



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

## ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

## DETEKCE OBTÍŽNĚ DIFERENCovatELNÝCH SKUPIN SRDEČNÍCH ARYTMÍÍ

DETECTION OF POORLY DIFFERENTIATED CARDIAC ARRHYTHMIAS

### DIPLOMOVÁ PRÁCE

MASTER'S THESIS

### AUTOR PRÁCE

AUTHOR

Bc. Marek Kantor

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Petra Novotná

BRNO 2022





# Diplomová práce

magisterský navazující studijní program **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

**Student:** Bc. Marek Kantor

**ID:** 203667

**Ročník:** 2

**Akademický rok:** 2021/22

**NÁZEV TÉMATU:**

## Detekce obtížně diferencovatelných skupin srdečních arytmií

### POKYNY PRO VYPRACOVÁNÍ:

1) Vypracujte literární rešerši na téma detekce obtížně diferencovatelných skupin srdečních arytmií (zaměřte se na rozlišení fibrilace síní od síňového flutteru, nebo rozlišení AV bloku typu II a III). Zaměřte se na moderní metody, např. využití hlubokých neuronových sítí. 2) Seznamte se s databázemi EKG signálů z různých zdrojů (ÚBMI, CPSC2018). Proveďte potřebné kroky předzpracování. 3) Navrhněte a realizujte model detekující obtížně rozlišitelné arytmie. Návrh detailně popište včetně parametrů učení. Realizaci proveďte v prostředí Matlab (případně jiném). 4) Model optimalizujte na základě výsledků z bodu 3, případně proveďte rozšíření o další typy těžce rozlišitelných arytmií. 5) Dosažené výsledky podrobně interpretujte a diskutujte. Proveďte porovnání s dostupnými zahraničními studiemi na podobné téma.

### DOPORUČENÁ LITERATURA:

[1] Y.-Y. JO, J.-M. KWON, K.-H. JEON, et al. Detection and classification of arrhythmia using an explainable deep learning model. *Journal of Electrocardiology*, 2021, vol. 67, pp. 124-132.

[2] Zahra Ebrahimi, Mohammad Loni, Masoud Daneshtalab, Arash Gharehbaghi. A review on deep learning methods for ECG arrhythmia classification.

*Expert Systems with Applications: X*, Volume 7, 2020, 100033, ISSN 2590-1885.

**Termín zadání:** 7.2.2022

**Termín odevzdání:** 20.5.2022

**Vedoucí práce:** Ing. Petra Novotná

**prof. Ing. Ivo Provazník, Ph.D.**  
předseda rady studijního programu

### UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové 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**

Tato práce se zabývá problematikou detekčních metod fibrilace síní, flutteru síní a sinusového rytmu ze záznamu EKG. Práce rovněž pojednává o těchto arytmiích a klasifikačních algoritmech vhodných pro tuto problematiku. V rámci této práce je vytvořeno několik přístupů klasifikace. Pro extrakci příznaků je využita konvoluční neuronová síť a klasifikace je realizovaná prostřednictvím umělé neuronové sítě. Vybrána metoda 1D CNN pro tyto těžko diferencovatelné srdeční arytmie dosahuje průměrné přesnosti klasifikace F1 - skóre = 91 %. Vybrána CNN optimalizovaná pomocí GA je rychlá mělká síť s lepší přesností než hluboká síť. Vytvořené modely jsou použity i pro klasifikaci jiných typů arytmií.

## **KLÍČOVÁ SLOVA**

elektrokardiogram, EKG, fibrilace síní, FIS, flutter síní, FLUT, detekce arytmií, konvoluční neuronová síť, CNN, genetický algoritmus, GA

## **ABSTRACT**

This thesis focusses on the detection methods of atrial fibrillation, atrial flutter and sinus rhythm from ECG. Thesis also concentrate on the description of this arrhythmias and the learning algorithms used. In this thesis are implemented several classification approaches. For extraction of features is used convolution neural network and classification artificial neural network. Selected 1D CNN method achieved classification accuracy global F1 - score is 91 %. Moreover, the proposed CNN optimized with GA appears to be fast shallow network with better accuracy than the deep network. Created model are used for classification other type of arrhythmias too.

## **KEYWORDS**

electrocardiogram, ECG, atrial fibrillation, AFIB, atrial flutter, arrhythmias detection, atrial arrhythmias convolutional neural network, CNN, genetic algorithm, GA



## Prohlášení autora o původnosti díla

<b>Jméno a příjmení autora:</b>	Bc. Marek Kantor
<b>VUT ID autora:</b>	203667
<b>Typ práce:</b>	Diplomová práce
<b>Akademický rok:</b>	2021/22
<b>Téma závěrečné práce:</b>	Detekce obtížně diferencovatelných skupin srdečních arytmí

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

Jako autor uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno .....

.....

podpis autora\*

---

\*Autor podepisuje pouze v tištěné verzi.





## PODĚKOVÁNÍ

Rád bych poděkoval vedoucímu semestrální práce paní Ing. Petře Novotné za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.



# Obsah

Úvod	17
<b>1 Elektrofyziologie srdce</b>	<b>19</b>
1.1 Převodní srdeční systém	19
1.2 EKG křivka	19
1.3 Popis EKG křivky svodu II zdravého srdce.	20
1.4 Srdeční blokády.	21
1.4.1 AV blokáda prvního stupně	21
1.4.2 AV blokáda druhého stupně	21
1.4.3 Kompletní srdeční AV blokáda	22
1.4.4 Blokáda pravého nebo levého Tawarova raménka.	22
<b>2 Srdeční arytmie</b>	<b>25</b>
2.1 Supraventrikulární arytmie	25
2.1.1 Sinusová tachykardie	25
2.1.2 Atrioventrikulární reentry tachykardie	25
2.1.3 Atrioventrikulární nodální reentry tachykardie (AVNRT)	26
2.2 Fibrilace síní (FIS)	26
2.2.1 Klinický projev fibrilace síní	27
2.3 Flutter síní (FLUT)	27
<b>3 Metody klasifikace srdečních arytmií</b>	<b>29</b>
3.1 Klasifikace založené na metodách redukce příznaků	29
3.2 Klasifikace signálu bez výběru příznaků	30
3.3 Metody založené na vytvoření 2D příznakového pole.	30
3.3.1 Navržená metoda využití EKG segmentů	31
3.3.2 Spektrogram	32
3.3.3 Vlnková transformace	33
3.4 Klasifikace pomocí RR intervalů	33
3.5 Klasifikace prostřednictvím modulů, které reprezentují specifické vlastnosti EKG	34
<b>4 Klasifikátory hlubokého učení pro klasifikaci arytmií</b>	<b>37</b>
4.1 Vícevrstvý perceptron	37
4.2 Rekurentní neuronové sítě	37
4.2.1 Radial basis function network (RBF síť)	38
4.3 Long short-term memory	39
4.4 Konvoluční neuronová síť (CNN)	39

4.4.1	Konvoluční vrstva . . . . .	41
4.4.2	Poolingová vrstva . . . . .	41
4.4.3	DropOut vrstva . . . . .	42
4.4.4	Plně propojená vrstva . . . . .	43
4.5	Deep belief network . . . . .	43
<b>5</b>	<b>Optimalizační algoritmy</b>	<b>45</b>
5.1	Gradientní sestup . . . . .	45
5.2	Hybnost . . . . .	46
5.3	Adaptivní gradient . . . . .	46
5.4	Odhad adaptivní hybnosti, dále ADAM . . . . .	46
5.5	Genetické algoritmy . . . . .	47
<b>6</b>	<b>Praktické kroky práce</b>	<b>49</b>
6.1	Data pro zpracování . . . . .	49
6.1.1	Databáze ÚBMI . . . . .	49
6.1.2	Databáze II . . . . .	50
6.2	Realizace prostřednictvím spektrogramu a vytvoření zarovnaných segmentů signálu . . . . .	50
6.2.1	Výběr příznaků . . . . .	50
6.2.2	Klasifikátor . . . . .	52
6.3	Realizace prostřednictvím 1D CNN . . . . .	54
6.3.1	Definice problematiky . . . . .	54
6.3.2	Výběr dat . . . . .	54
6.3.3	Jednotlivé funkce pro zpracování signálů. . . . .	55
6.3.4	Program . . . . .	57
6.3.5	Skladání výstupu klasifikace segmentů signálu . . . . .	59
6.3.6	Klasifikace signálů včetně rozšíření databáze o FLUT. . . . .	61
6.3.7	Optimalizace pomocí genetického algoritmu. . . . .	62
6.3.8	Klasifikátor s hlubší CNN. . . . .	63
6.4	Využití realizovaného 1D CNN klasifikátoru pro jiné arytmie . . . . .	63
6.4.1	Klasifikace RBBB, LBBB a PVC . . . . .	63
6.4.2	Klasifikace infarktu myokardu, projev srdeční ischemie a sinusového rytmu . . . . .	65
6.4.3	Klasifikace bradykardie, tachykardie a sinusového rytmu . . . . .	65
6.5	Diskuze výsledků . . . . .	66
	<b>Závěr</b>	<b>69</b>
	<b>Literatura</b>	<b>71</b>

# Seznam obrázků

1.1	Popis ekg, převzato z:[7]	20
1.2	Popis šíření elektrického impulzu zdravého srdce	21
1.3	AV blok 1 blok, převzato z:[2]	22
1.4	AV blok, Mobitz 1, převzato z:[2]	22
1.5	AV blok, Mobitz 2, převzato z:[2]	22
1.6	Kompletní srdeční AV blokáda, převzato z:[2]	22
1.7	Blokáda Tawarova raménka	23
2.1	Sinusová tachykardie, převzato z:[2]	25
2.2	Fibrilace síní, převzato z:[2]	26
2.3	Flutter síně, převzato z:[2]	27
3.1	Výběr příznaků, převzato z:[7]	29
3.2	Možná architektura 1D CNN, převzato z:[8]; layer představuje vrstvu, kde je uvedena délka vstupního signálu a počet filtrů nebo neuronů. Convolutions udává konvoluční vrstvu a fully-connected znamená plně propojená vrstva.	31
3.3	rozložení segmentů síňové fibrilace	31
3.4	rozložení segmentů síňového flutteru	31
3.5	Spektrogramy, rozdílných arytmií	32
3.6	CWT fyziologického ekg a signálu s fibrilací síní, převzato z:[12]	34
3.7	Popis navržené konvoluční sítě, převzato z:[13]	35
3.8	Moduly reprezentující určité rysy signálu, převzato z:[14]	36
4.1	Sigmoidální transformační funkce	38
4.2	Rekurentní neuronová síť, převzato z:[21]	38
4.3	Architektura LSTM, převzato z:[15]	40
4.4	Architektura CNN, převzato z:[10]	40
4.5	1D konvoluce, kernel = 3, krok = 1 s váhami pro i-tý filtr, převzato z:[15]	41
4.6	Aktivační funkce ReLu	42
4.7	Poolingová vrstva, převzato z:[15]	42
5.1	Příklad kritériální funkce, převzato z:[16]; osy x a y představují vývoj funkce v čase	45
5.2	cesta dle pravidla hybnosti, převzato z:[16]; osy x a y představují prostorové souřadnice	46
6.1	Filtrace brumu pomocí adaptivního filtru	51
6.2	Rozložení segmentů síňové fibrilace	51
6.3	Rozložení segmentů síňového flutteru	52
6.4	Vytvořené spektrogramy	52

6.5	Sestavení datasetu . . . . .	55
6.6	Úprava izolinie signálu, pomocí mediánové filtrace . . . . .	56
6.7	Princip ukládání dat . . . . .	56
6.8	Zjednodušený algoritmus klasifikace . . . . .	58
6.9	Skládání segmentů . . . . .	60
6.10	průběh učení modelu, dle studie [24] . . . . .	66
6.11	průběh učení vlastního modelu 1D CNN s optimalizací GA . . . . .	67

## Seznam tabulek

6.1	Struktura 2D CNN . . . . .	53
6.2	1DCNN . . . . .	59
6.3	Výsledky 1DCNN - skladání segmentů . . . . .	60
6.4	Výsledky 1D CNN, pouze jeden segment . . . . .	61
6.5	Výsledky 1D CNN, rozšířené databáze . . . . .	62
6.6	Výsledky 1D CNN, rozšířená databáze, optimalizace GA . . . . .	63
6.7	1D CNN, hlubší architektura . . . . .	64
6.8	Výsledky 1D CNN, rozšířené databáze a hlubší CNN . . . . .	64
6.9	Výsledky 1D CNN (RBBB, LBBB, PVC) . . . . .	65
6.10	Výsledky 1D CNN (RBBB, LBBB) . . . . .	65
6.11	Výsledky 1D CNN (STCHNG, MI) . . . . .	65
6.12	Výsledky klasifikace 1D CNN (BRADY, TACHY a SIN) . . . . .	66





# Úvod

Mezi těžko diferencovatelné srdeční arytmie bez pochyby patří fibrilace síní a flutter síní.

Fibrilace síní (FS) je celosvětově nejčastější srdeční arytmií v klinické praxi. Fibrilace síní je spojena se zvýšeným rizikem cévní mozkové příhody, srdečním selháním a mortalitou. Fibrilace síní je zodpovědná za 15 % - 20 % všech mozkových příhod. Nedostatečné stahy síní vedou k nedostatečnému průtoku krve síněmi, který může mít za následek vznik trombů.

Flutter síní (FLUT) má zpravidla pravidelnou frekvenci. Komorové stahy závisí na atrioventrikulárním vedení a taktéž na typu flutteru. U pacientů s FLUT se může rozvinout FS, obě arytmie mohou existovat současně.

Cílem této práce je navrhnout a realizovat vhodný klasifikátor pro rozlišení jednotlivých srdečních arytmí od sebe navzájem a od sinusového rytmu.

V této práci jsou popsány a realizovány různé přístupy klasifikace. Nejvhodnější realizací je 1D konvoluční neuronová síť s optimalizací pomocí genetického algoritmu. Tato práce taktéž pojednává o srovnání přesnosti klasifikace EKG signálů pomocí mělkých a hlubších klasifikátorů. Vytvořené klasifikátory jsou použity pro vyhodnocení dalších arytmí.



# 1 Elektrofyzologie srdce

Srdce je dutý fibromuskulární orgán uložený v hrudníku. Srdeční svalovina (myokard) zajišťuje pravidelné kontrakce srdce. Srdce se skládá ze čtyř dutin. Jedná se o pravou a levou síň, pravou i levou komoru. Srdce je obaleno perikardem tzv. vazivovým vakem a zevně pokryto endokardem. V krevním oběhu srdce zastává funkci pumpy. Pravá komora zprostředkovává nízkotlakový plicní oběh, odvádí odkysličenou krev do plic. Levá komora odvádí okysličenou krev do těla, oproti pravé komoře má tlustší stěnu. Komory se plní krví ze síní [1].


