

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2022

Bc. Jakub Abbrent



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

IDENTIFIKACE SEGMENTŮ SUPRAVENTRIKULÁRNÍCH TACHYKARDIÍ POMOCÍ METODY MULTIPLE-INSTANCE LEARNING

IDENTIFICATION OF SUPRAVENTRICULAR TACHYCARDIA SEGMENTS USING MULTIPLE-
INSTANCE LEARNING

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Jakub Abbrent

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Marina Ronzhina, Ph.D.

BRNO 2022

Diplomová práce

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

Ústav biomedicínského inženýrství

Student: Bc. Jakub Abbrent

ID: 195731

Ročník: 2

Akademický rok: 2021/22

NÁZEV TÉMATU:

Identifikace segmentů supraventrikulárních tachykardií pomocí metody multiple-instance learning

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s metodami hlubokého učení pro zpracování signálů. 2) Vytvořte literární rešerši se zaměřením na konvoluční neuronové sítě a principy multi-instančního učení. 3) Prostudujte dostupná elektrokardiografická data a v prostředí Python navrhnete a implementujete pipe-line pro jejich předzpracování. 4) Vyberte a implementujte vhodný model pro segmentaci záznamů. 5) Proveďte optimalizaci architektury a hyperparametrů modelu. 6) Proveďte vyhodnocení a diskuzi dosažených výsledků.

DOPORUČENÁ LITERATURA:

- [1] Zhi-Hua Zhou, A brief introduction to weakly supervised learning, National Science Review, Volume 5, Issue 1, January 2018, pp. 44–53, <https://doi.org/10.1093/nsr/nwx106>.
- [2] Kanavati, F., Toyokawa, G., Momosaki, S. et al. Weakly-supervised learning for lung carcinoma classification using deep learning. Sci Rep 10, 9297 (2020), <https://doi.org/10.1038/s41598-020-66333-x>.
- [3] L. Sun, Y. Lu, K. Yang and S. Li, "ECG Analysis Using Multiple Instance Learning for Myocardial Infarction Detection," in IEEE Transactions on Biomedical Engineering, vol. 59, no. 12, pp. 3348-3356, Dec. 2012, doi: 10.1109/TBME.2012.2213597.

Termín zadání: 7.2.2022

Termín odevzdání: 20.5.2022

Vedoucí práce: Ing. Marina Ronzhina, Ph.D.

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

Supraventrikulární tachykardie mají v populaci vysokou incidenci a často způsobují zhoršení zdravotního stavu. Cílem této diplomové práce je automaticky detekovat a lokalizovat paroxysmální fibrilace síní v záznamech EKG. Algoritmus implementovaný v jazyce Python používá k detekci konvoluční neuronovou síť ResNet s využitím multi-instančního učení a rozhodovacích pravidel. K lokalizaci slouží výstup detekce v podobě feature signálu. Při klasifikaci bylo na testovací množině dosaženo F1 skóre 0,87. Následně byly lokalizovány paroxysmální fibrilace síní s odchylkou $-0,40 \pm 2,26$ sekund pro začátky a $1,09 \pm 2,75$ sekund pro konce epizod. V závěru práce jsou získané výsledky vyhodnoceny a diskutovány.

Klíčová slova

EKG, fibrilace síní, hluboké učení, konvoluční neuronové sítě, ResNet, multi-instanční učení, feature signál

Abstract

Supraventricular tachycardias have a high incidence in the population and often cause health disorders. The aim of this thesis is to automatically detect and localize atrial fibrillation in ECG records. The algorithm, implemented in Python, uses a convolutional neural network ResNet for detection with multiple-instance learning and decision rules. The output of the detection in the form of a feature signal is used for localization. The classification achieved F1 score of 0.87 on the test dataset. Then, paroxysmal atrial fibrillation was localized with a deviation of -0.40 ± 2.26 seconds for the onsets and 1.09 ± 2.75 seconds for the terminations of the episodes. Lastly, the obtained results are evaluated and discussed.

Keywords

ECG, atrial fibrillation, deep learning, convolutional neural networks, ResNet, multiple-instance learning, feature signal

Bibliografická citace

ABBRENT, Jakub. *Identifikace segmentů supraventrikulárních tachykardií pomocí metody multiple-instance learning* [online]. Brno, 2022 [cit. 2022-05-17]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/142091>. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Marina Ronzhina.

Prohlášení autora o původnosti díla

Jméno a příjmení studenta:	Jakub Abbrent
VUT ID studenta:	195731
Typ práce:	Diplomová práce
Akademický rok:	2021/22
Téma závěrečné práce:	Identifikace segmentů supraventrikulárních tachykardií pomocí metody multiple-instance learning

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

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

V Brně dne: 20. května 2022

podpis autora

Poděkování

Děkuji vedoucí diplomové práce Ing. Marině Ronzhině, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne: 20. května 2022

podpis autora

Obsah

ÚVOD	1
1. SUPRAVENTRIKULÁRNÍ TACHYKARDIE	2
1.1 ELEKTROKARDIOGRAM	2
1.2 TYPY SUPRAVENTRIKULÁRNÍCH TACHYKARDIÍ	3
1.2.1 Síňové tachykardie	3
1.2.2 AV junkční reentry tachykardie	6
1.2.3 Patologie komplikující identifikaci SVT	7
2. VYUŽITÍ HLUBOKÉHO UČENÍ PRO IDENTIFIKACI SVT	8
2.1 ÚVOD DO STROJOVÉHO UČENÍ	8
2.1.1 Základní algoritmy strojového učení	9
2.1.2 Umělé neuronové sítě	9
2.2 HLUBOKÉ UČENÍ	10
2.2.1 Proces učení	11
2.3 KONVOLUČNÍ NEURONOVÉ SÍTĚ	11
2.3.1 Základní typy vrstev	12
2.3.2 Ztrátová funkce	17
2.3.3 Optimalizační algoritmy učení	17
2.3.4 Hyperparametry sítě	18
2.3.5 Inicializace vah	19
2.4 RESNET	20
2.5 MULTI-INSTANČNÍ UČENÍ	22
2.5.1 Algoritmy multi-instančního učení	22
2.6 METRIKY HODNOTÍCÍ KVALITU MODELU	23
3. ALGORITMUS PRO IDENTIFIKACI FIBRILACE SÍNÍ	25
3.1 POUŽITÁ DATA	25
3.2 PŘEDZPRACOVÁNÍ DAT	27
3.2.1 Filtrace stejnosměrné složky a driftu	28
3.2.2 Vytvoření trénovací množiny a její rozdělení	29
3.2.3 Augmentace	30
3.3 DETEKCE FIBRILACE SÍNÍ	32
3.3.1 Implementace modelu pro identifikaci záznamů	32
3.3.2 Učení modelu	34
3.3.3 Optimalizace hyperparametrů	34
3.3.4 Příznaková mapa	35
3.4 KLASIFIKACE FIBRILACE SÍNÍ	36
3.4.1 Rozhodovací pravidla	38
3.5 LOKALIZACE PAROXYSMÁLNÍ FIBRILACE SÍNÍ	39
3.5.1 Vytvoření feature signálu	39
3.5.2 Prahování	40
3.6 OPTIMALIZACE ARCHITEKTURY	41
4. VÝSLEDKY	45
4.1 KLASIFIKACE FIS	45

4.1.1	<i>Model Default</i>	45
4.1.2	<i>Model Optim 1</i>	47
4.1.3	<i>Model Optim 2</i>	48
4.1.4	<i>Srovnání modelů</i>	50
4.2	LOKALIZACE FIS	51
4.2.1	<i>Příklady lokalizace paroxysmální FIS</i>	52
5.	DISKUZE	57
5.1	KLASIFIKACE ARYTMÍ	57
5.1.1	<i>Srovnání s jinými publikacemi</i>	58
5.2	LOKALIZACE FIS	58
	ZÁVĚR	60
	LITERATURA	61
	SEZNAM ZKRATEK	69

Seznam obrázků

1.1	EKG křivka [4].....	2
1.2	Fibrilace síní EKG [6].....	4
1.3	Výřez EKG paroxysmální a perzistentní fibrilace síní.....	5
1.4	Flutter síní s AV blokádou 4:1 EKG [6]	6
1.5	AVRT EKG [6].....	6
1.6	AVNRT EKG [6]	7
1.7	Síňová extrasystola EKG [4].....	7
2.1	Klasické programování vs. strojové učení [11].....	8
2.2	Dopředná plně propojená neuronová síť [17].....	10
2.3	Propojení neuronů CNN (nahore) a neuronů plně propojené ANN (dole) [13]	12
2.4	Princip konvoluční vrstvy – upraveno [12]	13
2.5	ReLU aktivační funkce [23].....	14
2.6	Rozdíl mezi max poolingem a GMP [26].....	15
2.7	Síť před (vlevo) a po DropOut metodě (vpravo) [28]	16
2.8	1 x 1 konvoluce se dvěma filtry – upraveno [12].....	16
2.9	Reziduální blok [41].....	20
2.10	ResNet 34 [45]	21
2.11	Matice záměn	23
3.1	Schéma postupu pro identifikaci FiS.....	25
3.2	Příklad signálů pro jednotlivé kategorie z databáze	27
3.3	Signál perzistentní FiS před a po filtraci	28
3.4	Frekvenční spektrum EKG s perzistentní FiS před a po filtraci.....	29
3.5	Výřez signálů EKG představující vliv jednotlivých augmentačních metod.....	31
3.6	ResNet model Default pro binární klasifikaci EKG (FiS vs. Ostatní).....	33
3.7	Průběh učení modelu: F1 skóre (vlevo) a chyba (vpravo).....	35
3.8	Odvození příznakové mapy v síti ResNet	36
3.9	Příklad příznakové mapy pro paroxysmální a perzistentní FiS	37
3.10	Schéma rozhodovacích pravidel pro klasifikaci FiS	38
3.11	Vytvoření redukované příznakové mapy.....	39
3.12	Vytvoření a zpracování feature signálu	40
3.13	Lokalizace paroxysmální FiS	41
3.14	Průběh učení modelu Optim 1: F1 skóre (vlevo) a chyba (vpravo).....	42
3.15	Průběh učení modelu Optim 2: F1 skóre (vlevo) a chyba (vpravo).....	43
3.16	Příklad příznakových map – model Optim 1.....	43
3.17	Příklad příznakových map – model Optim 2.....	44
4.1	Odchylka začátku a konců epizod FiS testovací množiny.....	52
4.2	Příklad správné detekce začátku i konce FiS.....	53
4.3	Příklad nevhodné detekce začátku FiS	54
4.4	Příklad nevhodné detekce konce FiS.....	55
4.5	Příklad detekce začátku a konce FiS (flutteru) v signálu se šumem.....	56

Seznam tabulek

3.1	Četnost záznamů a popis délek signálů jednotlivých tříd.....	26
3.2	Četnost záznamů v nové množině.....	30
3.3	Četnost záznamů v trénovací, validační a testovací množině.....	30
3.4	Parametry modelu Default.....	33
3.5	Rozmezí a výsledná hodnota hyperparametrů.....	35
3.6	Nastavení parametrů klasifikace FiS.....	38
3.7	Rozmezí parametrů pro optimalizaci architektury Default a hodnoty výsledných modelů Optim 1 a Optim 2.....	42
3.8	Charakteristika modelů.....	43
4.1	Model Default – matice záměn pro detekci FiS.....	45
4.2	Model Default – F1 skóre detekce FiS.....	46
4.3	Model Default – matice záměn pro klasifikaci paroxysmální FiS.....	46
4.4	Model Default – F1 skóre klasifikace paroxysmální FiS.....	46
4.5	Model Optim 1 – matice záměn pro detekci FiS.....	47
4.6	Model Optim 1 – F1 skóre detekce FiS.....	47
4.7	Model Optim 1 – matice záměn pro klasifikaci paroxysmální FiS.....	48
4.8	Model Optim 1 – F1 skóre klasifikace paroxysmální FiS.....	48
4.9	Model Optim 2 – matice záměn pro detekci FiS.....	49
4.10	Model Optim 2 – F1 skóre detekce FiS.....	49
4.11	Model Optim 2 – matice záměn pro klasifikaci paroxysmální FiS.....	50
4.12	Model Optim 2 – F1 skóre klasifikace paroxysmální FiS.....	50
4.13	F1 skóre detekce FiS.....	51
4.14	F1 skóre klasifikace paroxysmální/perzistentní FiS.....	51
4.15	Výsledky detekce začátků a konců FiS v testovací množině.....	52

ÚVOD

Srdeční arytmie je jedním z nejnebezpečnějších kardiovaskulárních onemocnění a řadí se mezi nemoci s největším rizikem, jelikož může způsobit selhání srdce a další život ohrožující stavy. Velmi často se v populaci vyskytují tzv. supraventrikulární tachykardie (SVT), které vznikají v místech nad srdečními komorami. Mezi ně patří fibrilace síní (FiS), která je vůbec nejčastější srdeční arytmií. Aby byla zahájena správná léčba a zabránilo se vzniku dalších komplikací, je důležité diagnostikovat FiS přesně a včas. Běžně se to provádí pomocí elektrokardiogramu (EKG), který udává informaci o elektrické aktivitě srdce. Hodnocení je založeno na odborné zkušenosti zdravotnického personálu, což může vést k chybám.

Proto vznikla potřeba automatické klasifikace EKG, k čemuž se stále častěji používají metody hlubokého učení. Úspěch hlubokého učení souvisí s dostupností velkého množství anotovaných dat. Avšak anotace jednotlivých cyklů v EKG signálů je velmi odbornou a časově náročnou činností.

Metoda multi-instančního učení (Multiple-Instance Learning – MIL) umožňuje lokálně určit místo v EKG, kde se vyskytuje klasifikovaná SVT. K tomu jsou použity pouze globální anotace, které udávají informace, zda je SVT přítomna v EKG záznamu.

Tato diplomová práce je zaměřena na identifikaci začátku a konce FiS v EKG využitím metod hlubokého učení, zejména konvolučních neuronových sítí. Lokalizace FiS je důležitá pro zjištění celkové doby trvání FiS u pacienta, pomocí níž se hodnotí riziko srdečního selhání nebo cévní mozkové příhody. V teoretické části jsou nejprve shrnuty informace o základním principu EKG a jednotlivých typech SVT. Další kapitola zahrnuje základní principy hlubokého učení, především konvolučních neuronových sítí a multi-instančního učení.

V praktické části této práce je navržen algoritmus na klasifikaci a lokalizaci fibrilací síní implementovaný v programovacím jazyku Python. Třetí kapitola obsahuje popis použité databáze EKG záznamů a jednotlivé kroky předzpracování dat. Také je v této kapitole představena vybraná architektura ResNet k detekci FiS, optimalizace hyperparametrů a výstup v podobě příznakové mapy. Dále jsou zde charakterizována pravidla pro klasifikaci paroxysmální vs. perzistentní FiS a postup vytvoření feature signálu pro následnou lokalizaci začátků a konců paroxysmální FiS. Kromě toho jsou vytvořeny i dva modely k optimalizaci uvedené architektury. Nakonec jsou v samostatné kapitole prezentovány dosažené výsledky klasifikace i lokalizace, které jsou poté zevrubně diskutovány.

1. SUPRAVENTRIKULÁRNÍ TACHYKARDIE

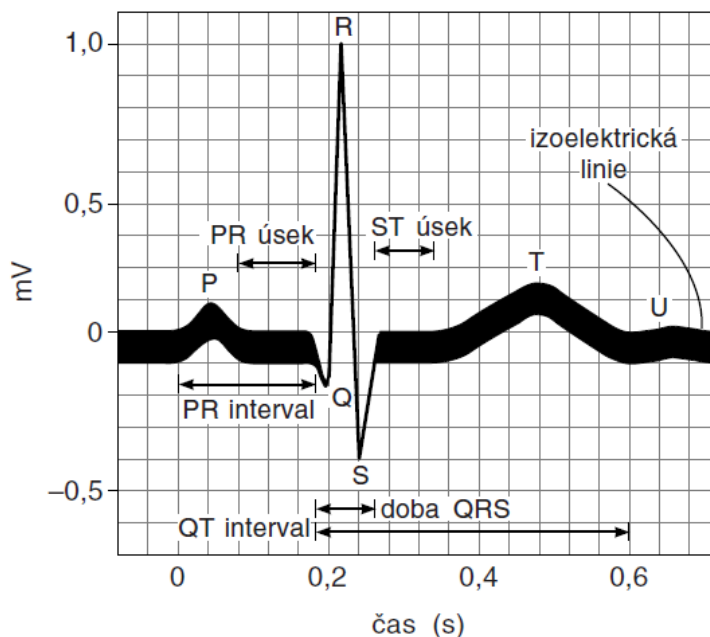
Srdce v klidovém stavu má pravidelnou frekvenci v rozmezí 60–100 tepů za minutu a každý stah nastává depolarizací v sinoatriálním (SA) uzlu, jedná se o normální sinusový rytmus. Všechny ostatní tepové frekvence, nepravidelné rytmy, jiná místa depolarizace a vedení vzruchu v srdci jsou považovány za arytmie. Jestliže se srdeční frekvence zvýší nad 100/min, rytmus se nazývá sinusová tachykardie. V případě, že dojde ke zpomalení srdeční frekvence pod 60/min, tak se označuje jako sinusová bradykardie.

Některé arytmie mohou být životu ohrožující a je nutné je včas diagnostikovat pomocí analýzy elektrokardiogramu (EKG). [1]

1.1 Elektrokardiogram

EKG snímá v čase elektrickou aktivitu srdečních buněk (depolarizaci), která je důležitá pro správnou funkci celého srdce. Vlna depolarizace se vytváří spontánně v SA uzlu, ze kterého se šíří postupně přes atrioventrikulární (AV) uzel, Hisův svazek, levé a pravé Tawarovo raménko až na Purkyňova vlákna a ty aktivují svalovinu komor.

Po dokončení depolarizace se srdeční buňky vracejí do své klidové podoby pomocí procesu označovaného jako repolarizace. Oba procesy, depolarizace i repolarizace, jsou zaznamenány pomocí elektrodového systému jako malé změny napětí. Výsledkem snímání je EKG křivka, která popisuje časový průběh elektrické činnosti srdce a skládá se z různých typů vln, kmitů, segmentů a intervalů (viz Obrázek 1.1). [1], [2], [3], [4]



Obrázek 1.1 EKG křivka [4]

Vlna P reprezentuje depolarizaci síní a vzniká na základě aktivity SA uzlu. Zpravidla trvá 80 ms a velikost amplitudy má do 0,25 mV. Dále následuje PQ interval, který označuje dobu od vzniku vzruchu v SA uzlu, přes převod vzruchu síněmi a AV uzlem až do komor. Měří se tak od začátku vlny P až do začátku QRS komplexu. Jeho fyziologická délka, na kterou má největší vliv vedení AV uzlu, je 120–210 ms.

Poté se na EKG křivce zobrazuje QRS komplex, který odpovídá depolarizaci komor. QRS komplex má normální délku 80–120 ms a zahrnuje kmity Q, R, a S. Oproti vlně P má vyšší amplitudu, jelikož komory mají silnější svalovinu než síně. Současně s depolarizací komor probíhá repolarizace síní, která je však na EKG překryta větším QRS komplexem.

Po QRS komplexu následuje ST segment, který představuje dobu mezi depolarizací a repolarizací komor. Na ST segment navazuje T vlna značící repolarizaci komor. Jedná se o vlnu proměnlivého tvaru s amplitudou 0,2–0,8 mV a maximální délkou 200 ms. Někdy bývá doprovázena vlnou o třetinové amplitudě vlny T, vlnou U. Vlna U je projevem depolarizace Purkyňových vláken.

QT interval udává časovou vzdálenost depolarizace i repolarizace komor. Měří se tedy od začátku QRS komplexu až po konec T vlny a s vyšší srdeční frekvencí se zkracuje. [1], [2], [5]

1.2 Typy supraventrikulárních tachykardií

Existují různé druhy tachykardií, ale za supraventrikulární jsou považovány pouze ty tachykardie, které pochází ze síní nebo z AV junkce. Společným znakem supraventrikulárních tachykardií (SVT) jsou štíhlé komplexy QRS (méně než 120 ms), čímž se odlišují od komorových tachykardií. Avšak všechny tachykardie se štíhlým komplexem QRS nelze považovat za supraventrikulární, mohou existovat i SVT se širokými komplexy QRS, což nastává u převodní blokády mezi Hisovým svazkem a pravým nebo levým Tawarovým raménkem.

