y^2(n)$ poté vyhladit filtrem typu dolní propusti s impulzní charakteristikou $h_s(k)$ o délce L : [12]

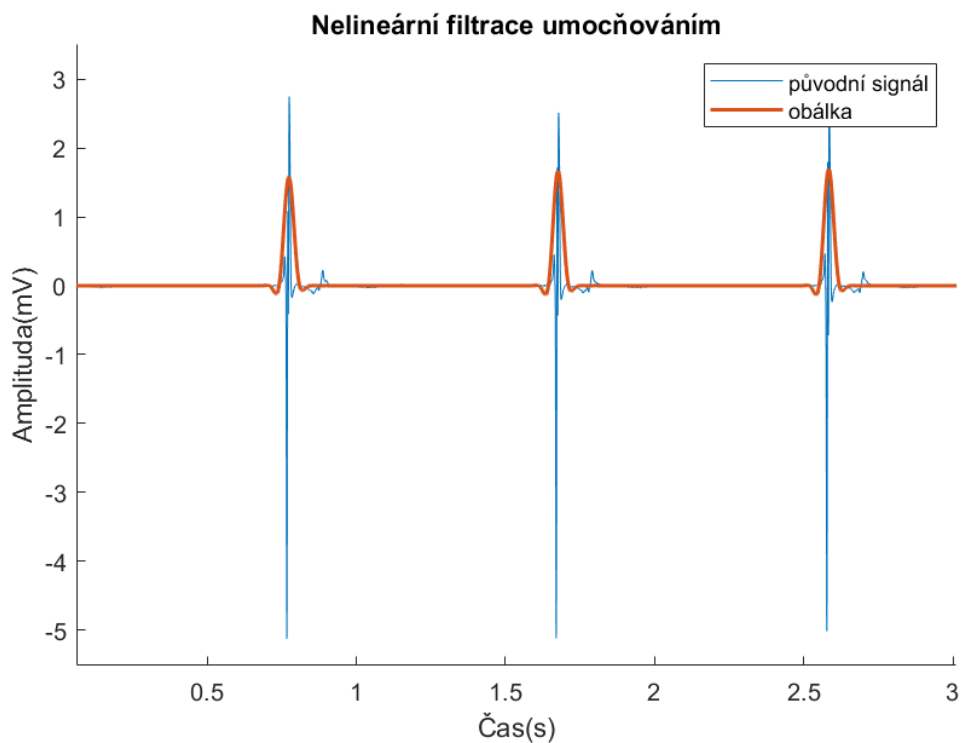
$$z(n) = \sum_{k=n-L-1}^n y^2(k)h_s(n-k). \quad (5.3)$$

Dalším způsobem nelineární filtrace je využití Hilbertovy transformace. Bere v potaz hledanou vlnu jako model kladného nízkofrekvenčního signálu modulovaného kosinovou funkcí se vzorkovací frekvencí ω_m a fázový úhlem φ : [5]

$$s[n] = e[n] \times \cos(\omega_m n + \varphi). \quad (5.4)$$


$H(e^{j\omega})$ je lineární časově nezávislý filtr, jehož transformační funkce je: [12]

$$H(e^{j\omega}) = \begin{cases} -j, & 0 \leq \omega < \pi \\ j, & -\pi \leq \omega < 0 \end{cases} \quad (5.5)$$



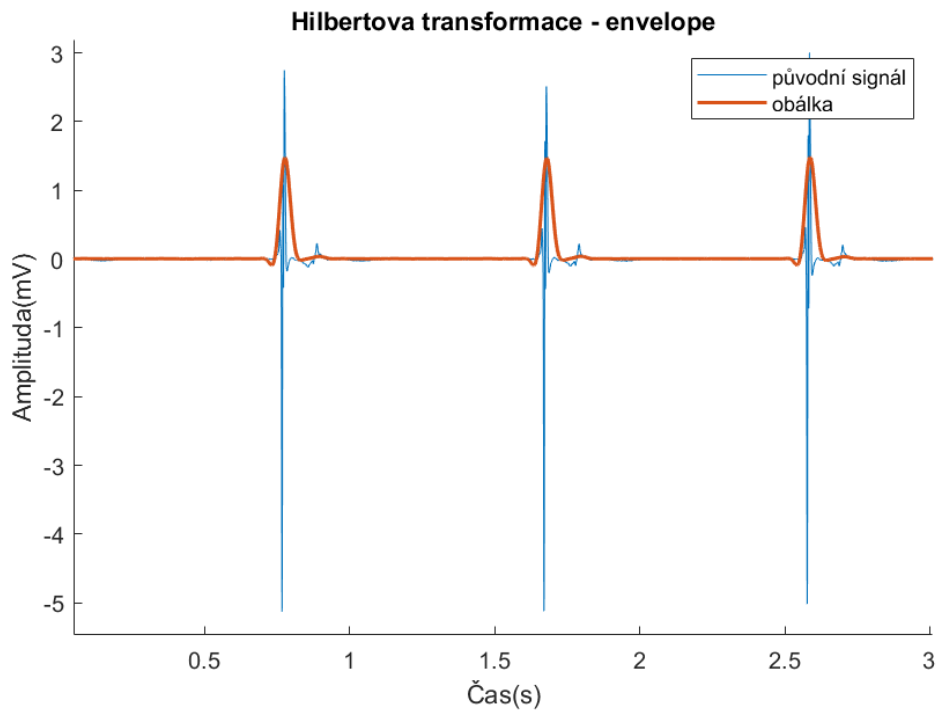
Obr. 5-6: Obálka vytvořená umocňováním původního signálu 00005E.json svodu CS1.

V prostředí MATLAB lze Hilbertova transformace provést pomocí funkce *envelope*. Do funkce vstupují dva parametry, signál a vzorkovací frekvence. Na výstupu funkce jsou dva parametry. První parametr udává horní obálku signálu, druhý udává spodní obálku signálu. Využijeme pouze horní obálku signálu, kterou můžeme zvýraznit následným umocněním. Odstranění šumu z obálky probíhá filtrem FIR dolní propusti s obdélníkovým oknem o šířce 50 ms. Výsledná obálka signálu je ukázána na Obr. 5-9. Blokové schéma nelineární filtrace je uvedené na Obr. 5-7.




Obr. 5-7: Blokové schéma tvorby obálky signálu.

Je-li vstupní signál zašuměn, patří metoda vytvoření obálky pomocí Hilbertovy transformace mezi přesnější oproti metodě tvorby obálky umocněním. Takovým šumem může být nedokonale vyfiltrovaná komorová aktivita. Z daného důvodu byla metoda tvorby obálky pomocí Hilbertovy transformace zvolena.



Obr. 5-8: Obálka vytvořená Hilbertovou transformací signálu 00005E.json svodu CS1 bez zvýraznění umocněním.



Obr. 5-9: Obálka vytvořená Hilbertovou transformací signálu 00005E.json svodu CS1 se zvýrazněním umocněním.

Na Obr. 5-8 a Obr. 5-9 jsou zobrazeny obálky vytvořené Hilbertovou transformací. Na Obr. 5-9 je obálka navíc zvýrazněna druhou mocninou. Mezi Obr. 5-8 a Obr. 5-9 vidíme značný rozdíl mezi obálkou, která vznikla pomocí Hilbertovy transformace bez zvýraznění umocněním, a obálkou, která vznikla pomocí Hilbertovy transformace se zvýrazněním umocněním. Pro následnou analýzu je použita obálka vytvořená pomocí Hilbertovy transformace, která je ještě zvýrazněna umocněním. Taková obálka vykazuje výraznější píky síňové aktivity. Malá komorová vlna, která je vidět na obálce vytvořené pomocí Hilbertovy transformace bez zvýraznění umocněním na Obr. 5-8 (překrývání frekvenčního spektra síňové a komorové aktivity), byla také zvýrazněním více potlačena.

5.4 Výběr příznaků pro extrakci

Pro výpočetní efektivitu a další zvýraznění užitečných složek signálu provedeme výběr příznaků. Pro následnou detekci tak budeme používat vybraný příznak (resp. příznaky), který získáme vhodnou metodou z původních signálů z pěti svodů CS5, CS4, CS3, CS2 a CS1.

První a nejjednodušší možností je průměrování svodů. Výsledný příznak získáme tak, že provedeme aritmetický průměr vzorků obálek přes všechny svody n :

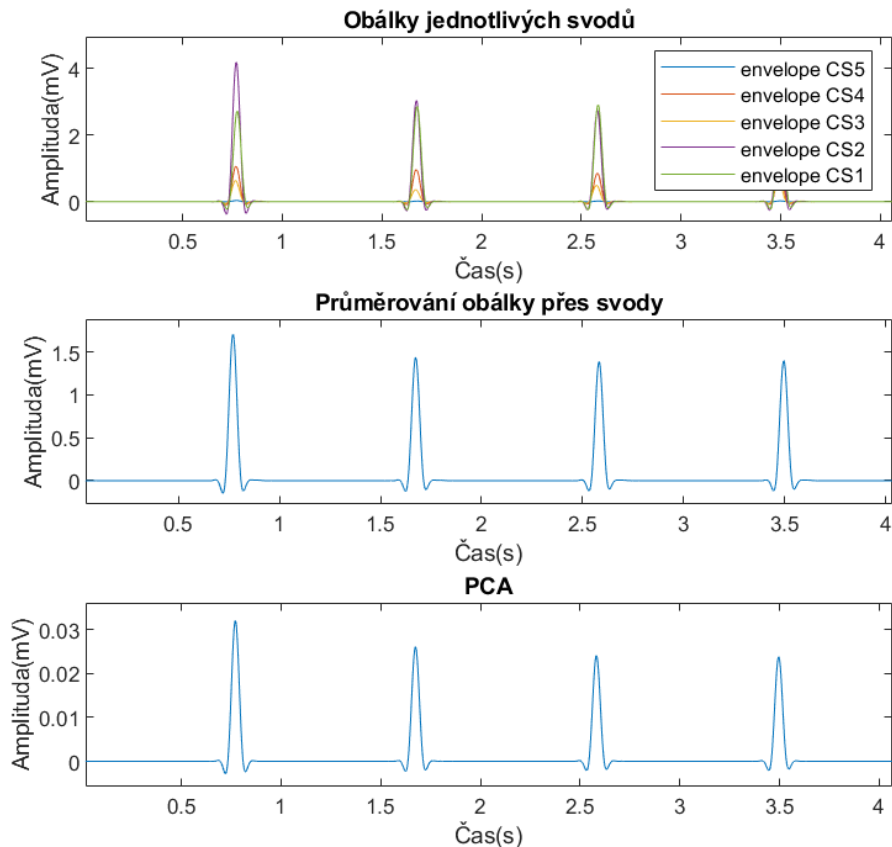
$$\overline{x(l)} = \frac{1}{n} \sum_{i=1}^n x_i(l), \quad (5.6)$$

kde x_i je hodnota amplitudy pro pozici l v daném svodu i .

Další metodou je metoda analýzy hlavních komponent (PCA). Metoda analýzy hlavních komponent redukuje data tím, že je geometricky promítá do nižších dimenzí nazývaných hlavní komponenty (PC) s cílem najít nejlepší souhrn dat pomocí omezeného počtu PC. První hlavní komponenta je volena tak, aby minimalizovala celkovou vzdálenost mezi daty a zobrazí projekci dat na hlavní komponentě. Minimalizací této vzdálenosti také maximalizujeme rozptyl promítaných bodů. Následující hlavní komponenty jsou vybrány stejným způsobem, tak aby nebyly ve vzájemném vztahu s předchozími hlavními komponentami. Hlavní komponenty jsou definovány jako lineární kombinace původních proměnných dat. [16] Metoda PCA, pak může být zapsána pomocí centrované matice X se vstupními n -rozměrnými daty v m řádcích a matice vlastních vektorů matice V o velikosti $n \times n$. Pak výstupní matice hlavních komponent Y odpovídá:

$$Y = XV. \quad (5.7)$$

Funkce *pca* provede analýzu hlavních komponent v prostředí MATLAB. Vstupním parametrem je datová matice, ve které řádky odpovídají pozorováním a sloupce jednotlivým proměnným. Její první výstupní parametr vrací matici koeficientů. Každý sloupec této matice obsahuje koeficienty pro jednu hlavní komponentu a sloupce jsou v sestupném pořadí podle rozptylu. Pátým výstupním parametrem je odhadovaný průměr každé proměnné.