## 1.1 Převodní srdeční systém

Elektrická aktivita srdce předchází její mechanickou aktivitu. V převodním systému srdečním vzniká a šíří se podnět ke kontrakci srdeční svaloviny. Mezi nodální myocyty, tzv. pacemakerové buňky patří sinoatriální uzel (SA uzel) a atrioventrikulární uzel (AV uzel). Z SA uzlu se vzruch šíří na AV uzel. Z AV uzlu impuls prochází Hisovým svazkem, z něhož odstupuje levé a pravé Tawarovo raménko. Raménka a jeho svazky vláken jsou uloženy pod endokardem septa. Následně přechází v Purkyňova vlákna. Purkyňova vlákna tvoří specializovaný srdeční převodní systém, který umožňuje velmi rychlý převod vzruchů komorovou svalovinou.[1, 3]

## 1.2 EKG křivka

Záznam elektrické aktivity srdce nazýváme elektrokardiogram (EKG). Amplituda jednoho svodu EKG je dána rozdílem potenciálu mezi dvojicí elektrod. Elektrokardiogram vynalezl Dr. Willem Einthoven. Za tento objev a interpretaci EKG křivky získal Nobelovou cenu roku 1924.

Standardně je snímáno klidové EKG. Dvanácti svodové EKG se skládá z bipolárních končetinových svodů, které tvoří Einthovenův trojúhelník, a dále z hrudních unipolárních svodů, které jsou označeny (V1 – V6). Zaznamenávají napětí vzhledem k indiferentní elektrodě, zde Wilsonové svorce. Goldbergovy svody (aVR, aVF, aVL) měří potenciál mezi elektrodou a průměrem potenciálu zbylých elektrod Einthovenova trojúhelníku. Zaznamenáván je rozdíl potenciálu na elektrodách. Depolarizační impuls má kladným náboj. Šíří-li se ke kladné elektrodě má tvar pozitivní vlny akčního potenciálu (AP). Impuls šířící se k záporné elektrodě vytváří negativní AP křivku. Jedná-li se o repolarizaci, náboj bude negativní. Křivky AP budou mít opačnou polaritu. Izoelektrická aktivita srdce se neprojeví na signálu. Pro diagnostiku síňových arytmí je nejvíce vypovídající a diagnostikovaný signál ze svodu II, jelikož kopíruje srdeční osu.




Obr. 1.1: Popis ekg, převzato z:[7]

### 1.3 Popis EKG křivky svodu II zdravého srdce.

EKG křivka jednoho úderu zdravého srdce se skládá z vlny P, komplexu QRS a vlny T. Vlna P vlna reprezentuje depolarizaci síní. Na základě P vlny je určován sinusový rytmus. Je sledováno, zda předchází QRS komplex a je pozitivní ve svodech (II, III a aVF) v dolní části srdce. Rovněž negativní ve svodu (V1) v horní části. Depolarizace síní postupuje směrem dolů k AV uzlu, tedy ke kladné elektrodě (II svod). Komplex QRS představuje depolarizaci komor. Doba trvání není delší než 0,10 s. V QRS komplexu je skrytá repolarizace síní. Záporný kmit Q reprezentuje depolarizaci septa. Septum je depolarizováno především z LR a tedy el. vektor směřuje k záporné elektrodě, vytváří se negativní Q vlna. Kladný kmit značíme písmenem R a jedná se o depolarizaci komor. Je depolarizováno velké množství tkáně, z tohoto důvodu dosahuje vlna R vysoké amplitudy. Depolarizace komor je dána šířením vzruchu po svalovině směrem k srdečnímu hrotu a následně k síním. Výsledkem je pozitivní R vlna. Malá záporná vlna následující R kmit se nazývá vlna S, reprezentuje depolarizaci purkyňových vláken. Je negativní, jelikož se šíří především směrem z hrotu k chlopním.

Vlna T je dána repolarizací komorového myokardu. Výsledný elektrický vektor repolarizace komor směřuje k záporné elektrodě, nese záporný náboj. Vzniká kladná T vlna. Vlna U se nachází bezprostředně po vlně T. Reprezentuje repolarizaci AV uzlu a Tawarových ramének. Vlna U obvykle nelze na EKG pozorovat, taktéž její přítomnost může souviset s nedostatkem draslíku.

PQ interval odpovídá převodu vzruchů ze síní na komory prostřednictvím AV uzlu, který je jediným elektricky vodivým spojením mezi síněmi a komorami. Zároveň je nejpomalejším místem srdečního převodního systému. Trvání PQ intervalu je v intervalu od 0,12 - 0,21 s. Depolarizace AV uzlu se projeví izoelektrickou aktivitou



Obr. 1.2: Popis šíření elektrického impulzu zdravého srdce

srdce, jelikož depolarizace je dána směrem dovnitř, a tedy nevzniká žádný vektor šíření el. vzruchu. Úsek ST nastává po depolarizaci komor. Doprovází fázi plato, nastává nulová elektrická aktivita srdce po dobu 0,20 s.

## 1.4 Srdeční blokády.

Vznikají v důsledku porušeného vedení vzruchu.

### 1.4.1 AV blokáda prvního stupně

Veškeré síňové vzruchy jsou převedeny na komory, avšak s dlouhým PR intervalem. Důvodem je zpomalení vedení v AV uzlu. Délka PR intervalu je delší než 0,2 s. Častým důvodem je zvýšený tonus vagu.

### 1.4.2 AV blokáda druhého stupně

U blokády druhého stupně se převádí pouze některé vzruchy na komory. Blokáda II. stupně typu Mobitz I lze rozeznat dle Wenkebachova intervalu. PR interval se prodlužuje s každým úderem až do doby, kdy dojde k vynechání komorové odpovědi. Dále se AV blokáda druhého stupně může projevit opakovaným výpadkem QRS komplexu za P vlnou, tento typ blokády se označuje jako Mobitz II.

### First Degree AV Block



Obr. 1.3: AV blok 1 blok, převzato z:[2]

### Second Degree AV Block Mobitz Type I (Wenckebach)



Obr. 1.4: AV blok, Mobitz 1, převzato z:[2]

### Second Degree AV Block Mobitz Type 2



Obr. 1.5: AV blok, Mobitz 2, převzato z:[2]

## 1.4.3 Kompletní srdeční AV blokáda

Blokáda třetího stupně, je stav, kdy se vzruch ze síní nedostane na komory. Vedení je úplně přerušeno. Tyto blokády dělíme na idioventrikulární a infranodální. Idioventrikulární blokády bývají způsobeny nodální blokádou AV uzlu. Infranodální blokády jsou způsobeny postižením Hisova svazku.[3].

### 3rd Degree AV Block




Obr. 1.6: Kompletní srdeční AV blokáda, převzato z:[2]

## 1.4.4 Blokáda pravého nebo levého Tawarova raménka.

Zpravidla se jedná o blokádu pravého nebo levého Tawarova raménka. Vzruch se šíří nepoškozeným Tawarovým raménkem na myokard komory a následně se šíří na

komoru, kterou nelze depolarizovat poškozeným raménkem. Blokádá vzniká za Hisovým svazkem. Blokády Tawarových ramének mají specifický tvar, který lze rozeznat ve svodu V1 a V6. Blokádá levého Tawarového raménka se ve svodu V1 projeví ve tvaru písmene V, tvar písmene M s negativní T vlnou se projeví ve svodu V6. Podobně blokádá pravého Tawarového raménka se ve svodu V1 projeví ve tvaru písmene W, tvar písmene N s pozitivní T vlnou se projeví ve svodu V6 [3].



Obr. 1.7: Blokádá Tawarova raménka





## 2 Srdeční arytmie


Srdeční arytmie jsou definovány jako porucha srdečního rytmu. Arytmie mohou vzniknout poruchou vedení, automacií a reentry. Reentry jsou určeny překážkami, kolem kterých se vzruch šíří v kruhu.

### 2.1 Supraventrikulární arytmie

Takto jsou označovány arytmie, které vznikají v síních či z AV junkce. Vzruch se dále šíří Hisovým svazkem, Tawarovými raménky a Purkyňovými vlákny. Výsledkem je štíhlý QRS komplex. Do výčtu supraventrikulárních tachykardií patří atrioventrikulární reentry tachykardie (AVRT), atrioventrikulární nodální reentry tachykardie (AVNRT), fibrilace síní, flutter síní, sinusová tachykardie. U fibrilace síní a flutteru síní se AV uzel nepodílí na vzniku arytmie, pouze určité vzruchy převádí na komory. Příčinou mohou být chlopenní vady či onemocnění myokardu.

#### 2.1.1 Sinusová tachykardie

Jedná se o sinusový rytmus, který má vyšší frekvenci než 100 úderu za minutu. RR intervaly jsou konstantní, každý QRS komplex předchází P vlna. Může se vyskytnout při zátěži či stresu [3].



Obr. 2.1: Sinusová tachykardie, převzato z:[2]

#### 2.1.2 Atrioventrikulární reentry tachykardie

Junkční reentry vznikají v síních, kde vzruch krouží přes AV uzel. Vzruch se na komory může přenést pomocí přidatného vedení, například Kentova svazku svazek. Tuto tachykardii nazýváme AVRT (atrioventrikulární reentry tachykardie). Wolffův-Parkinsonův-Whiteův syndrom (WPW) je jev, kdy se vzruch vrací zpět retrográdním vedením[3].

### 2.1.3 Atrioventrikulární nodální reentry tachykardie (AVNRT)

Představuje tzv. duální AV nodální dráhu. Při těchto arytmiích se v AV uzlu nachází dodatečná dráha, která umožní vznik reentry tachykardie. Nejčastěji se vyskytuje Slow-fast (SF) AVNRT. Při této arytmií slouží pomalá dráha k šíření impulsu na komory, zatímco rychlá zpět na síně. SF-AVNRT má krátký RP interval, může se objevit pseudo R, či pseudo S vlna. Přídatná dráha se zde nachází v prodloužení AV uzlu směrem doprava dolů. [4, 5]

## 2.2 Fibrilace síní (FIS)

Jedná se o jednu z nejčastěji vyskytujících se arytmií v populaci. Arytmie je způsobena reentry vedením uvnitř síní. Přirozené překážky jsou dány anatomíí srdce, jedná se o ústí plicních žil, dutých žil a koronárního sinu (CS). Překážky mohou být dány taktéž jizvami z předešlé katéetrové ablace. Elektrický vzruch může rovněž vzniknout v ektopických ložiscích myokardu. Ektopické ložisko je patologický pacemaker, ruší normální převodní systém a může převzít roli SA uzlu. Vzruch se následně po síních šíří chaoticky.



Obr. 2.2: Fibrilace síní, převzato z:[2]


Fibrilaci síně často předchází síňové extrasystoly. Extrasystoly jsou vzruchy, které vznikají předčasně v AV uzlu nebo ve stěnách síní. Síňové extrasystoly bývají převedeny přes AV uzel a poté Tawarovými raménky na komory. V důsledku toho je QRS komplex štíhlý. Vlna P je předčasná, velice často nasedá na vlnu T. V případě, že vlna P nasedne na vlnu T, dojde k deformaci obou vln. Pokud není přítomen WPW či blokáda Tawarova raménka, je QRS komplex fyziologický. Výše je popsán vznik fibrilace síně, ovšem její příčinou může být onemocnění srdečního svalstva, infarkt, hypertenze, kardiomyopatie, chlopenní vada. Ovšem ve většině případů je příčina neznámá [3].

### 2.2.1 Klinický projev fibrilace síní

Paroxysmální FIS má trvání do 7 dnů, sinusový rytmus se obnoví spontánně. Perzistující FIS trvá více než 30 dní. Pro obnovení sinusového rytmu a přerušení arytmie se používá kardioverze. Kardioverze je neinvazivní výkon, kde se používá výboj stejnosměrného proudu defibrilátoru. Při permanentní fibrilaci přetrvávající déle než rok dochází ke změnám anatomie srdce. Vsruch se šíří vlastní cestou a vznikají nová ektopická ložiska a reentry.[6] Fibrilace síní se projeví zrychleným dýcháním z důvodu tzv. atrial kick, bolestí hrudníku a palpitací. Při diagnostice FIS je indikován lék na ředění krve. V oušku levé síně může vznikat trombus a dojít tak k embolizaci. Trombus může způsobit cévní mozkovou příhodu nebo i infarktu myokardu.

## 2.3 Flutter síní (FLUT)

Jedná se o arytmii, která je charakterizována reentry smyčkou v pravé síní. Vzniká z jednoho či malé skupiny ektopických ložisek v této oblasti. Flutter má pravidelnou frekvenci přibližně 300 stahů za minutu. Na EKG se aktivita síní projeví ve formě pravidelných f vln.



Obr. 2.3: Flutter síně, převzato z:[2]

Síňová aktivita je regulérně převáděna na komory v poměru 2:1, či 3:1. Důvodem je refrakterní fáze AV uzlu. Jelikož arytmie představuje tvar smyčky, na EKG se projeví jako vzor zubů pily. První vlna f může být překryta vlnou T a tudíž je těžké tuto arytmii detekovat hned v počátku. Již klidová frekvence rovna 150 kontrakcí za minutu je významným příznakem flutteru síní a pacient je podroben rozsáhlejšímu vyšetření. Flutter síně je jasně viditelný při vyšších AV blokádách. Flutter síně se dělí do kategorií typický a atypický. Typický flutter síně se šíří definovanou dráhou proti hodinovým ručičkám, atypický flutter dosahuje vyšších frekvencí.