Je důležité si uvědomit, že jednotlivé typy supraventrikulárních arytmií se mohou lišit v mechanismu vzniku, EKG obrazu a léčbě. [1], [2]

1.2.1 Síňové tachykardie

Prvním typem SVT jsou síňové tachykardie, které jsou charakteristické vznikem rychlého abnormálního elektrického podnětu uvnitř síní. Mezi síňové tachykardie patří fibrilace síní, flutter síní a síňová tachykardie. U těchto arytmií je funkce AV uzlu neporušena, tudíž slouží k převodu vzruchu ze síní do komor. Také zpravidla souvisí s přítomností srdečních chorob. [2]

Fibrilace síní

Fibrilace síní je srdeční arytmie, která se u lidí vyskytuje nejčastěji. Počet případů narůstá se stále se zvyšujícím věkem dožití populace. Vznik fibrilace je mnohdy podnícen

síňovou extrasystolou. Navíc se většinou vyskytuje u pacientů se srdeční chorobou. Častokrát bývá příčinou akutní infarkt myokardu, hypertenze, kardiomyopatie, chlopenní vada, hypertyreóza nebo sick sinus syndrom. U fibrilace síní se také pravidelně stává, že je idiopatická, tedy není známá žádná příčina vzniku. [2]

Fibrilace síní se projevuje jako rychlá a chaotická elektrická síňová aktivita, při které je v síních dosaženo frekvence 350–600/min. Kvůli četným náhodným aktivacím síňové svaloviny dochází ke snížení efektivity kontrakce síní. Na EKG se projevuje chybějícími vlnami P a nepravidelným komorovým rytmem (viz Obrázek 1.2). Místo vln P je patrné slabé zvlnění izolinie reprezentované nepravidelnými vlnami f s nízkou amplitudou a vysokou frekvencí. [1], [2], [3]

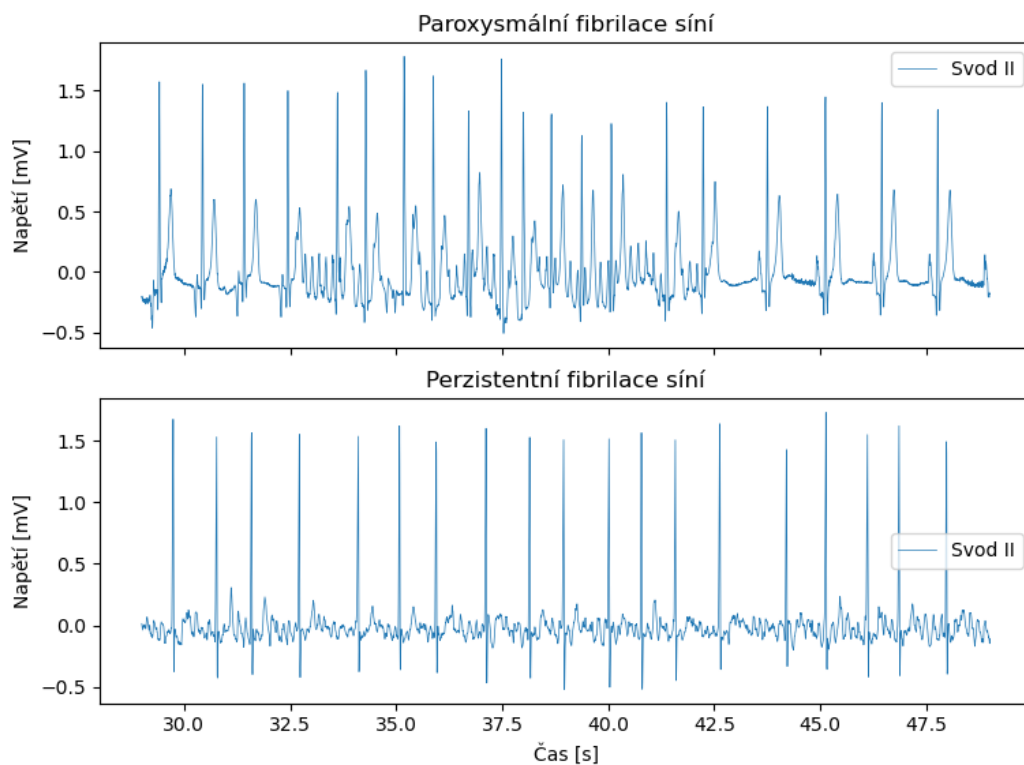
Jelikož vlny f následují velmi rychle za sebou, tak je všechny AV uzel nestíhá převádět dále na komory, a proto se QRS komplexy tvoří v nepravidelných intervalech. Navzdory nepravidelnému rytmu komor mají QRS komplexy normální tvar, protože převod na komory a vedení v komorách probíhá přirozenou dráhou. Jedinou výjimku tvoří případy, kdy je spolu s fibrilací přítomna blokáda Tawarových ramének nebo Wolffův-Parkinsonův-Whiteův (WPW) syndrom. [1], [2], [3]



Obrázek 1.2 Fibrilace síní EKG [6]

Fibrilaci síní (FiS) lze dále rozdělit podle délky trvání a způsobu ukončení. V případě, že FiS zahrnuje epizody, které trvají maximálně 48 hodin a následně spontánně odezní, tak se označuje jako paroxysmální. Pokud FiS trvá déle než 7 dní a musí být ukončena léčbou stanovenou lékařem, nazývá se jako perzistentní. Jestliže však FiS nelze ukončit žádnou léčbou a zároveň její délka trvání přesahuje 6 měsíců, tak se jedná o permanentní FiS. [7], [8]

Obrázek 1.3 uvádí ukázkou paroxysmální a perzistentní FiS z použité databáze EKG záznamů již po filtraci.




Obrázek 1.3 Výřez EKG paroxysmální a perzistentní fibrilace síní

Flutter síní

Flutter síní je sice méně častý než fibrilace, ale může se objevit i u lidí bez poškození srdečního svalu. Zvýšený výskyt byl zjištěn u aktivních vytrvalostních sportovců. Má podobné příčiny vzniku jako fibrilace a také může být idiopatický. V některých případech může přejít do fibrilace.

Typický flutter síní je způsoben kroužením impulzu, který se nazývá jako reentry, uvnitř pravé komory orientovaným zpravidla proti směru hodinových ručiček. Na EKG nejsou patrné vlny P, díky velmi rychlé depolarizaci síní. Místo nich lze pozorovat pro flutter typické vlny f, které neustále oscilují okolo nulové izolinie, a proto jejich tvar připomíná „zuby od pily“ (viz Obrázek 1.4). Vlny f mají pravidelnou frekvenci 300/min.

Jelikož AV uzel nestíhá převádět všechny f vlny na komory a vytvářet QRS komplexy, tak jsou v AV uzlu blokovány. Tomuto jevu se říká AV blokáda. Výsledná frekvence komor tedy záleží na typu AV blokády. Pokud je AV blokáda 2:1, tak to znamená, že jedna vlna f vytvoří QRS komplex, ale druhá je zablokována. V takovém případě je frekvence komor 150/min. [1], [2]



Obrázek 1.4 Flutter síní s AV blokádou 4:1 EKG [6]

1.2.2 AV junkční reentry tachykardie

Druhým typem SVT jsou AV junkční reentry tachykardie, které jsou typické přítomností přídavné elektrické dráhy mezi síněmi a komorami. Díky této dráze může vzruch z komor putovat zpět do síní. Proto se na EKG zobrazují nenormální P vlny. Tyto vlny následují vždy po QRS komplexu, ale často nejsou viditelné. Srdeční frekvence je v rozsahu 130–250/min.

Tato kategorie SVT na rozdíl od fibrilace a flutteru nemá spojitost s žádným srdečním onemocněním a jde o pravidelné tachykardie. Dále se dělí na AV reentry tachykardii (AVRT) a na AV nodální reentry tachykardii (AVNRT). [2]

AV reentry tachykardie (AVRT)

Příčinou AVRT je pruh myokardu mezi síněmi a komorami, který se označuje jako přídavná AV dráha, a je získán již při narození. Pokud může být vzruch veden přes přídavnou AV dráhu také opačným směrem, tedy ze síní na komory, tak se jedná o WPW syndrom.

Na EKG se AVRT projevuje úzkými QRS komplexy a vlny P typicky nasedají na vlny T, čímž se tvoří hrotnaté vlny T (viz Obrázek 1.5). Zároveň díky tomu, že okruh reentry u AVRT je delší než u AVNRT, tak se vlny P nachází zhruba v polovině RR intervalů. [2]



Obrázek 1.5 AVRT EKG [6]

AV nodální reentry tachykardie (AVNRT)

AVNRT neboli paroxysmální supraventrikulární tachykardie je způsobena duální AV nodální dráhou, která se skládá z AV uzlu a části svaloviny síní v jeho blízkém okolí. Duální dráha je funkčně rozdělena na dráhu rychlou, která vede impuls ze síní na komory, a dráhu pomalou, která převádí impuls zpátky na síně.

Stejně jako AVRT má na EKG úzké QRS komplexy, ale protože má kratší reentry okruh než AVRT, tak vlny P přicházejí těsně po QRS komplexech nebo na ně přímo nasedají (viz Obrázek 1.6). [1], [2]




Obrázek 1.6 AVNRT EKG [6]

1.2.3 Patologie komplikující identifikaci SVT

Při identifikaci supraventrikulárních tachykardií se mohou vyskytnout komplikace v případech, že se v záznamu objeví patologie, které mají podobné manifestace v EKG jako SVT. Mezi takové patologie se řadí supraventrikulární extrasystoly, které vytváří předčasný vzruch následovaný normálním, úzkým QRS komplexem. Dochází tak k nepravidelné komorové aktivitě, kdy se změní délka RR intervalu. Díky tomu by mohly být supraventrikulární extrasystoly zaměněny za fibrilaci síní.

Dělí se podle místa vzniku na síňové a junkční extrasystoly. Síňové extrasystoly (premature atrial contraction – PAC) vznikají v místech síní mimo SA uzel, proto se předčasná P vlna tvarově odlišuje od normální P vlny. V některých případech může předčasná vlna P deformovat předcházející vlnu T (viz Obrázek 1.7). Junkční extrasystoly se tvoří v okolí AV uzlu a jsou méně obvyklé než síňové extrasystoly. Kvůli jejich místě vzniku se na EKG se neprojevuje vlna P, ale pouze předčasné QRS komplexy. [1], [2], [9]



Obrázek 1.7 Síňová extrasystola EKG [4]

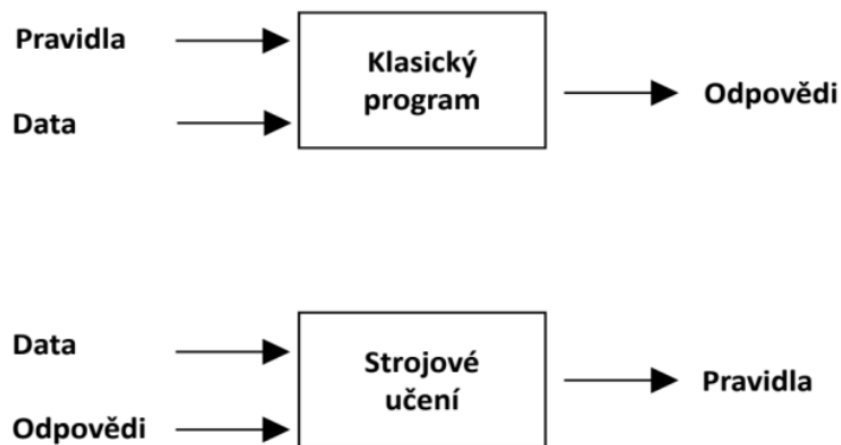
Další poruchou ovlivňující identifikaci SVT jsou komorové extrasystoly (premature ventricular contraction – PVC), které se na EKG projevují zejména širokými QRS komplexy. Právě širokými QRS komplexy mohou být charakterizovány SVT v kombinaci s bloádou Tawarova raménka nebo s WPW syndromem. V takovém případě by mohlo dojít k záměně těchto dvou patologií a nesprávnému ohodnocení EKG záznamu. [1], [3]

2. VYUŽITÍ HLUBOKÉHO UČENÍ PRO IDENTIFIKACI SVT

V této kapitole jsou popsány hlavní principy hlubokého učení, zejména konvolučních neuronových sítí, které jsou použity pro identifikaci SVT.

2.1 Úvod do strojového učení

Přirozenou snahou vědců je poučit se z biologického procesu a vytvořit co nejpřesnější umělý model zpracování dat [10]. Od poloviny minulého století se zabývali otázkou, zda je možné automatizovat intelektuální úlohy, které normálně provádějí lidé. Vznikl nový obor informatiky „Umělá Inteligence“, který se zabýval řešením úloh pomocí počítačové techniky. Z počátku programátoři vytvářeli pravidla pro zpracování dat, což postačovalo k vyřešení konkrétních úloh a jasně definovaných logických úkolů. Vytvořit tyto algoritmy pro nejasné problémy (rozpoznávání řeči, překlad jazyka, klasifikace obrazu atd.) se však ukázalo prakticky nemožné, nepřinášelo to žádané výsledky a vědci začali hledat jiný přístup k řešení těchto složitých úloh. Když je nemožné to počítač naučit, mohl by se to naučit sám? Mohl by se sám naučit, jak provádět určitou úlohu? Znamenalo to zásadní změnu v programování. Namísto zadávání pravidel, jak zpracovat data byla zadávána data spolu s odpověďmi a počítač sám hledal pravidla (viz Obrázek 2.1), která pak aplikoval na nová data a získal nové odpovědi. Tento přístup byl nazván strojové učení. [11]



Obrázek 2.1 Klasické programování vs. strojové učení [11]

2.1.1 Základní algoritmy strojového učení

Učení s učitelem (řízené učení, supervised learning)

Učení s učitelem je nejčastěji používaným přístupem, který využívá vztahu vstupních dat a známých výstupů (labelů, cílů). Algoritmu jsou předkládány různá vstupní data a soubor správných výstupů. Požadovaným výsledkem je model, který naučeným mechanismem mapuje vstupní data na správné labely, případné rozdíly jsou motivací k dalšímu cyklu učení. [11], [12]

Učení bez učitele (neřízené učení, unsupervised learning)

Tento typ strojového učení hledá zajímavé transformace vstupních dat bez cílových výstupů. Využívá se zejména pro účely vizualizace a komprese dat, odstraňování šumu v datech nebo pro pochopení korelací ve vstupních datech. Model obvykle nachází nečekané algoritmy, třídí vstupy do skupin podle podobnosti či charakteristických znaků, transformuje vstupní data do jiných dat použitelných pro další zpracování.

Je vhodným nástrojem pro porozumění a pochopení vstupních dat. Hlavní metodou využívající učení bez učitele je shluková analýza. [11], [13]

Částečně řízené učení (semi-supervised learning)

Je to kombinace dvou předchozích typů. Část vstupních dat je se známými definovanými výstupy a druhá skupina vstupních dat je bez výstupů. Obvykle je množství neklasifikovaných dat větší. Cílem je vytvořit model, který pomocí menšího počtu označených dat klasifikuje neoznačená data. [13], [14]

Zpětnovazebné učení (posilované učení, reinforcement learning)

Posilované učení využívá zpětnou vazbu z jednotlivých předchozích aktivit a vyhodnocuje, zda konkrétní akcí získal či nezískal nějakou odměnu. Model neustále získává informace o svém prostředí, dílčí výsledky procesu učení průběžně vyhodnocuje (známkuje) a postupně se učí volit správnou iteraci, která přináší nějakou výhodu. [11]


2.1.2 Umělé neuronové sítě

S rozvojem strojového učení byly vytvořeny nové výpočetní modely, které byly inspirovány fungováním lidského nervového systému. Tyto modely jsou založeny na spojení velkého množství výpočetních uzlů, označovaných též jako neurony, a proto modely nesou název Umělé neuronové sítě (Artificial Neural Networks – ANN).

Neurony ANN se společně učí, optimalizují své parametry (váhy), aby po předložení vstupních dat byl získán správný výstup. Jedná se tedy o model strojového učení s učitelem. Učení probíhá změnou vah hodnotících spojení mezi neurony. Cílem je změnit váhy tak, aby byla celková chyba modelu na vstupních trénovacích datech co nejnižší a bylo dosaženo správné výstupní hodnoty. [15], [16]

ANN jsou tvořeny několika vrstvami neuronů, kde každý neuron dané vrstvy je propojen se všemi neurony vrstvy následující (plně propojená síť). Do vstupní vrstvy jsou vložena vstupní data, která dále převádí do skrytých vrstev. Právě skryté vrstvy provádí výpočty a rozhodují o podobě výstupu. Jejich počet se liší podle řešené problematiky. Většinou se využívají jedna až dvě skryté vrstvy. Taková síť se poté označuje jako mělká (shallow) neuronová síť. v případě, že by bylo v síti více skrytých vrstev, jednalo by se o tzv. hlubokou (deep) neuronovou síť (viz kapitola 2.2). Po skrytých vrstvách následuje výstupní vrstva, ve které je získáno finální výstupní ohodnocení vstupních dat a vypočtena celková chyba pomocí ztrátové funkce.

Uvedená architektura vícevrstvé ANN se současně označuje jako dopředná (viz Obrázek 2.2), protože se neurony jednotlivých vrstev ovlivňují směrem od vstupu k výstupu. [11], [15], [16]



Obrázek 2.2 Dopředná plně propojená neuronová síť [17]

2.2 Hluboké učení

Speciální podskupinou strojového učení je hluboké učení. Přístup, který klade důraz na učení pomocí velkého množství vrstev, které obsahují různé reprezentace vstupních dat (příznaků). Hloubka (deep) udává počet vrstev modelu. Modely hlubokého učení zahrnují desítky až stovky vrstev, které s rostoucí hloubkou získávají vyšší úroveň abstrakce. První vrstvy vybírají z dat příznaky nižší úrovně (např. R kmit Z EKG), které se v dalších vrstvách kombinují v příznaky vyšší úrovně reprezentované složitějšími motivy. Znamená to, že síť se sama naučí extrahovat vhodné příznaky. To je jedna z největších výhod hlubokého učení.

Protože u mělkých neuronových sítí bylo vždy nutné data před vstupem do sítě vhodně předzpracovat, což představovalo mnohdy velmi složitý úkol. Tudiž až poté mohlo být ze získaných příznaků dosaženo dobré úspěšnosti sítě. [11], [18], [19]

2.2.1 Proces učení

Hluboké neuronové sítě mapují vstupy na výstupní labely prostřednictvím posloupnosti jednoduchých transformací dat (vrstev). Aby síť správně klasifikovala vstupy na požadované výstupy, je nutno správně definovat množinu hodnot pro parametry (váhy) všech vrstev. Čím větší je hloubka sítě, tím se zvyšuje množina parametrů. Každá vrstva pracuje se svými vstupními daty dle nastavené váhy a výsledek předává další vrstvě. Proces učení je tak samozřejmě mnohem složitější než u mělkých sítí.

Zpočátku jsou vahám sítě přiřazeny náhodné hodnoty a výstupy jednotlivých vrstev jsou nepřesné. Ve výstupní, klasifikační vrstvě je pomocí ztrátové funkce spočtena ztrátová chyba, tedy porovnání získaného výsledku modelu a očekávaného labelu. Jakmile je tato hodnota získána, využije se jako zpětnovazební signál na úpravu hodnot vah pro snížení ztrátové chyby. K tomu se používá algoritmus zpětného šíření chyby (backpropagation), který pomocí výpočtu gradientů ztrátové funkce podle jednotlivých vah určí, jak moc daná váha přispívá k chybě a podle toho jsou váhy upraveny. Úprava vah probíhá postupně od výstupní vrstvy až na začátek sítě.


Jedná se o mnohokrát opakovaný trénovací cyklus. Nakonec se váhy nastaví tak, aby minimalizovali ztrátovou funkci a výstupy byly co nejblíže požadovanému labelu, tedy aby se získala natrénovaná síť. Poté jsou síti předložena nová, testovací data a pokud jsou výstupy sítě správné, potom má dobrou generalizační schopnost, což znamená, že dokáže správně určit i neznámá data. [11], [12], [17]

2.3 Konvoluční neuronové sítě

Vícevrstvé plně propojené ANN mají uspořádány neurony ve vrstvách tak, že každý neuron z dané vrstvy je spojen s každým neuronem následující vrstvy. S rostoucím množstvím vrstev a velikostí dat dochází k velkému nárůstu počtu parametrů, což může vést až k přeučení sítě, tedy ke stavu, kdy se síť příliš přizpůsobí trénovacím datům a na testovací data nereaguje.

Východiskem jsou konvoluční neuronové sítě (Convolutional Neural Networks – CNN), které dokážou pomocí operace konvoluce, podle níž jsou pojmenované, účinně zpracovat objemná data jako obrazy a videa. [20]

Každý neuron konkrétní konvoluční vrstvy je propojen pouze lokálně, s malou prostorovou oblastí s určitým počtem neuronů nebo vstupů předchozí vrstvy (viz Obrázek 2.3). Tím je zachována prostorová struktura dat, protože hloubka neuronů CNN je dána hloubkou vstupních dat (např. RGB obraz o velikosti 300 x 300 pixelů má tři dimenze – šířku 300 pixelů, výšku 300 pixelů a hloubku 3). 1D signály jako je EKG mají pouze dvě dimenze, které tvoří délka a hloubka signálu tvořená počtem použitých EKG svodů (kanálů). Navíc velikost neuronů je vždy menší než velikost dat. [13], [15]



Obrázek 2.3 Propojení neuronů CNN (nahore) a neuronů plně propojené ANN (dole) [13]

Další výhodou je i nižší počet vah, protože dané typy neuronů mezi sebou váhy sdílejí. Celkový počet vah v jedné vrstvě závisí na velikosti neuronu neboli filtru, hloubce vstupních dat a počtu filtrů. Obvykle je počet vah v porovnání s klasickými plně propojenými vrstvami mnohem menší, což přináší rychlejší trénování sítě a také snížení požadavků na paměť. [16]

V současné době CNN díky své schopnosti extrahovat příznaky do více úrovní, dostupnosti velkého množství dat a rychlému rozvoji hardwaru zvyšující výpočetní výkon prokazují mimořádné výsledky na poli zpracování obrazu, videa, přirozeného jazyka a rozpoznávání řeči. [21]

Výhody CNN jsou využity také při zpracování EKG signálů, kde slouží např. ke klasifikaci arytmií nebo detekci ischemické choroby srdeční. [22]

Architektura CNN je tvořena několika různými vrstvami s tím, že vždy musí být použita konvoluční vrstva. Většina vrstev slouží k extrakci příznaků. Poslední vrstvy provádí klasifikaci. [18]

2.3.1 Základní typy vrstev


Konvoluční vrstva

Konvoluční vrstva je zásadní částí CNN. Hlavním smyslem této vrstvy je extrakce rozlišujících příznaků ze vstupních dat. Vstupem do konvoluční sítě je matice číselných

hodnot v podobě obrazu nebo signálu, na kterou je aplikován filtr (konvoluční jádro nebo kernel) se stejnou hloubkou, ale menší velikostí než vstup. Filtr obsahuje váhy. Proveďte se skalární součin mezi filtrem a danou oblastí vstupní matice. Následně je filtr s určitým krokem postupně posouván a opět se provede výpočetní úkon. Tento proces se nazývá konvoluce a je popsán pomocí rovnice

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t - a), \quad (2.1)$$

kde s udává výstup konvoluce, x představuje hodnotu vstupu s indexem pozice t a w značí hodnotu váhy jádra pro danou pozici [13]. Výstupem průchodu jednoho filtru je příznaková mapa s hloubkou jedna. Celkový výstupní objem (hloubka) je tvořen takovým počtem příznakových map jako je počet aplikovaných filtrů. Konvoluční jádro je ve všech místech obrazu stejné (sdílení vah). Princip konvoluční vrstvy zobrazuje Obrázek 2.4. [15]



Obrázek 2.4 Princip konvoluční vrstvy – upraveno [12]

Konvoluční vrstvu lze optimalizovat nastavením několika parametrů, kterými jsou velikost filtru, počet filtrů, krok filtru (posun, stride) a doplnění vstupu nulami (zero-padding). Filtry bývají symetrické a s klesající velikostí dokážou objevit jemnější detaily. Počet filtrů určuje hloubku na výstupu dané vrstvy, tedy počet příznakových map. Snižováním tohoto parametru je sice možné dosáhnout menšího počtu neuronů v síti, ale tím pádem hrozí, že síť nebude schopna rozeznávat v datech vhodné vzory. Krok filtru definuje, o kolik vzorků se posune filtr po vstupu. Pokud je dostatečně velký, snižuje se tím výpočetní náročnost, ale zároveň se snižuje schopnost rozlišení specifických příznaků a detailů ze vstupních dat. Doplněním vstupu na začátku a na konci nulami se řídí velikost výstupní příznakové mapy a používá se zejména pro uchování stejné velikosti výstupu a vstupu. [15]


Aktivační vrstva

Za konvoluční vrstvou je na příznakové mapy aplikována aktivační vrstva, která prostřednictvím nelineární aktivační funkce provádí jejich bodové transformace. Výstup aktivační vrstvy se nazývá jako aktivační mapa a je totožných rozměrů jako vstup.