Obr. 5-10: Průměrování jednotlivých svodů a metoda PCA pro získání jednodimenzionálního signálu z více svodů.

Metoda PCA se snaží redukovat počet proměnných nalezením nových latentních proměnných. Nové proměnné vysvětlují co nejvíce variability původních proměnných. PCA se tak jeví jako lepší možnost pro analýzu oproti průměrování. Při výběru metody PCA je nutné zvolit optimální počet hlavních komponent. V Tab. 5-4 je uvedena míra zastoupení variability první a druhé hlavní komponenty ve vybraných souborech. Míra zastoupení dalších hlavních komponent je násobně menší oproti uvedeným mírám. Z hodnot v Tab. 5-4 je patrné výrazné zastoupení variability v první hlavní komponentě u většiny souborů. Pro další analýzu je tedy volena metoda PCA a pouze první hlavní komponenta.

Tab. 5-4: Míra zastoupení variability v první hlavní komponentě a v druhé hlavní komponentě.

Soubor	Míra variability PC1	Míra variability PC2
00005B.json	70,9589	20,7987
00003F.json	81,9340	15,8700
000063.json	44,6739	33,9890
000040.json	72,8229	24,1464
00000A.json	80,3458	14,2454
00005B.json	81,3823	16,9760
000012.json	63,0059	28,9213
000033.json	91,3340	8,2031

5.5 Detekce píků

Rozhodovací pravidlo je nutné aplikovat, abychom zjistili, zda se v daném místě nachází vrchol. Nejjednodušší rozhodovací pravidlo je pevná prahová hodnota μ , avšak amplituda signálů se může v rámci databáze i jednoho signálu drasticky měnit. Proto je vhodné aplikovat adaptivní prahovou hodnotu. Mezi jednoduché metody pro adaptivní filtraci závislé na amplitudě patří určování prahové hodnoty z mediánu nebo modusu amplitud signálu nebo již detekovaných prvků. [12]

Další adaptivní metodou je metoda závislá na intervalech. Prahová hodnota θ_i je pro každou novou detekci aktualizovaná a je platná pro daný subinterval, dokud není detekován další pík. Mezi tyto metody patří metoda založená na exponenciálním průměrování. Prahová hodnota $\eta_U(n)$ se vypočítá za pomoci exponenciálního průměru předešlých detekovaných píků: [12]

$$\eta_U(n) = \mu \tilde{z}_{e,i}, \quad n = \theta_i, \theta_{i+1}, \dots, \quad (5.8)$$

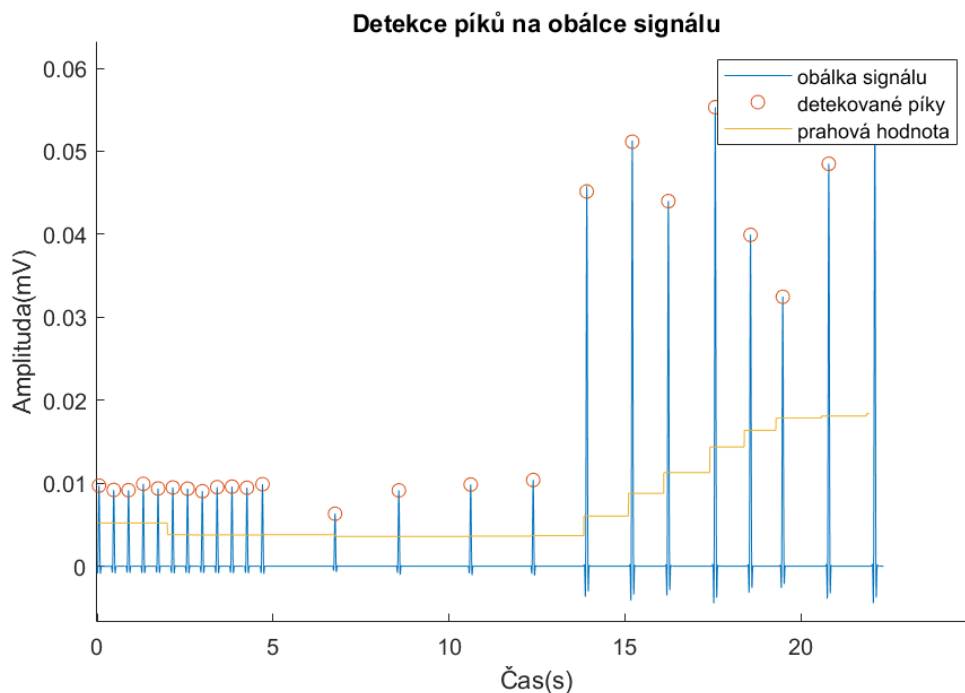
kde $\tilde{z}_{e,i}$ je exponenciální průměr z amplitud detekovaných píků z předpracovaného signálu a parametr μ určuje dělení amplitudy $\tilde{z}_{e,i}$ pro určení výpočtu prahové hodnoty. Parametr μ je volen z intervalu (0,5; 0,7).

Pro zjištění počáteční prahové hodnoty využijeme funkci *findpeaks*. Náš předpoklad je, aby do funkce vstupovala část signálu alespoň s jedním píkem. Proto bude dostačující využít pouze první 2 sekundy ze signálu obálky. Pomocí poloviny maximální hodnoty signálu (největšího píku) získáme vstupní parametr *MinPeakHeight*, který určuje hledání lokálních maxim nad touto hodnotou. Pokud tyto lokální maxima nejsou nalezena, v signálu se nachází drastický rozdíl mezi píky na začátku obálky a v jiném místě obálky.

V daném případě je hodnota *MinPeakHeight* určena pouze z „učící fáze“. Výstupem funkce jsou hodnoty amplitudy a indexy lokálních maxim v dané části obálky.

Provedeme exponenciální průměr přes detekované píky pomocí funkce *movmean*. Exponenciální průměr je dle vzorce (5.8) vynásoben parametrem 0,55 určeným z intervalu (0,5; 0,7) pro získání prahové hodnoty.

Při procházení obálky jsou hodnoty porovnávány s prahovou hodnotou. Pokud je nalezena hodnota nad prahovou hodnotou, okno o délce odpovídající 50 vzorků je položeno od dané hodnoty. V okně je nalezeno maximum, které označíme jako amplitudu píku na dané pozici. Okno o délce 50 vzorků je dostačující, aby po nalezení nadprahové hodnoty překrývalo vzestupnou i sestupnou část vrcholu píku. Po nalezení píku je vždy vypočtena nová prahová hodnota odpovídající exponenciálnímu průměru přes detekované píky vynásobeným parametrem 0,55. Signál procházíme od místa, které časově odpovídá 2 sekundám záznamu (vzorek 4000). Detekce píků je ukončena, pokud by položené okno přesahovalo délku signálu. Po nalezení píku cyklus nepokračuje o krok 1, ale pokračuje o krok dán indexem píku s přičtenou hodnotou odpovídající 150 ms (300 vzorků). Tato doba odpovídá refrakterní fázi buněk myokardu, kdy ani nadprahový podnět nevyvolá akční potenciál.



Obr. 5-11: Průběh prahové hodnoty signálu 000013.json.


Na Obr. 5-11 je zaznačen průběh prahové hodnoty žlutou barvou v průběhu detekce vrcholů v jednom vybraném signálu. V první polovině signálu dosahují vrcholy menších hodnot amplitudy oproti vrcholům v druhé polovině signálu. Po průběhu detekce píků v počáteční fázi je vypočítán z detekovaných vrcholů exponenciální průměr, který značí prahovou hodnotu. Při přibližně nízké amplitudě signálu se prahová hodnota příliš nemění. Při zvýšení amplitudy vrcholů dochází i k postupnému zvýšení prahové hodnoty.

5.6 Vymezení síňové aktivity

Pro dosaženými časových bodů je potřebné vymezit hranice každé vlny. Klasickou definicí vymezení vln je časový bod, kdy vlna překročí prahovou hodnotu. Další metody využívají změnu sklonu, ke které dochází na hranici mezi vlnami nebo mezi vlnou a izolinií, aby se zabránilo problémům v důsledku nízkofrekvenčního šumu. Pracují tak s první derivací signálu s ohledem na nulové přechody a extrémní hodnoty. Tato metoda počítá, že se byla detekovaná každá vlna. Proto je nejprve potřeba analyzovat píky a zjistit tak přítomnost daných vln, což bylo provedeno v podkapitole 5.5.

Pomocí dvou oken o délce 100 vzorků, které jsou položeny napravo i nalevo od klasifikovaného vrcholu píku, vybereme celý pík.

Následně je vypočítána hodnota AUC (*Area under the Curve*), neboli obsah plochy pod křivkou. K numerické integraci AUC byla vyžita lichoběžníková metoda. Tato metoda aproximuje integraci v určitém intervalu rozdělením oblasti na pravoúhlé lichoběžníky se snadněji vypočitatelnými obsahy. Celková plocha pod křivkou je pak dána součtem obsahů ploch daným počtem lichoběžníků. Body pro proložení trapezoidní metodou odpovídají jednotlivým vzorkům daného úseku. Následně je potřeba plochu normalizovat, tak aby celková plocha pod vybraným vrcholem odpovídala hodnotě 1.



Obr. 5-12: Ukázka výběru plochy pod křivkou pomocí prahové hodnoty.

Každý bod vybraného úseku podělíme celkovou plochou vypočítanou pomocí funkce *trapz*. Do funkce vstupuje signál v absolutní hodnotě, neboť funkce plochu pod křivkou označuje zápornou hodnotu.

Postupně vypočítáváme hodnoty AUC, tak že s každým krokem přidáváme jeden vzorek od píku na začátek a na konec vybrané sekce. Plochu pod křivkou vybrané sekce porovnááme s prahovou hodnotou. Prahová hodnota odpovídá hodnotě 0,95, tedy 95 % celkové plochy pod křivkou. Prahovou hodnotu není vhodné volit 1, protože signál je vždy zkreslen určitým šumem, který nebyl dokonale vyfiltrován. Po překročení prahové hodnoty je zaznamenán první index a poslední index, které ohraničují nalezený úsek.

Na Obr. 5-12 vidíme jeden vybraný pík. Jeho celková plocha pod křivkou odpovídá součtu ploch modrých a červených. Červená plocha vyznačuje výběr 95 % z celkové plochy. Začátek síňové aktivity pro daný úsek se tak nachází v prvním vzorku červené plochy. Za index značící konec síňové aktivity můžeme označit stejným způsobem poslední vzorek červené plochy. Výstupem celé funkce je binární vektor o souhlasné délce s délkou signálu, kde hodnoty 1 značí výskyt síňové aktivity a hodnoty 0 naopak.

5.7 Metrika hodnocení

Podobnost mezi automatickými a manuálními výsledky extrakce lze posoudit pomocí zhodnocení průniku finálních binárních vektorů mezi těmito výsledky. Použitá metoda se nazývá Diceův koeficient podobnosti (*Dice Similarity Coefficient, DSC*). Diceův koeficient podobnosti je definován jako: [17]

$$DSC(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (5.9)$$

kde A a B představují porovnávané oblasti, přičemž v binární klasifikaci tyto značky nabývají pouze hodnot $[0, 1]$. Konkrétněji A značí množinu výsledků pro automaticky zaznačenou aktivitu a B značí množinu výsledků pro manuálně zaznačenou (referenční) aktivitu. Průnik množin $A \cap B$ obsahuje hodnoty, které v množině A i množině B nabývají hodnoty 1.

Tento průnik tedy odpovídá množině pravdivě pozitivních výsledků (*True positive, TP*). Můžeme tedy zapsat:

$$TP = |A \cap B|. \quad (5.10)$$

Množina A poté odpovídá součtu pravdivě pozitivních hodnot a falešně negativních hodnot (*False negative, FN*)

$$|A| = TP + FN \quad (5.11)$$

Množina B nabývá součtu pravdivě pozitivních hodnot a falešně pozitivních hodnot (*False positive, FP*)

$$|B| = TP + FP. \quad (5.12)$$

Celá rovnice lze tedy přepsat jako:

$$DSC = \frac{2TP}{2TP + FN + FP}. \quad (5.13)$$

5.8 Zhodnocení dosažených výsledků

Algoritmus byl testován na 100 záznamech, popis těchto záznamů byl již uveden v kapitole 4.

Diceův koeficient podobnosti je v MATLAB vypočítán pomocí naimplementované funkce *GetScore*. Při vstupu dvou binárních vektorů do funkce určuje podobnost těchto dvou vektorů na základě uvedených vztahů v podkapitole 5.3. Výstupem funkce jsou hodnoty TP, TN, FP, FN a vypočítané Dice skóre pro jeden objekt.