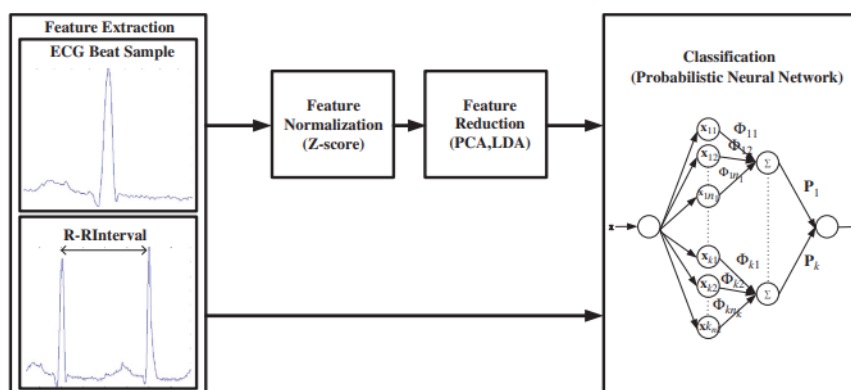


### 3 Metody klasifikace srdečních arytmií

Metody klasifikace využívají různé typy klasifikátorů, které jsou popsány v následující (kapitole 4)

#### 3.1 Klasifikace založené na metodách redukce příznaků

Tento přístup je velice úspěšný pro klasifikaci arytmií se specifickým průběhem, například komorové extrasystoly, blokády ramének, komorový flutter, předčasná síňová kontrakce a taktéž stimuly z kardiostimulátoru. Tyto metody jsou založeny na předzpracování, segmentaci, normalizaci, extrakci příznaků, redukci příznaků a klasifikaci (viz.Obr 3.1). Předzpracováním rozumíme potlačení nežádoucích složek signálů. Vhodně předzpracovaný signál usnadní další zpracování a klasifikaci. Signál často postihuje rušení elektrického vedení a kolísání nulové izolinie. Rušení elektrického vedení znamená vysoce zvýrazněnou frekvenci 50 Hz, způsobenou například elektromagnetickým rušením z elektrického vedení. K potlačení této rušivé frekvence se používají filtry typu pásmová zadrž. Ovšem nejvhodnějším řešením je adaptivní filtr. Pro vyhlazení lze použít filtraci pomocí vlnkové transformace. Kolísání nulové izolinie může být vyvoláno dýcháním a pohybem pacienta, nebo elektrochemickými ději mezi elektrodou a kůží. Postižené frekvence jsou do 2 Hz. Nulové izolinie je dosaženo odečtením izolinie od signálu. Izolinií signálu lze získat vhodnou mediánovou filtrací. Dalším přístupem filtrace je vytvoření dolní propusti, jejíž výstup je odečten od originálního signálu. Potlačí se tak frekvence nižší než 2 Hz. Segmentací rozumíme oddělení důležitých struktur od sebe navzájem.



Obr. 3.1: Výběr příznaků, převzato z:[7]

Výběr příznaků lze z časové oblasti provést například rozměření jednotlivých vln, posouzením RR intervalů. Z frekvenční oblasti lze získat zastoupením určitých frekvencí. Posléze se pak jedná o časově-frekvenční analýzu, vlnkovou transformaci a statistickou reprezentaci. Příznakům, které mají vysokou směrodatnou odchylku či vysoké hodnoty, klasifikátor přiřkládá větší význam. Standardně se používá Z funkce pro normalizaci. Normalizované příznaky se nacházejí v intervalu  $(-2,2)$  s nulovou střední hodnotou.

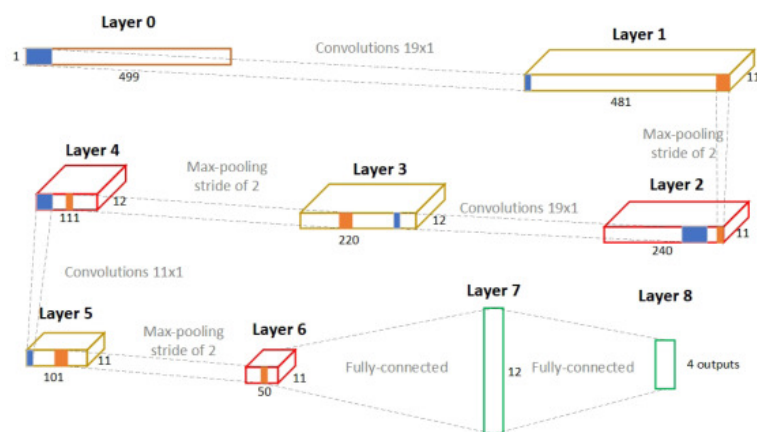
Mezi metody pro redukci příznaků patří PCA, LDA, ICA. Analýza hlavních komponent (PCA) je statistická metoda, která využívá lineární transformaci originálních příznaků na nové nekorelované hlavní komponenty. První hlavní komponenta udává největší variabilitu dat. Výpočet je prováděn z korelační matice za pomoci výpočtu vlastních čísel a vlastních vektorů. Lineární diskriminační analýza (LDA) je podobně jako PCA lineární metoda. Ovšem využívá popisu dat. Metoda hledá projekci, která má velkou variabilitu mezi skupinami a zároveň variabilitu jedné třídy co nejmenší. Analýza nezávislých komponent (ICA) rozděluje signál na nezávislé složky. Pro klasifikace se používají neuronové sítě, metoda podpůrných vektorů a metoda nejbližších sousedů.[7]

## 3.2 Klasifikace signálu bez výběru příznaků

Pro klasifikaci signálu lze využít 1D konvoluční neuronovou síť, kde vstupem tohoto klasifikátoru je měřený signál o dané velikosti. Kratší signály jsou doplněny o nuly do požadované délky funkcí zero padding. Tento signál je zpravidla normalizován pomocí Z-skóre, které využívá průměru a směrodatné odchylky. Tyto parametry se odvíjejí od získaného signálu. Klasifikace je založena na použití hluboké neuronové sítě, zde je využita konvoluční neuronová síť. Architektura konvoluční neuronové sítě (CNN) je složena z vrstev konvoluční, poolingové a plně propojené vrstvy (viz.Obr 3.2). Krok udává délku okna pro filtraci. Pokud je krok roven 1, filtr se pohybuje od jednoho vzorku k dalšímu. Velikost okna 2 udává, že filtr se posouvá vždy o dva vzorky. Parametry jednotlivých sítí závisí na velikosti vstupního signálu a dané studie.[8, 9] Jednotlivé vrstvy CNN budou dále popsány (v kapitole 4.4). Možná architektura sítě je zobrazena na (Obr. 3.2).

## 3.3 Metody založené na vytvoření 2D příznakového pole.

Konvoluční neuronová síť byla původně vyvinuta pro klasifikaci obrazů. Vstupem je 2D příznakové pole. Pro barevné obrazy RGB, jsou na vstupu 3 příznakové mapy.




Obr. 3.2: Možná architektura 1D CNN, převzato z:[8]; layer představuje vrstvu, kde je uvedena délka vstupního signálu a počet filtrů nebo neuronů. Convolutions udává konvoluční vrstvu a fully-connected znamená plně propojená vrstva.


EKG signál je nutno převést do 2D příznakového pole. Každá informace, která slouží k rozlišení fibrilace síní a normálního signálu nebo flutteru síní lze použít jako příznak. Tyto příznaky je možno extrahovat přímo ze signálu v časové, frekvenční, popřípadě časově-frekvenční analýze. [14]

### 3.3.1 Navržená metoda využití EKG segmentů

Příznakové pole je vytvořeno z jednotlivých segmentů. Segment tvoří oblast, kolem R kmitů. Jednotlivé řádky tvoří vybrané úseky EKG na základě detekce R kmitů. Obrázek je složen z vybraných EKG svodů. Popsané R kmity jsou správně detekované, je ovšem nutno provést korekci jejich pozic. Detekované R kmity označují přibližnou pozici QRS komplexu, při vykreslení se segmenty jeví různě posunuty. Po úpravě je výsledné příznakové pole zarovnáno dle R vlny a ve středu se nachází analyzovaný R kmit.



Obr. 3.3: rozložení segmentů síňové fibrilace



Obr. 3.4: rozložení segmentů síňového flutteru

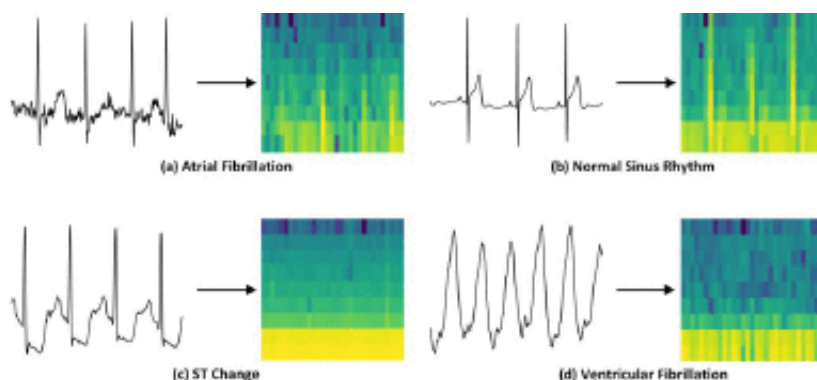
### 3.3.2 Spektrogram

Jedná se o časově-frekvenční analýzu signálu (viz.Obr. 3.5). Spektrogram určuje, jak se mění spektrum signálu v čase. Důsledkem různé morfologie síní a specifickému šíření vzruchu je průběh fibrilace síní různý. V signálu lze pozorovat různé charakteristiky této arytmie. Tyto příznaky a průběhy se projeví ve spektru zastoupením specifických frekvencí.

Signál je rozdělen na segmenty o délce  $N$ , jednotlivé segmenty se ovšem mohou překrývat. Okno, které určuje konkrétní segment, se posouvá po signálu. Pro výběr segmentu se používá především Hammingovo nebo Gausovské okno. Pro každou vybranou oblast se stanovuje spektrum. Spektra jsou uspořádána do matice, kde osa  $x$  představuje časovou složku, osa  $y$  frekvenci a osa  $z$  míru zastoupení dané frekvence. Matematicky je spektrogram definován takto: (viz.Eq 3.1)

$$STFT \{x[n]\} = X(m, \omega) = \sum_{n=-\infty}^{\infty} x[n] w[n-m] e^{-j\omega n} \quad (3.1)$$

, kde  $x[n]$  představuje EKG signál a  $w[n]$  je funkcí Hammingova okna. Pro dosažení dobrých výsledků je nutno zvolit správnou velikost okna. Je nemožné najít velikost okna, která by byla přesná jak pro frekvenční, tak i časovou složku. S rostoucí velikostí okna klesá časové rozlišení, zatímco frekvenční rozlišení roste.



Obr. 3.5: Spektrogramy, rozdílných arytmií

Spektrum diskrétního signálu (viz.Eq 3.2), které se podílí na vytvoření spektrogramu, je získáno pomocí diskrétní časové Fourierovy transformace (DTFT). Mezi vlastnosti DTFT patří inverzibilita, tedy ze spektra nelze získat signál zpět.

$$X(k) = \sum_{n=0}^{N-1} x(n) * e^{-j2\pi kn/N} \quad (3.2)$$

, kde  $x[n]$  představuje EKG signál a  $N$  udává počet vzorků. Pro klasifikaci pomocí STFT je využito 2D CNN.



### 3.3.3 Vlnková transformace

Hlavním využitím vlnkové transformace (WT) je zdůraznění různých detailů signálu. Nízké frekvence obsahují nejdůležitější části signálu. Vysoké frekvence poukazují na detaily. Vlnková transformace analyzuje signál na rozdílných frekvenčních pásmech za využití dekompozice. Výhodou je, že těsné okno dobře zobrazí detaily, tedy vysoké frekvence. Široké okno je vhodné pro reprezentaci nižších frekvencí. Hledanými detaily zde rozumíme příznaky pro klasifikaci vybraných arytmií. Pro získání validních příznaků se používá dyadická vlnková transformace (DWT) a kontinuální vlnková transformace (CWT).

Pro spojitě signály lze WT chápat jako korelaci signálu s vybranou bázovou funkcí  $\psi$ . Bázová funkce se mění s funkcí  $\lambda$ , která definuje měřítko bázové vlnky. S rostoucím  $\lambda$  roste roztažení vlnky, vlnka je roztažena  $\lambda$ -krát. Funkce  $\vartheta$  reprezentuje posun vlnky (viz.Eq 3.3).[14]

$$y(\lambda, \vartheta) = \frac{1}{\sqrt{\lambda}} \int_{-\infty}^{\infty} x(t) \psi * \left( \frac{t - \vartheta}{\lambda} \right) dt \quad (3.3)$$

,kde  $x(t)$  je analyzovaný signál,  $\psi$  odpovídá vybrané vlnce,  $\vartheta$  reprezentuje posun na časové ose a  $\lambda$  je měřítko.

Diskrétní vlnková transformace, tzv. dyadická DTWT, je realizována bankou diskrétních spojitých oktávových filtrů. Jednotlivé filtry tvořící horní a dolní propusti jsou zrcadlové. V mnohých studiích zaměřených na tuto problematiku se využívá rychlá DTWT, kde je signál podvzorkován neprodleně po filtraci. Často využívaná je taktéž kontinuální vlnková transformace (CWT), kde není využito podvzorkování signálu. Každý rozklad zachovává stejný počet vzorků. [11, 12]

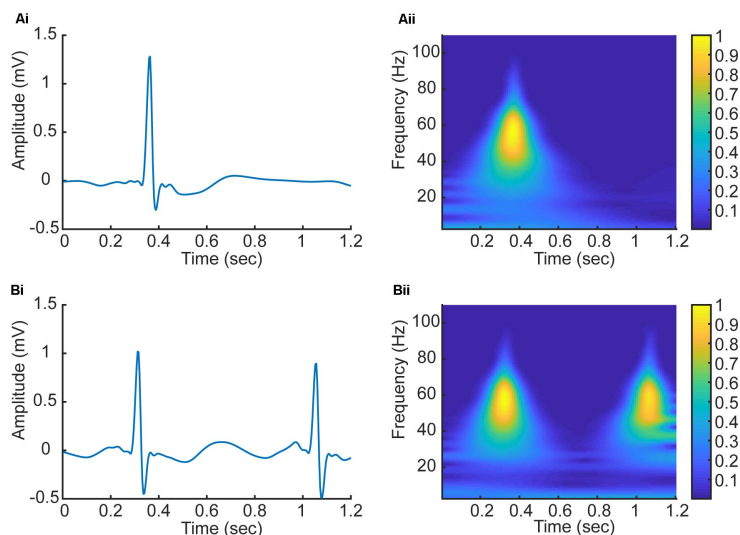
Studie [12] využívá CWT s typem vlnky db5. Obrázek níže ukazuje rozdíl mezi 2D vzory transformace CWT z fyziologického ekg a signálu s fibrilací síní. Osa  $x$  představuje časovou složku a osa  $y$  reprezentuje frekvenci (viz.Obr 3.6). Kratší vlnky mají širší spektrum posunuté k vyšším kmitočtům s lepším rozlišením vysofrekvenčních změn. Šíře vlnky nebo rozsah filtrů se mění dle rozkladu. Při STFT je zachována délka okna. [12]

## 3.4 Klasifikace pomocí RR intervalů

Tato metoda zahrnuje určení R kmitů, které jsou detekovány. Interval RR je určen pomocí vzorce (viz.Eq 3.3).

$$RR(n) = \frac{R(n) + 1 - R(n)}{f_s} \quad (3.4)$$

, kde  $RR(n)$  představuje délku RR intervalu a vzorkovací frekvenci reprezentuje ( $f_s$ ). Pro klasifikaci je navržena síť hlubokého učení, která je složena ze dvou částí. První