Aktivační vrstvy následují každou konvoluční vrstvu, proto je velmi důležité, aby byly jednoduché na výpočet a také diferencovatelné kvůli zpětnému šíření chyby a úpravě vah. Zároveň neobsahují žádný hyperparametr.

Typicky se používají aktivační funkce jako ReLU (Rectified Linear Unit), hyperbolický tangens a sigmoida nebo softmax, přičemž nejvíce je využívána právě ReLU, která nejlépe splňuje požadavky hlubokého učení. Jde o velmi jednoduchou funkci na výpočet, kdy pro záporné hodnoty a nulu je nulová a kladné hodnoty nemění (viz Obrázek 2.5). Také má derivaci buď nula, nebo jedna, což je vhodné pro zabránění problému mizejícího gradientu. [12]

Oproti tomu sigmoida a softmax jsou vhodné hlavně na klasifikaci, kdy v poslední vrstvě CNN převádí výstupy na pravděpodobnost příslušnosti k určité třídě. Sigmoida je použitelná pouze pro binární klasifikaci a softmax slouží i ke klasifikaci do více tříd. [23]




Obrázek 2.5 ReLU aktivační funkce [23]

Pooling vrstva

Mezi konvoluční vrstvy se vkládají tzv. pooling vrstvy, které provádí zmenšení prostorové velikosti (podvzorkování) vstupních aktivačních map. Sníží se tak výška a šířka vstupu, ale hloubka zůstává zachována, jelikož podvzorkování je aplikováno na každou aktivační vrstvu zvlášť. Používají se z důvodu snížení množství parametrů a výpočetní náročnosti. Navíc předávají na výstup nejsilnější příznak, který je tak prostorově invariantní.

Existuje několik typů pooling vrstev lišících se podle operace, kterou je podvzorkování provedeno. Výstup může být získán buď výběrem maximální hodnoty v daném okně aktivační mapy (Max Pooling), anebo průměrem (Average Pooling). [15], [24]

Dalšími typy poolingů převádí celou aktivační mapu na jednu hodnotu výběrem maxima (Global Max Pooling – GMP) nebo průměrem (Global Average Pooling – GAP). Tyto vrstvy mohou také sloužit ke klasifikaci místo plně propojených. Je to výhodné, protože neobsahují žádné učící parametry. Rozdíl mezi max poolingem a GMP ilustruje Obrázek 2.6. [25]



Obrázek 2.6 Rozdíl mezi max poolingem a GMP [26]


BatchNorm vrstva

Při trénování CNN mívají vnitřní vrstvy při extrakci velmi odlišné hodnoty, a to zpomaluje konvergenci a prodlužuje dobu trénování sítě. K odstranění těchto nedostatků se používá BatchNorm vrstva.

BatchNorm provádí normalizaci vstupních dat dané vrstvy v rámci každé dávky (batch), který je z pohledu CNN je chápán jako dávka dat vstupující do sítě. Normalizací je každá vstupní aktivační mapa upravena na nulovou střední hodnotu a jednotkový rozptyl. Úroveň normalizace řídí učící se parametry γ (směrodatná odchylka v dávce) a β (střední hodnota v dávce). Díky této vrstvě lze zrychlit učení nastavením vyššího kroku učení a není nutné tolik dbát na inicializaci vah. [21], [27]

DropOut vrstva

DropOut je jednoduchá a účinná metoda regularizace (snížení složitosti) modelu CNN. Používá se pouze při trénování sítě na konvoluční nebo plně propojené vrstvy, kdy náhodně vypne určité množství neuronů ve vrstvě (viz Obrázek 2.7). Brání tak přeučení sítě. Počet vypnutých parametrů je dán pravděpodobností zachování neuronů během učení. [13], [20]




Obrázek 2.7 Síť před (vlevo) a po DropOut metodě (vpravo) [28]

Plně propojená vrstva

Plně propojená vrstva je analogií k tradičním ANN, protože se skládá z neuronů, které jsou váhami spojeny se všemi neurony předchozí i následující vrstvy. Tato vrstva bývá umístěna na konci CNN, je možné jich použít několik za sebou. Jejím vstupem je zvektorizovaná matice hodnot z předchozí vrstvy. Výstupem je číslo nebo vektor hodnot, který je pomocí aktivační funkce např. Softmax převeden na pravděpodobnosti příslušnosti k dané třídě. [12], [20], [24]

1 x 1 konvoluční vrstva

1 x 1 konvoluční vrstva provádí konvoluci vstupu z předchozí vrstvy filtrem o prostorové velikosti 1. Z toho plyne, že prostorová velikost na výstupu se nezmění, ale hloubku výstupní příznakové mapy lze ovlivnit počtem aplikovaných filtrů. Tím pádem je provedena lineární kombinace vstupních dat, a proto pokud by byl použit pouze jeden filtr, mohla by 1 x 1 konvoluční vrstva v kombinaci s GMP nebo GAP nahradit plně propojenou vrstvu. Snížila by se tím výpočetní náročnost, protože 1 x 1 konvoluce má menší počet vah. Příklad aplikace 1 x 1 konvoluce se dvěma filtry uvádí Obrázek 2.8. [12], [25]



Obrázek 2.8 1 x 1 konvoluce se dvěma filtry – upraveno [12]

2.3.2 Ztrátová funkce

Ztrátová funkce (loss function, kriteriální funkce) vyhodnocuje úspěšnost modelu aplikovaného na data. Udává, jak se výstup modelu liší od ideálního výstupu. Pro naučení sítě je nutno tuto chybu minimalizovat. Z toho plyne, že ztrátová funkce je nedílnou součástí trénování modelu.

Mezi nejjednodušší funkce patří $L1$ (*Mean Absolute Error – MAE*) a $L2$ *regularizace* (*Mean Square Error – MSE*). MAE je získána jako rozdíl absolutních hodnot mezi aktuálním a očekávaným výstupem a MSE jako rozdíl čtverců. Jedná se o jednoduché funkce, které se využívají spíše u regresních úloh. Jejich nevýhodou jsou nevhodné konvergenční vlastnosti (MAE) a citlivost na zašuměná data (MSE).

Pro klasifikační úkoly se nejčastěji používá *vzájemná entropie* (*Cross Entropy*), která zvyšuje rychlost učení modelu a také zlepšuje generalizaci. Je popsána rovnicí

$$L_{CE} = -\sum_{i=1}^n t_i \log(p_i), \quad (2.2)$$

kde L_{CE} udává velikost chyby, t_i je očekávaný výstup, p_i značí získaný výstup i -té třídy a n představuje celkový počet tříd. [13], [29], [30]

Existuje několik variant vzájemné entropie. Ke klasifikaci do dvou tříd slouží binární vzájemná entropie a při rozdílném počtu dat v jednotlivých třídách lze aplikovat váhovanou vzájemnou entropii, která dává větší váhu méně zastoupené třídě. [30], [31]

2.3.3 Optimalizační algoritmy učení

Jak již bylo uvedeno v kapitole 2.2.1, učení neuronové sítě je opakující se proces s cílem minimalizovat ztrátovou funkci úpravou vah (parametrů) neuronů. Právě k efektivnímu naučení sítě slouží optimalizační algoritmy, které udávají způsob úpravy vah.

Gradientní sestup (*Gradient Descent*) je základním a nejjednodušším optimalizačním algoritmem. Při této optimalizaci se váhy mění proti směru gradientu o daný krok učení až po průchodu všech trénovacích dat sítí, tedy na konci epochy. Ačkoliv má tato metoda mnoho nedostatků (je pomalá, nevhodná pro velké soubory dat a při větší hodnotě kroku učení může dojít uvíznutí v lokálním minimu nebo sedlovém bodě atd.) přesto je podstatou pro další optimalizační metody.

Stochastický gradientní sestup (*Stochastic Gradient Descent – SGD*) aktualizuje parametry po každém vzorku z trénovacích dat. Pro urychlení namísto přímého výpočtu gradientu používá jeho odhad. Parametry tím upravuje častěji, ale konverguje mnohem rychleji. Aby nebyl SGD závislý na pořadí vzorků, je důležité trénovací dataset před každou epochou náhodně promíchat. Kombinací těchto dvou přístupů je Minibatch SGD, který upravuje váhy po dávce (minibatch) několika vzorků trénovací množiny.

SGD s hybností je modifikací metody gradientního sestupu s využitím parametru hybnosti (momentum). Hybnost napomáhá dalšímu urychlení konvergence tím, že reguluje velikost následujícího kroku pomocí několika přechozích gradientů. Dokáže se

tím i částečně vyřešit uvíznutí v lokálním extrému. Obdobně funguje *Nestrov Accelerated Gradient (NAG)*, který počítá gradient až po výběru směru hybnosti. Mnohdy dosahuje rychlejší konvergence než SGD s hybností. Nevýhodou těchto technik je přidání nového parametru, který je nutné nastavit.

Následující typy algoritmů využívají adaptivní nastavení kroku učení, kdy při nízkém gradientu ho zvyšují a opačně. *AdaGrad* využívá adaptivní úpravy kroku učení pomocí sumy druhých mocnin velikostí předchozích gradientů pro každou váhu. Suma však postupem času narůstá a učení se stává pomalejším. To řeší *RMSProp*, který zahrnuje do výpočtu pouze několik předchozích gradientů pomocí exponenciálního zapomínání. Nepochází tak ke kumulaci gradientu a ukončení procesu učení.

Adam (Adaptive Moment Estimation) je v současnosti jedním z nejčastěji používaným optimalizačním algoritmem. Jde o metodu s rychlou konvergencí a malými paměťovými nároky, která spojuje dohromady několik předchozích přístupů jako RMSProp a SGD s hybností a jejich výhody. Díky tomu je schopna řešit i velmi malý gradient. Pracuje s adaptivním krokem učení pro každou váhu, kdy využívá sumu prvních i druhých mocnin předešlých gradientů a také exponenciální zapomínání. Pokud však pracuje s gradienty o velkém rozptylu mívá obtíže s konvergencí. [12], [32], [33], [34]

2.3.4 Hyperparametry sítě

Takto je označována skupina parametrů, jejichž optimální hodnoty musí být stanoveny před začátkem procesu učení. Správná volba hyperparametrů má významný podíl na celkové efektivitě neuronové sítě. Hodnoty hyperparametrů jsou na sobě navzájem závislé, je-li jeden z nich chybně stanovený, velmi výrazně ovlivní výsledný proces učení. [21]

Mezi základní hyperparametry patří počet epoch, velikost dávky, krok učení a počet skrytých vrstev modelu.

Počet epoch značí počet kompletních zpracování všech trénovacích vzorků neuronovou sítí ze souboru dat. Pokud je počet epoch příliš nízký, síť se nedokáže adekvátně naučit. Naproti tomu s vyšším počtem epoch se zvyšuje přesnost, ale při překročení hraničního počtu se model začíná přeučovat a přestává generalizovat. Někdy je proto vhodné učení při tomto hraničním počtu epoch ukončit.

Velikost dávky (batch size) reprezentuje počet vzorků, které současně prochází neuronovou sítí a ze kterých se vypočítá ztrátová chyba. Vyšší dávka efektivně využívá výpočetní kapacitu, paralelizuje učení a zajišťuje plynulost gradientů. Obvykle se stanovuje okolo několika desítek až stovek vzorků.

Krok učení (learning rate) stanovuje velikost změny vah během procesu hledání jejich optimálních hodnot a ovlivňuje rychlost konvergence. Bude-li krok učení příliš velký, rychlost konvergence se zkrátí, ale model může vynechat globální minimum. Naopak jestliže bude hodnota kroku moc malá, zlepší se schopnost nalezení optimálního

výsledku, ale konvergence bude trvat mnohem delší dobu, což může být výpočetně náročné. [17], [35], [36]

Počet skrytých vrstev udává úroveň abstrakce extrahovaných příznaků. Čím více skrytých vrstev je v modelu, tím komplexnější příznaky jsou získány. Zvyšuje se tím však výpočetní náročnost a hrozí i riziko přeučení modelu. Proto se počet vrstev modelu nastavuje v závislosti na charakteru prováděné úlohy a typu použitých dat.

Pro optimální určení hodnot jednotlivých hyperparametrů je na výběr z několika metod. První z nich je prohledávání stavového prostoru, kdy každý hyperparametr má stanovený rozsah hodnot a postupně se zkouší všechny jejich kombinace. Je to nejjednodušší metoda, ale při větším počtu hyperparametrů či velkém rozsahu prohledávaných hodnot velmi časově náročná.

Podobnou metodou je náhodné hledání, kdy se pro trénování modelu náhodně vyberou hodnoty jednotlivých hyperparametrů, vyzkouší se různé kombinace těchto hodnot, a nakonec se použije ta, která je nejbližší očekávanému výsledku.

Propracovanější metodou je Bayesovská optimalizace, jejíž principem je selekce nových hyperparametrů z oblasti, kde byly předcházející pokusy o nalezení správných hyperparametrů nejméně úspěšné. Tím se snižuje rychlost získání vhodné kombinace.

Dále je možné k optimalizaci využít evoluční nebo genetické algoritmy. [16], [37]

2.3.5 Inicializace vah

Při počátku učení sítě jsou váhy jednotlivých vrstev nastaveny jako náhodné hodnoty (viz kapitola 2.2.1). Způsob inicializace vah přispívá k průběhu učení a výsledné kvalitě hluboké neuronové sítě. Jedná se o důležitý krok při návrhu sítě, jelikož nesprávným nastavením může dojít ke zpomalení učení nebo dokonce k nedoučení.


Nejjednodušší metodou je nastavení všech vah na nulu nebo jinou konstantu, nejčastěji na jedničku. Váhy tak budou stejné ve všech neuronech podobně jako výsledné aktivity, proto je vytvořen pouze lineární model.

Další základní technikou je náhodná inicializace vah, kdy jsou z normálního rozdělení náhodně vybrány malé, nenulové hodnoty. Neurony se tak mohou učit různé příznaky, a proto tato metoda funguje mnohem lépe než ta předchozí. Problém ale může nastat při náhodném výběru pouze velmi malých nebo velmi vysokých hodnot, kdy dojde k vymizení nebo explodování gradientů. Při vymizení gradientu se váhy během učení mění o velmi malou hodnotu, čímž dochází k pomalé konvergenci. Naopak při explodujícím gradientu dochází k velké změně, což může způsobit oscilaci kolem optimálního nastavení vah.

Tento problém do jisté míry řeší techniky jako Xavierova nebo Heova inicializace, které náhodně vybírají váhy z normálního rozložení s takovým rozptylem, ve kterém zohledňují počet vstupních a výstupních neuronů dané vrstvy. [38], [39], [40]

2.4 ResNet

Podle principů hlubokého učení a CNN by hlubší sítě měli dosahovat lepších výsledků, jelikož s rostoucí hloubkou získávají stále abstraktnější příznaky. Ukázalo se však, že při pouhém skládání vrstev za sebe může dojít k vymizení gradientu, který se zpětně šíří předchozími vrstvami a umožňuje změnu vah. v konečném důsledku to znamená, že se síť přestane učit.



Obrázek 2.9 Reziduální blok [41]

Tento problém řeší konvoluční neuronová síť ResNet vyvinutá pracovníky Microsoftu, která byla představena v roce 2015 na ImageNet Large Scale Visual Recognition Challenge (ILSVRC), kdy tento ročník také vyhrála. Autoři této sítě [41] zavádí tzv. reziduální blok (viz Obrázek 2.9), který k výstupu z dané konvoluční vrstvy $F(x)$ připojuje její vstup x označovaný jako identita a vytváří tak novou příznakovou mapu $H(x)$. To udává rovnice (2.3).

$$H(x) = F(x) + x \quad (2.3)$$

Tím je eliminován problém mizejícího gradientu, kdy může být gradient zpětně šířen pomocí identity. Současně lze říci, že tímto přístupem je síť umožněno učit se pouze malé změny $F(x)$ získané aplikací konvoluce na identitu, což popisuje rovnice (2.4).

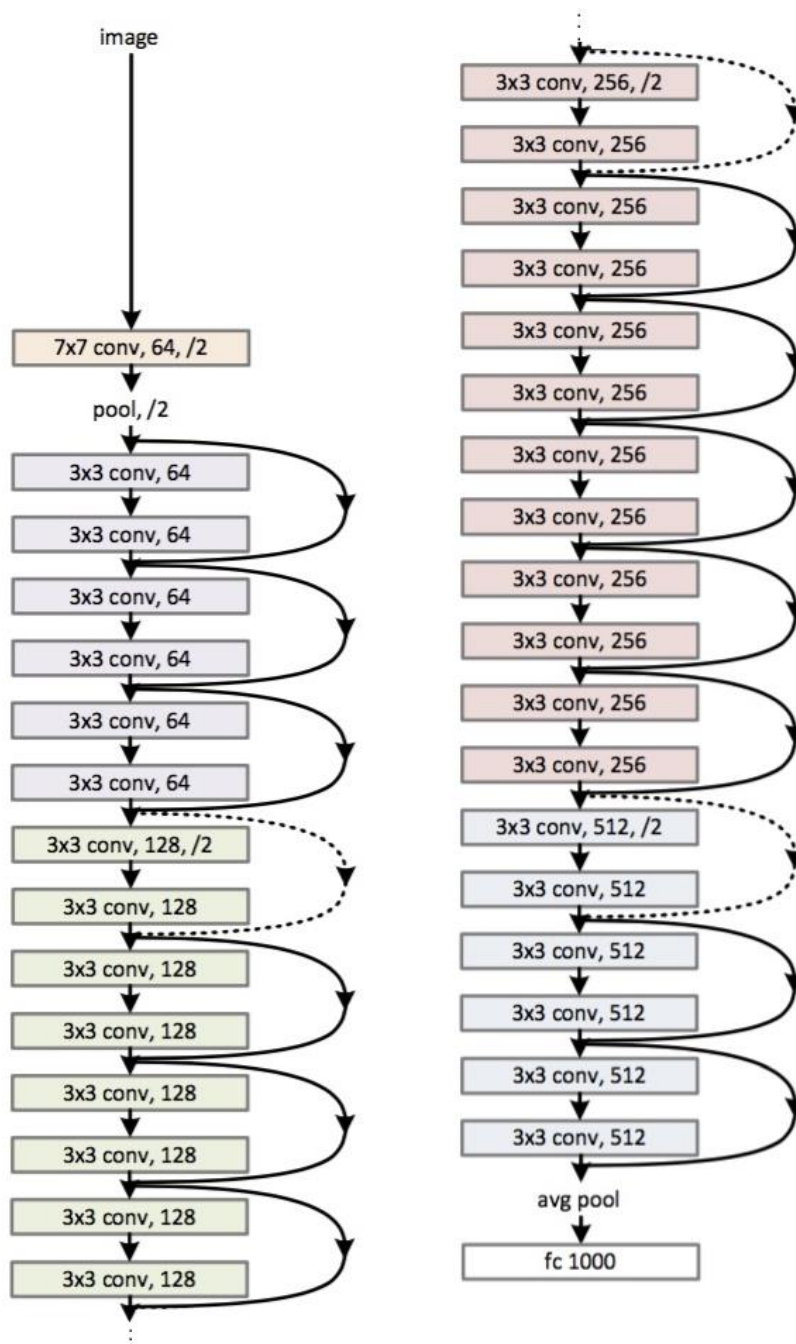
$$F(x) = H(x) - x \quad (2.4)$$

ResNet je tvořena spojením několika po sobě jdoucích reziduálních bloků. Díky reziduálním bloků je stále schopna s rostoucím počtem vrstev snižovat celkovou chybu učení. Podle počtu vrstev, který je volen v závislosti na dané aplikaci, existuje několik verzí ResNet 18, 34, 50, 101 a 152.

V základní implementaci jsou vstupem sítě ResNet obrazy o velikosti 32 x 32 pixelů. Následuje inicializační konvoluční vrstva s filtrem 7 x 7. Poté jsou aplikovány reziduální bloky. Po průchodu vstupu určitým počtem bloků je prostorová velikost příznakových map v obou směrech snížena na polovinu pomocí maxpoolingu a také je zdvojnásoben počet filtrů. Jiným způsobem se prostorová velikost ani počet filtrů nemění. Uvnitř

každého reziduálního bloku jsou vždy dvě konvoluční vrstvy s filtrem 3 x 3 a po každé z nich následuje BatchNorm a ReLU aktivace. Ke klasifikaci slouží GAP a plně propojená vrstva. Obrázek 2.10 zobrazuje architekturu sítě ResNet se 34 vrstvami. [21], [41], [42]

ResNet se běžně používá také ve zpracování EKG signálů. Autoři [43] implementovali modifikovanou síť ResNet 18 na klasifikaci srdečních rytmtů v EKG. ResNet tvořil základ i při klasifikaci zašuměných EKG signálů představený autory [44].