Tab. 5-5: Výsledné hodnocení.

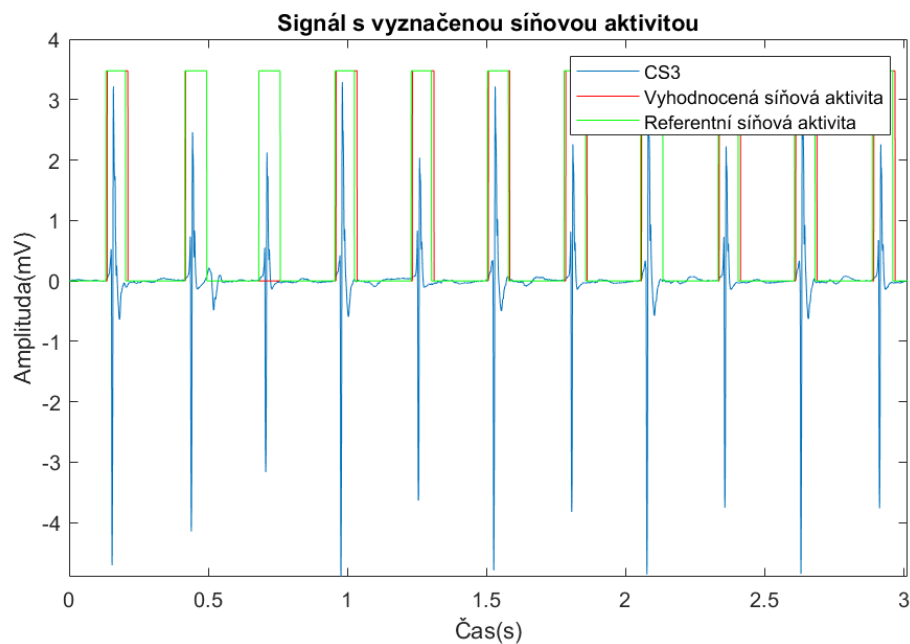
Celkové Dice skóre	76,34 %.
--------------------	-----------------

Výsledky Dice skóre jsou uvedeny v Tab. 7-1 v Příloze 1. Výsledná získaná úspěšnost extrakce je 76,34 %. V Tab. 5-6 jsou uložena hodnocení vybraných signálů. Tyto signály jsou dále v této podkapitole zobrazeny a je zde popsáno jejich hodnocení. Vybraná podmnožina signálů dobře reprezentuje, v jakých signálech naimplementovaný algoritmus selhal a kde naopak uspěl.


Tab. 5-6: Výsledné hodnocení vybraných souborů.

Název souboru	Dice skóre
00000D.json	0,9139
00004F.json	0,7291
000043.json	0,0000
000063.json	0,2007

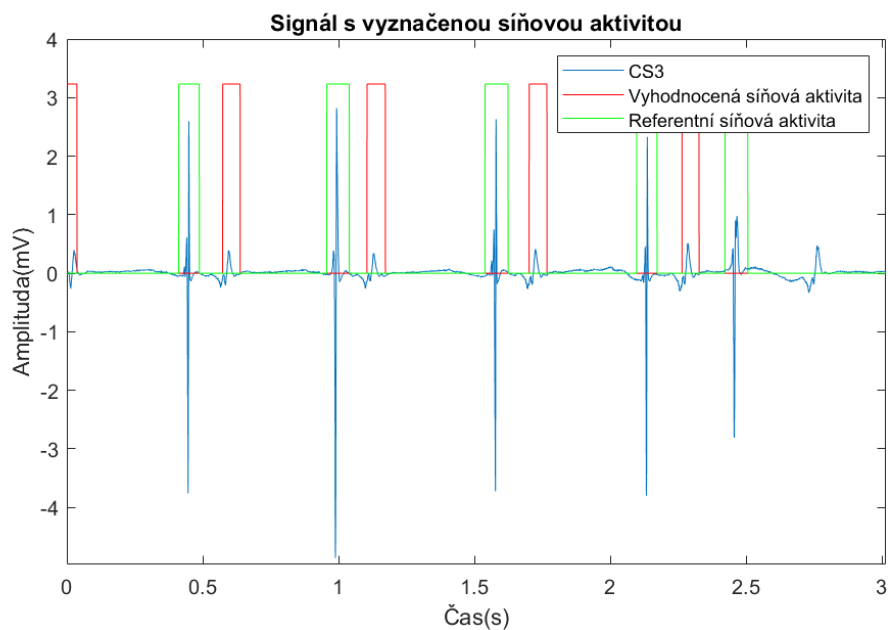
Na Obr. 5-13 a Obr. 5-14 vidíme úspěšnou extrakci síňové aktivity s uvedeným výsledným hodnocením 91,39 % a 72,91 %. Referenční a automaticky detekované úseky se síňovou aktivitou na Obr. 5-13 jsou téměř totožné. Na Obr. 5-14 odpovídají místa a středy extrakce, avšak automaticky extrahovaná aktivita má delší trvání oproti referenční.



Obr. 5-13: Výsledné hodnocení signálu 00000D.json s Dice skóre 0,9139.

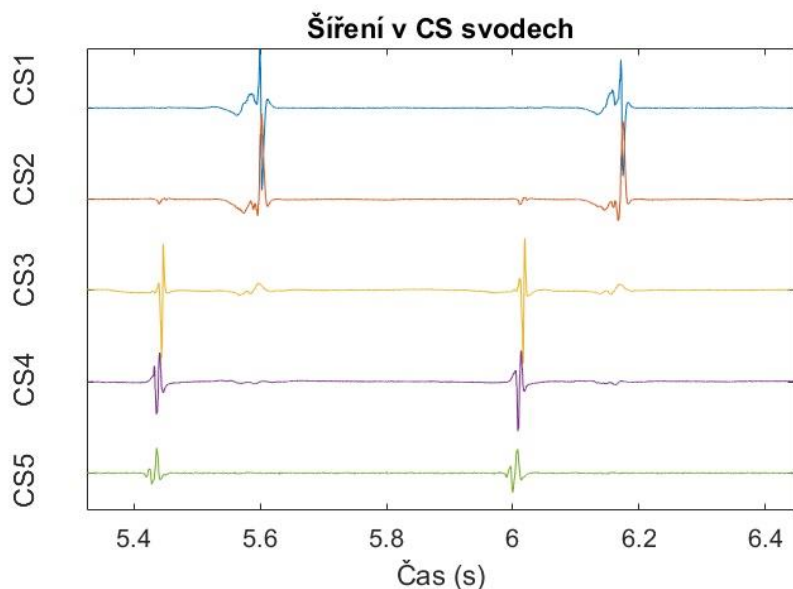


Obr. 5-14: Výsledné hodnocení signálu 00004F.json s Dice skóre 0,7291.



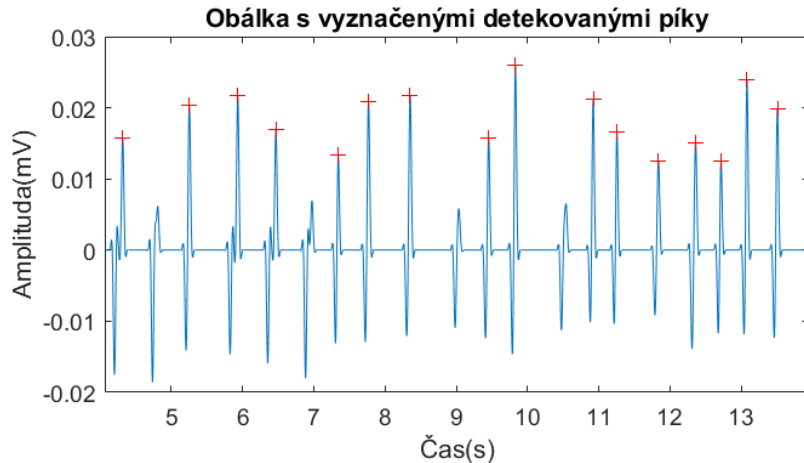
Obr. 5-15: Výsledné hodnocení signálu 000043.json s Dice skóre 0.

Extrahovaná aktivita v signálu na Obr. 5-15 proběhla s nulovou úspěšností. Přesto, že se jedná o sinusový rytmus a signál se šíří správně od svodu CS5 ke svodu CS1, vyskytlo se zde velké časové zpoždění svodu CS2 a CS1. Toto zpoždění zapříčiní posunutí kladných vrcholů výsledné obálky vzniklé pomocí metody PCA směrem zpoždění. Na Obr. 5-16 je vidět výrazné zpoždění impulzu ve svodech CS1 a CS2.




Obr. 5-16: Šíření impulzu sítěmi záznamu 000043.json.

Podobný problém se vyskytl u detekce píků, kdy díky vyššímu zpoždění obálek jednotlivých svodů došlo ke snížení amplitudy některých kladných vrcholů. Díky nízké amplitudě poté nebylo možné tyto píky detekovat. Taková neúspěšná detekce některých píků je zobrazena na Obr. 5-17. Daný záznam je sinusový záznam kombinovaný s junkčním rytmem. Pokud tyto vrcholy nebyly detekované, naimplementovaný algoritmus poté neuvažuje výskyt síňové aktivity v daných místech.



Obr. 5-17: Neúspěšná detekce píků obálky signálu 000028.json.

Některé záznamy, ve kterých se vyskytuje fibrilace síní nebo flutter síní, vykazují nízké hodnoty Dice skóre. Příklad záznamu s výskytem fibrilace síní je zde zobrazen na Obr. 5-18. Zobrazený záznam má vyhodnocení Dice skóre 20,07 %. Amplituda vrcholů je v těchto signálech proměnlivá. V záznamech se také vyskytuje chaotická aktivace impulsu ve svodech CS. Tyto faktory pak právě můžou vést k neúspěšné detekci píků na obálce signálu a zanášet tak chybu do extrakce síňové aktivity.



Obr. 5-18: Výsledné hodnocení signálu 000063.json s Dice skóre 0,2007.

5.9 Diskuse

Jedním z cílů dané práce je představit možnost automatické extrakce síňové aktivity z intrakardiálních elektrogramů v programovém prostředí MATLAB a pro danou databázi otestovat úspěšnost modelu. Jak již bylo zmíněno výše, navržený algoritmus pro extrakci síňové aktivity dosáhl výsledné hodnoty Dice skóre 76,55 %.

V naimplementovaném algoritmu docházelo k výběru příznaků pomocí metody PCA. Byla vybrána pouze první hlavní komponenta. Ve většině případu byla míra zastoupení variability v této komponentě dostatečná, v několika případech však není ideální pouze jedna volba. Z Tab. 5-4 vyplývá skutečnost, že např. u souboru 000063.json došlo také k výběru pouze první hlavní komponenty, přičemž druhá hlavní komponenta vykazuje pouze o něco menší míru zastoupení variability. Ztráta míry variability poté mohlo vést k neúspěšné detekci píků, což je zobrazeno na Obr. 5-18. Výsledné Dice skóre pro daný soubor je poté nízké. Dosahuje hodnoty pouze 20,07 %.

Výsledná úspěšnost algoritmu je značně ovlivněna úspěšností detekce píků. Při nedetekovaném vrcholu obálky signálu nedochází v daném místě k vymezení vlny síňové aktivity. Vysoké falešně negativní hodnoty mohou z části vykazovat o neúspěšné detekci píků. Z Tab. 7-1 v Příloze 1 můžeme uvést jako příklad méně úspěšné detekce soubor 000012.json, kdy bylo správně pozitivních pozic detekováno 683 a falešně negativních 6528 pozic. Dalším takovým příkladem je již zmiňovaná soubor 000063.json nebo 000053.json. Pro tyto signály vykazuje naimplementovaný signál velmi nízkou senzitivitu.