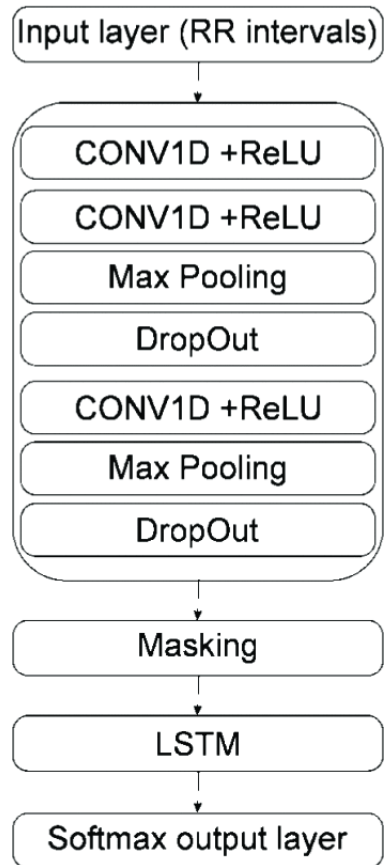
Obr. 3.6: CWT fyziologického ekg a signálu s fibrilací síni, převzato z:[12]

část sloužící pro zpracování příznaků představuje 1D CNN, dále je pro klasifikaci zahrnuta long short-term memory (LSTM) s poslední vrstvou Softmax. (viz.Obr 3.7). [13]

### 3.5 Klasifikace prostřednictvím modulů, které reprezentují specifické vlastnosti EKG

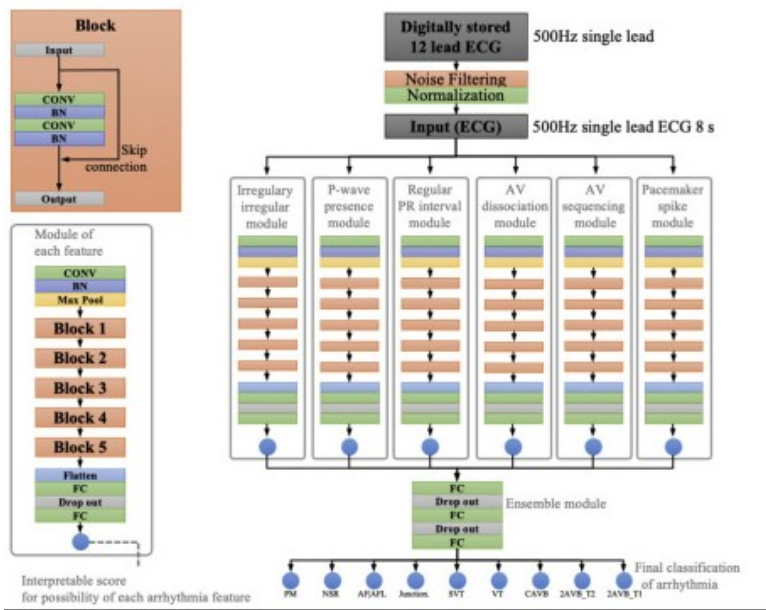
Předzpracování bylo realizováno odebráním jedné sekundy originálního signálu na jejím počátku a konci, jelikož zde se nachází nejvíce chyb měření. V této studii jsou vytvořeny moduly pro určení příznaků. (viz.Obr 3.8)Jednotlivé moduly reprezentují určité vlastnosti EKG [14]. Určují přítomnost P vln, pravidelnost RR intervalů, atrioventrikulární disociace, atrioventrikulární sekvenování a přítomnost stimulace kardiostimulátoru. Každý modul byl vyvinutý pomocí pěti bloků konvolučních vrstev. Ve zbytkových vrstvách bloků, jsou dvě konvoluční a normalizační vrstvy. Každý modul reprezentuje pravděpodobnost pro vybranou arytmii. Ve výstupním uzlu byla použita funkce Softmax. Pravděpodobnost výskytu jednotlivých arytmii je určeno vícevrstevným perceptronem.

Autoři studie pracují s daty, kde se nachází popis signálu dle požadavků modulů. Takovéto data nemáme k dispozici. Ovšem lze uvažovat vytvoření jednoho modulu, reprezentující typické znaky vybraných arytmii.[14]



Obr. 3.7: Popis navržené konvoluční sítě, převzato z:[13]

A. Explainable deep learning model



Obr. 3.8: Moduly reprezentující určité rysy signálu, převzato z:[14]

## 4 Klasifikátory hlubokého učení pro klasifikaci arytmií

Klasifikátory slouží k vyhledávání vzorů, extrakci, predikci, rozhodování. Dosahují vyšší přesnosti než mělké modely jako SVM. Mezi klasifikátory pro hluboké učení patří vícevrstvý perceptron (MLP), CNN, rekurentní neuronová síť (RNN), deep belief network (DBN) a omezený Boltzmanův stroj (RBM).

### 4.1 Vícevrstvý perceptron

Neuronová síť lze přirovnat k spojení neuronů v mozku. Oproti jednoduchým klasifikátorům umí tato síť řešit nelineární problémy. S rostoucím počtem vrstev lze řešit komplexnější problémy. Již trojvrstvá síť dokáže řešit většinu klasifikačních problémů. Geometricky si lze perceptron představit jako přímku rozdělující prostor. V neuronové síti perceptrony tvoří jednotlivé vrstvy. Perceptron v předchozí vrstvě je propojen se všemi ve vrstvě následující. První vrstva se nazývá vstupní a poslední, výstupní, vrstva udává konkrétní výstup. Vrstvy uprostřed se nazývají vrstvy skryté. Základní jednotkou je jednoduchý neuron, který je matematicky definován takto:


$$y = F \left( \sum_{i=1}^n x_i w_i + b \right) \quad (4.1)$$

, kde  $F$  představuje aktivační funkci,  $x(i)$  daný vstup,  $w(i)$  váhy neuronu a  $b$  je práh. Pro účely MLP se nejčastěji používá sigmoidní funkce (viz. Obr 4.1). Předpokládá se, že vstupní data jsou škálována. Prah je určen hodnotou  $b$ . Mnohdy se práh neuvádí, jelikož je součástí vah a tvoří rozšířené vektory.

Delta pravidlo určuje chybu na výstupu, jedná se o rozdíl očekávané a aktuální hodnoty. Tato chyba se rozdělí mezi neurony v poměru jejich vah. Pro optimalizaci neuronové sítě se často používá např. metoda gradientního sestupu či jiná metoda pro optimalizaci (viz. Optimalizační algoritmy). Gradient definuje směr nejstrmějšího růstu chyby klasifikátoru.


### 4.2 Rekurentní neuronové sítě

Jedná se o rozšíření umělé neuronové sítě, jejíž váhy jsou v čase sdíleny. K ANN je přidán minimálně jeden spoj, který má opačný směr. Model je vhodný pro klasifikaci časově označených dat, kde je výstup znovu přiveden na vstup a výstupem je odhad dalších čísel řady (viz. Obr 4.2). Trénování RNN je pomocí algoritmu zpětného šíření



Obr. 4.1: Sigmoidální transformační funkce

chyby, kde je využit descentní gradient. Problém může vznikat v rekurentní části sítě, kde se váhy nerovnejí jedné. [21]



Obr. 4.2: Rekurentní neuronová síť, převzato z:[21]

#### 4.2.1 Radial basis function network (RBF síť)

Vstupní vrstva se výrazně liší od standardního ANN přístupu. Tato vrstva je definovaná kernelovou aktivační funkcí. Vstupem funkce je rozdíl vstupu od středu neuronu, středem se rozumí centroid. Vysoké hodnoty budou dosahovat hodnoty blízké středu neuronu. Učení RBF sítě ve dvou krocích. Prvně je určen střed neuronů a je spočítán parametr  $\beta$ , který vychází z průměrné vzdálenosti bodů ve shlucích od

centroidu ke středů. Parametr  $\beta$  je součástí kernel aktivační funkcí. Posléze jsou nastaveny váhy dalších vrstev, například gradientní metodou. Vstupní vrstvu zpravila následuje pouze jedna výstupní vrstva.[21]

### 4.3 Long short-term memory

V rámci této sítě je neuron nahrazen blokem s pamětí. Paměťový blok obsahuje jednu či více paměťových buněk a dvě adaptivní multiplikativní brány, které představují vstupní a výstupní váhy. Paměťové bloky uchovávají důležité informace a aktualizují je dle vstupních a zapomínajících bran. (viz.Obr 4.5) Brány řídí vstup a výstup informací z paměťových buněk. Vstupem do buňky je vždy její předchozí stav. Hodnoty bran  $h(n)$  jsou počítány ze vstupních dat, vah jednotlivých bran a předchozího stavu  $h_{n-1}$  dle aktivační funkce sigmoidy. Kandidát  $\tilde{C}$  (viz.Eq 4.2) na nový stav buňky  $C$  je dán vstupy a předchozím stavem  $h_{n-1}$ , definován vahou a prahem pro výpočet stavu.

$$\tilde{C}_n = \tanh \left( b_c + w_c^T [h_{n-1}] + u_c^T x_n \right) \quad (4.2)$$

Nový stav buňky je definován jako: (viz.Eq 4.3)

$$C_n = f_n c_{n-1} + i_n \tilde{C}_n \quad (4.3)$$

Výstup buňky  $h_n$  je dán stavem buňky a výstupní bránou.


$$h_n = o_n \tanh(c_n) \quad (4.4)$$

Brány  $f_n, i_n, o_n$ , reprezentují zapomínací bránu, vstupní bránu a výstupní bránu(viz.Eq 4.4). [15, 21]

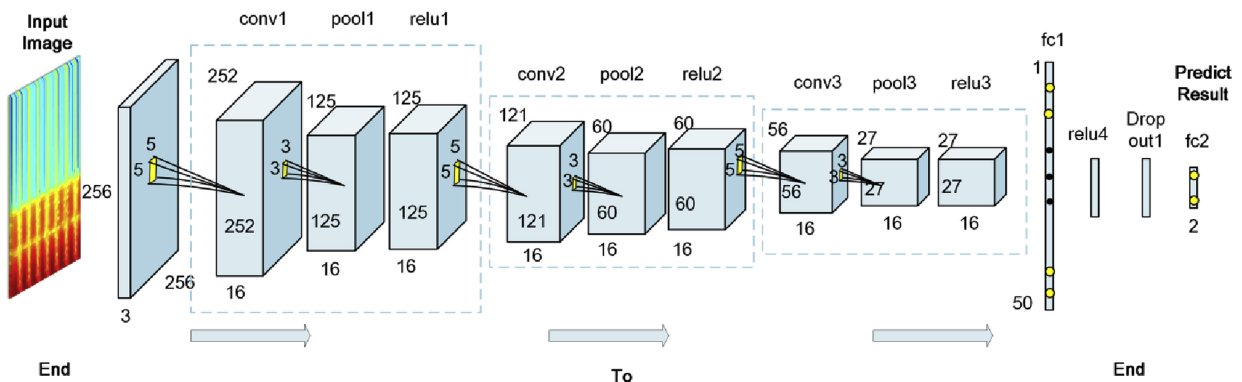
Obdobou této metody je gated recurrent unit (GRU), která využívá pouze vstupní a výstupní bránu. Nový stav je definován pomocí interpolace mezi předchozím stavem a kandidátem na nový stav. Tato metoda má menší výpočetní náročnost než LSTM. [21]

### 4.4 Konvoluční neuronová síť (CNN)

Konvoluční neuronové sítě byly původně navrženy pro zpracovávání obrazů, ovšem mají velké využití v segmentaci a klasifikaci 1D signálů. Oproti ANN má nižší výpočetní náročnost, jelikož každý neuron je propojen pouze s lokálním okolím nikoli s každým neuronem předešlé vrstvy. Signifikantním rozdílem oproti přístupu ANN je využití konvoluce oproti skalárnímu součinu.



Obr. 4.3: Architektura LSTM, převzato z:[15]



Obr. 4.4: Architektura CNN, převzato z:[10]


Konvoluční neuronová síť je schopna využít prostorovou nebo časovou strukturu v datech. [15, 16] V CNN je každý neuron v první skryté vrstvě spojen s určitou oblastí vstupních dat. Každé propojení má určitou váhu. Ve skrytých vrstvách jsou extrahovány určité detaily. Váhy pro každý neuron jsou sdíleny, tedy hluboká vrstva má jednu sadu vah a posun.

Architektura konvoluční neuronové sítě je dána kombinací konvolučních, poolin-  
gových, plně propojených a drop out vrstev. V poslední plně propojené vrstvě je stejný počet neuronů jako je počet tříd pro klasifikaci. Výsledkem je pravděpodobnost zařazení do dané třídy.



### 4.4.1 Konvoluční vrstva

Konvoluční vrstvu lze považovat za fuzzy filtr [16], který může zlepšit vlastnosti signálů. Jedná se o konvoluci příznakového vektoru s konvolučním jádrem. Aktivační funkce určuje výsledek této vrstvy. Parametr kernel představuje velikost jádra. Určuje velikost masky, která klouže po signálu či obrazu. Krok určuje pohyb kernel okna po signálu nebo obrazu. Pokud je krok roven jedné, filtr se pohybuje od jednoho vzorku k dalšímu (viz. Obr 4.5). Hloubka udává počet konvolučních vrstev a je závislá na počtu neuronů předchozí vrstvy. [15, 18]



Obr. 4.5: 1D konvoluce, kernel = 3, krok = 1 s váhami pro  $i$ -tý filtr, převzato z:[15]


Aktivační funkce je bodová transformace. Mezi aktivační funkce patří sigmoida, ELU, ReLu, tangens a prosakující ReLu. Aktivační funkce ReLu vybírá kladnou část jejího argumentu. Oproti ReLu aktivační funkce ELU obsahuje i záporné hodnoty s exponenciálním vyhlazením. V poslední vrstvě klasifikační sítě se používá zejména funkce softmax, jelikož udává pravděpodobnost zařazení signálu do dané třídy. Funkce softmax reprezentuje exponenciálu dané hodnoty dělená exponenciálám celého vektoru. V ostatních vrstvách se používá aktivační funkce ReLu, popřípadě její variace (viz. Obr 4.5). [19]

Funkce zero-padding rozšiřuje obraz nebo signál o nuly na okrajích před konvolucí. Využívá se, pokud velikost masky a krok neodpovídají velikosti obrazu na vstupu. [15]

### 4.4.2 Poolingová vrstva

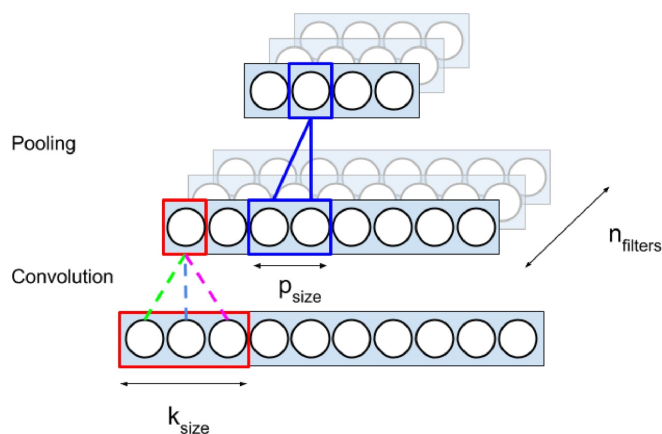
Zde dochází k redukci dat, snížení výpočetní náročnosti a předchází tak přeučení modelu. Parametr kernel opět představuje velikost okna pro podvzorkování (viz. Obr 4.7). V EKG zpracování se především používají okna velikosti 2 s krokem 2, výstupem je příznakové pole s poloviční velikostí. Pokud by krok byl roven 1, výstup je dán velikostí vstupu -1.