Obrázek 2.10 ResNet 34 [45]

2.5 Multi-istanční učení

Při učení s učitelem jsou klasifikačnímu modelu představeny trénovací data (vstup) spolu s označením tříd labely (požadovaný výstup). V některých případech je problematické labely získat. Zejména ve zdravotnictví by určení třídy (diagnózy) na základě záznamu EKG nebo snímků ze zobrazovacích modalit vyžadovalo vysoce kvalifikovanou a časově náročnou činnost, když by měl být ohodnocen každý EKG cyklus nebo pixel obrazu.

Vyřešit tento problém umožňuje metoda označovaná jako Multi-istanční učení (Multiple-Instance Learning – MIL), která učí model pomocí trénovacích dat uspořádaných do košů (bags). Jeden koš se skládá z několika vstupních dat, které jsou pojmenovány jako instance. Těmto košům jsou přiřazeny (globální) labely příslušící dané třídě, ale (lokální) labely instancí zůstávají neznámé. Tudíž z pohledu MIL je EKG signál koš a jednotlivé EKG cykly jsou instancemi.

Hlavním cílem MIL je tedy vytvořit natrénovaný model tak, aby správně klasifikoval nové koše a současně byl schopný definovat instance, které byly důvodem k přiřazení koše do konkrétní třídy – klíčové instance. Proto je MIL zařazeno do typu učení označovaného jako učení se slabým učitelem (weakly supervised learning).

V případě standardní binární klasifikace je koš klasifikován jako negativní, pokud jsou všechny instance v něm negativní. Ale jestliže obsahuje alespoň jednu pozitivní instanci, je označen jako pozitivní. [46], [47], [48]

Pro získání celkové predikce slouží MIL pooling, který nejčastěji provádí výběr maxima, nebo průměr. Oba tyto operátory jsou diferencovatelné, proto je možné MIL pooling využít k naučení modelu správně klasifikovat koše metod hlubokého učení, zejména CNN. [49], [50]

MIL nerozlišuje, zda je provedena klasifikace binární nebo do více tříd. Umožňuje přiřazení více labelů jak košům, tak i instancím. [48]

MIL a jeho benefity lze využít v různých oblastech a v řadě z nich již bylo aplikováno např. v počítačovém vidění (pro klasifikace či anotaci obrazů, detekci a trasování objektů), ve farmacii (při navrhování léků), ve zpracování signálů (při identifikaci mluvího) a hlavně v medicíně (při stanovení diagnózy ze záznamu EKG, snímků ze zobrazovacích modalit nebo mikroskopů snímků z histopatologického vyšetření). [46], [47], [48], [51]

2.5.1 Algoritmy multi-istančního učení

MIL může být řešeno pomocí mnoha algoritmů. Mezi ty nejdůležitější patří algoritmus založený na predikci instancí a algoritmus založený na vnoření instancí.

Algoritmus založený na predikci instancí (instance predictions) nejprve ohodnotí (klasifikuje) jednotlivé instance pravděpodobností výskytu pozitivní třídy, klasifikátor se tedy trénuje na instance. Následně je na pravděpodobnosti aplikován MIL pooling a tím je určen výstupní label koše. Hlavní výhodou tohoto algoritmu je, že díky označení všech instancí pravděpodobností umožňuje snadno najít klíčové instance. Na druhou stranu při

klasifikaci instancí může vytvářet novou chybu, jelikož nejsou známy lokální labely instancí.

Algoritmus založený na vnoření instancí (instance embedding) se nejdříve snaží získat charakteristické informace o koši. K tomu jsou vhodné CNN, kdy je vytvořen příznakový vektor (mapa) koše. V druhém kroku je na příznakový vektor použit MIL pooling, jehož výstup následuje do klasifikátoru, který určí výsledný label koše. Oproti předchozímu algoritmu dosahuje lepších výsledků při klasifikaci košů. [49], [50]

2.6 Metriky hodnotící kvalitu modelu

Průběh učení modelu lze sledovat nejenom pomocí ztrátové funkce, ale slouží k tomu i rozličné metriky, jejichž volba závisí na typu algoritmu strojového učení. Zároveň existují různé metriky pro klasifikaci a regresi.

Matice záměn je základní klasifikační metrikou, která udává počet správně detekovaných a chybně určených případů (viz Obrázek 2.11). Provádí se porovnáním predikované a skutečné třídy. Správné detekce jsou označeny jako skutečně pozitivní (true positive – TP) nebo skutečně negativní (true negative – TN). Pokud při klasifikaci dojde k chybě a model určí výsledek jako pozitivní, avšak ve skutečnosti je negativní, tak je zařazen mezi falešně pozitivní (false positive – FP) případy. Při opačném průběhu chybné klasifikace se jedná o falešně negativní (false negative – FN) případ. Cílem modelu je dosáhnout nulového FP a FN.

Matice záměn tvoří základ pro další klasifikační metriky, mezi které patří přesnost, senzitivita, pozitivní prediktivní hodnota a F1 skóre.

Matice záměn		Predikovaná třída	
		Negativní – 0	Pozitivní – 1
Skutečná třída	Negativní – 0	Pravdivě negativní (TN)	Falešně pozitivní (FP)
	Pozitivní – 1	Falešně negativní (FN)	Pravdivě pozitivní (TP)

Obrázek 2.11 Matice záměn

Přesnost (accuracy) je definována jako podíl správně klasifikovaných dat ze všech dat, které projdou modelem (viz rovnice (2.5)). Hodí se na vyvážený dataset. Problém nastává, když je v datech jedna třída zastoupena mnohonásobně více než třída sledovaného jevu. V tomto případě je i při chybné klasifikaci minoritní třídy stále dosaženo dobrých výsledků, což neodpovídá skutečnosti.

$$\text{Přesnost} = \frac{TP + TN}{TP + FP + FN + TN} \quad (2.5)$$

Senzitivita (recall) udává podíl skutečně pozitivních případů klasifikovaných modelem z celkového počtu skutečně pozitivních (viz rovnice (2.6)). [13], [17], [52]

$$\text{Senzitivita} = \frac{TP}{TP + FN} \quad (2.6)$$

Pozitivní prediktivní hodnota (precision – PPH) popisuje, jaký podíl pozitivně detekovaných případů je skutečně pozitivních (viz rovnice (2.7)).

$$\text{PPH} = \frac{TP}{TP + FP} \quad (2.7)$$

Pro získání kvalitního modelu je důležité mít co nejvyšší hodnotu senzitivity a PPH, čímž se minimalizuje počet FN a FP případů, avšak u mnoha modelů nelze dosáhnout vysokých hodnot u obou metrik. Řešením je metrika nazývaná jako *F1 skóre*, která kombinuje senzitivitu a PPH v jednu hodnotu. F1 skóre se vypočítá jako jejich harmonický průměr (viz rovnice (2.8)), kdy mají ve výpočtu obě metriky stejnou váhu a používá se při nevyváženém počtu dat v jednotlivých třídách. [13], [52]


$$\text{F1 skóre} = 2 \cdot \frac{\text{PPH} \cdot \text{Senzitivita}}{\text{PPH} + \text{Senzitivita}} \quad (2.8)$$

3. ALGORITMUS PRO IDENTIFIKACI FIBRILACE SÍNÍ

Fibrilace síní (FiS) byla vybrána, protože se často zaměňuje za různé typy arytmii a zároveň u pacientů zvyšuje riziko cévní mozkové příhody nebo selhání srdce, což se vyhodnocuje mimo jiné na základě procenta doby, po kterou se u člověka vyskytuje FiS (zátěž – burden), a to se dopočítává pomocí přesné lokalizace začátku a konce FiS. [53], [54]

Program pro identifikaci fibrilace síní byl implementován v programovacím jazyce Python (verze 3.8.5) s využitím prostředí PyCharm a knihovny pro hluboké učení Pytorch (verze 1.6.0).

Program se skládá z několika částí (viz Obrázek 3.1). Prvním krokem bylo načtení a předzpracování dat. Následovala binární klasifikace na třídu obsahující fibrilaci síní a třídu bez fibrilace síní pomocí tří modelů neuronové sítě ResNet s MIL pooling vrstvou. Dále byla data s FiS klasifikována podle příznakové mapy získané předchozí CNN na paroxysmální a perzistentní FiS. Po klasifikaci a výběru nejlepšího modelu přišla na řadu lokalizace (identifikace) místa výskytu paroxysmální FiS v EKG záznamu, která byla provedena pomocí příznakového vektoru (feature signálu) získaného z příznakové mapy.



Obrázek 3.1 Schéma postupu pro identifikaci FiS

3.1 Použitá data

Pro identifikaci fibrilace síní byla použita dlouhodobá dynamická EKG data ze soutěže The 4th China Physiological Signal Challenge 2021 [55], která se zabývala detekcí paroxysmální fibrilace síní. Snímání datových záznamů probíhalo pomocí 12svodového holteru nebo 3svodového nositelného EKG zařízení, ze kterých byly autory databáze extrahovány pouze signály ze svodu I a svodu II se vzorkovací frekvencí 200 Hz.

Jednotlivé záznamy také zahrnují standardizované anotace podle databáze PhysioBank [56], ve kterých je uložena informace o globální anotaci (paroxysmální, perzistentní FiS a ostatních typech srdečních rytmů) i o místech začátků a konců jednotlivých epizod paroxysmální fibrilace, tedy lokálních anotacích. Zaznamenané lokální anotace byly dlouhé minimálně 5 srdečních stahů. Zároveň anotace obsahují pozice QRS komplexů.

V databázi je 1436 záznamů získaných od 100 pacientů a uložených ve formátu WFDB. Z toho 229 záznamů pocházejících od 23 pacientů je označeno jako paroxysmální fibrilace a 475 záznamů od 24 pacientů jako perzistentní fibrilace. Zbýlých 732 záznamů od 53 pacientů patří do třídy ostatních rytmů, které nejsou fibrilací síní, ale

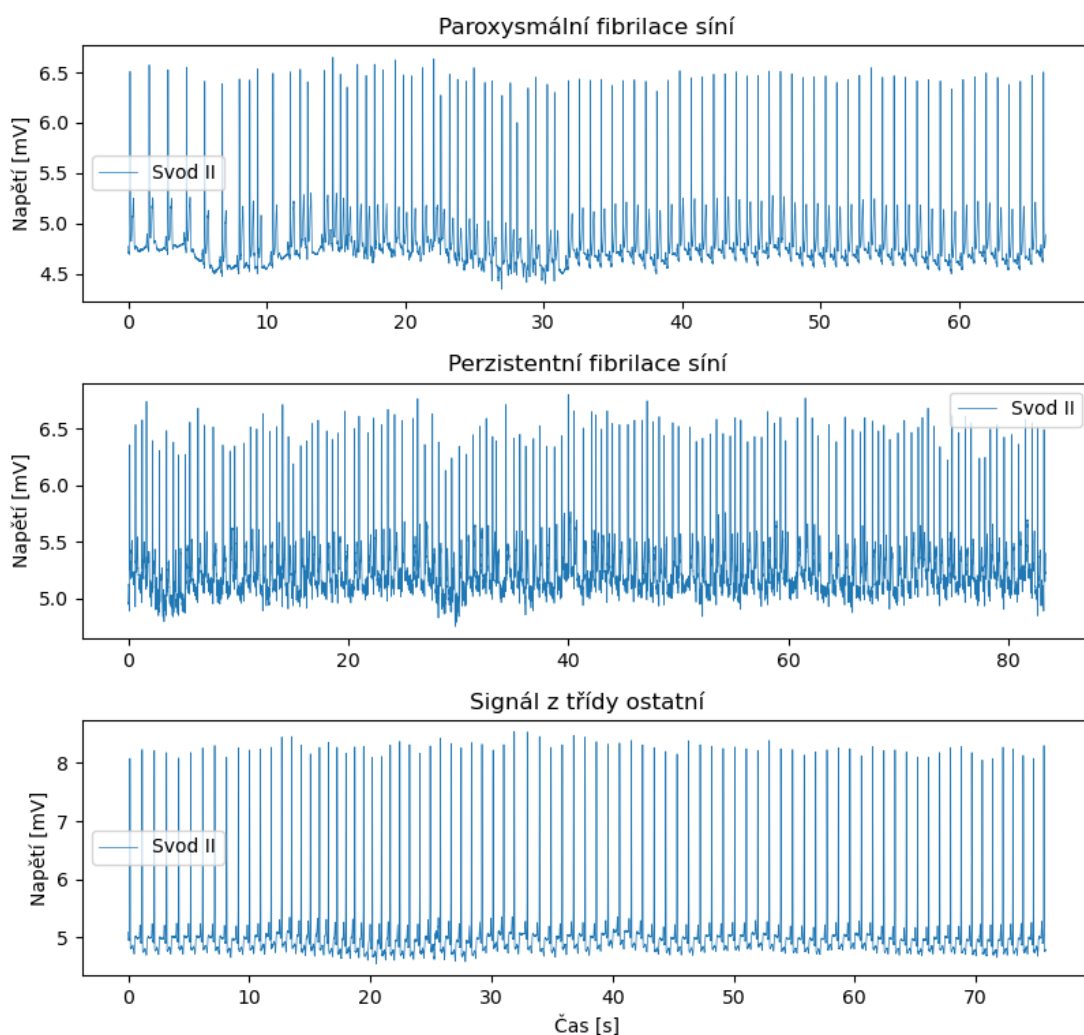
jsou zde obsaženy např. sinusový rytmus, PAC nebo PVC. Navíc mezi paroxysmálními fibrilacemi je zahrnuto 22 záznamů flutteru síní.

Délky extrahovaných signálů se pohybují v rozsahu od 8,38 sekund až do 6,85 hodin, přičemž polovina signálů je kratších než 9,34 minut. Popis délek signálů a četnost jednotlivých tříd je uvedena v Tabulce 3.1.

Příklad signálů pro jednotlivé kategorie obsažené v použité databázi zobrazuje Obrázek 3.2. [55]

Tabulka 3.1 Četnost záznamů a popis délek signálů jednotlivých tříd

Třída	Četnost [-]	Počet pacientů [-]	Délky signálů			
			Min [s]	Medián [min]	Průměr [min]	Max [h]
Paroxysmální FiS (flutter)	229 (22)	23	39,61	5,14	12,04	5,49
Perzistentní FiS	475	24	8,38	7,20	18,65	6,85
Ostatní	732	53	25,19	18,30	24,01	4,61
Celkem	1436	100	8,38	9,34	20,33	6,85



Obrázek 3.2 Příklad signálů pro jednotlivé kategorie z databáze

3.2 Předzpracování dat

Před aplikováním modelu hlubokého učení na EKG záznamy je důležité tato vstupní data předzpracovat, jelikož kvalita dat přímo ovlivňuje schopnost učení modelu. [57]

Nejprve byly z načtených dat vybrány oba dostupné svody (I i II) a k nim příslušné globální anotace, které byly převedeny na binární klasifikaci fibrilace síní tak, že paroxysmální a persistentní FiS byly označeny labelem 1 a třída ostatních labelem 0.

Poté byla v datech odstraněna stejnosměrná složka a drift nulové izoliny. Následně byla z dat vytvořena nová množina umožňující trénování na grafické kartě, která byla dále rozdělena na trénovací, validační a testovací množinu. Navíc byla do procesu trénování také zahrnuta augmentace dat.

Zároveň při případné různé délce dat byla data při výběru do dávky (batch) upravena na stejnou délku tak, že kratší záznamy byly doplněny nulami na délku nejdelšího záznamu pomocí funkce *collate_fn*.

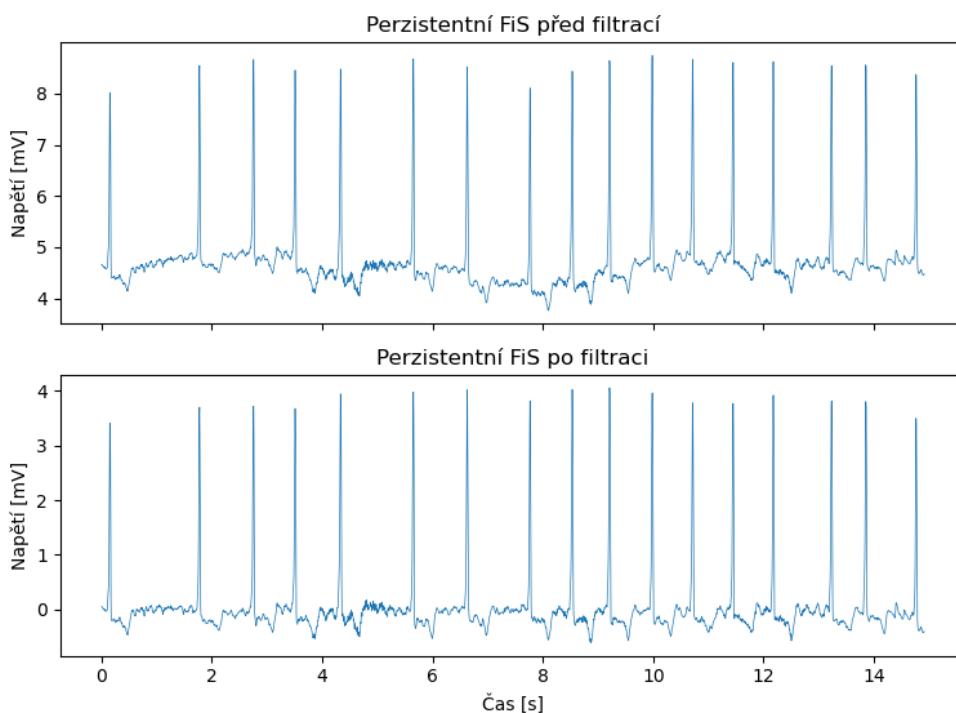
3.2.1 Filtrace stejnosměrné složky a driftu

Zobrazením signálů z použité databáze byl patrný výskyt stejnosměrné složky a kolísání nulové izolinie (viz Obrázek 3.2 a 3.3), což dokládá i analýza jejich frekvenčních spekter (viz Obrázek 3.4).


Filtrace byla provedena pomocí Butterworthova filtru 4. řádu typu horní propust s mezní frekvencí 0,5 Hz. Jedná se o velmi používaný filtr, jelikož má maximálně plochou amplitudovou frekvenční charakteristiku, ostrý přechod mezi propustným a nepropustným pásmem a jeho fázová frekvenční charakteristika je blízká lineární [58].

Signál perzistentní FiS před a po filtraci je uveden na Obrázku 3.3 a změnu ve frekvenčním spektru dokládá Obrázek 3.4.

Na uvedeném příkladu perzistentní FiS lze vizuálním pozorováním dokázat, že filtrací nedochází k výraznému zkreslení f vln, tudíž tím nebude ovlivněn průběh klasifikace a následné lokalizace FiS.



Obrázek 3.3 Signál perzistentní FiS před a po filtraci



Obrázek 3.4 Frekvenční spektrum EKG s perzistentní FiS před a po filtraci

3.2.2 Vytvoření trénovací množiny a její rozdělení

Jelikož se v použité databázi vyskytuje velké množství objemných záznamů, tak bylo nutné z nich vytvořit novou množinu, která obsahuje již zkrácené, 30 sekund dlouhé záznamy.

Nejprve byly odstraněny záznamy kratší než 30 sekund. Dalším krokem byl výběr záznamů s paroxysmální FiS, který byl proveden posouváním okna o velikosti 30 sekund s krokem 10 sekund po signálu. Signál o délce okna byl uložen do nové množiny, pokud se v něm vyskytovala právě jedna paroxysmální FiS obsahující začátek a konec. Takto bylo vytvořeno 344 záznamů paroxysmální FiS (viz Tabulka 3.2).

Nakonec bylo vybráno z původních záznamů, které obsahovaly perzistentní FiS nebo jiné arytmie a rytmy ve třídě Ostatní, prvních 30 sekund. Jejich počet byl stanoven podle počtu záznamů s paroxysmální FiS tak, aby v množině byly rovnoměrně zastoupeny třídy FiS a Ostatní (viz Tabulka 3.2). U všech nově vytvořených záznamů byla zachována jejich původní globální anotace a počet svodů.

Tabulka 3.2 Četnost záznamů v nové množině

Třída	Četnost [-]	Zastoupení [%]	Label [-]	Délka signálů [s]
Paroxysmální FiS (flutter)	344 (123)	25	1	30
Perzistentní FiS	344	25	1	30
Ostatní	688	50	0	30

Poté byla data z nové množiny rozdělena do trénovací, validační a testovací množiny. Rozdělení dat do množin je důležité k tomu, aby bylo možné vyhodnotit kvalitu modelu neuronové sítě. Na trénovací množině se neuronová síť učí. Validací množina udává, jak dobře síť generalizuje (reaguje na nová data).

Data byla do množin rozdělena náhodně v poměru 8:1:1, aby byla vytvořena co největší trénovací množina, ale současně zůstalo zachováno stejné procentuální zastoupení jednotlivých tříd v obou množinách, tzn. že byly podle uvedeného poměru samostatně rozděleny záznamy patřící do třídy FiS a poté záznamy ze třídy Ostatní. Zastoupení obou tříd v jednotlivých množinách je uvedeno v Tabulce 3.3.