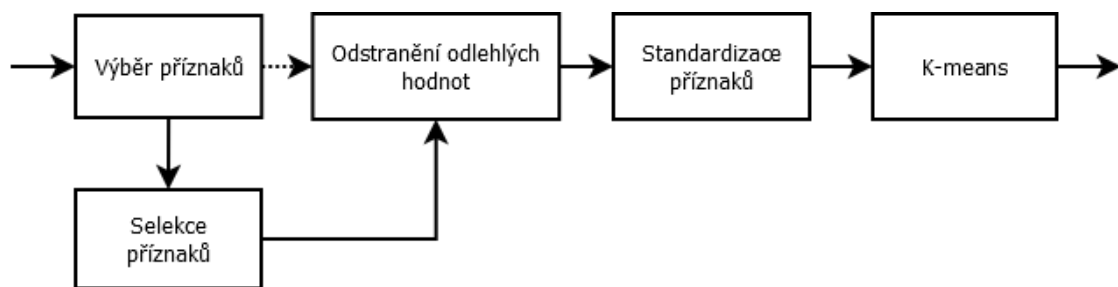
Vylepšení výsledků by mohlo spočívat v propracovanější filtraci experimentálních dat, která se snaží co nejvíce zvýraznit vlny síňové aktivity na úkor ostatních vln a artefaktů. Případně by mohla být provedena optimalizace algoritmů. Jak již bylo zmíněno, bylo by při analýze hlavních komponent vhodné brát v potaz míru zastoupení variability v hlavních komponentách a při nižším zastoupení variability využít více hlavních komponent. Podmínka by mohla být, že počet hlavních komponent je vybrán tak, aby celková míra zastoupení ve vybraných komponentách přesahovala míru zastoupení 70 % z celku.

6. Klasifikace síňového rytmu

Automatická klasifikace rytmu poskytuje objektivní a automatizovaný pohled na diagnózu pacienta. Může tak zvýšit efektivitu nemocničních center a zařízení z časového hlediska.

Data, která klasifikujeme, jsou označena diagnózou rytmu pro celé trvání naměřeného signálu. Mezi signály se vyskytuje značný zlomek dat, která jsou kombinací některého z typů arytmií a sinusového rytmu nebo kombinací více typů arytmií. Mezi diagnózou však není poskytnuto, v jaké části naměřeného signálu se vyskytuje konkrétní rytmus. Rozhodla jsem se však neklasifikovat celé signály jednou klasifikační třídou, ale označit každý cyklus typem rytmu. Každý cyklus z celého průběhu naměřených elektrogramů je klasifikován buď jako sinusový rytmus nebo jako nesinusový. Každý cyklus je tedy označen, zda je postižen některým z typů arytmií nebo ne.

Na základě této informace bude vhodné využití algoritmu strojového učení bez učitele, neboť by bylo obtížné poskytnout jednotlivým cyklům jako vstupním datům třídu pro klasifikaci. Jedná se o učení, kdy ke vstupním datům není poskytnut správný výstup. Algoritmus strojového učení bez učitele se tedy snaží rozpoznat složité procesy a vzorce bez toho, aby mu bylo poskytnuto bližší trvalé vedení.



Obr. 6-1: Blokové schéma postupu klasifikace rytmu.

Postup klasifikace rytmu, který je uveden v této kapitole je shrnut v blokovém schématu na Obr. 6-1. Pro vlastní klasifikaci je nejprve nutné vybrat množinu příznaku, která reprezentuje daná data. Následně pro tuto množinu je vhodné provést selekci příznaků pomocí korelační analýzy. Před vlastním použitím metody shlukování K-means je potřeba odstranit odlehlé hodnoty a vybranou podmnožinu (resp. množinu) příznaků standardizovat, neboť je metoda K-means citlivá na odlehlé hodnoty a rozdílné rozsahy vstupních dat.

Pro celý postup klasifikace je vytvořen skript s názvem *KmeansClustering.mat*. Posledním krokem v tomto skriptu je uložení souřadnic vytvořených centroidů shluků. Dle nejmenší vzdálenosti objektu od centroidu vytvořených shluků lze zobrazit pomocí funkce *FindMyCluster.mat* do jakého shluku byly cykly jednoho souboru přiřazeny.

6.1 Výběr příznaků pro klasifikaci

Před vlastní klasifikací je důležité vybrat vhodné příznaky a jejich vhodný počet pro dosažení co nejvyšší přesnosti klasifikace. Při dosažení dostatečného počtu příznaků pro klasifikaci také snižujeme časovou náročnost algoritmu. Vybrané příznaky pro klasifikaci rytmu by měli co nejlépe reprezentovat soubor s daty. V databázi se vyskytují soubory obsahující sinusové, nesinusové a kombinované rytmy. Nesinusové rytmy a kombinované rytmy jsou dané především arytmiemi AVNRT, AVRT, fibrilací síní, junkčním rytmem, síňovým flutter či síňovými nebo komorovými extrasystolami.

Každý detekovaný síňový stah je tak reprezentován globálními a lokálními příznaky. Globální příznaky jsou takové příznaky, které nereprezentují pouze jeden stah. Globální příznak reprezentuje všechny stahy z jednoho určitého záznamu. Lokální příznaky jsou specificky přiřazeny ke každému stahu. V rámci jednoho souboru jsou pro každý stah rozdílné.

6.1.1 Příznaky odvozené z převodu na komory

Pro příznaky odvozených z převodu na komory je nejprve nutné komorové vlny detekovat. Detekci vln komorové aktivity je nutno provést pro následný výběr příznaků odvozených z převodu na komory pro klasifikaci rytmu.

Detekce vln komorové aktivity probíhá velmi obdobně jako detekce vln síňové aktivity v podkapitolách 5.2 až 5.5. Detekce komorové aktivity se liší v krocích lineární filtrace a detekce píků. Detekce QRS komplexu probíhá ze svodu I z naměřených signálů z povrchového EKG.

Tab. 6-1: Parametry pro návrh filtru.


	Symbol	Frekvence (Hz)	Normalizovaná frekvence (-)
Hraniční frekvence propustného pásma	W_p	[11, 21]	[0,011; 0,021]
Hraniční frekvence koncového pásma	W_s	[10, 24]	[0,010; 0,024]

Tab. 6-2: Parametry pro návrh filtru.

	Symbol	Zvlnění (dB)
Zvlnění propustného pásma	R_p	5
Zvlnění nepropustného pásma	R_s	10

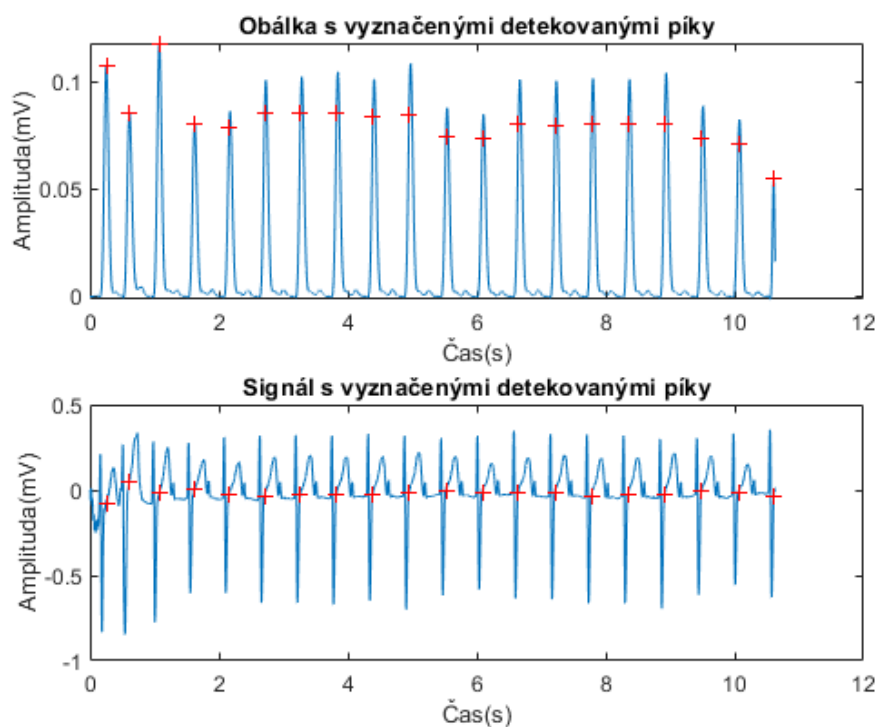
Pro lineární filtraci byl opět využit Butterworthův filtr stejně jako v podkapitole 5.2. Filtr je typu pásmové propusti. Propustné pásmo je určeno podle výkonového spektra pro komorovou aktivitu uvedeného na Obr. 5-3. Propustné pásmo má mezní frekvence 11–24 Hz. Pro dané pásmo frekvencí nabývá výkonové spektrum komorové aktivity nejvyšších hodnot. Nastavené parametry pro návrh filtru jsou uvedené v Tab. 6-1 a Tab. 6-2.

Na Obr. 6-2 vidíme návrh Butterwothova filtru, kdy jsou v propustném pásmu nejvíce propouštěny normalizované frekvence 0,09 až 0,25. Tyto normalizované frekvence odpovídají frekvencím 9–25 Hz. Rozsah frekvencí pásmové propusti téměř kopíruje určený frekvenční rozsah s nejvyšší komorovou aktivitu.



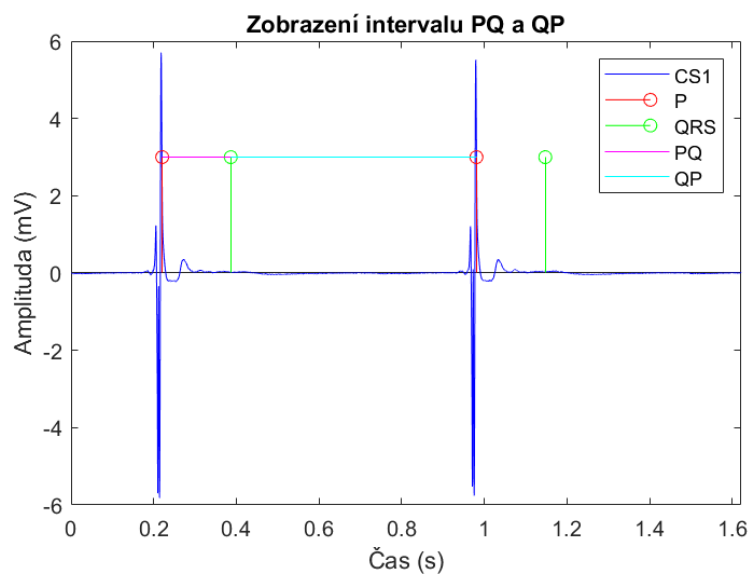
Obr. 6-2: Frekvenční charakteristika navrhnutého filtru pásmové propusti (modře) v dB.

Z vyfiltrovaného signálu je vytvořena obálka signálu pomocí Hilbertovy transformace. Postup této metody je již popsán v podkapitole 5.3. Detekce píků na obálce signálu se zvýrazněnými komorovými píky probíhá obdobným způsobem, jak je již popsáno v podkapitole 5.5. Tato detekce píků je však obohacena o jeden krok navíc při hledání lokálních maxim. Pokud je vzdálenost dvou píků po sobě jdoucích větší než 1,66-násobek předešlé vzdálenosti dvou píků, tak v daném subintervalu je hledán pík s prahovou hodnotou určenou proti směru vzniku obálky z detekovaných píků. Je to fyziologicky daná časová hodnota mezi sousedními intervaly. Srdeční rytmus není schopný rychlejší změny než právě 1,66-krát. [19] Na Obr. 6-3 jsou zaznačené úspěšně detekované píky na vytvořené obálce vybraného signálu a poté na vlastním záznamu z povrchového svodu I.



Obr. 6-3: Detekce píků komorové aktivity signálu 00000D.json.


Příznaky odvozené z převodu na komory jsou délky intervalů PQ a QP. K vypočítání délek intervalů byly využity detekované píky síňové aktivity z podkapitoly 5.5 a komorové aktivity. Intervaly PQ a QP mohou být zkráceny či naopak prodlouženy při výskytu supraventrikulární tachykardie.



Obr. 6-4: Velikost intervalů QP a PQ v signálu 000003.json.

Příkladem může být atypická AVNRT, kdy se síňové vlny vyskytují až v druhé polovině RR intervalů, jak již bylo uvedeno v podkapitole 2.2.4. Při fibrilaci síní tyto intervaly budou nepravidelné až chaotické. Pokud se komorová vlna nevyskytuje před nebo za síňovou vlnou, tedy vyskytuje se v pořadí další síňová vlna, interval QP nebo PQ je označen hodnotou 0. To má i vypovídající hodnotu o převodu na komory. Při výskytu nulové hodnoty je převod ze síní na komory nižší. To neodpovídá sinusovému rytmu, kdy je každá síňová vlna střídána komorovou. Na Obr. 6-4 je zobrazeno trvání intervalu PQ růžovou barvou a QP světle modrou barvou.