Průměrný pooling udává průměrnou hodnotu v kernelu, zatímco maximální pooling udává maximální hodnotu v okně. [15, 16] Na obrázku (viz. Obr 4.7) parametr



Obr. 4.6: Aktivační funkce ReLu

$p$  reprezentuje velikost poolingového okna,  $k$  je velikost kernelu konvoluční vrstvy a  $n$  reprezentuje počet neuronů;



Obr. 4.7: Poolingová vrstva, převzato z:[15]

### 4.4.3 DropOut vrstva

Jedná se o vrstvu, která funguje jako regularizátor proti přeučení. Stochasticky nastavuje na nulu určité aktivace skrytých vrstev v průběhu trénování. Tato vrstva velice dobře funguje v kombinaci s plně propojenou vrstvou. Její použití je možné i pro poolingové vrstvy. [20]

#### **4.4.4 Plně propojená vrstva**

Po extrakci příznaků je nutno klasifikovat data do odpovídajících tříd. Výstup bývá zploštěn. Data jsou upravena do vektoru příznaků. Zde se využívá plně propojená vrstva. Neurony v této vrstvě jsou připojeny ke všem aktivacím předchozí vrstvy. Slouží pro klasifikaci extrahovaných příznaků. Pro výstupní klasifikaci je možno použít i jiný klasifikátor, jako například SVM. [16, 21]

### **4.5 Deep belief network**


Tato síť je tvořena několika vrstvami RBM a Bayesovou sítí. Horní vrstvy jsou složeny z RBM. Učení postupuje po vrstvách od spodní k vrchní vrstvě, využívá se wake-sleep algoritmus. Učení této sítě je velice náročné a je obtížné správně nastavit dané parametry. [21]



## 5 Optimalizační algoritmy

Optimalizační algoritmy slouží pro nalezení nejlepšího možného minima dané funkce.

Společným parametrem pro všechny optimalizační metody je  $\mu$  – tzv. krok učení. Nastavení kroku učení je zásadní pro správnou optimalizaci celého učení navržené sítě. Pokud je krok příliš velký, může dojít k explodujícímu gradientu. Chybové gradienty se mohou hromadit, takto nahromaděné gradienty vedou k velkým změnám vah. Pokud je krok učení zvolen malý, trénování sítě bude trvat dlouhou dobu a také řešení může uvíznout v lokálním minimu (viz. Obr 5.1). Neexistuje shoda o obecně nejlepším optimalizačním algoritmu. V současné době mezi nejpoužívanější optimalizační algoritmy patří algoritmy typu stochastický gradientní sestup (SGD), root mean square propagation (RMSProp), adaptivní krok učení (AdaDelta) a odhad adaptivní hybnosti (ADAM). [16]




Obr. 5.1: Příklad kriteriální funkce, převzato z: [16]; osy x a y představují vývoj funkce v čase

### 5.1 Gradientní sestup

Jedná se o optimalizační algoritmus diferencovatelné funkce. Gradient udává směr nejvyššího růstu. Pohyb je dán zvoleným krokem a záporným gradientem. Váhy se mění po epoše učení, tedy po předložení veškerých dat. **SGD**, jedná se o velice často používanou variantu gradientního sestupu. Váhy jsou aktualizovány po proběhnutí učení na části vzorků. Dochází tak k rychlejší konvergenci ke globálnímu minimu. [16, 19]

## 5.2 Hybnost

Vychází z fyzikálního konceptu hybnosti, kterou lze vypočítat jako hmotnost násobenou rychlostí. Je zaveden parametr v určující směr a rychlost, kterou se parametry pohybují parametrickým prostorem. Rychlost udává exponenciálně klesající průměr negativních gradientů. Hybnost ve fyzice je hmotnost násobená rychlostí. Předpokládáme jednotkovou hmotnost, vektor rychlosti lze chápat jako hybnost. Parametr  $\alpha$  určuje, jak rychle se příspěvky předchozích gradientů exponenciálně snižují. Na obrázku (viz. Obr 5.2), je červeně zobrazena cesta dle pravidla hybnosti. Oproti gradientním krokům neztrácí čas pohybem tam a zpět přes kriteriální funkci.



Obr. 5.2: cesta dle pravidla hybnosti, převzato z: [16]; osy x a y představují prostorové souřadnice

## 5.3 Adaptivní gradient

Pro každou váhu definuje krok učení, který se během učení mění. Parametry s velkou parciální derivací kriteriální funkce mají rychlý pokles učebního kroku. Gradient se akumuluje, kterým se dělí učební krok. Při vysokém gradientu se váhy přestanou měnit.

## 5.4 Odhad adaptivní hybnosti, dále ADAM

Výhodou této optimalizační metody je malá výpočetní a paměťová náročnost. Tato optimalizace je vhodná pro práci s rozsahlými daty a velkým množstvím nastavitelných parametrů. Optimalizace vyhodnocuje adaptivní rychlost učení pro jednotlivé

parametry. Jedná se o kombinaci exponenciální zapomínajícího gradientu a exponenciální zapomínání hybnosti. Zavádí se dva nové parametry  $\beta_1$  a  $\beta_2$ .  $\beta_1$  reprezentuje parametr zapomínání hybnosti a  $\beta_2$  reprezentuje zapomínání gradient. Metoda zahrnuje korekci biasu. Optimalizace je považována za velice odolnou vůči výběru parametrů. [16, 19]

## 5.5 Genetické algoritmy

Jedná se o heuristický postup využívající principu evoluce. Počáteční populace řešení se vyvíjí v čase vlivem selekce, křížení a mutace. Jsou schopny prohledávat a využívat prohledávací prostor efektivně. Ovšem zkoumá různé kombinace, tudíž je model zatížen časovou náročností.[16, 22]





## 6 Praktické kroky práce

V rámci této práce je podrobně popsána navržená metoda klasifikace fibrilace síní, flutteru síní a sinusového rytmu pomocí 1D CNN včetně realizace vícero přístupů ke klasifikaci. Dále jsou realizovány dva pokusy o rozlišení fibrilace síní a flutteru síní, pomocí 2D CNN spektrogramu a zarovnaných segmentů EKG. Metoda klasifikace pomocí spektrogramu dává z hlediska realizace CNN velký smysl, bohužel se ukázala jako nepříliš účinná.

### 6.1 Data pro zpracování

Pro řešení této problematiky jsou k dispozici data ze dvou databází.

#### 6.1.1 Databáze ÚBMI

Tato databáze obsahuje 60579 záznamů EKG. Každé EKG obsahuje vlastní anotaci se zařazením do daných tříd. Třídy jsou seřazeny dle rytmu a morfologie. Mezi morfologické znaky patří AV bloky prvního až třetího stupně, sinoatriální blok, síňové a komorové extrasystoly a jejich typ, blokády ramének, infarkt myokardu, nespecificky intraventrikulární blok a preexcitace komor. Do podskupiny rytmů se řadí sinusový rytmus, fibrilace síní, flutter síní, síňový rytmus, supraventrikulární rytmus, junkční rytmus, komorový rytmus, komorová stimulace, tachykardie a bradykardie. Jednotlivým datům může náležet vícero diagnóz. Například trigemie je vždy součástí extrasystol. Signály jsou uloženy v CSV souboru, k dispozici je vždy svod II. Vybrané signály obsahují i svod I a aVF. Vzorkovací frekvence je 250 Hz. V datovém formátu JSON jsou uloženy popisy daných signálů. K dispozici jsou pozice detekovaných QRS komplexů, informace o měření, datum měření, identifikace zařízení. Dále obsahují ID pacienta, věk, pohlaví. V databázi se nachází 1085 EKG záznamů flutteru a 10248 záznamů fibrilace síní. Sinusový rytmus je zastoupen u 46788 signálů. Signály FIS a FLUT mají délku zpravidla 20 nebo 60 sekund. Při vzorkovací frekvenci 250 Hz se jedná o signály délky 5000 a 15000 vzorků. Jen několik málo signálů je kratších, nebo přesahuje uvedenou délku. V EKG databázích je obecně malý výskyt signálů s flutterem síní. Některé databáze obsahují vyšší počty signálů, je ovšem nutno podotknout, že se jedná o několik málo dlouhých signálů, které jsou roztrženy na kratší. Takto vytvořená databáze nemůže poskytnout relevantní výsledky pro klasifikaci, jelikož testovací množina je podobná od množiny trénovací. Taktéž signály stejného pacienta snímané stejným zařízením pouze v různých časových intervalech nepřinášejí nové validní informace. V této databázi se nechází signály naměřené na různých přístrojích a nestejných pacientech.

## 6.1.2 Databáze II

Tato databáze obsahuje pouze EKG záznamy síňové fibrilace a flutteru. Signály jsou rozděleny do dvou složek, dle arytmií. Data jsou uložena v souborů XML. Počet EKG záznamů s fibrilací síní je 3293 a záznamů obsahující flutter je 195. Hlavička souboru obsahuje ID pacienta, popis symptomů, věk pacienta, čas měření, délku měření, vzorkovací frekvenci. Posléze soubor obsahuje data II svodu a pozice R kmitů. Délka záznamů je 40 sekund. Ojediněle se vyskytují i kratší signály.

## 6.2 Realizace prostřednictvím spektrogramu a vytvoření zarovnaných segmentů signálu

### 6.2.1 Výběr příznaků


Vybraný EKG signál tvoří vlastní třídu `Signal`. Vstup třídy tvoří index signálu a vybranou složku. Třída signálu obsahuje metody pro zobrazení signálů, vytvoření spektrogramu, zarovnání segmentů a výběr hlavních komponent signálů pomocí PCA analýzy. Pro realizaci těchto metod třída využívá funkce pro načtení jednotlivých dat, filtraci, korekci R kmitů, vytvoření spektrogramu a zarovnání segmentů. Jednotlivé metody jsou složeny převážně z kombinací jednotlivých funkcí.

**Filtrace** slouží k potlačení nežádoucích složek signálu. Nulové izolinie je dosaženo pomocí dvou mediánových filtrů (viz. filtrace 1D CNN). Pomocí adaptivního filtru je potlačena výrazná 50 Hz složka (viz. Obr 6.1).


**Výběr dat** je realizován pomocí funkce pro načtení dat využívá knihovnu **minidom** sloužící k extrakci dat ze souboru JSON, XML a YAML. Detekované R kmitu u krajů signálu nejsou vybrány z důvodů nemožnosti vytvoření okna, pro následné zpracování a taktéž kraje originálních signálů jsou zatíženy větším množstvím šumu. **Zarovnání segmentů** využívá funkci **posun**, pracuje s detekovanými pozicemi R kmitů. Tyto pozice jsou anotovány ručně, pro zarovnání segmentů je nutno vytvořit jejich korekci. Korekcí rozumíme prohledávání blízkého okolí vybraného kmitu a stanovení náležité pozice kmitů R po korekci.

**Vytvoření 2D příznakového pole ze zarovnaných segmentů.** Funkce **obraz** vytváří ze signálu příznakové pole segmentů. Příznakové pole obsahuje zarovnané segmenty, přičemž maximální počet segmentů je 50 a délka jednoho je 3,2 sekundy. Ze signálů s větším počtem R kmitů, je vybráno pouze 50 segmentů. Neúplné příznakové pole, které vznikne z kratších signálů a je doplněno o nuly.

Obrázky (viz. Obr 6.2 a Obr 6.3) demonstrují rozdíly v rozložení segmentů síňové fibrilace a flutteru.



Obr. 6.1: Filtrace brumu pomocí adaptivního filtru



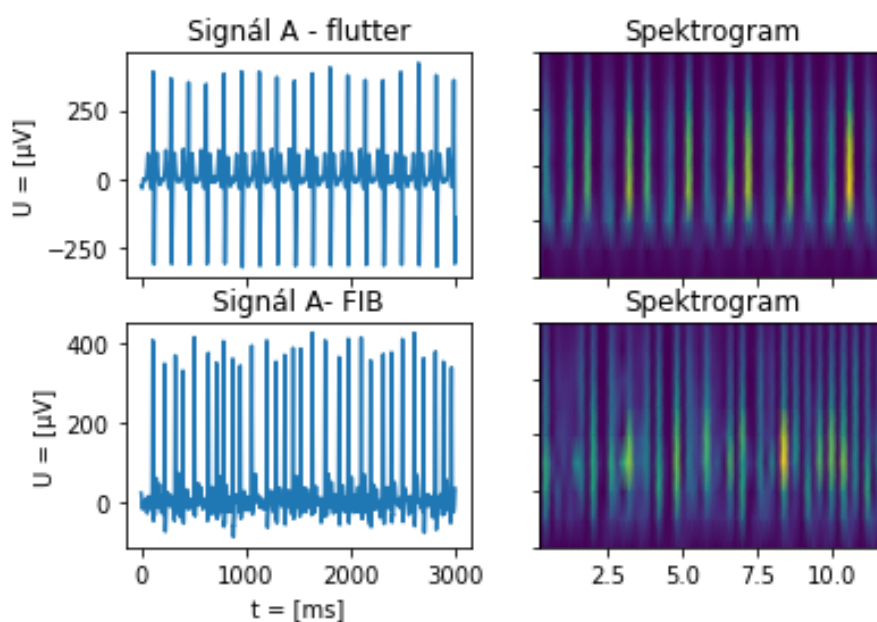
Obr. 6.2: Rozložení segmentů síňové fibrilace

Funkce **spektrogram** vytvoří a upraví daný spektrogram. Jedná se o časově-frekvenční analýzu signálu. Spektrogram určuje, jak se mění spektrum signálů v čase (viz. Kapitola 3.3.2). K vytvoření spektrogramu je použita knihovna **signal**. Výběr segmentu je realizováno pomocí Hammingova okna, délka segmentů je 100 vzorků s přesahem 50 vzorků. Zobrazeny jsou pouze frekvence v rozmezí 0 – 40 Hz. Vyšší frekvence nepřinášejí další informace k této klasifikaci. Výsledný obraz má délku 59 pixelů a výšku 18 pixelů. Rozdíl mezi spektrogramy fibrilace síní a flutteru



Obr. 6.3: Rozložení segmentů síňového flutteru

je zobrazen (viz.Obr 6.4).