Tabulka 3.3 Četnost záznamů v trénovací, validační a testovací množině

Třída	Trénovací množina	Validační množina	Testovací množina
	Četnost [-]	Četnost [-]	Četnost [-]
FiS	551	69	68
Ostatní	550	68	70
Celkem	1101	137	138

3.2.3 Augmentace

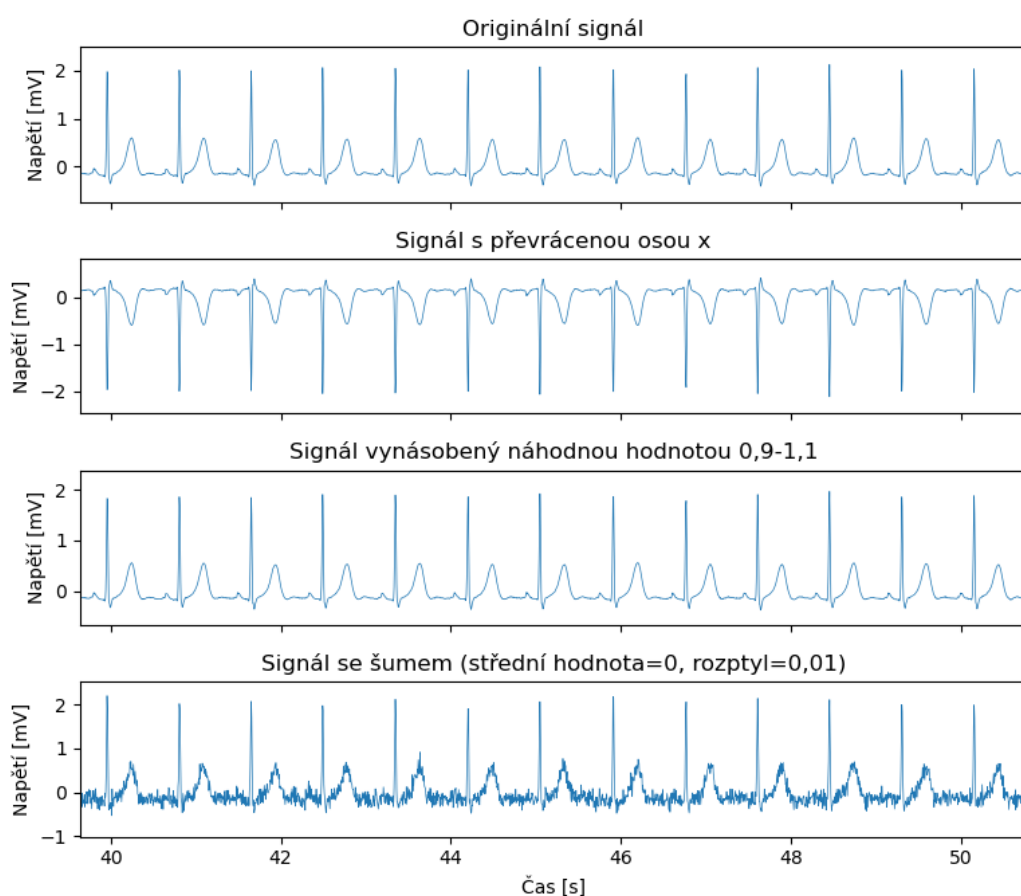
Aby bylo možné využít výhody modelu hlubokého učení, je žádoucí mít velké množství trénovacích dat. Rozšíření trénovací sady lze dosáhnout pomocí augmentace dat.

Augmentace dat je metoda, která umožňuje zvětšení počtu trénovacích dat a tím také zabraňuje rychlému přeučení. Provádí se aplikací náhodných transformací na trénovací data, kdy dojde k úpravě dat, ale jejich label zůstává zachován. Při klasifikaci obrazů mohou být takovými transformacemi např. ořiznutí, rotace nebo převrácení obrazu. Tyto jednoduché transformace lze použít i pro 1D signály (jako je EKG), ale není u nich zaručeno dosažení správného výsledku, protože EKG signál se skládá z tvarově odlišných vln a kmitů. [59], [60]

Augmentace EKG záznamů je vhodná také díky tomu, že je stále velmi složité sestavit kvalitní soubor dat pro hluboké učení. Problematická je zejména anotace dat, která je i pro kvalifikované lékaře velmi obtížná a pracná. [59], [61]

Podle autorů [61] je třeba k rozšíření počtu trénovacích EKG záznamů použít více než jednu augmentační metodu, aby bylo možné dostat dostatečně velký a rozmanitý trénovací dataset. Zároveň tito autoři uvádějí, že stejné transformace budou mít na různé soubory dat odlišný dopad.

Pro účely této práce byly vybrány tři augmentační metody, které byly postupně aplikovány na trénovací data během načítání do dávek (batchů). První transformací bylo převrácení znaménka podél osy x, kdy vzorky signálu byly vynásobeny hodnotou -1 . Další transformace zahrnovala vynásobení osy y náhodně zvolenou hodnotou z rozmezí od $0,9$ do $1,1$. Poslední implementovanou metodou pro augmentaci bylo přidání Gaussova šumu se střední hodnotou 0 a rozptylem $0,01$ k signálu. Všechny transformace byly použity na každý svod v EKG záznamu s pravděpodobností 70% . Z toho vyplývá, že na jeden EKG záznam mohou být aplikovány klidně všechny tři metody. Vliv samostatných augmentačních metod na výřez EKG signálu demonstruje Obrázek 3.5.



Obrázek 3.5 Výřez signálů EKG představující vliv jednotlivých augmentačních metod

3.3 Detekce fibrilace síní

Pro binární klasifikaci (FiS vs. Ostatní) fibrilace síní a zbylých EKG záznamů byl zvolen model podle autorů [62], kteří ji používali k identifikaci PVC. Tento model se skládá ze dvou částí, kdy první z nich slouží ke klasifikaci a druhá k lokalizaci PVC. v rámci této práce byla použita pouze klasifikační část, která je tvořena konvoluční neuronovou sítí ResNet upravenou na zpracování signálu převedením všech 2D konvolučních vrstev na 1D. [62]

Model ResNet byl vybrán, jelikož díky reziduálním blokům dokáže vyřešit problém s mizejícím gradientem, kdy se pomocí identity učí pouze malé změny. Jakmile se tedy daný příznak naučí, již se ho nemusí znovu učit a může se zaměřit na další příznaky. Tím zlepšuje výsledek trénování modelu a současně snižuje dobu trénování. Zároveň zachovává přednosti hlubokého učení, kdy extrahuje příznaky na různé úrovni složitosti, a tak nevyžaduje složité předzpracování dat.

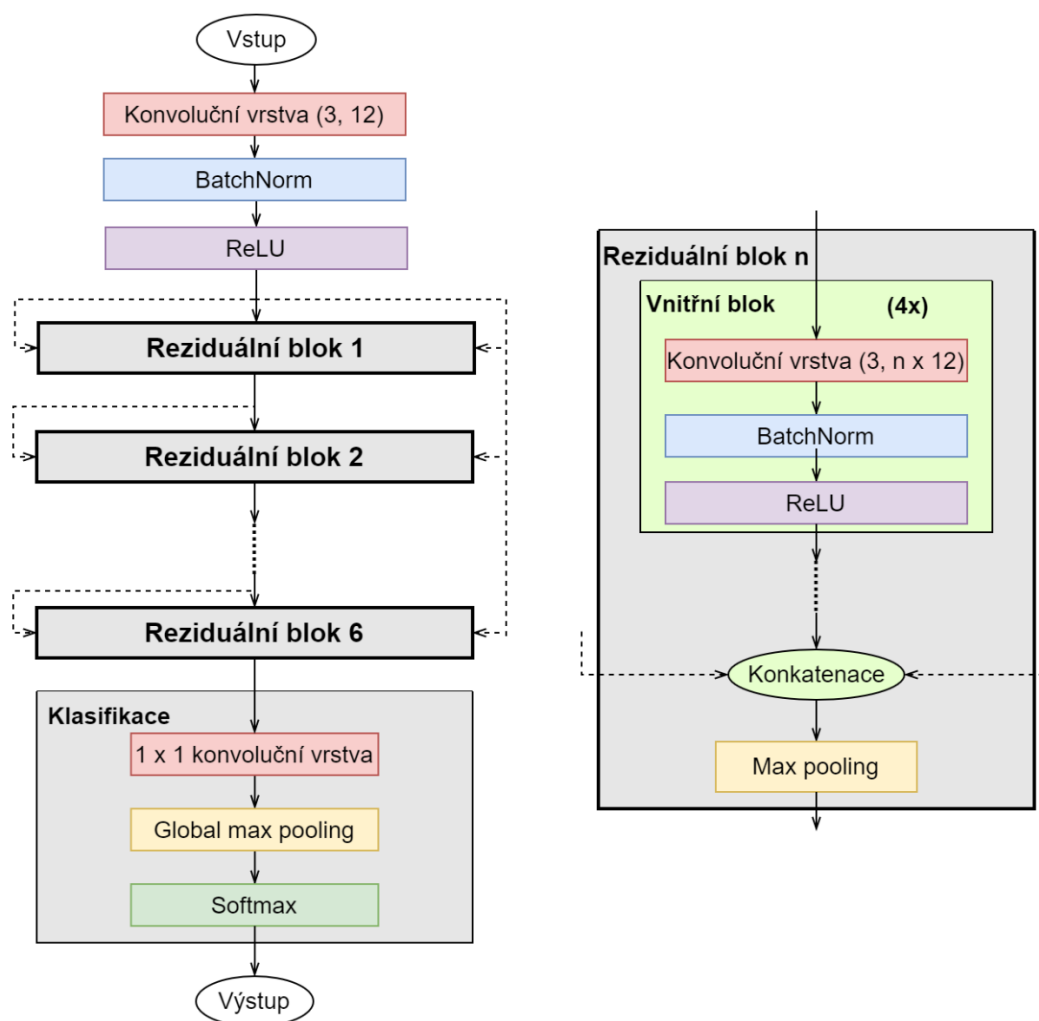
3.3.1 Implementace modelu pro identifikaci záznamů

Autoři [62] model, jehož vstupem je 12 svodů EKG, navrhli jako 6 reziduálních bloků, kdy v každém z nich jsou 4 konvoluční vrstvy o velikosti filtru 3, po kterých vždy následují BatchNorm a ReLU vrstvy. Po každém reziduálním bloku je aplikován maxpooling s velikostí filtru 2 a posunem 2, čímž se sníží prostorová velikost příznakových map na polovinu. Počet filtrů konvolučních vrstev uvnitř bloků se vždy v dalším bloku zvyšuje o 12, tzn. že počet filtrů pro jednotlivé bloky je 12, 24, 36, 48, 60 a 72. Klasifikace je řešena 1 x 1 konvoluční vrstvou a MIL poolingem (GMP, popř. GAP) se sigmoidou.

Uvedený model (viz Obrázek 3.6 a Tabulka 3.4) byl pomocí knihovny Pytorch implementován ve skriptu *model.py* ve dvou blocích. Nejprve byl implementován vnitřní blok *myConv* jako třída dědicí z *nn.Module*. Tento blok zahrnoval konvoluční, BatchNorm a ReLU aktivační vrstvu v uvedeném pořadí a jeho vstupem byly atributy sloužící k definování konvoluční vrstvy, tudíž počet příznaků vstupního tensoru, počet příznaků výstupního tensoru (počet filtrů), velikost filtru a posun (stride). Blok *myConv* slouží k vytvoření jednotlivých reziduálních bloků.

Před reziduálními bloky je ještě na vstupní data (2 svody EKG) aplikována úvodní konvoluční vrstva, která upravuje počet vstupních signálů na počet filtrů v konvolučních vrstvách prvního reziduálního bloku.

Druhý blok byl pojmenován jako *ResNet*, který nejprve definoval všechny konvoluční vrstvy modelu tvořené úvodní konvolucí, blokem *myConv* (reziduální bloky) a 1 x 1 konvolucí. Následně byl v metodě *forward* stanoven průchod (pořadí) vrstvami modelu. Úvodní konvoluční vrstvu následovaly reziduální bloky s konkatencí. Po každém reziduálním bloku byl proveden maxpooling. Na závěr byla aplikována 1 x 1 konvoluční vrstva, GMP (MIL pooling) a místo sigmoidy byla jako aktivační funkce použita softmax, u které není nutné nastavovat klasifikační práh. [62]



Obrázek 3.6 ResNet model Default pro binární klasifikaci EKG (FiS vs. Ostatní)

Tabulka 3.4 Parametry modelu Default

Parametry modelu	Hodnota
Počet reziduálních bloků	6
Počet vnitřních bloků s konvoluční vrstvou uvnitř reziduálních bloků	4
Velikost filtru konvolučních vrstev	3
Počet filtrů konvolučních vrstev v prvním reziduálním bloku	12

3.3.2 Učení modelu

Trénování modelu bylo realizováno na trénovací množině s náhodným pořadím dat. Jako optimalizační algoritmus byl zvolen Adam s defaultními parametry ($\beta_1=0,9$ a $\beta_2=0,999$), který je blíže popsán v kapitole 2.3.3 a v současné době je považován za standard. Inicializace vah byla provedena pomocí Xavierovy metody. Pro výpočet celkové chyby klasifikace byla použita jako ztrátová funkce často využívaná vzájemná entropie (viz kapitola 2.3.2). Také byla zavedena postupná změna kroku učení umožňující se co nejlépe přiblížit globálnímu minimu, proto byl krok učení po každých 50 epochách vynásoben hodnotou 0,1 [62].

Učení probíhalo na grafické kartě NVIDIA GeForce GTX 1070 Ti a jeho úspěšnost byla vyhodnocena zejména pomocí F1 skóre a matice záměn.

3.3.3 Optimalizace hyperparametrů

Efektivita modelu také závisí na vhodném nastavení hyperparametrů jako jsou počet epoch, velikost dávky a krok učení. Pro zvýšení úspěšnosti učení byla zařazena dropout vrstva, která slouží jako regularizace a zabraňuje tak rychlému přeučení modelu. Pravděpodobnost vypnutí neuronů ve vnitřních vrstvách sítě udává parametr p .

K nalezení optimální konfigurace byly určeny rozmezí jednotlivých hyperparametrů (viz Tabulka 3.5) s ohledem na informace uvedené v teoretické části. Podle nich byly experimentálně vybírány hodnoty hyperparametrů a trénovány modely.


Pro trénování modelů bylo použito nastavení uvedené v kapitole 3.3.2 s tím, že během trénování byly ukládány jednotlivé verze modelů, aby bylo možné zvolit model, který bude mít vysokou hodnotu F1 skóre na validační množině a zároveň nebude přeučený.

Velikost dávky byla zvolena 30, jelikož při hodnotách větších než 40 i menších než 20 byl pozorován velký rozkmit v průběhu chybové funkce a F1 skóre. Nejlepší hodnota kroku učení byla 0,001. U ostatních zkoumaných hodnot (0,0002 a 0,005) bylo během 100 epoch učení dosaženo nižšího F1 skóre (a vyšší chyby) než při určené hodnotě. V dropout vrstvě byl parametr p stanoven na 0,1, protože při velikosti parametru 0,2 nastal stejný problém jako při nastavení kroku učení a pro $p = 0,5$ se dokonce F1 skóre v průběhu učení snižovalo. Nakonec byl stanoven počet epoch podle křivky učení modelu s uvedeným nastavením hyperparametrů na hodnotu 66.

Výsledný průběh chyby učení a F1 skóre modelu s optimalizovanými hyperparametry je zobrazen na Obrázku 3.7.

Tabulka 3.5 Rozmezí a výsledná hodnota hyperparametrů

Hyperparametry	Rozmezí	Výsledná hodnota
Velikost dávky	15–50	30
Krok učení	0,0002–0,005	0,001
Dropout – parametr p	0,1–0,5	0,1
Počet epoch	1–100	66

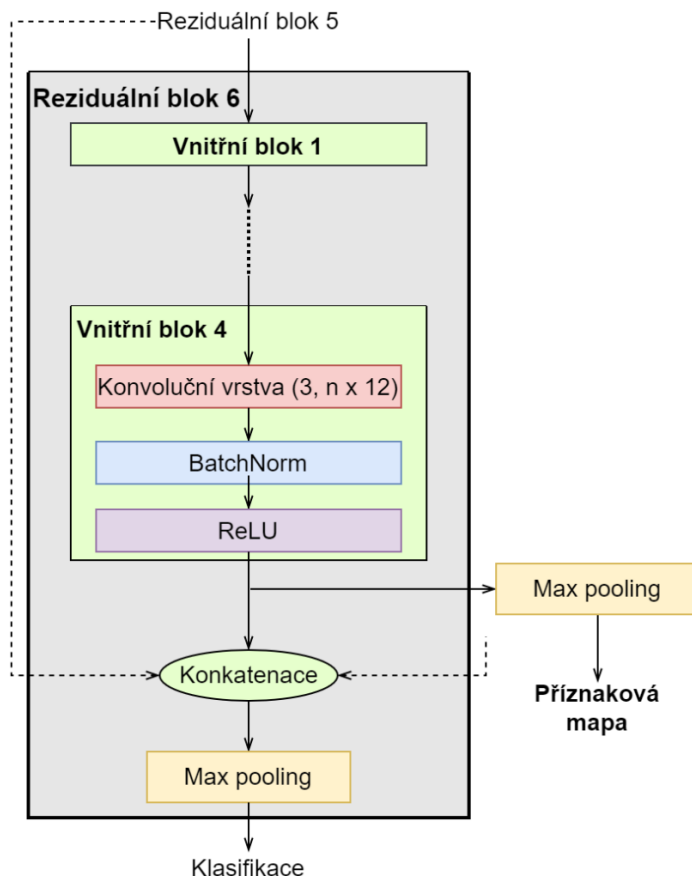


Obrázek 3.7 Průběh učení modelu: F1 skóre (vlevo) a chyba (vpravo)

3.3.4 Příznaková mapa

Z výstupu posledního, šestého reziduálního bloku sítě ResNet byla pro všechny záznamy získána příznaková mapa, kde řádky reprezentují jednotlivé příznaky vytvořené konvolučními filtry a sloupce komprimovanou časovou osu jednotlivých signálů. Hodnota jednotlivých „pixelů“ mapy udává úroveň výskytu paroxysmální FiS. Přesné místo v síti, ze kterého pochází příznaková mapa je zobrazeno na Obrázku 3.8.

Síť v počátečních vrstvách nejdříve v EKG signálu „detekuje“ QRS komplexy a následně se v hlubších vrstvách zaměřuje na extrakci detailnější informace pocházející z blízkosti QRS komplexu, zejména z PQ intervalu.

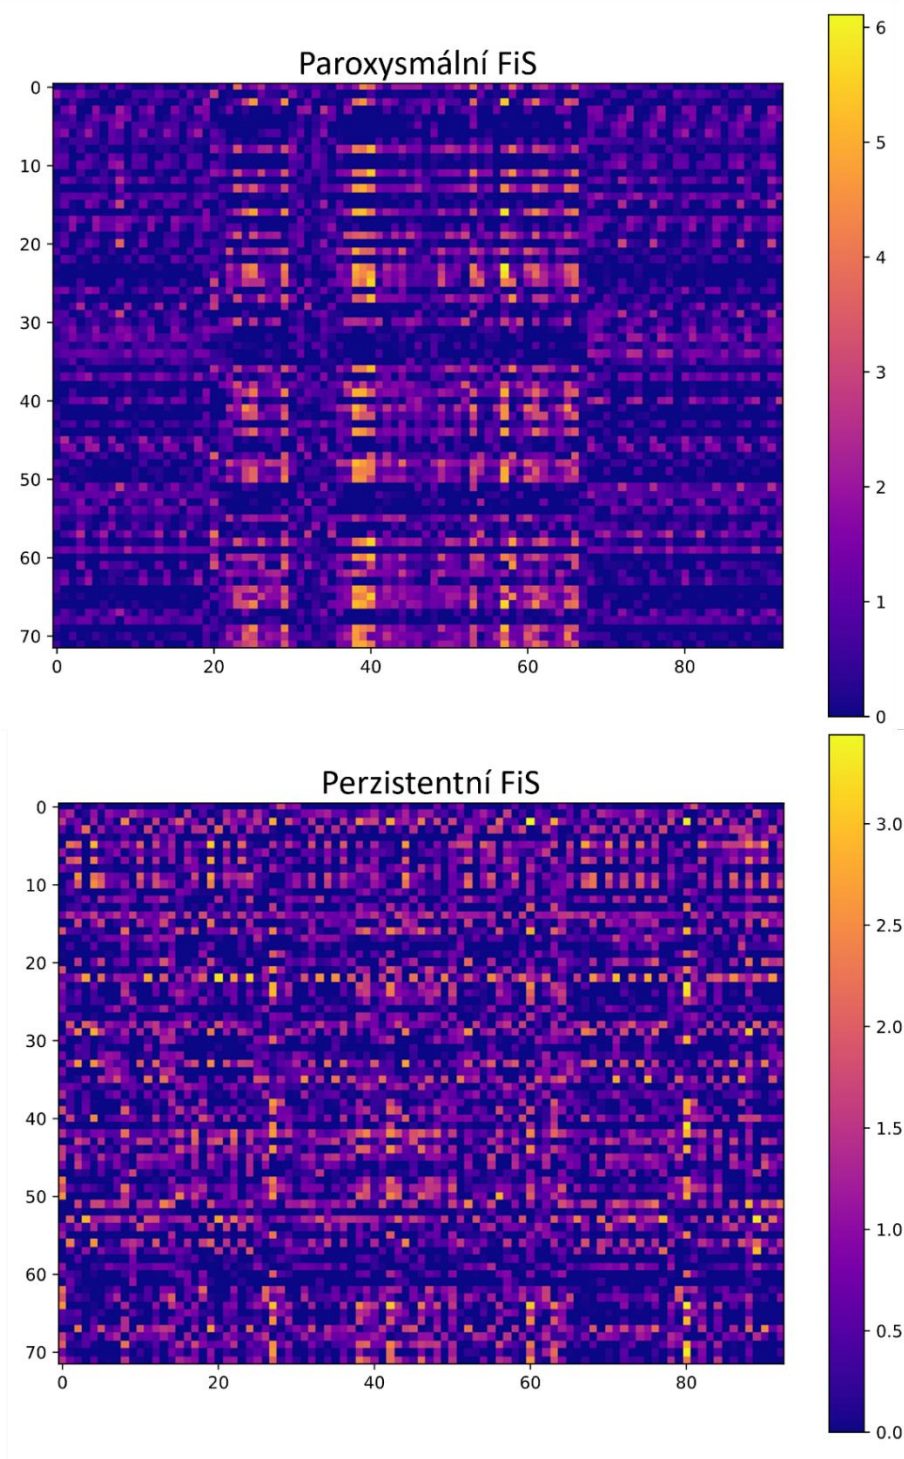


Obrázek 3.8 Odvození příznakové mapy v síti ResNet

3.4 Klasifikace fibrilace síní

Po binární klasifikaci na záznamy s FiS a ostatní záznamy bylo nutné od sebe odlišit paroxysmální a perzistentní FiS, popř. ostatní rytmy falešně detekované jako FiS. Perzistentní FiS probíhá nepřetržitě po celou dobu trvání záznamu, tudíž není v těchto záznamech možné identifikovat začátek a konec FiS.