Dalším významným globálním příznakem odvozeným z převodu na komory je poměr převodu síňové aktivity na komorovou. Při normálním AV převodu se všechny vzruchy převedou na komory a frekvence komor (QRS komplexů) bude stejná jako frekvence síní (P vln). Normální AV převod v poměru 1:1 je typický pro sinusové rytmy. Supraventrikulární tachykardie mohou mít převod na komory nepravidelný či se poměr převodu síňové aktivity na komorovou může pohybovat v poměru 2:1, 3:1 či 4:1. Nepravidelný převod aktivity mezi síněmi a komorami je typický pro fibrilaci síní nebo zmíněné poměry pro flutter síní.



Obr. 6-5: Ukázka poměru převodu P:Q na signálu 000030.json .

Na Obr. 6-5 je uvedena ukázka poměru převodu pro signál klasifikovaný jako atriální flutter. Poměr převodu P:Q signál v uvedené části vykazuje 2:1. Čísla 1 a 2 na daném obrázku reprezentují dvě po sobě jdoucí vlny P nepřerušené QRS komplexem. V Tab. 6-3 jsou uvedené hodnoty poměrů převodů ze síní na komory pro vybrané signály. Signály diagnostikované jako fibrilace síní nebo atriální flutter nabývají vyšších hodnot poměru převodu než signály, kterým byl diagnostikován sinusový rytmus. Signály s diagnostikovaným sinusovým rytmem nabývají hodnot převodu přibližně rovné 1.

Tab. 6-3: Hodnoty poměrů síní a komor pro vybrané signály.


Soubor	Diagnóza	Rytmus síní / rytmus komor	Střední napěťová hodnota [mV]
000026.json	FiS	1,8810	0,0494
000054.json	Sinus Rhythm	0,9996	0,0077
00000A.json	Sinus Rhythm	0,9396	0,0103
000025.json	FiS	2,0234	0,0217
000041.json	Pace	0,9992	0,0197
000044.json	AVNRT	0,9992	0,0158
000030.json	Atrial Typical Flutter	1,1168	0,0161
000014.json	AVRT	1,0199	0,0150

6.1.2 Napěťové příznaky

Při fibrilaci síní jsou v elektrogramu přítomny fibrilační vlnky různé amplitudy. Během akutní fibrilace má většina fibrilačních potenciálů vysokou amplitudu. Předpokládáme, že rozdílná střední hodnota amplitudy signálu překračující napěťové kritérium sinusového signálu bude mít také vypovídající hodnotu o výskytu sinusového či nesinusového rytmu. Napěťová střední hodnota byla určena jako medián každé hodnoty napětí v absolutní hodnotě. Střední napěťové hodnoty jsou uvedené v Tab. 6-3 Pro sinusové rytmy se napěťová střední hodnota pohybuje kolem setiny mV a méně, zatímco pro fibrilace síní střední napěťové hodnoty nabývají vyšších hodnot. [20]


6.1.3 Příznaky odvozené z časové aktivace síní

Pět příznaků odvozených z časové aktivace síní uvádí informaci o šíření dané vlny síňové aktivity v CS svodech. Koronární sinus se nachází mezi levou síní a komorou a ústí do pravé síně. Normální sinusový rytmus se postupně šíří ze svodu CS5 až do svodu CS1. Ukázka takového šíření je na Obr. 6-6. Při výskytu supraventrikulárních tachykardií v signálu tomu nemusí tak být. Z podkapitoly 2.2 vyplývá, že při patofyziologii typického flutteru síní můžeme vidět změnu vedení v CS svodech způsobenou reentrantním okruhem. Také při fibrilaci síní je aktivace v CS svodech chaotická.



Obr. 6-6: Ukázka šíření vlny sinusového rytmu v CS svodech.

V případě AVNRT jsou síně i komory aktivovány v CS svodech současně. Ukázka šíření vlny s AVNRT v CS svodech je na Obr. 6-7. Informace o šíření je udávána jako zpoždění vůči prvnímu výskytu dané vlny v jakémkoliv svodu CS, např. pokud se je signál jako první zaznamenan v svodu CS5, tento příznak je označen hodnotou 0 a další příznaky jsou označeny jako zpoždění vůči této hodnotě.



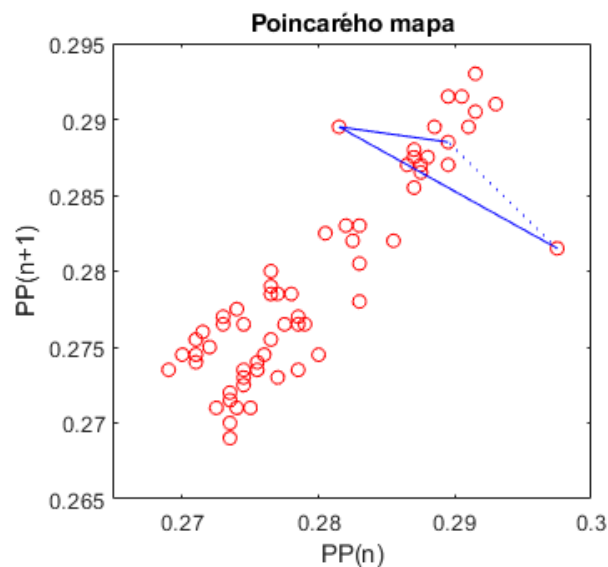
Obr. 6-7: Ukázka šíření vlny charakterizované jako AVNRT v CS svodech.

6.1.4 Complex Correlation Measure

Vybraný příznak vyplývá z CCM (*Complex Correlation Measure*). CCM se odvozuje z Poincarého mapy. Je cenný díky své schopnosti zobrazit nelineární aspekty datové sekvence a bere v potaz i časovou stránku Poincarého mapy. Posuzuje se pohyblivé okno tří po sobě jdoucích bodů z Poincarého grafu a vypočítá se plocha trojúhelníku tvořená těmito třemi body. Tuto plochu trojúhelníku nazvěme A . Plocha A tvoří další lokální parametr, který náleží třetímu intervalu z pokládaného okna. Plocha A pro i -té okno se vypočítá pomocí následujícího determinantu: [22]

$$A(i) = \frac{1}{2} \begin{vmatrix} x_1 & y_1 & 1 \\ x_2 & y_2 & 1 \\ x_3 & y_3 & 1 \end{vmatrix}, \quad (6.1)$$

Body a, b, c jsou tři po sobě jdoucí intervaly PP v i -tém okně a tyto body jsou definovány jako $a(x_1, y_1)$, $b(x_2, y_2)$ a $c(x_3, y_3)$. Na Obr. 6-8 je zobrazena Poincarého mapa pro signál klasifikovaný jako AVNRT. Modře jsou zde spojeny první tři body zobrazení tvořící trojúhelník, jehož plocha je A .



Obr. 6-8: Ukázka Poincarého mapy pro signál 000055.json.

6.1.5 Variabilita síňového rytmu

Příznakem reprezentující variabilitu PP intervalů je RMSSD neboli odmocnina průměru kvadrátů diferencí sousedních intervalů NN. RMSSD je významným indikátorem pro fibrilaci síní i jiných srdečních poruch. RMSSD se vypočítá jako: [21]

$$RMSSD = \sqrt{\frac{\sum_{i=1}^{L-1} (NN_i - NN_{i+1})^2}{L - 1}}, \quad (6.2)$$

kde NN_i je interval mezi sousedními N vlnami, NN_{i+1} je následující NN interval a L je celkový počet intervalů. RMSSD je počítáno v okně o velikosti tři, tedy pro každé tři po sobě následující intervaly vrcholů síňové aktivity. Vypočítaná RMSSD náleží třetímu intervalu v pořadí v daném okně.

6.2 Standardizace příznaků

Při aplikaci eukleidovské vzdálenosti jako metriky pro metodu K-means je nutné provést standardizaci dat. Pokud jsou aplikovány geometrické metriky, příznakům s velkými rozsahy budou přiřazeny vyšší váhy a budou více ovlivňovat výsledek oproti příznakům s nižšími rozsahy. Kromě toho musí být příznaky bezrozměrné, protože výběr jednotek měření může významně změnit výsledky shlukování. Data jsou převedena pomocí lineární transformace, tak aby měla určený rozsah. [23]

Před vlastní standardizací příznaků byly odstraněny odlehlé hodnoty. Hodnoty, které jsou menší než percentil 5, a hodnoty, které přesahují percentil 95, byly z dat odstraněny. Využití percentilů je vhodné pro data, která nemají normální rozložení. Tyto hodnoty se významně liší od ostatních a nereprezentují zajímavé vzory, které se v datech vyskytují. Metoda K-means, která je použita pro vlastní klasifikaci rytmu v podkapitole 6.4, je velmi citlivá na odlehlé hodnoty.


Pro normalizaci byla použita metoda Z-skóre. Příznaky x jsou tak standardizované pomocí střední hodnoty μ a rozptylu σ :

$$z = \frac{x - \mu}{\sigma}. \quad (6.3)$$

Využití Z-skóre je vhodné v případě, kdy skutečné minimum a maximum daných atributů nejsou známy. Metoda je tedy vhodná pro použití na vybraném setu příznaků. [23]

6.3 Selekcce příznaků

Selekcí příznaků redukuje počet charakteristických vlastností, zároveň se snažíme odstranit redundantní příznaky. Cílem selekcce příznaků je zvýšit přesnost a srozumitelnost výsledků. Při tomto kroku je vybrána podmnožina příznaků z původní množiny příznaků.



Obr. 6-9: Zobrazení Pearsonova korelačního koeficientu mezi jednotlivými příznaky.

Pearsonův korelační koeficient měří sílu vzdálenosti mezi dvěma veličinami. Nabývá hodnot z intervalu $\langle -1; 1 \rangle$. Jestliže jsou veličiny nezávislé, je korelace mezi nimi nulová. Maximální a minimální hodnoty nabývá v případě, že je mezi veličinami vztah přímé nebo nepřímé úměry. Pro n objektů předpokládáme vždy dvojice příznaků označené $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$, pak výpočet Pearsonova korelačního koeficientu r je zapsán: [24]

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X}_i)(Y_i - \bar{Y}_i)}{\sqrt{\sum_{i=1}^n (X_i - \bar{X}_i)^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2}}, \quad (6.4)$$

kde \bar{X} je aritmetický průměr prvního příznaku pro všechny objekty a \bar{Y} je aritmetický průměr druhého příznaku pro všechny objekty.

Z nízkých hodnot Pearsonova korelačního koeficientu a vizuální kontroly z Obr. 6-9 je patrné, že se v datech korelované příznaky nevyskytují, a tedy je možné využít celou množinu příznaků.

6.4 Metoda K-means

Metoda K-means patří k nehierarchickým tvrdým metodám shlukování do k shluků. V každém iteračním kroku jsou všechny objekty přiřazeny právě do jednoho z k shluků na základě jejich vlastností. Každý shluk je reprezentován adaptivně se měnícím centroidem, jejichž počet je znám předem. Iniciální souřadnice centroidů jsou voleny náhodně z prostoru či ze souřadnic souborů. V každém iteračním procesu jsou vypočteny vzdálenosti mezi každým objektem a každým shlukem. Každý objekt je přiřazen k nejbližšímu centroidu a následně jsou přepočteny souřadnice centroidů každého shluku jako průměru objektů přiřazeného do daného shluku: [25]

$$\bar{V}_k = \frac{1}{N_k} \sum_{\forall \bar{x}_n \in C_k} \bar{x}_n, \quad (6.5)$$

pro N_k objektů \bar{x}_n zařazených do shluku C_k .

Ke shlukování jednotlivých cyklů síňové aktivity byla využita právě metoda K-means. Shlukování pomocí metody K-means je vhodné pro využití na datech, které jsou reprezentovány vnitřní vlastní přirozenou strukturou. Jedná se o jednoduchý a výpočetně nenáročný algoritmus.

Je však potřeba rozhodnout, jaký počet shluků bude použit, aby bylo dosaženo co nejoptimálnějšího výsledku. Metoda K-means není reprodukovatelná. Výsledek shlukování také záleží na iniciálním umístění souřadnic centroidů. Metoda K-means je v prostředí MATLAB implementovaná pomocí funkce *kmeans* z toolboxu Deep Learning.