Obr. 6.4: Vytvořené spektrogramy

## 6.2.2 Klasifikátor

Další třídu tvoří klasifikátor. Vstupními parametry jsou předzpracovaná data a hyperparametry pro možnou optimalizaci. Metody této třídy slouží pro vytvoření, zobrazení navrženého modelu, trénování sítě a následně testování modelu.

Pro výběr relevantních příznaků slouží 2D CNN zapojena jako kodér a pro klasifikaci neuronová síť. Model je vytvořen pomocí struktury Sequential (Viz. Tab.6.1. Klasifikátor je složen ze dvou 2D konvolučních vrstev, mezi nimiž je vrstva batch normalizace. Následuje vrstva max poolingová. Posléze klasifikátor obsahuje sérii dvakrát opakující se 2D konvoluční a max poolingové vrstvy.

Realizace prostřednictvím spektrogramu					
	vrstva	počet filtrů	kernel	krok	aktivační funkce
	2D konvoluce	16	5x5	1	L ReLu
	vrstva batch normalizace				
KODÉR - 2D CNN	2D konvoluce	32	3x3	1	L ReLu
	max pool	-	2x2	2x2	-
	2D konvoluce	64	3x3	1	L ReLu
	max pool	-	2x2	2x2	-
	2D konvoluce	128	3x3	1	L ReLu
	max pool	-	2x2	2x2	-
	vrstva flatten				
ANN	vrstva	počet neuronů			
	plně propojená	128			L ReLu
	plně propojená	30			L ReLu
	plně propojená	2			SoftMax

Tab. 6.1: Struktura 2D CNN

Parametry konvolučních a plně pojených vrstev jsou inicializovány pomocí Xavier inicializace, rovněž tyto vrstvy pracují s aktivační funkcí prosakující ReLu, kde nastaven parametr sklonu  $\alpha = 0,1$ . Aktivační funkce Leaky ReLu vychází z ReLu. Oproti ReLu může obsahovat jisté záporné hodnoty dle nastaveného sklonu. Využití této aktivační je z důvodu zpětného učení, kdy nedochází k vymizení gradientu. Počet filtrů v konvolučních vrstvách je 16, 32, 64 a 128. Velikost masky je vždy 3x3. Výjimku tvoří vstupní vrstva s velikostí masky 5x5. Je nastaven paddnig, před samotnou konvolucí je vstup rozšířen o 0 na okrajích. Velikost masky pro max poolingovou vrstvu je vždy velikostí 2x2. Před podvzorkováním je obraz rozšířen o 0 na okrajích. Krok je ponechán na defaultním nastavení, tedy dle velikosti masky. Vybrané příznaky jsou seřazeny do vektoru pomocí funkce flatten. Popis jednotlivých vrstev je k dispozici v kapitole 4.4. Samotná klasifikace vybraných příznaků je tvořena plně propojenými vrstvami. Počet neuronů v jednotlivých vrstvách je 128 a 30. Poslední vrstva obsahuje 2 neurony a funkci softmax, pro určení pravděpodobnosti zařazení signálu do dané třídy.

Výpočet chyby je dán pomocí kategoriální křížové entropie. Optimalizační funkcí je ADAM (viz. Kapitola 5.2), kde krok učení  $\mu = 0.001$ , parametr určující exponenciální zapomínání gradientu  $\beta_1 = 0,9$  a proměnná určující exponenciální zapomínání hybnosti  $\beta_2 = 0,99$ . Velikost batche je 64, navržené síti je v každém kroku předkládáno 64 signálů. Počet epoch učení je 5.

Klasifikace s využitím spektrogramu dosahuje přesnosti ACC = 66 %. Pro fibrilaci síní přesnost ACC = 64 % a senzitivita SE = 75 %. Klasifikátor detekuje flutter s přesností ACC = 70 % a senzitivitou SE = 57 %. Konvoluční neuronová síť pro klasifikaci zarovnaných segmentů má velice podobný charakter s navrženou sítí pro klasifikaci spektrogramu. Změna je pouze v počtu filtrů a počtu neuronů v plně propojených vrstvách Tato metoda dosahuje pouze přesnosti ACC = 63 %. Tato metoda není vhodná, jelikož senzitivita pro klasifikaci flutteru nedosahuje více jak 40 %.

## 6.3 Realizace prostřednictvím 1D CNN

Výběr příznaků je realizován pomocí 1D CNN vytvořené jako kodér. ANN slouží ke klasifikaci signálů do dané třídy.

### 6.3.1 Definice problematiky

V databázi ÚBMI je obsaženo pouze 1085 signálů EKG s fibrilací síní. Jedná se o EKG záznamy pacientů z různých pracovišť. V této práci pro klasifikaci je využito právě pouze 1085 signálů pro každou klasifikační skupinu. Testovací sada dat je zastoupena rovnoměrně z důvodu spolehlivé interpretace výsledků. Rovnoměrné rozdělení trénovací množiny dat umožňuje vhodné nastavení modelu, bez upřednostnění jedné z klasifikačních skupin. Data jsou uložena v sedmi složkách, kde každá složka obsahuje anotaci dat ve formátu JSON. Zatímco samotné signály jsou zapsány ve formátu CSV. Cílem této práce je vytvořit klasifikátor pro klasifikaci fibrilace síní, flutteru síní a sinusového rytmu.

### 6.3.2 Výběr dat

Každá klasifikační skupina obsahuje list, který slouží pro uložení názvu požadovaných signálů. V prvním kroku jsou v cyklu for otevřeny veškeré anotace z dostupných složek a ty jsou posléze procházeny. Informace o signálech jsou zapsány v datovém typu slovník, kdy klíč je názvem signálu a hodnoty udávají vybrané klasifikační třídy. Pokud hodnota slovníku pro daný signál obsahuje vybranou klasifikační skupinu, vhodný list je rozšířen o tento název signálu. Jednotlivé listy s názvy signálů

jsou zamíchány a upraveny na velikost nejméně obsažené skupiny, zde flutteru síní. Z následujících listů obsahující názvy signálu tříd je složena trénovací a testovací množina dat následujícím způsobem. Testovací množina je vytvořena z posledních částí vybraných listů, konkrétně se jedná o 100 signálů (viz.Obr 6.5).


SESTAVA DAT					
TŘÍDA	TRENOVACÍ SADA				TEST. SADA
1	a	b	c	d	e
2	a	b	c	d	e
3	a	b	c	d	e
Výstup					
a <sub>1</sub> b <sub>1</sub> c <sub>1</sub> d <sub>1</sub> a <sub>2</sub> b <sub>2</sub> c <sub>2</sub> d <sub>2</sub> a <sub>3</sub> b <sub>3</sub> c <sub>3</sub> d <sub>3</sub>					e <sub>1</sub> e <sub>2</sub> e <sub>3</sub>

Obr. 6.5: Sestavení datasetu

### 6.3.3 Jednotlivé funkce pro zpracování signálů.

Funkce **filtrace** je využita k potlačení nežádoucích složek signálu. Pro klasifikaci arytmií pomocí CNN není pravidlem složité předzpracování dat. Mnohé studie zaměřené na tuto problematiku pracují s naměřenými daty. Vstupem a výstupem této funkce je EKG signál uložen jako 1D vektorové pole. Vybrány filtr je zaměřen na odstranění kolísání nulové izolinie. Pomocí dvou mediánových filtrů o délce oken 800 ms a 440 ms byla získána izolinie. Hodnoty časových oken mediánových filtrů byly stanoveny experimentálně. Tato izolinie je odečtena od originálního signálu. Výsledkem je signál s nulovou izolinií (viz.Obr 6.6). Dalším realizovaným filtrem je adaptivní filtr pro potlačení výrazné 50 Hz složky. Z důvodu vysoké časové náročnosti a signálu bez výrazného rušení elektrického vedení není tento filtr aplikován. Pro práci se signály z databáze II je tento filtr vhodný.

Načtení vybraného EKG signálu je realizováno funkcí **nacti\_data**. Vstupem této funkce je pořadí signálu a klasifikační třída. Ze zadaného vstupu je znám název signálu. Z konkrétního názvu signálu jsou vybrány první dvě písmena, které odpovídají umístění daného signálu ve složkách. Realizovaná funkce k adresáři dat přidá vybranou složku a otevře daný signál. Pro načtení souboru CSV je použito knihovny Pandas. Soubor CSV zpravidla obsahuje několik sloupců, které reprezentují měřené svody EKG signálu. Některé soubory obsahují pouze jeden svod, konkrétně se jedná o analyzovaný svod II. Je vybrán druhý sloupec dat, který odpovídá svodu II. V případě, že není k dispozici více svodový záznam je vybrán první sloupec dat. Výstupem této funkce je již potřebný EKG signál. Velkou motivací je rozšířit vstupní dataset známých dat. Délka signálu není pravidelná a pohybuje se v rozsahu 14 až 60 sekund.



Obr. 6.6: Úprava izolinie signálu, pomocí mediánové filtrace

Vzorkovací frekvence je 250 Hz, počet hodnot signálu odpovídá délce 3 500 vzorků až 5 000 vzorků. Je velice málo pravděpodobné, že v signálu bude právě zachycen vznik či ukončení paroxysmálního projevu arytmie. Důvodem je krátké měření EKG s označením arytmie, paroxysmální arytmie trvá do 48 hodin. Hlavní myšlenkou je dlouhé signály rozdělit na kratší s fixní délkou a takto rozšířit data. Klasifikátor je vyhodnocen na rozšířené trénovací datové množině, ovšem finální klasifikace bere v úvahu vyhodnocení jednotlivých segmentů. Je zaveden nový vektor stříhu, který je stejné délky dle počtu rozšířených signálů. Na pozicích, kdy je vybrán nový signál, je zapsána logická jednička (viz.Obr 6.7).

SIGNAL	DÉLKA	ROZŠÍŘENÍ
1	3500	5000
2	15000	15000
3	9000	10000
4	7500	10000
VEKTOR STŘIHU =		11001010
POZICE =		12345678

Obr. 6.7: Princip ukládání dat

Další zpracování je provedeno pomocí funkce **zapis**. Vstupem funkce je EKG



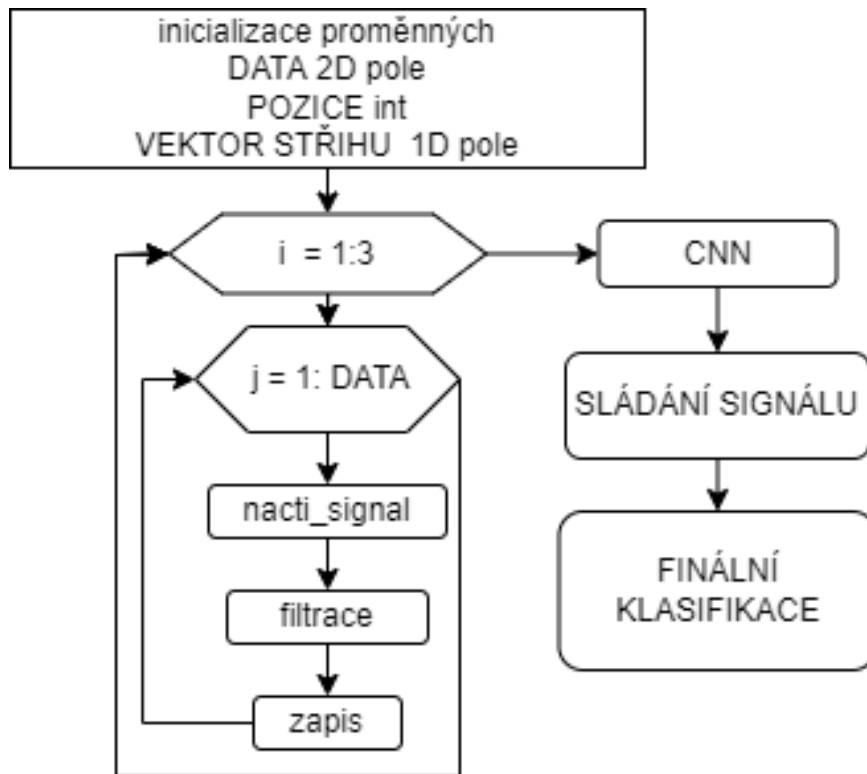
signál, vektor stříhu signálů, 2D pole signálů, typ vyplnění mezer pro kratší signály, pozice pro zápis a délka nových signálů. Vstupní signál je volán funkcí pro filtraci a je převeden na 1D list pro efektivní rozšíření na požadovanou délku. Signál je rozšířen přidáním požadovaného počtu nul. Požadavkem CNN je signál s fixní délkou vstupu. Většina realizací počítá s velikostí signálu 5000 vzorků. Z tohoto důvodu bude uvažována právě tato délka segmentu jako výchozí pro vytvoření klasifikátoru. Vstupní délka signálu je vydělena požadovanou délkou pro CNN. Následně je výsledek zaokrouhlen nahoru na celočíselnou hodnotu  $N$  a vynásoben požadovanou délkou. Rozdíl vypočtené hodnoty a vstupní délky je velikost rozšíření signálu. Signál je rozdělen na  $N$  segmentů, jednotlivé segmenty jsou uloženy do 2D struktury dat. Jestliže se jedná o první segment, na dané pozici vektoru stříhu je zapsána logická jednička. Výstupem funkce jsou aktualizované položky: 2D struktura uložených dat, vektor stříhu a pozice zápisu.

### 6.3.4 Program

V první části programu jsou načteny potřebné knihovny a funkce. Posléze je vytvořena 2D struktura pro zápis signálů o potřebné délce k dalšímu zpracování. Taktéž je iniciován vektor stříhu signálů a celočíselná hodnota pozice pro zápis do vytvořené struktury. Následují dva vnořené for cykly přes vybrané klasifikační třídy a trénovací množinu. V jednotlivých cyklech jsou volány funkce pro načtení, zpracování a zápis dat. Testovací množina je vybrána stejným způsobem. Data, která vstupují do klasifikátoru jsou náležitě upravena. Jsou převedeny do datového typu float32 a transformovány do tří rozměrné struktury. Zjednodušený algoritmus realizace je zobrazen na obrázku (viz. Obr 6.8).

Dále jsou vytvořeny tři vektory pro označená data. Jedná se o označení pro rozšířenou trénovací, testovací sadu a pro finální vyhodnocení testovací sady bez rozšíření. Signály s fibrilací síní jsou zapsány jako hodnoty logických nul. Flutter síní je zapsán hodnotou logická jednička a sinusový rytmus je zapsán hodnotou dva. Označená data jsou v třídě klasifikátoru převedena do one hot kodování.