Na základě vizuálního pozorování bylo zjištěno, že příznakové mapy paroxysmální a perzistentní FiS od sebe liší velikostí maxima celé mapy a také směrodatnou odchylkou jednotlivých příznaků (tj. hodnot „pixelů“) (viz Obrázek 3.9).



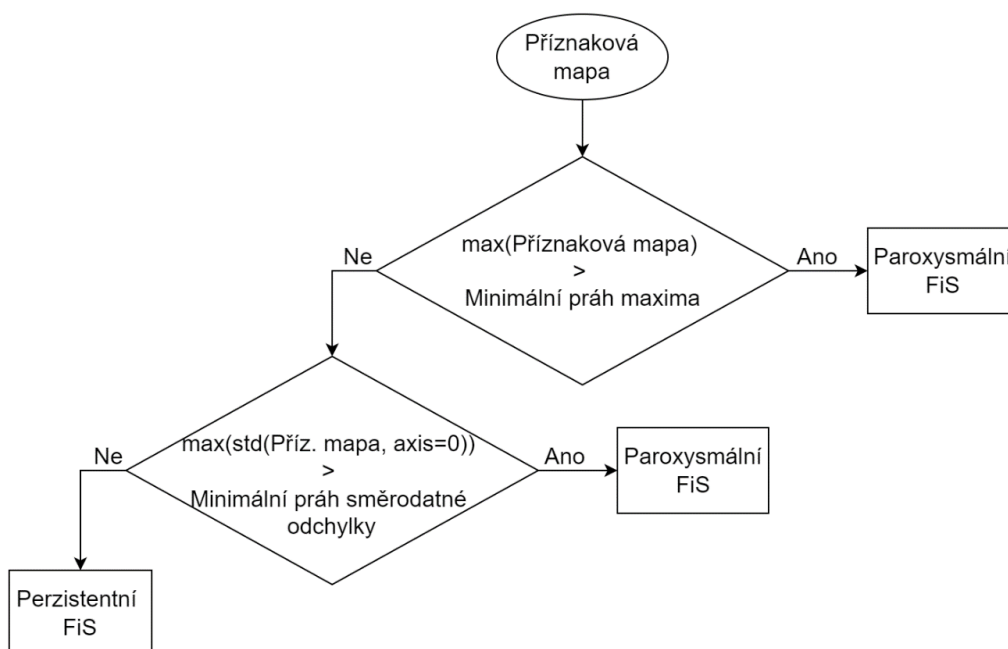
Obrázek 3.9 Příklad příznakové mapy pro paroxysmální a perzistentní FiS

Klasifikace tak byla uskutečněna pomocí příznakových map (heat mapy), na které byla aplikována sada rozhodovacích pravidel (viz Obrázek 3.10).

3.4.1 Rozhodovací pravidla

Nejprve bylo zkoumáno, zda maximum heat mapy je větší než hodnota parametru označeného jako Minimální práh maxima. Pokud byla podmínka splněna, tak se jednalo o paroxysmální FiS. Dále byla sledována maximální směrodatná odchylka z jednotlivých řádků heat mapy, kdy při hodnotě větší než hodnota parametru nazvaného Minimální práh směrodatné odchylky, byl signál zařazen do třídy paroxysmální FiS. V případě, že signál nesplňoval ani jednu ze dvou podmínek, tak byl klasifikován jako perzistentní FiS.

Oba parametry byly stanoveny na základě prohledávání stavového prostoru z daného rozsahu a jejich výsledné hodnoty byly získány podle velikosti F1 skóre na trénovací množině (viz Tabulka 3.6). Pro model Default byl získán Minimální práh maxima s hodnotou 4,2 a Minimální práh směrodatné odchylky o velikosti 0,9.



Obrázek 3.10 Schéma rozhodovacích pravidel pro klasifikaci FiS

Tabulka 3.6 Nastavení parametrů klasifikace FiS


Parametry	Prohledávaný rozsah	Krok	Model Default
Minimální práh maxima	2–8	0,1	4,2
Minimální práh směrodatné odchylky	0,5–3,55	0,05	0,9

3.5 Lokalizace paroxysmální fibrilace síní

Poslední částí programu je samotná identifikace začátku a konce paroxysmální FiS realizovaná prahováním feature signálu získaného z příznakové mapy.

3.5.1 Vytvoření feature signálu

Prvním krokem lokalizace je vytvoření feature signálu z příznakové mapy, která v řádcích obsahuje příznaky získané z natrénovaného modelu ResNet sítě. Z těchto příznakových řádků byly vybrány pouze ty, jejichž maximum bylo větší než hodnota o velikosti 75% maxima celé příznakové mapy. Tato hodnota byla stanovena experimentálně, protože příznaky s vysokou hodnotou maxima zahrnují i informace o místě výskytu paroxysmální FiS. Tím byla získána redukovaná příznaková mapa (viz Obrázek 3.11).

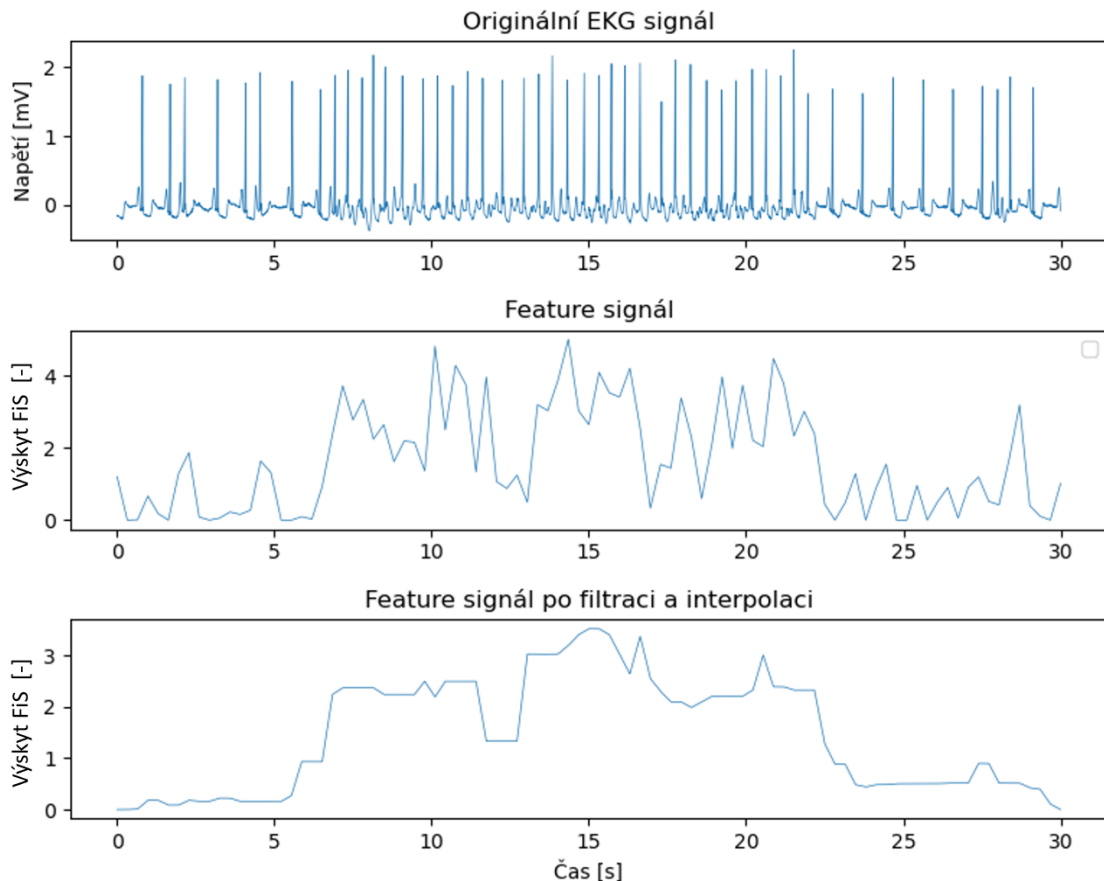


Obrázek 3.11 Vytvoření redukované příznakové mapy

Po výběru příznakových vektorů byl z redukované příznakové mapy pomocí mediánu vytvořen jeden signál (feature signál). Ten byl následně vyhlazen pomocí mediánového

filtru s velikostí okna 9 a interpolován na počet vzorků původního EKG signálu (viz Obrázek 3.12).

Mediánová filtrace byla provedena z důvodu odstranění nízkých hodnot mezi začátkem a koncem FiS a vyhlazení nízkých peaků mimo oblast FiS, protože tyto jevy by mohly negativně ovlivnit následnou lokalizaci. Mediánová filtrace byla zvolena také kvůli zachování hran v signálu. Interpolací došlo ke zvýšení časové rozlišovací schopnosti feature signálu a tím mohlo být dosaženo přesnější lokalizace začátků a konců epizod FiS.



Obrázek 3.12 Vytvoření a zpracování feature signálu

3.5.2 Prahování

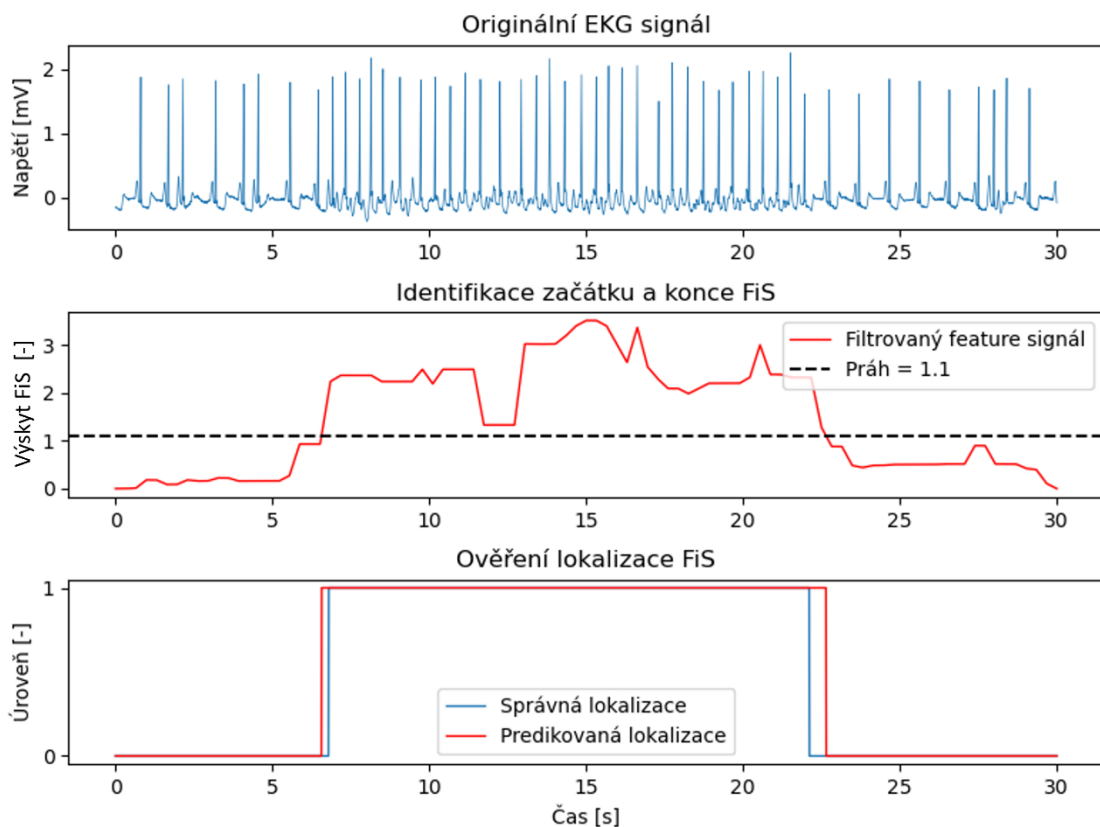
Po vytvoření a úpravě feature signálu bylo provedeno prahování tak, aby bylo možné označit začátek a konec FiS.

První vzorek ve feature signálu s hodnotou vyšší než práh byl označen jako začátek FiS. Konec FiS byl pak určen jako poslední vzorek s nadprahovou hodnotou. Práh pro identifikaci začátku a konce FiS byl stanoven jako směrodatná odchylka feature signálu.

Aby se předešlo falešně pozitivním lokalizacím kratších než 5 srdečních stahů, které nebyly v použité databázi anotovány, byl ověřen počet QRS komplexů vyskytujících se

v lokalizovaném časovém úseku v původním signálu. Pokud byl počet QRS komplexů menší než 5, tak byla lokalizace odstraněna.

Dalším omezením byl výběr pouze části signálu s jedním začátkem a koncem paroxysmální FiS při vytváření nové množiny dat z původní datové sady (viz kapitola 3.2.2). Při vzniku falešných začátků a konců epizod FiS v daném signálu by nebylo možné ověřit správnost lokalizace, proto byla vytvořena další podmínka, která vybírá pouze lokalizaci obsahující maximální hodnotu výskytu FiS ve feature signálu. Příklad lokalizace paroxysmální FiS je zobrazen na Obrázku 3.13.



Obrázek 3.13 Lokalizace paroxysmální FiS

3.6 Optimalizace architektury

Implementovaný model Default pro klasifikaci FiS byl dále optimalizován, jelikož získané příznakové mapy obsahují velké množství redundantních příznaků (řádků). Vliv na počet příznaků v mapě má především počet filtrů v konvolučních vrstvách prvního reziduálního bloku a počet reziduálních bloků, který má také dopad na délku příznaků.

Optimalizace také spočívá ve snížení počtu vah modelu, čímž se sníží výpočetní náročnost trénování. To lze ovlivnit nastavením počtu konvolučních vrstev uvnitř vnitřních bloků a velikostí filtrů.


Trénování modelů probíhalo se stejným nastavením učení i stejnými hyperparametry jako u modelu Default (viz kapitola 3.3.2 a 3.3.3). Totožně byl zvolen i počet epoch, který byl nejprve inicializován na hodnotu 100. Poté se během trénování ukládaly modely každé epochy, a výsledný model byl stanoven podle velikosti F1 skóre na validační množině a průběhu chyby učení.

Nakonec byly ze zkoumaných rozsahů parametrů (viz Tabulka 3.7) vybrány dva modely pojmenované jako Optim 1 a Optim 2 dosahující nejlepších výsledků na validační množině s hodnotou F1 skóre 0,97, resp. 0,98 (viz Obrázek 3.14 a Obrázek 3.15). Jejich parametry jsou uvedeny také v Tabulce 3.7.

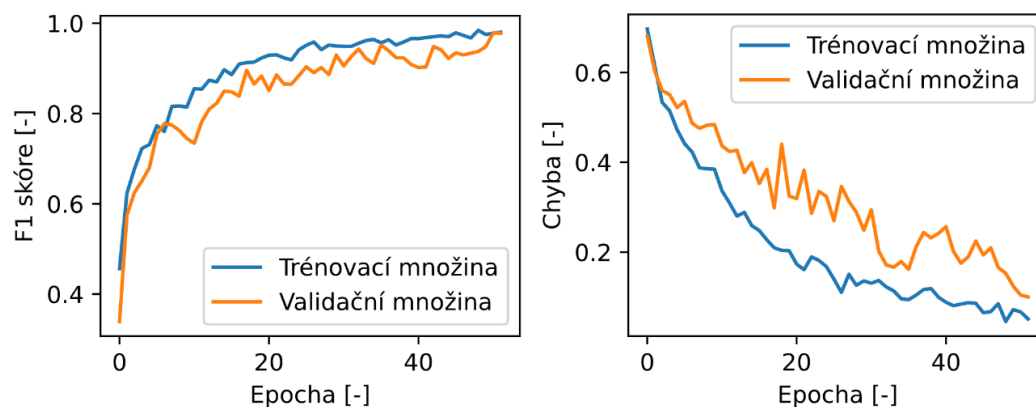
U obou modelů došlo optimalizací parametrů ke zmenšení počtu příznaků v příznakových mapách a k výrazné redukcí počtu vah oproti původnímu modelu (viz Tabulka 3.8, Obrázek 3.16 a Obrázek 3.17).

Tabulka 3.7 Rozmezí parametrů pro optimalizaci architektury Default a hodnoty výsledných modelů Optim 1 a Optim 2

Parametry modelu	Rozmezí	Optim 1	Optim 2
Počet reziduálních bloků	4–6	6	6
Počet vnitřních bloků s konvoluční vrstvou uvnitř reziduálních bloků	2–4	2	3
Velikost filtru konvolučních vrstev	3–7	7	5
Počet filtrů konvolučních vrstev v prvním reziduálním bloku	4–8	4	6



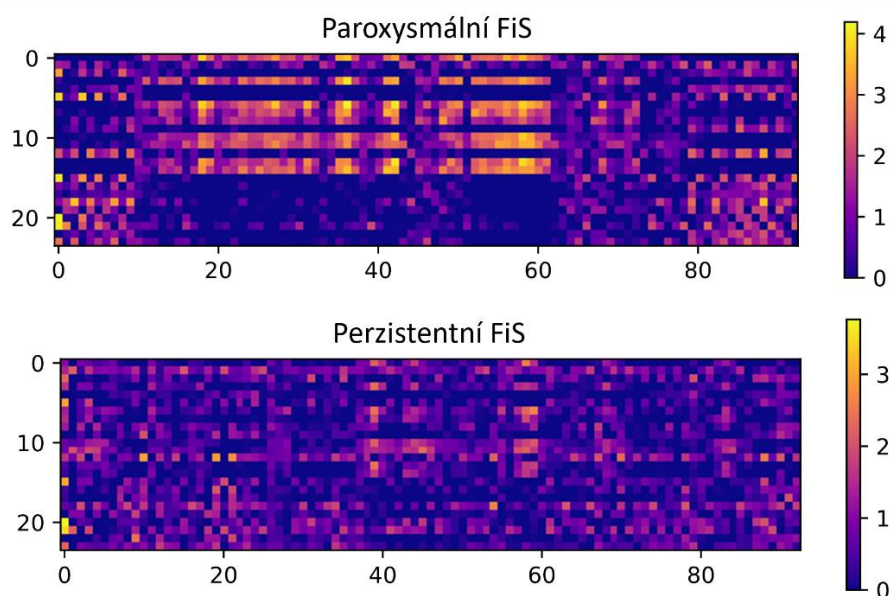
Obrázek 3.14 Průběh učení modelu Optim 1: F1 skóre (vlevo) a chyba (vpravo)



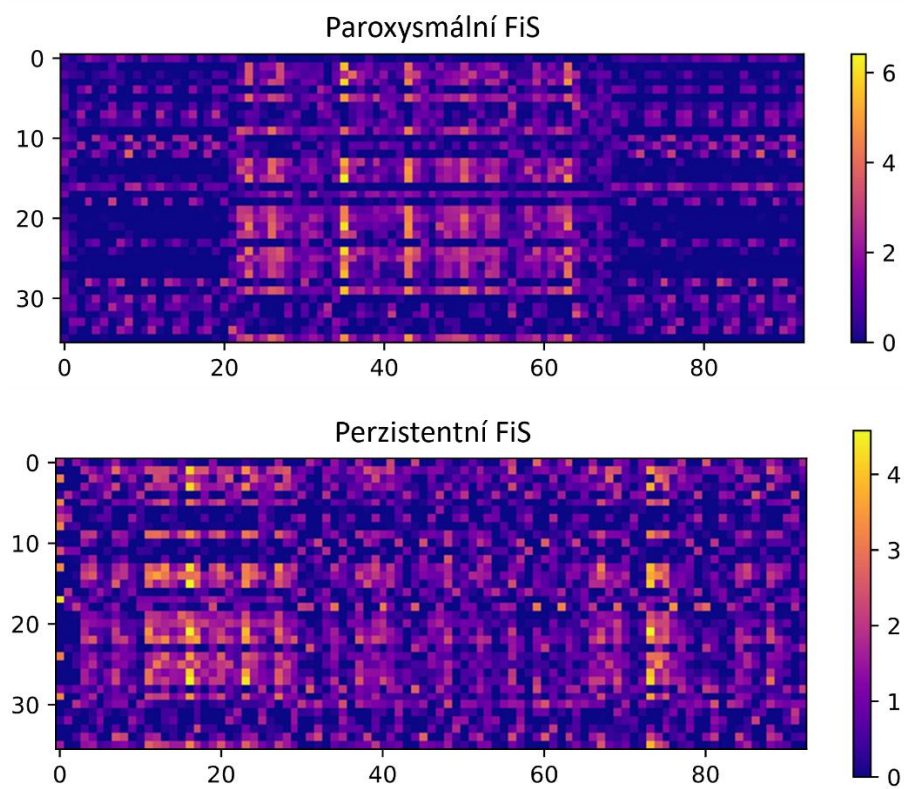
Obrázek 3.15 Průběh učení modelu Optim 2: F1 skóre (vlevo) a chyba (vpravo)

Tabulka 3.8 Charakteristika modelů

Charakteristika modelu	Default	Optim 1	Optim 2
Počet příznaků	72	24	36
Počet vah	190934	28902	63110
F1 skóre na validační množině	0,95	0,97	0,98



Obrázek 3.16 Příklad příznakových map – model Optim 1



Obrázek 3.17 Příklad příznakových map – model Optim 2

4. VÝSLEDKY

V této kapitole jsou uvedeny výsledky navržené architektury na trénovací, validační a testovací množině. Popis výsledků je rozdělen na klasifikaci a lokalizaci FiS. Klasifikace zahrnuje vyhodnocení pro jednotlivé modely a jejich porovnání. Lokalizace uvádí evaluaci detekce začátků a konců FiS a jejich příklady pro model s nejlepšími výsledky na testovací množině.