Jako vzdálenostní metrika je volen kvadrát eukleidovské vzdálenosti, který vyplývá ze vzorce eukleidovské vzdálenosti:

$$d^2(x_1, x_2) = \sum_{i=1}^n (x_{1i} - x_{2i})^2, \quad (6.6)$$

kde x_1 a x_2 jsou dva body o n -dimenzionálních souřadnicích. Pro porovnávání hodnot vzdáleností postačí kvadrát eukleidovské vzdálenosti, ponecháním kvadrátu však ušetříme výpočetní čas algoritmu. Výsledek shlukování vyjde totožný jako by vyšel při použití eukleidovské vzdálenosti.

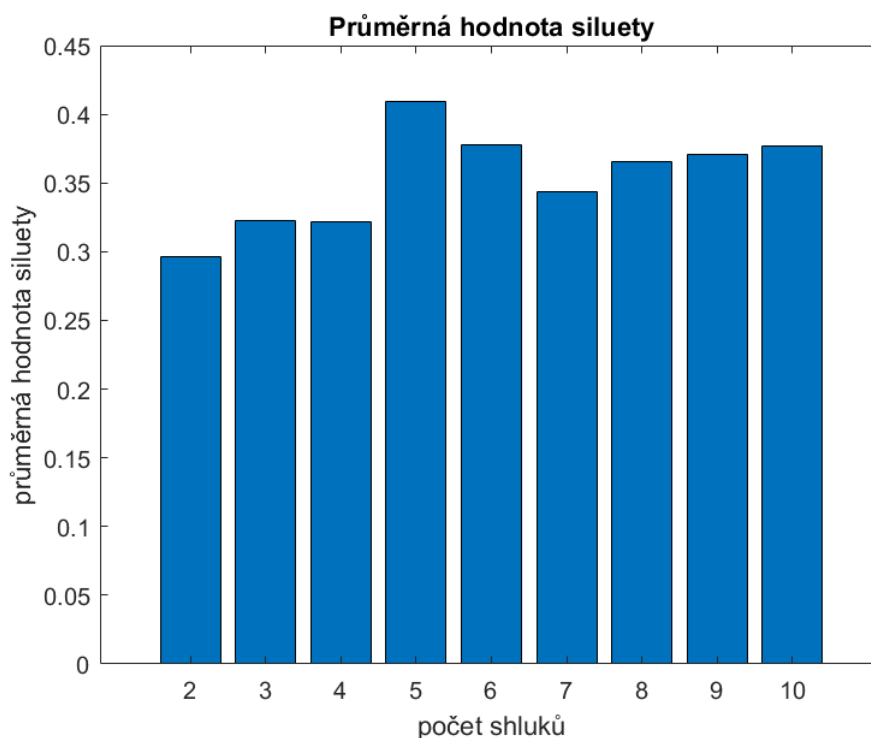
6.5 Metoda analýzy siluet shluků

Pro určení počtu shluků k byla použita metoda analýzy siluet shluků. Tato metoda porovnává vzdálenosti mezi objekty uvnitř shluku se vzdálenosti objektů mezi shluky pro každý objekt zvlášť. Silueta shluku s je kvantitativní míra úspěšného zařazení objektu do shluků a nabývá hodnot z intervalu $\langle -1; 1 \rangle$:

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}}, \quad (6.7)$$

kde $a(i)$ je průměrná vzdálenost i -tého atributu od všech ostatních atributů ve stejném shluku a $b(i)$ je minimum z průměrů vzdáleností i -tého objektu ke všem shlukům. Průměrná hodnota siluety slouží jako nástroj pro hodnocení kvality vytvořených shluků. Vyšší průměrnou hodnota siluety značí silnější a lepší výslednou strukturu shlukování. [26]

Metoda K-means byla replikovaná stokrát pro shlukování do dvou až deseti shluků. Ze sta replikací pro každé shlukování s k shluky byl vybrán výsledek dle nejnižší celkové sumy vzdálenosti každého objektu od přiřazeného centroidu. Pro každý vybraný nejúspěšnější výsledek byla určena průměrná hodnota siluety. Na Obr. 6-10 jsou zobrazeny průměrné hodnoty siluety pro výsledné shlukování do dvou až deseti shluků. Nejvyšší průměrné hodnoty siluety bylo dosaženo při shlukování do pěti shluků, a to hodnoty 0,4090.




Obr. 6-10: Výsledné průměrné hodnoty siluety shlukování do k shluků.

V Tab. 6-4 je uvedeno sedm náhodných replikací ze sta celkových replikací K-means shlukování do pěti shluků a jedna vybraná nejúspěšnější replikace. Nejúspěšnější replikace metody byla vybraná na základě nejmenší celkové sumy vzdáleností od všech objektů k jejich přiřazeným centroidům. Na Obr. 6-11 jsou poté zobrazeny jednotlivé hodnoty siluet objektů v daných pěti shlucích pro vybraný nejúspěšnější výsledek. Další analýzou vytvořených shluků se bude zabývat podkapitola 6.6.

Tab. 6-4: Výsledky shlukování do čtyř shluků.

Replikace	Počet iterací	Celková suma vzdáleností	Průměrná hodnota siluety
5	6	8873,83	0,3275
17	7	8929,90	0,3273
22	13	9100,74	0,3171
52	15	8799,03	0,3313
85	13	8588,05	0,3352
93	7	8305,35	0,4090
98	6	9060,72	0,2324
Nejlepší výsledek:		8305,35	0,4090




Obr. 6-11: Výsledné hodnoty siluety shlukování do čtyř shluků.

6.6 Analýza výsledných shluků

Výsledné shluky vytvořené pomocí metody K-means z podkapitoly 6.4 je následně nutné analyzovat. Je potřebné zjistit reprezentativní obsazení shluků a na základě toho určit jaká kategorie cyklů spadá do daného shluku. Prvním zobrazením je zobrazení každé dvojice příznaků ve 2D prostoru, některé zobrazení dvojic jsou vybrána a v této podkapitole popsána.


Dalším vizuálním zobrazením shluků v závislosti na vybraných příznacích je zobrazení pomocí výběru hlavních komponent za použití metody PCA, jejíž princip je popsán v podkapitole 5.4. Výsledný 2D obrázek je zobrazen na Obr. 6-12. Barvy na daném obrázku rozlišují shluky, zatímco znaky rozlišují anotaci záznamu, ze kterého stah pochází. Jak je napsáno i v legendě, např. černé kolečko značí stah ze záznamu anotovaného jako fibrilace síní, který byl zařazen do druhého shluku, nebo tmavě modrý diamant značí stah ze záznamu anotovaného jako kombinovaný rytmus skládající se ze sinusového rytmu a fibrilace síní, který byl zařazen do prvního shluku.



Obr. 6-12: Zobrazení shluků K-means pomocí hlavních komponent.


První shluk označený tmavě modrou barvou a druhý shluk označený červenou barvou obsahují především cykly z AVRT/AVNRT záznamů a z kombinovaných záznamů sinusového rytmu s AVRT/AVNRT.

Na Obr. 6-13 je zobrazen vztah délky trvání intervalů PQ a QP. Z Obr. 6-13 je patrné, že první shluk je reprezentován vysokými hodnotami délky trvání intervalu PQ, a naopak velmi nízkými hodnotami trvání intervalu QP. Platí tedy, že interval QP je menší než interval PQ. Tedy P vlna se vyskytuje po krátké době za QRS komplexem. Tato skutečnost je typická právě pro AVRT a atypickou AVNRT. Pro druhý shluk naopak interval PQ nabývá hodnot nízkých a vyšších hodnot intervalu QP oproti hodnotám trvání intervalu PQ. Trvání intervalu QP je v daném případě větší než trvání intervalu PQ. Typickou arytmií, kdy se P vyskytuje před QRS komplexem je atypická AVNRT. Ve druhém shluku se vyskytují i cykly, které nabývají nulových nenstandardizovaných hodnot pro trvání intervalu PQ a QP. Může se jednat o přítomnost typické AVNRT (*slow-fast*), kdy na elektrogramu P vlna a QRS komplex splývají. Symboly zaznačené zelenou barvou reprezentují třetí shluk. Nejvyšší zastoupení v tomto shluku mají cykly ze signálů, které jsou označené jako AVRT nebo AVNRT a ze signálů sinusového rytmu s komorovými nebo síňovými extrasystolami.

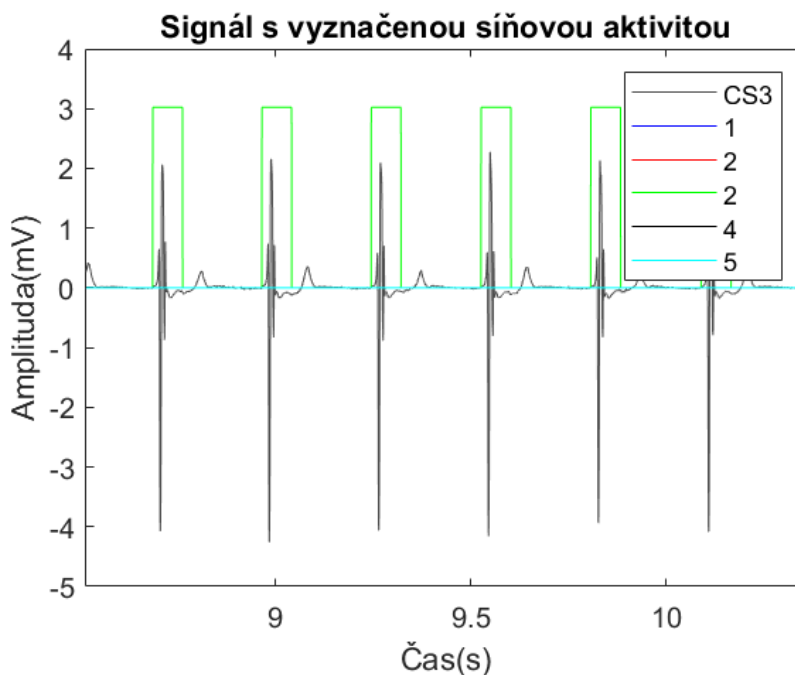


Obr. 6-13: Zobrazení vztahů parametrů intervalů PQ a QP.

Při pohledu na příznaky odvozené z časové aktivace síní, konkrétně vztahu příznaků CS3 a CS5 na Obr. 6-14, nabývají cykly z třetího shluku nízkých hodnot příznaku CS3 a vyšších hodnot příznaku CS5. Lze tedy předpokládat, že se elektrický impuls síněmi nešíří postupně ze svodu CS5 až do svodu CS1, a tedy se nejedná o sinusové cykly. Tuto skutečnost můžeme potvrdit i zobrazením zařazených cyklů v záznamech diagnostikovaných jako AVRT nebo AVNRT. Konkrétně na záznamu zobrazeném na Obr. 6-15, který je diagnostikován jako AVNRT, jsou všechny tyto nesinusové cykly zařazeny právě do třetího shluku.




Obr. 6-14: Zobrazení vztahů parametrů intervalů CS5 a CS3.



Obr. 6-15: Zařazení jednotlivých cyklů záznamu 000019.json do shluků.


Čtvrtý shluk je reprezentován černou barvou. Většinu jeho přiřazených cyklů, tvoří cykly z čistě sinusových záznamu. Nachází se zde i množství stahů pocházejících ze záznamu s kombinovaným rytmem. Předpokladem tedy je, že tento shluk je tvořen především sinusovými stahy ze sinusových záznamů a ze záznamů s kombinovaným rytmem.

Signály dosahují i spíše nižších hodnot parametru CS5 a vyšších hodnot parametru CS4, CS3, CS2 a CS1. Tedy signály se šíří správným směrem ze svodu CS5 do svodu CS1. Na Obr. 6-14 je vidět že hodnoty cyklů přiřazených do čtvrtého shluku nabývají nejnižší standardizované hodnoty pro příznak CS5. Délky intervalů PQ a QP z Obr. 6-13 nabývají konstantních hodnot, což značí pravidelnou aktivitu.



Obr. 6-16: Zobrazení vztahů parametrů intervalů A a RMSSD.

Pátý shluk, jež je označen světle modrou barvou, je v největším počtu zastoupen cykly z kombinovaných rytmů. Pro tento shluk je typickým, že nabývá vysokých hodnot RMSSD a spíše nízkých hodnot velikosti trojúhelníku A. Vztah těchto dvou příznaků je zobrazen na Obr. 6-16, kde tento shluk značně vyčnívá od ostatních shluků. Jelikož je tento shluk tvořen kombinovanými rytmy, může to být způsobeno přechodem mezi sinusovým a nesinusovým rytmem v záznamu. Extrasystoly také mohou způsobit tento výkyv ve zmíněných příznacích. Na Obr. 6-17 je zobrazena extrasystola a následující cyklus, které byly právě přiřazeny do pátého shluku.