Vytvořený klasifikátor je zapsán jako třída **CNN** s pěti metodami. Pro každou  $k$  - validaci je vytvořený nový klasifikátor, který je zapsán do nové dynamické proměnné `klas_0` - `klas_K-1`. První metoda je inicializační `__init__`, obsahuje veškeré hyperparametry pro optimalizaci. Mezi tyto parametry patří počty neuronů v plně propojených vrstvách, velikost batche, počet epoch. Do této metody jsou zapsány vstupní data pro klasifikaci a evaluaci s jejich štítky. V této části je definována inicializace vah pomocí algoritmu Xavier. Další metoda obsahuje vytvořený model klasifikátoru `get_model`. CNN je složena ze čtyřikrát se opakujících bloků složených z 1D konvoluční vrstvy s aktivační funkcí leaky ReLu a max poolingové



Obr. 6.8: Zjednodušený algoritmus klasifikace

vrstvy s velikostí okna 3. První konvoluční vrstva obsahuje 3 filtry, velikost okna 37. Druhá konvoluční vrstva obsahuje 10 filtrů, velikost okna je 27. Rozměr okna se s dalším zpracováním snižuje. V následující konvoluční vrstvě je okno délky 10 a posléze o rozsahu 6. Ve čtvrté max poolingové vrstvě je okno změněno na velikost 2 z důvodu vhodného rozsahu výstupního signálu. Následuje vrstva flatten, která vytváří příznakový vektor. ANN obsahuje tři plně propojené vrstvy s počty neuronů 10 a 5. Výstup poslední vrstvy určuje pravděpodobnost zařazení signálu do dané třídy. Obsahuje 3 neurony s aktivační funkcí Softmax. Popis modelu je znázorněn (viz. Tab 6.2).

Výpočet chyby je dán pomocí kategoriální křížové entropie. Optimalizační funkcí je ADAM (viz. Kapitola 5.2) s krokem učení  $\mu = 0.001$ . Parametr určující exponenciální zapomínání gradientu  $\beta_1 = 0,4$  a proměnná určující exponenciální zapomínání hybnosti  $\beta_2 = 0,45$ . Velikost batche je 32, tedy navržené síti je v každém kroku předkládáno 32 signálů. Veškeré váhy jsou iniciovány zavedeným algoritmem Xavier.

V další metodě se spouští učení modelu **train**, kdy se mění váhy jednotlivých neuronů. Modelu jsou předložena trénovací a testovací data, označená one hot data, velikost batche a počet epoch. Po každé epoše učení je vypsána přesnost a hodnota ztrátové funkce pro trénovací a validační data. Pro výpis úspěšnosti klasifikace je

Realizace prostřednictvím 1D CNN					
	vrstva	počet filtrů	kernel	krok	aktivační funkce
	1D konvoluce	3	37	1	L ReLu
KODÉR - 1D CNN	max pool	-	3	3	-
	1D konvoluce	10	27	1	L ReLu
	max pool		3	3	-
	1D konvoluce	10	16	1	L ReLu
	max pool		2	2	-
	1D konvoluce	10	6	1	L ReLu
	max pool		2	2	
	vrstva flatten				
ANN	vrstva	počet neuronů			
	plně propojená	20			L ReLu
	plně propojená	10			L ReLu
	plně propojená	3			SoftMax

Tab. 6.2: 1DCNN

zavedena evaluační metoda **test**. Výstupem je tabulka pro určení úspěšnosti klasifikace. Výsledná tabulka obsahuje přesnost, senzitivitu, F-1 skóre a počet signálů v jednotlivých třídách. Z poslední hodnoty lze určit jakým způsobem klasifikátor vyhodnotí data vzhledem k rovnoměrně zastoupené testovací množině. Další metoda **save** slouží k uložení architektury modelu ve formátu JSON a vah modelu ve formátu H5. Poslední metodou je klasifikace **classify**, kdy po předložení testovací množiny klasifikátor určí pravděpodobnosti přiřazení segmentu do jednotlivých klasifikačních tříd.

### 6.3.5 Skladání výstupu klasifikace segmentů signálu

Po ukončení CNN klasifikace je znám vektor stříhu, výsledek klasifikace jednotlivých segmentů. Dalším dílčím cílem je složit jednotlivé klasifikované segmenty daného signálu a určit správné zařazení do třídy.

Výsledky z CNN metody klasifikace určují hodnotu pravděpodobnosti zařazení pro každou třídu. Je vybrána maximální pravděpodobnost a na této pozici je zapsána logická jednička. Ostatním klasifikačním třídám s menší pravděpodobností je přiřazena logická nula. Výsledky jsou transponovány, tak aby řádek představoval klasifikační třídu a sloupec klasifikaci segmentu. Cyklus for vybere pozice signálu z vektoru stříhu a vytvoří vektor s pozicemi načítání nového signálu. Následně je určen počet

jednotlivých segmentů (viz. Obr. 6.9).

VEKTOR STŘIHU =	1	100	10	10
VÝBĚR POZIC =	1	2	5	6
POČET SEGMENTŮ =	1	3	1	2

Obr. 6.9: Skládání segmentů

Následují dva vnořené cykly přes všechny řádky, zde klasifikační třídy a počty nerozšířených signálů. V každém cyklu je vybrána daná část řádku, dle pozice a velikosti segmentu pro daný vstupní signál. Pokud je signál zařazen právě do této třídy, bude se zde nacházet alespoň jedna logická jednička. Pro danou klasifikační třídu je zapsána suma logických jedniček. Výsledný vektor klasifikací je zpětně transponován tak, aby řádek představoval vybraný signál. Finální zařazení do tříd je určeno dle následujících pravidel. Jestliže je v segmentech klasifikována alespoň jedna fibrilace síní a zároveň počet klasifikovaných FIS přesahuje počet FLUT, signál je klasifikován jako FIS. Podmínkou pro klasifikaci flutteru síní je potřeba, aby opět alespoň jeden signál byl klasifikován jako flutter síní anebo počet FLUT je alespoň stejný jako počet FIS. Signál považován za sinusový nesmí obsahovat ani jednu z arytmií v žádném ze segmentů.

$$\text{klasifikace} = \begin{cases} FIS & \text{if } FIS > 0 \wedge FIS > FLUT \\ FLUT & \text{if } FLUT > 0 \wedge FLUT \geq FIS \\ SIN & \text{if } SIN > 0 \wedge FLUT = 0 \wedge FIS = 0 \end{cases}$$

Výsledky této realizace jsou zapsány v tabulce (viz. Tab. 6.3). Výhodou této realizace je využití veškerých segmentů signálu. Pro klasifikaci je zohledněn celý signál, nikoli jeho část. Další výhodou je rozšíření trénovací množiny o potřebná data k lepší klasifikaci. Dále tento přístup vyhodnocení zvýšil senzitivitu klasifikace.

<b>Klasifikace 1D CNN</b>				
klas. třída	přesnost [%]	senzitivita [%]	F1 - skóre [%]	podpora
FIS	64	69	66	93
FLUT	75	71	73	105
SIN	89	87	88	102

Tab. 6.3: Výsledky 1DCNN - skladání segmentů

Počáteční verze klasifikátoru definuje, že vstupní signál musí obsahovat délku 5000 vzorků. Důsledkem této podmínky jsou kratší signály doplněny o logické nuly

na požadovanou délku. Velké množství dlouhých signálů je oříznuto na délku pouze 5000 vzorků. U mnohých signálů se jedná o zachování pouze jedné třetiny informace. Jak již bylo zmíněno, je velice málo pravděpodobné, že v signálu bude právě zachycen vznik či ukončení paroxysmálního projevu arytmie. Pokud je vzato v úvahu maximální délka signálu 60 sekund, tedy 15000 vzorků, klasifikace vybraných 5 000 vzorků plně postačuje pro určení arytmie. Realizace je shodná s realizací rozšířenou pouze zde chybí vektor sestřihu, následné skladání a vyhodnocení segmentů. Data jsou zapsána do 2D struktury dle signálů. Tato realizace 1D CNN dosahuje očekávaných výsledků (viz.Tab 6.4).

<i>Klasifikace 1D CNN, pouze jeden segment</i>				
klas. třída	přesnost [%]	senzitivita [%]	F1 - skóre [%]	podpora
FIS	73	81	77	100
FLUT	74	73	73	100
SIN	91	82	86	100

Tab. 6.4: Výsledky 1D CNN, pouze jeden segment

### 6.3.6 Klasifikace signálů včetně rozšíření databáze o FLUT.

V průběhu práce byla získána nová EKG data s zastoupením flutteru. Tato nová databáze obsahuje 12 000 záznamů EKG s flutterem síní. Tyto signály jsou kratší, respektive obsahují vždy 2500 vzorků. Z tohoto důvodu jsou všechny signály ořezány na tuto velikost. V případě, že by tento krok nebyl proveden. Výsledek by nebyl validní vzhledem k realizaci navrženého klasifikátoru. Podstatným příznakem by byla délka signálů, zde rozšíření signálu o nuly. Z každé klasifikační skupiny jsou vybrány veškeré signály. Pro tuto práci je použito 10 000 signálů z každé klasifikační třídy. Signály jsou rozděleny v poměru 8:1:1. Tedy 80% dat tvoří signály pro trénování, 10% signálů je určeno pro validaci a správné nastavení modelu, poslední nezávislá testovací skupina je opět zastoupena v rozsahu 10 %. Testovací signály jsou použity pro určení přesnosti bez vlivu na vytvoření modelu. Rozšíření databáze poskytlo značné zlepšení klasifikace (viz.Tab 6.5). Hyperparametry modelu byly nastaveny experimentálně. Je vytvořen nový skript **nezavilsetestovanimodelu**, jehož funkcí je načtení požadovaného klasifikátoru z uložené architektury a vah. Vstupem jsou nezávislá data, která nebyla součástí učení a validace modelu. Výstupem je vyhodnocení přesnosti klasifikace modelu.

Klasifikace 1D CNN, rozšířená databáze				
klas. třída	přesnost [%]	senzitivita [%]	F1 - skóre [%]	podpora
validační dataset				
FIS	76	90	82	838
FLUT	94	84	89	1119
SIN	97	93	95	1043
testovací dataset				
FIS	78	88	83	887
FLUT	93	85	89	1088
SIN	96	93	95	1025

Tab. 6.5: Výsledky 1D CNN, rozšířené databáze

### 6.3.7 Optimalizace pomocí genetického algoritmu.

Pomocí genetického algoritmu (GA) jsou hledány optimální parametry nastavení sítě. GA je adaptivní heuristické vyhledávání, založeno na populační genetice[22].

Optimalizované hyperparametry sítě jsou počet epoch, počty neuronů v plně propojených vrstvách, krok učení a parametry optimalizace ADAM. Cílem této optimalizace je maximalizovat kritériální funkce. Genetický algoritmus se skládá z vytvoření počáteční populace. Populace představuje matici hodnot, kdy řádky reprezentují jedince. Jeden jedinec udává nastavení modelu, sloupce v matici jsou jednotlivé parametry. Populace se skládá z 10 jedinců, kde hodnoty nejsou voleny náhodně, ale z experimentální znalosti modelu. Parametry počtu epoch a neuronů jsou celočíselné. Dále jsou parametry voleny tak, aby obsahovaly rozsah pro optimalizaci daných parametrů. Nastavený počet generací je 40. Kritériální funkce je průměrné F1 – skóre pro validační data CNN. Pro každý řádek je stanovena hodnota funkce a zapsána do vektoru. Nová populace je vytvořena pomocí selekce nejlepších příznaků. Parametry jsou posléze kříženy metodou crossover a dochází k náhodné mutaci hodnot. Pro simulaci mutace jsou vytvořeny dvě funkce. Mutace počtů neuronů v plně propojených vrstvách mění náhodně hodnoty v rozsahu (-3,7), k mutaci dochází s pravděpodobností 20 %. Mutace parametrů optimalizační funkce ADAM dosahuje malých náhodných změn v rozsahu (-1,1). Další funkcí je kontrola parametrů, kdy v případě vytvoření modelu s nevhodnými parametry dojde ke korekci parametrů s jistou mírou neurčitosti. Nové hyperparametry modelu budou náhodné, ovšem v rozsahu vhodném pro danou problematiku.

Takto je vytvořena nová populace, kterou nazýváme generace a opět vstupuje do kritériální funkce. Díky optimalizační metodě GA byly upraveny parametry CNN. Výsledky optimalizované sítě GA jsou zapsány (viz. Tab 6.6).

klasifikace 1D CNN, rozšířená databáze + GA optimalizace				
klas. třída	přesnost [%]	senzitivita [%]	F1 - skóre [%]	podpora
validační dataset				
FIS	89	85	87	1042
FLUT	87	93	90	940
SIN	96	95	95	1018
testovací dataset				
FIS	90	84	87	1081
FLUT	87	94	91	930
SIN	94	95	95	989

Tab. 6.6: Výsledky 1D CNN, rozšířená databáze, optimalizace GA

### 6.3.8 Klasifikátor s hlubší CNN.

V rámci této práce byla navržena nová daleko hlubší architektura sítě pro vhodnější výběr příznaků (viz. Tab 6.7). Tato CNN se skládá ze dvou konvolučních vrstev a max poolingů z důvodu podvzorkování vstupního signálu. Dále architektura sítě obsahuje 4 po sobě jdoucí konvoluční vrstvy s 3 filtry velikostí 16. Následuje max poolingová vrstva s oknem velikosti dva. Posléze jsou zastoupeny opět 4 konvoluční vrstvy s počty filtrů 3 a velikostí okna 32. Opět následuje max poolingová vrstva. Dále jsou obsaženy další 4 konvoluční vrstvy. Následuje vrstva flatten a plně propojená s počty neuronů 300 a na konci je obsaženy 3 neurony s aktivační funkcí softmax.

Tato hlubší a sofistikovanější CNN dosahuje velice výborných výsledků (viz. Tab 6.8). Ovšem pro zpracování této problematiky se ukázala jako vhodnější mělčí CNN.

## 6.4 Využití realizovaného 1D CNN klasifikátoru pro jiné arytmie

Pro řešení problematiky detekce arytmií se zdá jako vhodnější použít více modelů pro detekci jednotlivých arytmií než jeden rozsáhlý model. Následné výstupy klasifikace modulů mohou sloužit k zařazení do tříd pomocí ANN.