4.1 Klasifikace FiS

4.1.1 Model Default

V Tabulce 4.1 jsou zobrazeny matice záměn modelu Default pro trénovací, validační a testovací množinu. Podle uvedených matic záměn a F1 skóre (viz Tabulka 4.2) lze říci, že model je dostatečně naučený k detekci FiS, jelikož množství falešně negativních a falešně pozitivních případů ve validační a testovací množině je 5,11 %, resp. 2,9 % a současně F1 skóre ve všech množinách přesahuje hodnotu 0,9.

Tabulka 4.1 Model Default – matice záměn pro detekci FiS

Trénovací množina		Predikovaná třída	
		Ostatní	FiS
Skutečná třída	Ostatní	545	5
	FiS	14	537

Validační množina		Predikovaná třída	
		Ostatní	FiS
Skutečná třída	Ostatní	67	1
	FiS	6	63

Testovací množina		Predikovaná třída	
		Ostatní	FiS
Skutečná třída	Ostatní	69	1
	FiS	3	65

Tabulka 4.2 Model Default – F1 skóre detekce FiS

Model Default	F1 skóre
Trénovací množina	0,98
Validační množina	0,95
Testovací množina	0,97

Při klasifikaci na paroxysmální FiS a perzistentní FiS je však již úspěšnost nižší. To dokazují hodnoty F1 skóre v Tabulce 4.4, jehož nejvyšší hodnota je pouze 0,72 na trénovací množině. To samé dokládají matice záměn (viz Tabulka 4.3), ve kterých se vyskytuje velké množství falešně pozitivních případů, např. v trénovací množině je 210 (38,75 %) falešně pozitivních z celkového počtu 542 záznamů. Klasifikace byla provedena s hodnotami Minimálního prahu maxima 4,2 a Minimálního prahu směrodatné odchylky 0,9 získané prohledáváním určených rozsahů parametrů.

Tabulka 4.3 Model Default – matice záměn pro klasifikaci paroxysmální FiS

Trénovací množina		Predikovaná třída	
		Perzistentní FiS	Paroxysmální FiS
Skutečná třída	Perzistentní FiS	54	210
	Paroxysmální FiS	4	274

Validační množina		Predikovaná třída	
		Perzistentní FiS	Paroxysmální FiS
Skutečná třída	Perzistentní FiS	6	27
	Paroxysmální FiS	1	30

Testovací množina		Predikovaná třída	
		Perzistentní FiS	Paroxysmální FiS
Skutečná třída	Perzistentní FiS	9	25
	Paroxysmální FiS	1	31

Tabulka 4.4 Model Default – F1 skóre klasifikace paroxysmální FiS

Model Default	F1 skóre
Trénovací množina	0,72
Validační množina	0,68
Testovací množina	0,70

4.1.2 Model Optim 1

Výsledek detekce FiS pomocí modelu Optim 1 je uveden v Tabulkách 4.5 a 4.6, kdy stejně jako u modelu Default ve všech množinách je F1 skóre větší než 0,9 s minimální hodnotou 0,93 na testovací množině (viz Tabulka 4.6). Zároveň matice záměn obsahují minimální množství falešných klasifikací, resp. 2,8 % na trénovací, 2,92 % na validační a 6,52 % na testovací množině (viz Tabulka 4.5).

Tabulka 4.5 Model Optim 1 – matice záměn pro detekci FiS

Trénovací množina		Predikovaná třída	
		Ostatní	FiS
Skutečná třída	Ostatní	546	4
	FiS	27	524

Validační množina		Predikovaná třída	
		Ostatní	FiS
Skutečná třída	Ostatní	68	0
	FiS	4	65

Testovací množina		Predikovaná třída	
		Ostatní	FiS
Skutečná třída	Ostatní	68	2
	FiS	7	61

Tabulka 4.6 Model Optim 1 – F1 skóre detekce FiS

Model Optim 1	F1 skóre
Trénovací množina	0,97
Validační množina	0,97
Testovací množina	0,93

Klasifikace paroxysmální/perzistentní FiS byla realizována s hodnotami Minimálního prahu maxima 5,3 a Minimálního prahu směrodatné odchylky 1,1. Její výsledky reprezentují matice záměn, ve kterých se vyskytuje 17,23 % (trénovací množina), 15,38 % (validační množina), 14,29 % (testovací množina) falešně detekovaných případů (viz Tabulka 4.7). F1 skóre je uvedeno v Tabulce 4.8, kde lze pozorovat, že nejnižší hodnoty 0,84 bylo dosaženo na trénovací množině a na validační a testovací množině bylo F1 skóre 0,85, resp. 0,87.

Tabulka 4.7 Model Optim 1 – matice záměn pro klasifikaci paroxysmální FiS

Trénovací množina		Predikovaná třída	
		Perzistentní FiS	Paroxysmální FiS
Skutečná třída	Perzistentní FiS	194	59
	Paroxysmální FiS	32	243

Validační množina		Predikovaná třída	
		Ostatní	Paroxysmální FiS
Skutečná třída	Perzistentní FiS	26	8
	Paroxysmální FiS	2	29

Testovací množina		Predikovaná třída	
		Perzistentní FiS	Paroxysmální FiS
Skutečná třída	Perzistentní FiS	23	9
	Paroxysmální FiS	0	31

Tabulka 4.8 Model Optim 1 – F1 skóre klasifikace paroxysmální FiS

Model Optim 1	F1 skóre
Trénovací množina	0,84
Validační množina	0,85
Testovací množina	0,87

4.1.3 Model Optim 2

Výsledky klasifikace FiS pomocí modelu Optim 2 jsou zobrazeny v Tabulkách 4.9 a 4.10. v maticích záměn pro jednotlivé množiny je zahrnuto určité množství falešně detekovaných vzorků dat, které činí v trénovací množině 1,27 %, ve validační 2,19 % a v testovací 1,45 % (viz Tabulka 4.9). F1 skóre dosahuje shodně na trénovací a testovací množině hodnoty 0,99 a na validační 0,98 (viz Tabulka 4.10).

Tabulka 4.9 Model Optim 2 – matice záměn pro detekci FiS

Trénovací množina		Predikovaná třída	
		Ostatní	FiS
Skutečná třída	Ostatní	550	0
	FiS	14	537

Validační množina		Predikovaná třída	
		Ostatní	FiS
Skutečná třída	Ostatní	68	0
	FiS	3	66

Testovací množina		Predikovaná třída	
		Ostatní	FiS
Skutečná třída	Ostatní	69	1
	FiS	1	67

Tabulka 4.10 Model Optim 2 – F1 skóre detekce FiS

Model Optim 2	F1 skóre
Trénovací množina	0,99
Validační množina	0,98
Testovací množina	0,99

Následná klasifikace paroxysmální FiS ze získaných klasifikací FiS je uskutečněna pomocí Minimálního prahu maxima o hodnotě 5,5 a Minimálního prahu směrodatné odchylky o velikosti 0,95. V Tabulce 4.11 jsou matice záměn klasifikace, které obsahují značné množství falešně stanovených případů. V trénovací množině se nachází 39,48 % falešných detekcí, ve validační 42,42 % a v testovací 33,82 %. Tabulka 4.12 zobrazuje F1 skóre, které se pro trénovací množinu rovná hodnotě 0,72, pro validační 0,69 a pro testovací 0,74.

Tabulka 4.11 Model Optim 2 – matice záměn pro klasifikaci paroxysmální FiS

Trénovací množina		Predikovaná třída	
		Perzistentní FiS	Paroxysmální FiS
Skutečná třída	Perzistentní FiS	52	206
	Paroxysmální FiS	6	273

Validační množina		Predikovaná třída	
		Perzistentní FiS	Paroxysmální FiS
Skutečná třída	Perzistentní FiS	7	28
	Paroxysmální FiS	0	31

Testovací množina		Predikovaná třída	
		Perzistentní FiS	Paroxysmální FiS
Skutečná třída	Perzistentní FiS	13	23
	Paroxysmální FiS	0	32

Tabulka 4.12 Model Optim 2 – F1 skóre klasifikace paroxysmální FiS

Model Optim 2	F1 skóre
Trénovací množina	0,72
Validační množina	0,69
Testovací množina	0,74

4.1.4 Srovnání modelů

Všechny tři modely dosahovaly při detekci FiS (tj. binární klasifikaci záznamů do kategorií FiS/Ostatní) vysoké úspěšnosti, což dokládají hodnoty F1 skóre v Tabulce 4.13. Nejnižší F1 skóre na validační množině měl model Default (0,95) a na testovací množině model Optim 1 (0,93). Naopak nejvyšších hodnot v obou množinách dosáhl model Optim 2, kdy na validační množině bylo F1 skóre 0,98 a na testovací 0,99. Ve všech modelech současně se častěji nacházely falešně negativní případy, které značí nesprávné umístění záznamů obsahujících FiS do třídy Ostatní.

V navazující klasifikaci FiS na paroxysmální a perzistentní, realizované aplikací rozhodovacích pravidel na záznamy označené jako FiS, které byly získány uvedenými modely, byl nejúspěšnější model Optim 1 s velikostí F1 skóre na validační množině 0,85 a na testovací 0,87 (viz Tabulka 4.14). Oproti tomu zbylé dva modely nedosáhly tak vysokých hodnot jako model Optim 1. Nejhorší F1 skóre měl model Default, jehož hodnota byla 0,68 na validační, resp. 0,70 na testovací množině (viz Tabulka 4.14). Nízká hodnota F1 skóre v modelech Default a Optim 2 byla způsobena hojným výskytem

falešně pozitivních klasifikací, které udávají chybné zařazení záznamů s perzistentní FiS do kategorie paroxysmálních FiS.

Tabulka 4.13 F1 skóre detekce FiS

F1 skóre	Model Default	Model Optim 1	Model Optim 2
Trénovací množina	0,98	0,98	0,99
Validační množina	0,95	0,97	0,98
Testovací množina	0,97	0,93	0,99

Tabulka 4.14 F1 skóre klasifikace paroxysmální/perzistentní FiS

F1 skóre	Model Default	Model Optim 1	Model Optim 2
Trénovací množina	0,72	0,84	0,72
Validační množina	0,68	0,92	0,69
Testovací množina	0,70	0,90	0,74

4.2 Lokalizace FiS

Podle výsledků v předchozí kapitole 4.1 vycházela nejlépe klasifikace paroxysmální FiS pomocí modelu Optim 1, který stejně jako ostatní v testovací množině detekoval všechny paroxysmální FiS, ale zároveň poskytoval nejméně falešně pozitivních detekcí. Proto byl výstup tohoto modelu dále použit pro identifikaci začátků a konců paroxysmálních FiS.

K vyhodnocení přesnosti lokalizace byla použita odchylka, která udává vzdálenost predikce od reference a je popsána pomocí rovnice

$$\text{Odchylka} = tlok_{skutečný} - tlok_{predikovaný} [s], \quad (4.1)$$

kde $tlok_{skutečný}$ reprezentuje skutečný čas lokalizace a $tlok_{predikovaný}$ udává predikovaný čas lokalizace v sekundách. Také byla vypočtena absolutní odchylka, která je dána vztahem

$$\text{Absolutní odchylka} = |tlok_{skutečný} - tlok_{predikovaný}| [s]. \quad (4.2)$$

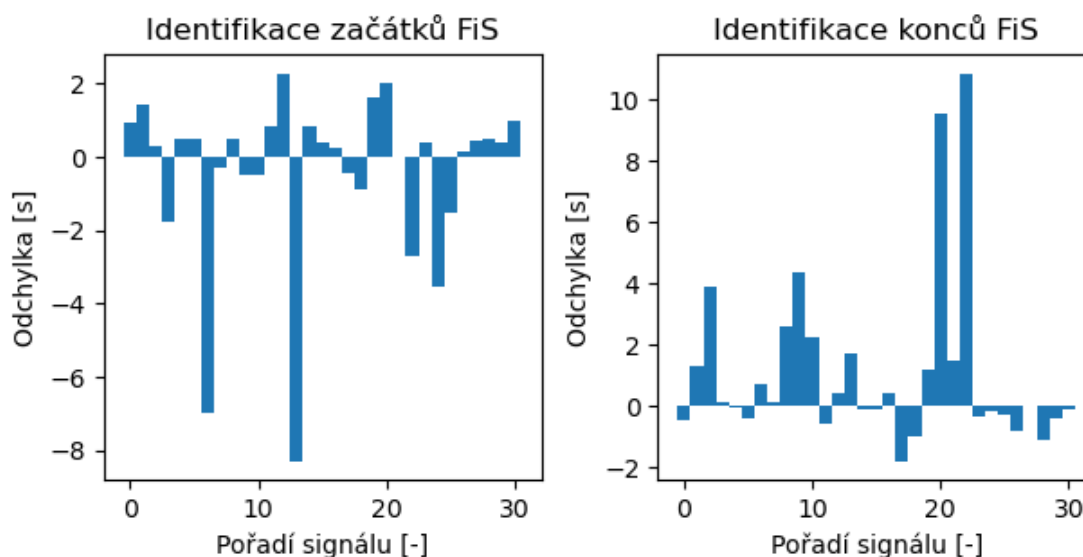
Výpočet odchylky a absolutní odchylky byl proveden pro všechny testovací signály. Dále byl získán jejich průměr a směrodatná odchylka z testovací databáze. Evaluace identifikace začátků a konců FiS byla vyhodnocena odděleně, zvlášť pro začátky a zvlášť pro konce.

Výsledné odchylky lokalizace na testovací množině uvádí Tabulka 4.15. Pro odchylku je průměr detekce začátků FiS $-0,40 \pm 2,26$ sekund. Pro detekce konců FiS průměr dosahuje hodnoty $1,09 \pm 2,75$ sekund. V případě absolutní odchylky jsou detekovány začátky FiS s průměrem $1,37 \pm 1,83$ sekund a konce o hodnotě průměru $1,57 \pm 2,51$ sekund. Velikosti odchylky pro jednotlivé signály testovací množiny jsou popsány ve sloupcovém grafu na Obrázku 4.1.

Z dosažených výsledků na testovací množině (viz Tabulka 4.15 a Obrázek 4.1) lze usoudit, že jednotlivé detekce jsou od sebe odlišné a v obou skupinách (začátky i konce FiS) se vyskytují extrémní hodnoty. Na druhou stranu 67,74 % detekcí začátků FiS a 67,74 % detekcí konců FiS má odchylky menší než 1 sekunda, což je normální velikost RR intervalu [63].

Tabulka 4.15 Výsledky detekce začátků a konců FiS v testovací množině

	Odchylka		Absolutní odchylka	
	Průměr [s]	Směrodatná odchylka [s]	Průměr [s]	Směrodatná odchylka [s]
Detekce začátků FiS	-0,40	2,26	1,37	1,83
Detekce konců FiS	1,09	2,75	1,57	2,51



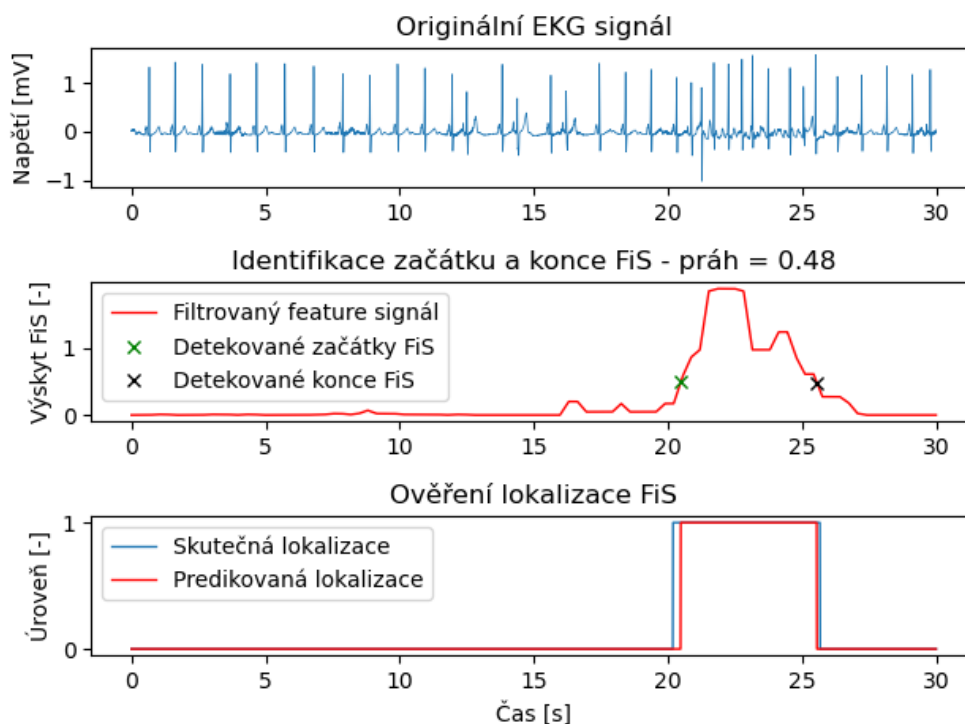
Obrázek 4.1 Odchylka začátků a konců epizod FiS testovací množiny

4.2.1 Příklady lokalizace paroxysmální FIS

Obrázek 4.2 uvádí příklad lokalizace (signál č. 7), která proběhla prahováním feature signálu s prahem o velikosti 0,48. V tomto případě mají predikované detekce začátku

i konce FiS velmi malou hodnotu odchylky. Pro začátek je to -0,29 sekund a pro konec 0,12 sekund. Z toho vyplývá, že jsou predikovaná a skutečná lokalizace téměř shodné a algoritmus tak správně vymežil trvání FiS.

Také je zde vidět, že mezi 10. a 20. sekundou se v signálu EKG vyskytují předčasné síňové kontrakce typu PAC a síňové extrasystoly, ale algoritmus na jejich přítomnost nereaguje a nevytváří tak falešně pozitivní detekce.

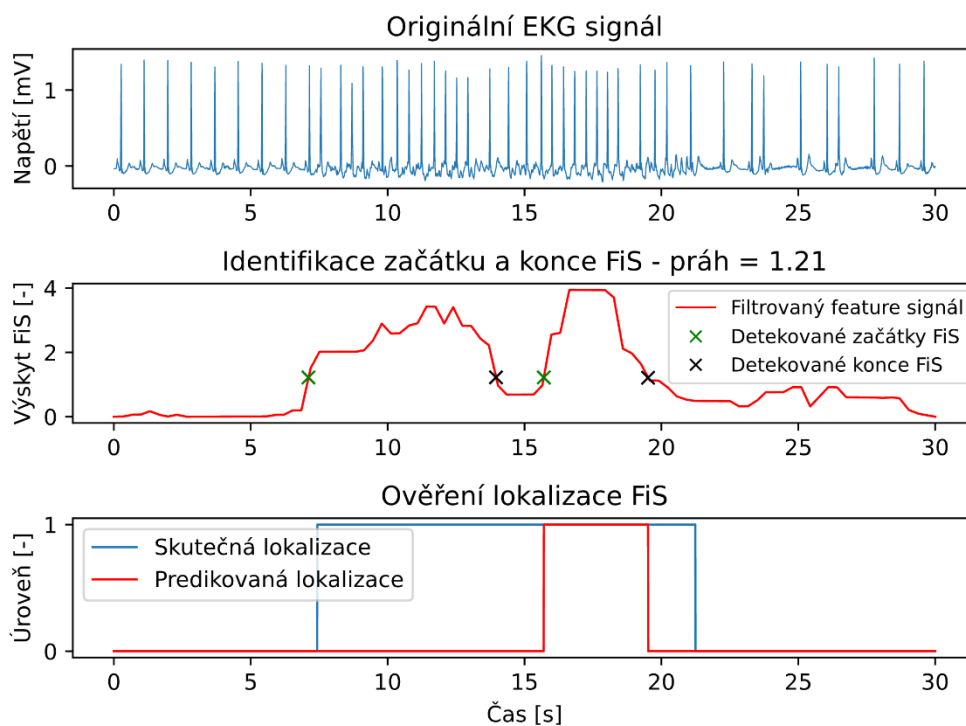


Obrázek 4.2 Příklad správné detekce začátku i konce FiS

Oproti tomu na Obrázku 4.3 je zobrazen výsledek lokalizace (signál č. 13), kde je značně vzdálen predikovaný začátek FiS od skutečného, což reflektuje odchylka o velikosti -8,28 sekund. To způsobuje především pokles hodnoty výskytu FiS ve feature signálu zaznamenaný přibližně v 15. sekundě, čímž se vytvoří dvě lokalizace, což je zapříčiněné i vlivem prahování o hodnotě 1,21. Následně je zvolena jako finální predikce ta lokalizace, která má vyšší hodnotu výskytu FiS. Stanovený konec FiS má odchylku 1,73 sekund.