Obr. 6-17: Zařazení jednotlivých cyklů záznamu 000010.json do shluků.

6.7 Zhodnocení výsledků klasifikace

Klasifikace jednotlivých cyklů probíhá na základě detekovaných vrcholů síňové aktivity z kapitoly 5. Každý detekovaný cyklus je klasifikován, zatímco nedetekované cykly klasifikovány nejsou. Úspěšnost klasifikace se tedy odvíjí od úspěšnosti extrakce síňové aktivity. Dále jsou v podkapitole 6.1.1 detekovány QRS komplexy. Od vrcholů detekovaných QRS komplexů jsou odvozeny příznaky odvozené z převodu na komory. Jedná se o příznaky délky trvání intervalu QP, délky trvání intervalu PQ a převodu síňové aktivity na komorovou. Tyto příznaky jsou silně závislé i na detekci QRS komplexů.


Z výsledků z podkapitoly 6.6 vyplývá, že velké množství cyklů sinusového rytmu bylo zařazeno do čtvrtého shluku, a proto se spíše v této kapitole zaměřím na zhodnocení výsledků klasifikace pro různé druhy arytmií.

Pro fibrilace síní často selhávala detekce vrcholů síňových vln, jak již bylo uvedeno v podkapitole 5.8. Na Obr. 6-18 je uveden signál kombinovaného rytmu fibrilace síní se sinusovým rytmem. V čase přibližně 2,25 s přechází fibrilace síní na sinusový rytmus. V daném případě nebyla fibrilace síní detekovaná a detekované cykly celého signálu, kromě prvního detekovaného cyklu, správně zařazeny do čtvrtého shluku odpovídajícímu sinusovému rytmu.




Obr. 6-18: Zařazení jednotlivých cyklů záznamu 000009.json do shluků.

Záznamy fibrilace síní s detekovanými cykly byly zařazeny do většinou nejednotného shluku. Cykly signálu na Obr. 6-19 byly většinou zařazeny do třetího shluku, avšak některé cykly byly zařazeny do druhého či pátého cyklu.



Obr. 6-19: Zařazení jednotlivých cyklů záznamu 000026.json do shluků


Flutter síní je charakterizován pravidelnou aktivitou komor, avšak v jiném poměru převodu ze síní na komory než je 1:1, jak již bylo uvedeno v podkapitole 2.2.2. Tato skutečnost může ovlivnit i klasifikaci rytmu tohoto signálu. Na Obr. 6-20 jsou uvedeny cykly flutteru síní, kdy algoritmus některé cykly zařadí do třetího shluku značící nesusosvé cykly a některé cykly do čtvrtého shluku značící sinusové cykly.



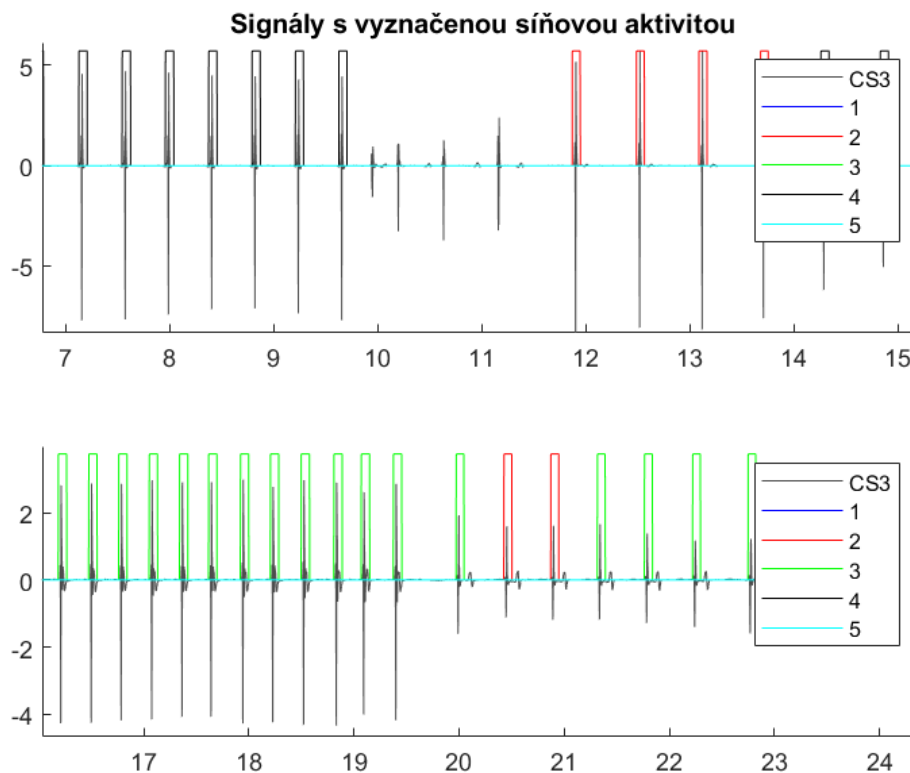
Obr. 6-20: Zařazení jednotlivých cyklů záznamu 000030.json do shluků.

Cykly ze signálu, které jsou diagnostikovány jako AVRT nebo AVNRT, jsou často přiřazeny do shluku prvního, druhého nebo třetího. Přiřazení do shluků probíhá bez vlivu, zda se jedná o arytmi AVRT nebo AVNRT. Ukázka přiřazení cyklů ze signálů označených jako AVRT je na Obr. 6-21, kde je většina cyklů zařazena do prvního shluku a některé cykly zařazeny do shluku druhého.

Problém nastává u kombinovaných rytmů AVRT/AVNRT s rytmem sinusovým. Daný algoritmus není schopný rozeznat v těchto záznamech sinusové rytmy od nesusosvých a většinu cyklů ze záznamů klasifikuje buď jako sinusové nebo jako nesusosvé. Na Obr. 6-22 nahoře je zobrazen kombinovaný rytmus AVRT se sinusovým rytmem. Na stejném obrázku dole je zobrazen kombinovaný rytmus AVNRT se sinusovým rytmem. Cykly horního signálu jsou i před přechodem klasifikovány do čtvrtého shluku značící sinusový rytmus. Naopak cykly ze signálu zobrazeného dole na Obr. 6-22 jsou i po přechodu do sinusového rytmu zařazeny do shluků značící nesusosvový rytmus. Při přechodu mezi rytmy jsou pak i následující signály zařazeny do druhého shluku.



Obr. 6-21: Zařazení jednotlivých cyklů záznamu 00000B.json do shluků.



Obr. 6-22: Zařazení jednotlivých cyklů záznamu 000016.json (nahore) a záznamu 000018.json (dole) do shluků.

6.8 Diskuse

Další cíl této práce byl představit algoritmus pro automatickou detekci síňového rytmu z intrakardiálních elektrogramů v programovém prostředí MATLAB.

Klasifikace je provedena pro jednotlivé cykly, které byly detekované v kapitole 5. Každý cyklus je reprezentován vybranými příznaky, které jsou popsány v podkapitole 6.1. Výběr příznaků je závislý na úspěšnosti detekce vrcholů síňových vln. Dále jsou také příznaky odvozené z převodu na komory závislé na úspěšnosti detekce QRS komplexů.

Pomocí Pearsonova korelačního koeficientu a rozptylových diagramů byla zobrazena lineární závislost jednotlivých příznaků. Na základě nízkých hodnot Pearsonova korelačního koeficientu a vizuální kontroly bylo rozhodnuto, že jednotlivé příznaky nejsou korelované. Bylo tedy možné využít celou množinu extrahovaných příznaků.

Počet shluků byl vybrán na základě metody analýzy siluet. Byl vybrán počet shluků s nejmenší průměrnou hodnotou siluety vypočítanou z jednotlivých hodnot siluety přiřazených objektů do shluku. Data tvoří shluky dle Obr. 6-12, které jsou od sebe příliš vzdálené. Tedy pro některé objekty pak nemusí platit, že hodnota $a(i)$ je mnohem menší než hodnota $b(i)$ v rovnici (6.7). Přes tuto skutečnost můžeme označit průměrnou hodnotu siluety 0,4090 za přijatelnou. Tato hodnota siluety odpovídá shlukování objektů do pěti shluků.

Následuje aplikace metody K-means s pěti centroidy na náhodně umístěných inicializačních souřadnicích. Náhodné umístění souřadnic může vést k rozdílným výsledkům shlukování. Bylo tedy nutné algoritmus opakovat. Ze sta replikací algoritmu byl vybrán výsledek s nejmenší celkovou sumou vzdáleností přiřazených objektů. Nejmenší celková suma vzdáleností odpovídá hodnotě 8305,35, a právě i hodnotě siluety 0,4090.

Na základě zhodnocení výsledků tedy můžeme určit, že cykly zařazené do prvního, druhého, třetího a pátého shluku obsahují cykly s nesinusovým rytmem. Zatímco cykly zařazené do čtvrtého shluku jsou cykly sinusové.

7. Závěr

V rámci bakalářské práce jsem se na teoretické úrovni seznámila s arytmogenezí supraventrikulárních tachykardií. Zaměřila jsem se na popis a projevy v intrakardiálních elektrogramech čtyř nejčastěji se vyskytujících supraventrikulárních tachykardií. Dále jsem nastudovala metody předzpracování elektrokardiografických signálů, které je potřebné provést před následnou analýzou. V kapitole se také vyskytují základní principy FIR a IIR filtrů a metody základní filtrace šumů.

V kapitole 5 jsem na základě daných znalostí navrhla algoritmus, jehož cílem je extrahovat síňovou aktivitu z intrakardiálních elektrogramů. Navržený detektor nejprve provede filtraci signálu a vytvoří obálku signálu, na které detekuje vrcholy. Nakonec vyhledá začátky a konce síňové aktivity, dle těchto indexů je vyjádřeno i trvání síňové aktivity. Navržený detektor jsem otestovala na databázi 100 záznamů. Z každého záznamu jsem využila svodů CS5, CS4, CS3, CS2 a CS1. Tato multidimenzionalita byla redukována pomocí metody analýzy hlavních komponent. Úspěšnost algoritmu jsem vyhodnotila pomocí Diceova koeficientu úspěšnosti. Na daném algoritmu jsem dosáhla výsledků úspěšnosti 76,34 %. Nejúspěšnější detekce dosahuje hodnoty 97,40 %.

V navazující kapitole 6 byl navrhnut postup klasifikace jednotlivých síňových vln detekovaných v předchozí kapitole 5. Nejprve byly vybrány příznaky pro jednotlivé cykly. Tyto příznaky jsou příznaky odvozené z převodu na komory, napěťové příznaky, příznaky odvozené z časové aktivace síní, Complex Correlation Measure a příznaky reprezentující variabilitu srdečního rytmu. Klasifikace probíhá pomocí metody shlukování K-means. Předtím, než byla metoda použita, byl pomocí metody analýzy siluet určen počet shluků. Dle nejmenší průměrné siluety pro jednotlivé počty shluků byl určen počet shluků pět jako nejideálnější. Na základě následné analýzy byla každému shluku přiřazena klasifikační třída. Cykly přiřazené do prvního, druhého, třetího a pátého shluku jsou klasifikovány jako cykly s nesinusovým rytmem, zatímco cykly přiřazené do čtvrtého shluku reprezentují cykly se sinusovým rytmem.