### 6.4.1 Klasifikace RBBB, LBBB a PVC

V databázi ÚBMI se nachází velké množství signálů s Blokádou pravého Tawarova raménka (RBBB), Blokádou levého Tawarova raménka (LBBB)

Hyperparametry architektury klasifikátoru pro detekci RBBB, LBBB, které byly optimalizovány jsou následující. Počet klasifikačních tříd je roven 2, pro učení modelu

Architektura CNN				
vrstva	počet vrstev	počet filtrů	kernel	aktivační funkce
1D konvoluce	1	3	37	LeakyRelu
1D konvoluce	1	8	27	LeakyRelu
max pooling	1	-	2	-
1D konvoluce	4	3	16	LeakyRelu
max pooling	1	-	2	-
1D konvoluce	4	3	32	LeakyRelu
max pooling	1	-	2	-
1D konvoluce	4	3	64	LeakyRelu
max pooling	1	-	2	-
flatten	-	-	-	-
ANN	počet vrstev	počet neuronů	-	-
plně propojená	1	300	-	LeakyRelu
plně propojená	1	3	-	SoftMax

Tab. 6.7: 1D CNN, hlubší architektura

<i>Klasifikace 1D CNN, nová architektura, rozšíření databáze</i>				
validační dataset				
klas. třída	přesnost [%]	senzitivita [%]	F - skóre [%]	podpora
FIS	78	87	82	905
FLUT	89	85	87	1044
SIN	97	92	95	1051
testovací dataset				
FIS	83	86	84	964
FLUT	88	88	88	1001
SIN	97	94	95	1035

Tab. 6.8: Výsledky 1D CNN, rozšířené databáze a hlubší CNN

je využito 10 epoch. V plně propojených vrstvách se nachází 30, 10 a 2 neurony. Parametr pro učení  $\beta_1 = 0.4$  a  $\beta_2 = 0.5$ . V realizaci klasifikátoru RBBB, LBBB a PVC jsou změněny parametry počtu epoch = 7, počtu neuronů v plně propojených vrstvách, zde 30, 10 a 2 neuronů. Navržená CNN z předchozího zpracování dosahuje přesnosti pro tyto arytmie (viz.Tab 6.9) a (Tab 6.10).



<i>Klasifikace RBBB, LBBB a PVC metodou 1D CNN</i>				
klas. třída	přesnost [%]	senzitivita [%]	F1 - skóre [%]	podpora
RBBB	58	71	64	330
LBBB	83	67	75	495
PVC	71	76	73	375

Tab. 6.9: Výsledky 1D CNN (RBBB, LBBB, PVC)

<i>Klasifikace 1D CNN</i>			
klas. třída	přesnost [%]	senzitivita [%]	F - skóre [%]
RBBB	87	78	82
LBBB	80	88	84

Tab. 6.10: Výsledky 1D CNN (RBBB, LBBB)

#### 6.4.2 Klasifikace infarktu myokardu, projev srdeční ischemie a sinusového rytmu

Cílem je klasifikovat EKG signály, které indikují infarkt myokardu (MI). Jedná se o změny úrovně ST úseku, jako je elevaci či depresi. Dalšími příznaky MI je změna morfologie QRS komplexu a T vlny. Další klasifikační skupinu tvoří změna morfologie STT úseku (STCHNG). Jedná se o projev ischémie myokardu. Signály je velice obtížné rozlišit z důvodů jejich podobnosti. Výhodou je velké množství signálů s touto poruchou morfologie. Testovací množina je zastoupena rovnoměrně a pro každou testovací klasifikační třídu je vybráno 500 signálů. Tato metoda dosahuje F-1 skóre 73 % (viz. Tab. 6.11).

<i>Klasifikace 1D CNN</i>			
klas. třída	přesnost [%]	senzitivita [%]	F1 - skóre [%]
STCHNG	74	73	73
MI	72	74	73

Tab. 6.11: Výsledky 1D CNN (STCHNG, MI)

#### 6.4.3 Klasifikace bradykardie, tachykardie a sinusového rytmu


Bradykardie (BRADY) je označována za zpomalení srdeční frekvence pod 60 tepů za minutu. Opakem bradykardie je právě tachykardie (TACHY). Jedná se o zvýšení tepové frekvence nad 100 tepů za minutu. Výsledky jsou vyhodnoceny v následující tabulce (viz. Tab. 6.12).

<i>Klasifikace BRADY, TACHY a SIN metodou 1D CNN</i>				
klas. třída	přesnost [%]	senzitivita [%]	F1 - skóre [%]	podpora
BRADY	97	97	97	400
TACHY	98	91	94	400
SIN	90	96	93	400

Tab. 6.12: Výsledky klasifikace 1D CNN (BRADY, TACHY a SIN)


## 6.5 Diskuze výsledků

Zlepšení klasifikace obtížně diferencovatelných arytmií je v současné době výzvou mnoha studií a institucí. Tato konkrétní problematika nelze srovnávat s mnohými studii zaměřenými na klasifikaci srdečních arytmií. Záznamy EKG využity v této práci obsahují data z různých pracovišť a rozdílných osob. Ve většině dostupných studií zaměřující se na tuto problematiku jsou vzaty v úvahu holterovské signály, které jsou rozděleny na kratší segmenty. Toto rozdělení dat není optimální, jelikož trénovací, validační a testovací sady dat pochází od stejných pacientů a jsou téměř shodné. Variabilita dat je v tomto případě klíčová. Studie [23] používá data z databázi MIT - BIH AFDB a MIT-BIH MITDB. Signály pro klasifikaci jsou tvořeny rozdělením dlouhých 10 hodinových signálů několika osob. Klasifikováno je do tříd AFIB, FLUT a SIN, průměrná přesnost klasifikace ACC = 98%. Další studie [24] dosahuje průměrné F1- skóre 94.6 %, kde je použito 23 dlouhodobých EKG signálů pro detekci flutteru síní. O rozdílnosti problematiky vypovídají i průběhy učení modelů (viz.Obr 6.10) a (viz.Obr 6.11) .



Obr. 6.10: průběh učení modelu, dle studie [24]

Vzhledem k rozdílnosti problematiky této práce a studií uvedených výše dosahují vytvořené klasifikátory obdobných výsledků. Klasifikátor 1D CNN s mělčí architekturou dosahuje průměrné přesnosti F1 – skóre 91 % a klasifikátor 1D CNN s hlubší



Obr. 6.11: průběh učení vlastního modelu 1D CNN s optimalizací GA

architekturou dosahuje globální F1 - skóre 89 %.



## Závěr

V této diplomové práci byly popsány obtížně diferencovatelné arytmie fibrilace síní a flutter síní. Posléze byla vypracována řešerše metod klasifikace, včetně popisu klasifikátorů hlubokého učení vhodných pro tuto problematiku. Metoda klasifikace pomocí spektrogramu a zarovnaných EKG segmentů dává z hlediska realizace CNN velký smysl, bohužel se ukázala jako nepříliš účinná. Pro klasifikaci FIS, FLUT a SIN bylo realizováno několik přístupů klasifikace. Nejlepších výsledků dosahují klasifikátory 1D CNN. Celkem bylo 30000 signálů rozděleno do trénovacích, validačních a testovacích datových sad v poměru 8:1:1. Hluboký model CNN dosáhl F1 skóre 0,84, 0,88 a 0,95 pro FIS, FLUT a SIN. Mělký model CNN optimalizovaný pomocí GA dosáhl skóre F1 0,87, 0,91 a 0,95 pro FIS, FLUT a SIN. Optimalizace hyperparametrů modelu bylo dosaženo experimentálně. Následně dle znalosti vhodných parametrů byl sestaven genetický algoritmus pro další optimalizaci hyperparametrů modelu. Významného zlepšení klasifikace bylo docíleno přidáním dat z databáze MDT. Navrhovaný model je úspěšný v klasifikaci běžně chybně klasifikovaných FIS a FLUT. Navzdory jednodušší architektuře dosahuje mělká CNN lepších výsledků než hluboká CNN. Navržený model byl také použitý pro klasifikaci dalších typů arytmií (LBBB, RBBB, PVC, MI, STCHNT, BRADY, TACHY) bez specifické optimalizace a bylo dosaženo mírně horších výsledků.



# Literatura

- [1] KITTNAR, Otomar. *Lékařská fyziologie*. 1. Praha: Grada, 2011. ISBN 978-80-247-3068-4.
- [2] *ECG Educator Blog: ECG Rhythm Strips* [online]. 2021 [cit. 2021-11-27].
- [3] BENNETT, David H. Srdeční arytmie: praktické poznámky k interpretaci a léčbě. Praha: Grada, 2014. ISBN ISBN978-80-247-5134-4.
- [4] STAVRAKIS, Stavros, Warren M. JACKMAN, Deborah LOCKWOOD, Hiroshi NAKAGAWA, Karen BECKMAN, Khaled ELKHOLEY, Zulu WANG a Sunny S. PO. Slow/Fast Atrioventricular Nodal Reentrant Tachycardia Using the Inferolateral Left Atrial Slow Pathway. *Circulation: Arrhythmia and Electrophysiology* [online]. 2018, 11(9) [cit. 2021-11-28]. ISSN 1941-3149.
- [5] ARYA, Arash, Hans KOTTKAMP, Christopher PIORKOWSKI, et al. Differentiating atrioventricular nodal reentrant tachycardia from tachycardia via concealed accessory pathway. *The American Journal of Cardiology* [online]. 2005, 95(7), 875-878 [cit. 2021-11-28]. ISSN 00029149.
- [6] ORAL, Hakan, Bradley P. KNIGHT, Hiroshi TADA, et al. Pulmonary Vein Isolation for Paroxysmal and Persistent Atrial Fibrillation. *Circulation* [online]. 2002, **105**(9), 1077-1081 [cit. 2021-11-28]. ISSN 0009-7322.
- [7] LUZ, Eduardo José da S., William Robson SCHWARTZ, Guillermo CÁMARA-CHÁVEZ a David MENOTTI. ECG-based heartbeat classification for arrhythmia detection: A survey. *Computer Methods and Programs in Biomedicine* [online]. 2016, **127**, 144-164 [cit. 2021-11-27]. ISSN 01692607.
- [8] FUJITA, Hamido a Dalibor CIMR. Computer Aided detection for fibrillations and flutters using deep convolutional neural network. *Information Sciences* [online]. 2019, **486**, 231-239 [cit. 2021-11-27]. ISSN 00200255.
- [9] ACHARYA, U. Rajendra, Hamido FUJITA, Oh Shu LIH, Yuki HAGIWARA, Jen Hong TAN a Muhammad ADAM. Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network. *Information Sciences* [online]. 2017, **405**, 81-90 [cit. 2021-11-27]. ISSN 00200255.
- [10] XIA, Yong, Naren WULAN, Kuanquan WANG a Henggui ZHANG. Detecting atrial fibrillation by deep convolutional neural networks. *Computers in Biology and Medicine* [online]. 2018, **93**, 84-92 [cit. 2021-11-27]. ISSN 00104825.

- [11] SALEM, Milad, Shayan TAHERI a Jiann-Shiun YUAN. ECG Arrhythmia Classification Using Transfer Learning from 2- Dimensional Deep CNN Features. *2018 IEEE Biomedical Circuits and Systems Conference (BioCAS)* [online]. IEEE, 2018, 2018, , 1-4 [cit. 2021-11-27]. ISBN 978-1-5386-3603-9.
- [12] HE, Runnan, Kuanquan WANG, Na ZHAO, Yang LIU, Yongfeng YUAN, Qince LI a Henggui ZHANG. Automatic Detection of Atrial Fibrillation Based on Continuous Wavelet Transform and 2D Convolutional Neural Networks. *Frontiers in Physiology* [online]. 2018, **9** [cit. 2021-11-27]. ISSN 1664-042X.
- [13] IVANOVIC, Marija D., Vladimir ATANASOSKI, Alexei SHVILKIN, Ljupco HADZIEVSKI a Aleksandra MALUCKOV. Deep Learning Approach for Highly Specific Atrial Fibrillation and Flutter Detection based on RR Intervals. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* [online]. IEEE, 2019, 2019, , 1780-1783 [cit. 2021-11-27]. ISBN 978-1-5386-1311-5.
- [14] JO, Yong-Yeon, Joon-myung KWON, Ki-Hyun JEON, et al. Detection and classification of arrhythmia using an explainable deep learning model. *Journal of Electrocardiology* [online]. 2021, **67**, 124-132 [cit. 2021-11-27]. ISSN 00220736.
- [15] ANDERSEN, Rasmus S., Abdolrahman PEIMANKAR a Sadasivan PUTHUS-SERYPADY. A deep learning approach for real-time detection of atrial fibrillation. *Expert Systems with Applications* [online]. 2019, **115**, 465-473 [cit. 2021-11-27]. ISSN 09574174.
- [16] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. *Deep learning*. Cambridge: MIT Press, [2016]. Adaptive computation and machine learning (MIT Press). ISBN 978-026-2035-613.
- [17] WANG, Jibin. Automated detection of atrial fibrillation and atrial flutter in ECG signals based on convolutional and improved Elman neural network. *Knowledge-Based Systems* [online]. 2020, **193** [cit. 2021-11-27]. ISSN 09507051.
- [18] LI, Dan, Jianxin ZHANG, Qiang ZHANG a Xiaopeng WEI. Classification of ECG signals based on 1D convolution neural network. *2017 IEEE 19th International Conference on e-Health Networking, Applications and Services (Healthcom)* [online]. IEEE, 2017, 2017, , 1-6 [cit. 2021-11-27]. ISBN 978-1-5090-6704-6.
- [19] WANG, Yingying, Yibin LI, Yong SONG a Xuewen RONG. The Influence of the Activation Function in a Convolution Neural Network Model of Facial



- Expression Recognition. *Applied Sciences* [online]. 2020, **10**(5) [cit. 2021-11-27]. ISSN 2076-3417.
- [20] WU, Haibing a Xiaodong GU. Towards dropout training for convolutional neural networks. *Neural Networks* [online]. 2015, **71**, 1-10 [cit. 2021-11-27]. ISSN 08936080.
- [21] EBRAHIMI, Zahra, Mohammad LONI, Masoud DANESHTALAB a Arash GHAREHBAGHI. A review on deep learning methods for ECG arrhythmia classification. *Expert Systems with Applications: X* [online]. 2020, **7** [cit. 2021-11-27]. ISSN 25901885.
- [22] WHITLEY, Darrell. A genetic algorithm tutorial. *Statistics and Computing*. 1994, 4(2). ISSN 0960-3174.
- [23] WANG, Jibin. An intelligent computer-aided approach for atrial fibrillation and atrial flutter signals classification using modified bidirectional LSTM network. *Information Sciences*. 2021, 574, 320-332. ISSN 00200255.
- [24] PETMEZAS, Georgios, Kostas HARIS, Leandros STEFANOPOULOS, Vassilis KILINTZIS, Andreas TZAVELIS, John A ROGERS, Aggelos K KATSAGGELOS a Nicos MAGLAVERAS. Automated Atrial Fibrillation Detection using a Hybrid CNN-LSTM Network on Imbalanced ECG Datasets. *Biomedical Signal Processing and Control*. 2021, 63, 320-332. ISSN 17468094.
- [25] ROSS-HOWE, Sara, H.R. TIZHOOSH, Leandros STEFANOPOULOS, Vassilis KILINTZIS, Andreas TZAVELIS, John A ROGERS, Aggelos K KATSAGGELOS a Nicos MAGLAVERAS. Atrial Fibrillation Detection Using Deep Features and Convolutional Networks. *Biomedical Signal Processing and Control*. IEEE, 2019, 2019, 63, 1-4. ISBN 978-1-7281-0848-3. ISSN 17468094.