Literatura

- [1] SEDMERA, David a František VOSTÁREK. Moderní pohled na převodní systém srdeční. *ČASOPIS LÉKAŘŮ ČESKÝCH*. Praha, 2017, **156**(8), 417 - 421.
Dostupné z: <https://www.prolekare.cz/casopisy/casopis-lekaru-ceskych/2017-8/moderni-pohled-na-prevodni-system-srdecni-62750>
- [2] BLAHÚT, Peter. Supraventrikulárna tachykardia (SVT). *TECHmED: TECHmED / EKG & Arytmológia (Kniha)* [online]. Dostupné z: <https://www.techmed.sk/supra-ventrikularna-tachykardia-svt/>
- [3] SOHINKI, Daniel, a Owen A OBEL. Current trends in supraventricular tachycardia management. *The Ochsner journal* vol. 14,4 (2014): 586-95.. (2014).
Current trends in supraventricular tachycardia management. *The Ochsner journal*, 14(4), 586–595. Dostupné z: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4295736/>
- [4] CHEN-SCRABELLI Carol. Supraventricular Arrhythmias: An Electrophysiology Primer. *Prog Cardiovasc Nurs*. 2005, 20(1), 24-31. Dostupné z: https://www.medscape.com/viewarticle/502358_2
- [5] OTÍN, Alejandro Alcaine. Intracardiac Signal Processing for Mapping and Characterising Cardiac Arrhythmias. Zaragoza, December 2016. Ph.D. Thesis. Universidad Zaragoza.
- [6] JAN, Jiří. Číslicová filtrace, analýza a restaurace signálů. 2. upr. a rozš. vyd. Brno: VUTIUM, 2002. ISBN 8021429119.
- [7] NG, JASON a JEFFREY J GOLDBERGER. Understanding and Interpreting Dominant Frequency Analysis of AF Electrograms. *Journal of Cardiovascular Electrophysiology* [online]. 2007, **18**(6), 680-685. ISSN 1045-3873. Dostupné z: https://onlinelibrary.wiley.com/doi/full/10.1111/j.1540-8167.2007.00832.x?casa_token=oYwzuya6ziEAAAAA%3AKhCRKO-vswxkteYcRFKC7hNMsNidIuqBT8hbiLvn3VL8uiW_T-IRpddmc7CHiIT8Ij8ooHIDO_DA_PRp
- [8] BANCHS, Javier E. Atrial Tachycardia: Diagnosis and Treatment. The Cardiology Advisor [online]. Decision Support in Medicine, 2013. Dostupné z: <https://www.thecardiologyadvisor.com/home/decision-support-in-medicine/cardiology/atrial-tachycardia-diagnosis-and-treatment/>
- [9] BAUMBRIND, David. The Trouble with Sinus Tachycardia. *EMS 12-Lead* [online]. My EKG, April 30. Dostupné z: <http://ems12lead.com/2013/04/30/the-trouble-with-sinus-tachycardia/>
- [10] OLSHANSKY, Brian a Renee M. SULLIVAN. Inappropriate Sinus Tachycardia. *Journal of the American College of Cardiology*. American College of Cardiology Foundation, 2013, **61**(8), 793–801. ISSN 0735-1097/\$36.00.
- [11] AKAR, Saime Akdemir, Sadik KARA, Fatma LATIFOĞLU a Vedat BILGIÇ. Spectral analysis of photoplethysmographic signals: The importance of

- preprocessing. *Biomedical Signal Processing and Control*. 2013, 8(1), 16-22. ISSN 1746-8094. doi: <https://doi.org/10.1016/j.bspc.2012.04.002>, Dostupné z: <https://www.sciencedirect.com/science/article/abs/pii/S1746809412000468?via%3Dihub>
- [12] SÖRNMO, Leif a Pablo LAGUNA. *Bioelectrical Signal Processing in Cardiac and Neurological Applications*. Ilustrované vydání. Elsevier Science & Technology Books, 2005. ISBN 1493301454, 9781493301454.
- [13] KHER, Rahul. *Signal Processing Techniques for Removing Noise from ECG Signals*. *Journal of Biomedical Engineering and Research*. Vallabh Vidyanagar, Gujarat, India: G H Patel College of Engineering & Technology, 2019, 1(3), 1-9.
- [14] SEMMLOW, John L. *Biosignal and Biomedical Image Processing: MATLAB Based Applications*. TAYLOR & FRANCIS, 2004. ISBN 978-0824750688.
- [15] OOSTEROM, Adriaan van a Peter W. MACFARLANE. *Comprehensive Electrocardiology*. 2. England, United Kingdom: Publisher Springer London, 2013. ISBN 184882047X, 9781848820470.
- [16] LEVER, Jake, Martin KRZYWINSKI a Naomi ALTMAN. Principal component analysis. *Nat Methods*. 2017, (14), 641–642. doi: <https://doi.org/10.1038/nmeth.4346>
- [17] HOSSEINI, Mohammad-Parsa a Mohammad NAZEM-ZADEH, Dario POMPILI a Hamid SOLTANIAN-ZADEH. Statistical Validation of Automatic Methods for Hippocampus Segmentation in MR Images of Epileptic Patients. 2014, 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC 2014. 2014. 4707-10. 10.1109/EMBC.2014.6944675.
- [18] HOUBEN, R. P. M a M. A. ALLESSIE. Processing of intracardiac electrograms in atrial fibrillation. *IEEE Engineering in Medicine and Biology Magazine*. Nov.-Dec. 2006, 25(6), 40-51. Dostupné z: doi: 10.1109/EMB-M.2006.250507
- [19] PETERKOVA, Andrea a Maximilian STRÉMY. The raw ECG signal processing and the detection of QRS complex [online]. 2015, 6, ISSN 978-1-5090-0206-1/15. Dostupné z: <https://uksim.info/ems2015/data/0206a080.pdf>, doi:10.1109
- [20] GLANCY, D. Luke a William P. NEWMAN. Atrial fibrillation with QRS voltage low in the limb leads and high in the precordial leads. *Proc (Bayl Univ Med Cent)*. 2008, 21(4), 437–438. Dostupné z: doi: <https://doi.org/10.1080/08998280.2008.11928447>
- [21] CICCONE, Anthony B., Jacob A. SIEDLIK PHD, Jill M. WECHT, Jake A. DECKERT, Nhuquynh D. NGUYEN a Joseph P. WEIR. Reminder: RMSSD and SD1 are identical heart rate variability metrics. *Muscle Nerve*. 2017, 56, 674-678. Dostupné z: doi: <https://doi.org/10.1002/mus.25573>
- [22] KARMAKAR, Chandan K, Ahsan H KHANDOKER, Jayavardhana GUBBI a Marimuthu PALANISWAMI. Complex Correlation Measure: a new descriptor for Poincaré plot. *BioMed Eng OnLine*. 2009, 8(17). Dostupné z: doi: <https://doi.org/10.1186/1475-925X-8-17>

- [23] MOHAMAD, Ismail Bin a Dauda USMAN. Standardization and Its Effects on K-Means Clustering Algorithm. *Research Journal of Applied Sciences, Engineering and Technology*. 2013, **6**(17), 3299-3303. ISSN 2040-7459. doi: 10.19026/rjaset.6.3638
- [24] Příspěvatelé WikiSkript, *Fórum:Testy/Pearsonův korelační koeficient* [online], , c2014, Datum poslední revize 5. 12. 2014, 07:44 UTC, Dostupné z: https://www.wikiskripta.eu/index.php?title=F%C3%B3rum:Testy/Pearson%C5%AFv_korela%C4%8Dn%C3%AD_koeficient&oldid=290742
- [25] ŽALIK, Krista Rizman. An efficient k'-means clustering algorithm. *Pattern Recognition Letters*. 2008, 29(9), 1385-1391. ISSN 0167-8655. Dostupné z: doi: <https://doi.org/10.1016/j.patrec.2008.02.014>
- [26] ROUSSEEUW, Peter J. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*. 1987, 20, 53-65. ISSN 0377-0427. Dostupné z: doi: [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)

Seznam příloh

Příloha 1 - Výsledné hodnocení.....	74
-------------------------------------	----

Příloha 1 - Výsledné hodnocení

Tab. 7-1: Výsledná Dice skóre pro jednotlivé objekty.

Název souboru	TP	TN	FP	FN	Dice skóre
000049.json	1608	15665	1421	1076	0,5629
000050.json	3363	28279	42	440	0,9331
000051.json	12726	37493	592	665	0,9529
000052.json	215	5745	69	0	0,8617
000053.json	470	16319	1634	2373	0,1900
000054.json	8788	83258	581	724	0,9309
000055.json	8743	26341	1328	323	0,9137
000056.json	4072	33224	844	392	0,8682
000057.json	2105	15196	343	3787	0,5048
000058.json	7982	28424	638	732	0,9210
000059.json	8779	29248	1131	8869	0,6371
000060.json	7479	22304	1301	937	0,8699
000061.json	3594	13353	58	1134	0,8578
000062.json	4817	20491	919	104	0,9040
000063.json	2563	22376	399	20013	0,2007
000064.json	3104	21143	1390	7006	0,4251
00000A.json	2074	18723	505	3	0,8909
00000B.json	7689	27996	542	2013	0,8575
00000C.json	1209	21330	386	626	0,7050
00000D.json	5100	15193	562	399	0,9139
00000E.json	3838	15175	384	1108	0,8373
00000F.json	3078	30030	338	1840	0,7387
000001.json	4174	38897	161	505	0,9261
00001A.json	2894	26290	591	793	0,8070
00001B.json	1619	17729	370	1550	0,6278
00001C.json	5909	28131	161	809	0,9241
00001D.json	1924	18016	276	463	0,8389
00001E.json	2380	29425	252	3746	0,5435
00001F.json	1485	18258	515	932	0,6724
000002.json	1035	29738	1866	2093	0,3433
00002A.json	2676	15708	825	14044	0,2647
00002B.json	2098	18312	220	75	0,9343
00002C.json	4872	22598	270	281	0,9465
00002D.json	3423	23211	499	919	0,8284
00002E.json	2413	19597	61	334	0,9243
00002F.json	5970	24314	943	8449	0,5597
000003.json	716	8668	272	181	0,7597
00003A.json	2797	19741	524	152	0,8922
00003B.json	2671	23446	84	697	0,8724
00003C.json	2000	18288	374	1125	0,7274

00003D.json	5721	18857	974	478	0,8874
00003E.json	2580	26921	286	978	0,8032
00003F.json	411	2070	104	25	0,8644
000004.json	1858	16029	484	6228	0,3563
00004A.json	389	6027	68	175	0,7620
00004B.json	9140	43225	3811	907	0,7949
00004C.json	797	36076	323	2118	0,3950
00004D.json	2879	18516	349	169	0,9175
00004E.json	8021	25231	1361	226	0,9100
00004F.json	1713	25142	1238	35	0,7291
000005.json	2971	12822	759	662	0,8070
00005A.json	5399	24724	849	1791	0,8035
00005B.json	1898	21064	743	121	0,8146
00005C.json	3472	27092	6105	5088	0,3829
00005D.json	90	27472	3537	3807	0,0239
00005E.json	2347	31829	239	53	0,9414
00005F.json	3174	24334	107	440	0,9207
000006.json	1932	17516	56	47	0,9740
000007.json	2371	7192	719	1144	0,7179
000008.json	3075	30789	212	1247	0,8083
000009.json	3143	26468	439	862	0,8285
000010.json	2289	20397	624	4	0,8794
000011.json	1907	17036	379	0	0,9096
000012.json	683	38418	28	6528	0,1724
000013.json	3387	40299	207	804	0,8701
000014.json	6550	20158	732	546	0,9111
000015.json	2374	20635	144	883	0,8222
000016.json	4289	25634	522	1628	0,7996
000017.json	3484	30312	187	80	0,9631
000018.json	10998	33451	918	1311	0,9080
000019.json	11204	32461	1069	945	0,9175
000020.json	5924	33846	590	816	0,8939
000021.json	3927	16408	751	745	0,8400
000022.json	3030	28297	286	559	0,8776
000023.json	1661	25210	18	518	0,8611
000024.json	5666	30373	575	1321	0,8567
000025.json	9560	16502	1783	2848	0,8050
000026.json	12112	12906	1468	4387	0,8053
000027.json	3722	26475	818	471	0,8524
000028.json	2866	26716	2616	3929	0,4669
000029.json	7301	15240	832	245	0,9313
000030.json	9882	23663	567	4724	0,7888
000031.json	3413	30013	208	789	0,8726
000032.json	5470	17573	218	889	0,9081

000033.json	2782	25634	40	480	0,9145
000034.json	2441	18134	17	1486	0,7646
000035.json	4148	24860	7	3272	0,7167
000036.json	5519	20325	1278	692	0,8486
000037.json	2459	22712	0	1449	0,7724
000038.json	2667	20209	542	346	0,8573
000039.json	2990	19968	165	175	0,9462
000040.json	6804	22111	242	280	0,9631
000041.json	4805	22944	0	1797	0,8425
000042.json	5195	27914	246	1259	0,8735
000043.json	0	21170	2920	3779	0,0000
000044.json	7950	32622	2762	3100	0,7306
000045.json	2904	29349	1	892	0,8667
000046.json	3261	19745	118	5615	0,5322
000047.json	7680	33821	605	2663	0,8246
000048.json	8852	23102	2031	587	0,8712
Celkově	409989	2383712	72948	181155	0,7634