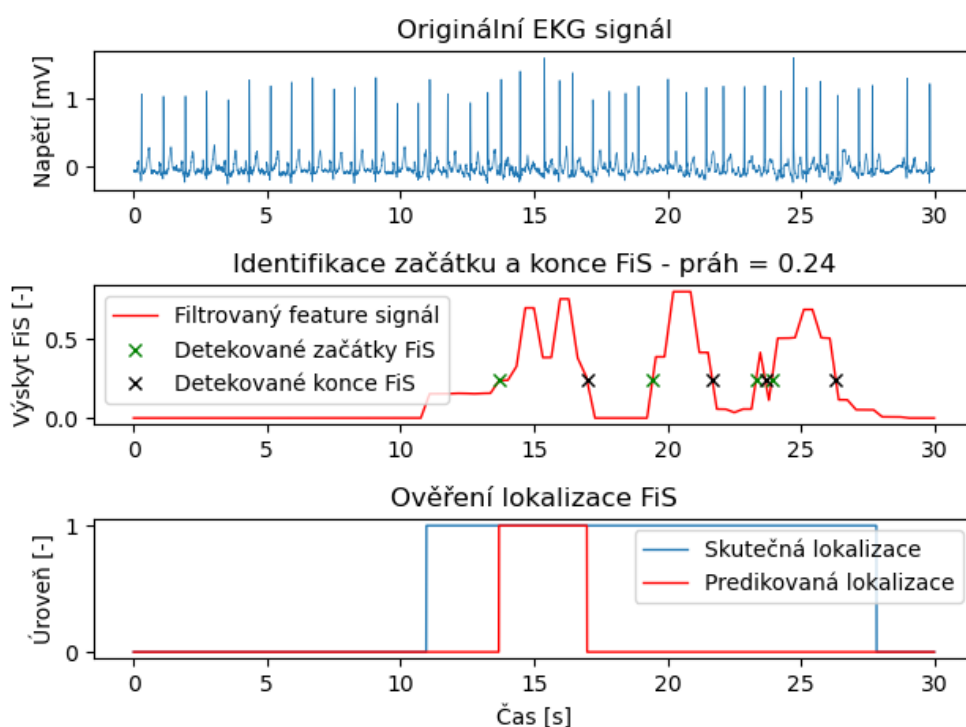
Zmíněný pokles je nejspíše důsledkem snahy srdce opět nastolit sinusový rytmus, kdy lze v uvedeném časovém úseku pozorovat přítomnost pravidelných QRS komplexů a morfologické změny v PQ intervalu.

Na druhou stranu úsek signálu s PAC pozorovaný přibližně od 21. do 27. sekundy algoritmus správně neoznačil jako FiS.




Obrázek 4.3 Příklad nevhodné detekce začátku FiS

Stejný jev jako v předchozím případě se vyskytnul také v případě lokalizace (signál č. 22) na Obrázku 4.4 s tím rozdílem, že extrémní hodnota odchylky 10,85 sekund se objevila při detekci konce FiS. Navíc ve feature signálu s prahem 0,24 nastaly dokonce 4 lokalizace a také detekce začátku byla vzdálena -2,72 sekund od referenční hodnoty.



Obrázek 4.4 Příklad nevhodné detekce konce FiS

Obrázek 4.5 představuje signál č. 5, ve kterém se podle originální anotace vyskytuje flutter síní. Jedná se o jeden z mnoha případů síňového flutteru, které jsou obsaženy ve skupině paroxysmálních FiS, na kterou byla aplikována uvedená metoda. Podle zmíněného obrázku a velikostí odchylek začátku (0,51 sekund) a konce FiS (-0,41 sekund) je zřejmé, že algoritmus byl schopen identifikovat skutečnou lokalizaci, i když byly ve feature signálu detekovány 2 falešné lokalizace, které nebyly v originálních anotacích. Predikovaná lokalizace tak byla získána na základě podmínky algoritmu o výskytu maximální hodnoty feature signálu v lokalizaci. Zároveň je na tomto obrázku vidět, že algoritmus dokáže stanovit začátek a konec arytmie i v signálu, který je značně postižen šumem.



Obrázek 4.5 Příklad detekce začátku a konce FiS (flutteru) v signálu se šumem

5. DISKUZE

Předešlá kapitola obsahuje výsledky klasifikace FiS pomocí tří modelů konvoluční neuronové sítě ResNet s MIL pooling vrstvou, na jejichž výstupy byla použita rozhodovací pravidla ke klasifikaci paroxysmální FiS. Dále byly v předchozí kapitole představeny výsledky lokalizace začátků a konců paroxysmální FiS. Tato kapitola se zabývá diskuzí získaných výsledků, případných limitací a také možných zdokonalení vytvořeného algoritmu.

5.1 Klasifikace arytmií

Z výsledků detekce FiS vychází podle hodnoty F1 skóre model Optim 2 s nejvyšší hodnotou F1 skóre v testovací množině (0,99). To potvrdila i matice záměn, která obsahovala pouze 1,44 % falešně stanovených případů. Nicméně i zbylé dva modely dosáhly srovnatelných výsledků, kdy model Default měl F1 skóre 0,97 a 2,90 % falešných vzorků v matici záměn a model Optim 1 klasifikoval FiS s velikostí F1 skóre 0,93 a 6,65 % falešných detekcí.

Podle výsledků klasifikace paroxysmální fibrilace pomocí rozhodovacích pravidel aplikovaných na příznakové mapy ze sítě ResNet, že nejlepším modelem je Optim 1, jelikož má nejvyšší hodnotu F1 skóre (0,87) a nejnižší množství falešných detekcí (14,29 %).

To, že model Optim 1 dosahuje nejlepších výsledků, je pravděpodobně způsobeno tím, že podle určených hodnot parametrů klasifikace jsou od sebe obě skupiny příznakových map dobře separovatelné. Parametry klasifikace byly získány na základě prohledávání stanoveného prostoru s daným krokem.

Z matice záměn je zřejmé, že tento přístup dokáže správně klasifikovat všechny paroxysmální FiS, ale současně zahrnuje 14,29 % falešně pozitivních případů, což může být způsobeno nedostatečným počtem rozhodovacích pravidel, velikostí prohledávaného prostoru nebo příliš velkým krokem pro nalezení nejlepších parametrů klasifikace. Tento typ klasifikace je dobře interpretovatelný, ale velmi náchylný k přeučení a zároveň je zde problematické nastavení prahů pro rozdělení vstupů do kategorií, proto by bylo vhodné ho nahradit jiným klasifikačním algoritmem.

Nabízí se tak využití metod strojového nebo hlubokého učení, které díky úpravě parametrů pomocí algoritmu zpětného šíření chyby během učení umožňují dosažení globálního minima za cenu ztráty jednoduché interpretace transformační funkce. Jednou z možností klasifikace paroxysmální FiS by mohlo být použití jednoduché mělké neuronové sítě, do které by jako příznaky vstupovaly jednotlivé pixely příznakové mapy.

Další variantou by mohla být konvoluční neuronová síť, jejíž vstupem by byla příznaková mapa v podobě 2D obrazu, popř. by mohl být klasifikován 1D feature signál vytvořený z příznakové mapy. V tomto případě by tak na rozdíl od mělké neuronové sítě

nebylo potřeba předzpracování dat. Také by bylo možné celou klasifikaci spojit pouze do jedné části a data klasifikovat pomocí sítě ResNet rovnou do tří tříd, kterými by byly paroxysmální FiS, perzistentní FiS a záznamy neobsahující FiS (Ostatní).

5.1.1 Srovnání s jinými publikacemi

Při srovnání s ostatními autory je třeba brát v úvahu eventuální rozdíly mezi porovnávanými pracemi, kdy jsou použity např. odlišné databáze s různým počtem a délkou záznamů nebo jiné evaluační metriky.

Autoři [64] automaticky detekují epizody paroxysmální FiS na základě víceúrovňové CNN a vlnového rozkladu z 1svodových signálů EKG s délkou trvání do 61 sekund, které pocházejí z databáze Physionet/CinC Challenge 2017. Pomocí navržené sítě dospěli autoři k hodnotě F1 skóre 0,8431.

Metoda prezentovaná v článku [65] provádí automatickou detekci FiS na stejném datasetu jako předchozí publikace, ale využívá k tomu 8vrstvou CNN, přeskoky (shortcut connection) a LSTM (long short-term memory) vrstvu. Autoři dosáhli F1 skóre 0,8489, 0,8955 a 0,8564 na segmentech EKG signálů dlouhých 5, 10 a 20 sekund.

Studie [66] využívá ke klasifikaci do tří tříd (paroxysmální FiS, perzistentní FiS a ostatní) model hlubokého učení, který spojuje reziduální bloky s transformerem. Autory vytvořený model byl trénován a testován také mimo jiné na datech pocházejících z The 4th China Physiological Signal Challenge 2021. Výsledné F1 skóre klasifikace bylo 0,9851.

Z výše uvedených výsledků relevantních zdrojů, je zřejmé, že navržený algoritmus pro klasifikaci FiS má s některými pracemi srovnatelnou hodnotu F1 skóre, ale současně existují publikace, které představenou metodu výrazně převyšují. To by mohlo být způsobeno použitím složitějších architektur zahrnujících kombinaci různých metod hlubokého učení.

5.2 Lokalizace FiS

Z příznakové mapy vytvořené z natrénovaného modelu Optim 1 byl pro klasifikované paroxysmální FiS vytvořen feature signál, který byl následně použit spolu s danou prahovou hodnotou k získání začátků a konců FiS. Na testovací množině bylo dosaženo odchylky $-0,40 \pm 2,26$ sekund pro začátky a $1,09 \pm 2,75$ sekund pro konce FiS. Podle absolutní odchylky byly výsledky detekce začátků epizod $1,37 \pm 1,83$ sekund a konců $1,57 \pm 2,51$ sekund.

Z výsledků je patrné, že v některých případech algoritmus reaguje na změny srdeční frekvence a morfologie PQ úseku během průběhu FiS, kdy je na EKG pozorován krátkodobý přechod z FiS do sinusového rytmu. Tím dojde ke snížení hodnoty výskytu FiS ve feature signálu, díky čemuž je detekován začátek nebo konec FiS. Nicméně v anotacích je celý tento úsek označen jako jedna epizoda FiS, a proto se místo predikce vzdaluje od své reference a vznikají extrémní hodnoty odchylky.

Pokud by uvedené případy měly opodstatnění z hlediska klinické aplikace, pak by mohly být uznány za bezproblémové. Jinak je žádoucí, aby algoritmus tyto krátké epizody spojoval do jedné jako v originálních anotacích. V takovém případě by řešením mohlo být zvětšení okna mediánové filtrace při tvorbě feature signálu, čímž by došlo ke spojení lokalizací. Avšak velikost okna by neměla být příliš vysoká, aby bylo možné správně lokalizovány i kratší epizody FiS.

Další úskalí by mohlo nastat při větším počtu epizod FiS v EKG, jelikož metoda je navržená na identifikaci pouze jedné FiS (jeden začátek a jeden konec) v signálu. Toto omezení bylo provedeno, aby bylo možné vyhodnotit úspěšnost lokalizace. V databázi totiž nejsou anotovány krátké epizody flutteru síní, které způsobují na výstupu algoritmu falešně pozitivní detekce. Možným řešením by bylo jako v předchozím případě zvětšení okna mediánové filtrace feature signálu, aby nebyly tyto krátké detekce lokalizovány. Potom by tak mohla být z algoritmu podmínka omezující identifikaci pouze jedné epizody FiS v EKG signálu odstraněna a metoda by mohla fungovat i pro vícenásobné detekce FiS. Načež by bylo vhodné tyto případy rozšířit trénovací množinu.

Jiným případem, kde by metoda mohla selhávat, je přítomnost samotného začátku nebo konce FiS v signálu. Pokud je v EKG záznamu pouze začátek epizody, pak metoda stanoví jako konec poslední vzorek feature signálu s nadprahovou hodnotou, i když ve skutečnosti FiS neskončila. Obdobně to platí pro určení začátku s tím rozdílem, že jako začátek FiS je vybrán první vzorek, který má hodnotu vyšší než práh. Pro tyto případy by bylo vhodné použít jiný způsob určení začátku a konce FiS z nadprahových hodnot pocházejících z feature signálu

Navzdory uvedeným limitacím byla vytvořena metoda, která umožňuje lokálně určit místo výskytu paroxysmální FiS v EKG pouze ze znalosti informace o přítomnosti FiS. Není tedy potřeba anotovat jednotlivé cykly EKG signálů, což je velmi časově náročná činnost. Další výhodou metody je, že výskyt předčasných síňových stahů (síňová extrasystola, PAC) v EKG záznamu se nijak neprojeví ve feature signálu ani ve výsledné detekci začátků a konců FiS a kromě toho je odolná vůči Gaussovskému šumu.

Po odstranění zmíněných nedostatků by mohla představená metoda sloužit jako modul pro vyhodnocení zátěže FiS nebo jako součást komplexního klasifikátoru srdečních arytmií v EKG záznamech.

ZÁVĚR

Tato diplomová práce prezentuje algoritmus navržený k identifikaci segmentů fibrilace síní s využitím metod hlubokého učení, zejména konvolučních neuronových sítí a multi-instančního učení. Algoritmus má dvě části, klasifikační a lokalizační.

Pro klasifikaci paroxysmální FiS bylo pomocí optimalizované architektury ResNet s rozhodovacími pravidly dosaženo F1 skóre 0,87 a 14,29 % falešných klasifikací v matici záměn na testovací množině pocházející z The 4th China Physiological Signal Challenge 2021, což lze považovat za srovnatelný výsledek s jinými publikovanými studii.

Následovala lokalizace epizod paroxysmální FiS, kde byly získány detekce s odchylkou $-0,40 \pm 2,26$ sekund pro začátky a $1,09 \pm 2,75$ sekund pro konce FiS. Z uvedených výsledků je zřejmé, že hodnoty odchylky jsou u některých případů FiS výrazně vzdáleny od reference. Navíc algoritmus umožňuje detekovat pouze jednu epizodu FiS, proto by v budoucím rozvoji této práce měl být tento fakt zohledněn.

I přes zmíněné nedostatky algoritmus umožňuje detekovat začátky a konce paroxysmální FiS v EKG záznamech pouze s využitím globálních anotací. To by bylo možné použít pro anotaci EKG signálů, kdy by mohl představený algoritmus po implementaci detekce dalších srdečních arytmií v této činnosti zcela nahradit odborný zdravotnický personál. Algoritmus by také mohl fungovat jako jedna z částí klasifikátoru srdečních patologií a také by mohl být využit při zkoumání celkové doby trvání FiS u pacientů.

LITERATURA

- [1] THALER, Malcolm S. *EKG a jeho klinické využití*. 1. české vyd. Praha: Grada, 2013. ISBN 978-80-247-4193-2.
- [2] BENNETT, David H. *Srdeční arytmie: praktické poznámky k interpretaci a léčbě*. 1. vyd. Praha: Grada, 2014. ISBN 978-80-247-5134-4.
- [3] HAMPTON, John R. *EKG stručně, jasně, přehledně*. Vyd. 2., rozš. Praha: Grada, 1996. ISBN 80-247-0960-0.
- [4] GANONG, William F. *Přehled lékařské fyziologie*. Dvacáté vydání. Praha: Galén, 2005. ISBN 80-7262-311-7.
- [5] *UCEBNICE-EKG.CZ* [online]. 2011 [cit. 2021-11-21]. Dostupné z: <http://www.ucebnice-ekg.cz/>
- [6] BLAHÚT, Peter. Supraventrikulární tachykardia (SVT). In: *TECHMED: EKG & Arytmológia (Kniha)* [online]. 2017 [cit. 2021-10-31]. Dostupné z: <https://www.techmed.sk/supra-ventrikularna-tachykardia-svt/>
- [7] BULKOVÁ, V., M. FIALA, J. CHOVANČÍK, D. WICHTERLE, R. ČIHÁK, M. BRANNY a J. KAUTZNER. Konvenční léčba fibrilace síní řízená ambulantními kardiology v ČR: přehled diagnostických a léčebných výkonů, medikamentózní léčby a hospitalizací. *Vnitřní lékařství*. 2008, **54**(1), 36-44.
- [8] ČIHÁK, Robert, Petr HEINC, Luděk HAMAN, Martin FIALA, Petr NEUŽIL a Ondřej TOMAN. Fibrilace síní. *Cor et Vasa*. 2011, **53**(88), 27-52. ISSN 0010-8650. Dostupné z: doi:DOI: 10.33678/cor.2011.193
- [9] ŠTEFÁNEK, Jiří. Supraventrikulární extrasystola - EKG. In: *Medicina, nemoci, studium na 1. LF UK* [online]. MUDr. Jiří Štefánek, 2011 [cit. 2021-11-24]. Dostupné z: <https://www.stefajir.cz/supraventrikularni-extrasystola-ekg>
- [10] MAŘÍK, Vladimír, Olga ŠTĚPÁNKOVÁ a Jiří LAŽANSKÝ. *Umělá inteligence*. Vyd. 1. Praha: Academia, 1993. ISBN 80-200-1044-0.
- [11] CHOLLET, François. *Deep learning v jazyku Python: knihovny Keras, Tensorflow*. První vydání. Přeložil Rudolf PECINOVSKÝ. Praha: Grada Publishing, 2019. Knihovna programátora (Grada). ISBN 978-80-247-3100-1.

- [12] ZHANG, Aston, Zachary LIPTON, Mu LI a Alexander SMOLA. *Dive into Deep Learning* [online]. 0.17.1. 2021 [cit. 2021-12-28]. Dostupné z: <https://d2l.ai/d2l-en.pdf>
- [13] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. *Deep Learning* [online]. MIT Press, 2016 [cit. 2021-12-28]. Dostupné z: <http://www.deeplearningbook.org>
- [14] SBAI INDRISSI, Youssef. An introduction to Machine Learning. In: *Medium* [online]. 2018 [cit. 2021-12-28]. Dostupné z: <https://medium.com/@youssefsbaiidrissi/an-introduction-to-machine-learning-60decab24a2a>
- [15] O'SHEA, Keiron a Ryan NASH. An introduction to convolutional neural networks. *ArXiv preprint arXiv:1511.08458*. 2015.
- [16] AGGARWAL, Charu C. *Neural networks and deep learning: a textbook*. Cham: Springer International Publishing, 2018. ISBN 9783319944623.
- [17] HOLČÍK, Jiří a Martin KOMENDA. *Matematická biologie: e-learningová učebnice* [online]. 1. Brno: Masarykova univerzita, 2015 [cit. 2021-12-28]. ISBN 978-80-210-8095-9. Dostupné z: <https://portal.matematickabiologie.cz/>
- [18] POUYANFAR, Samira, Saad SADIQ, Yilin YAN et al. A Survey on Deep Learning. *ACM computing surveys* [online]. NEW YORK: ACM, 2019, **51**(5), 1-36 [cit. 2021-12-28]. ISSN 0360-0300. Dostupné z: doi:10.1145/3234150
- [19] LECUN, Yann, Yoshua BENGIO a Geoffrey HINTON. Deep learning. *Nature (London)* [online]. BERLIN: NATURE RESEARCH, 2015, **521**(7553), 436-444 [cit. 2021-12-28]. ISSN 0028-0836. Dostupné z: doi:10.1038/nature14539
- [20] QIN, Tao. Deep Learning Basics. QIN, Tao. *Dual Learning* [online]. Singapore: Springer Singapore, 2020, s. 25-46 [cit. 2021-12-28]. ISBN 978-981-15-8883-9. Dostupné z: doi:10.1007/978-981-15-8884-6_3
- [21] KHAN, Asifullah, Anabia SOHAIL, Umme ZAHOORA a Aqsa QURESHI. A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review* [online]. 2020, **53**(8), 5455-5516 [cit. 2021-12-28]. ISSN 0269-2821. Dostupné z: doi:10.1007/s10462-020-09825-6
- [22] AVANZATO, Roberta a Francesco BERITELLI. Automatic ecg diagnosis using convolutional neural network. *Electronics (Basel)*

- [online]. MDPI AG, 2020, **9**(6), 1-14 [cit. 2021-12-28]. ISSN 2079-9292. Dostupné z: doi:10.3390/electronics9060951
- [23] VANDIT, Jain. Everything you need to know about “Activation Functions” in Deep learning models. In: *Towards Data Science* [online]. 2019 [cit. 2021-12-28]. Dostupné z: <https://towardsdatascience.com/everything-you-need-to-know-about-activation-functions-in-deep-learning-models-84ba9f82c253>
- [24] SUMIT, Saha. A Comprehensive Guide to Convolutional Neural Networks — the ELI5 way. In: *Towards Data Science* [online]. 2018 [cit. 2021-12-28]. Dostupné z: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>
- [25] LIN, Min, Qiang CHEN a Shuicheng YAN. Network in network. *ArXiv preprint arXiv:1312.4400*. 2013.
- [26] KIM, Hannah a Young-Seob JEONG. Sentiment Classification Using Convolutional Neural Networks. *Applied Sciences* [online]. 2019, **9**(11) [cit. 2022-01-02]. ISSN 2076-3417. Dostupné z: doi:10.3390/app9112347
- [27] IOFFE, Sergey a Christian SZEGEDY. Batch normalization: Accelerating deep network training by reducing internal covariate shift: Accelerating deep network training by reducing internal covariate shift. In: *International conference on machine learning*. PMLR, 2015, s. 448-456.
- [28] SRIVASTAVA, Nitish, Geoffrey HINTON, Alex KRIZHEVSKY, Ilya SUTSKEVER a Ruslan SALAKHUTDINOV. Dropout: a simple way to prevent neural networks from overfitting: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*. JMLR. org, 2014, **15**(1), 1929-1958. ISSN 1532-4435.
- [29] MARTINEZ, Manuel a Rainer STIEFELHAGEN. Taming the Cross Entropy Loss. BROX, Thomas, Andrés BRUHN a Mario FRITZ, ed., Thomas BROX, Andrés BRUHN, Mario FRITZ. *Pattern Recognition* [online]. Cham: Springer International Publishing, 2019, s. 628-637 [cit. 2021-12-28]. Lecture Notes in Computer Science. ISBN 978-3-030-12938-5. Dostupné z: doi:10.1007/978-3-030-12939-2_43
- [30] KOECH, Kiprono Elijah. Cross-Entropy Loss Function. In: *Towards Data Science* [online]. 2020 [cit. 2021-12-29]. Dostupné z: <https://towardsdatascience.com/cross-entropy-loss-function-f38c4ec8643e>

- [31] PERE, Christophe. What are Loss Functions?. In: *Towards Data Science* [online]. 2020 [cit. 2021-12-29]. Dostupné z: <https://towardsdatascience.com/what-is-loss-function-1e2605aeb904>
- [32] RUDER, Sebastian. An overview of gradient descent optimization algorithms. *ArXiv preprint arXiv:1609.04747*. 2016.
- [33] LUHANIWAL, Vikash Raj. Why Gradient descent isn't enough: A comprehensive introduction to optimization algorithms in neural networks. In: *Towards Data Science* [online]. 2019 [cit. 2021-12-29]. Dostupné z: <https://towardsdatascience.com/why-gradient-descent-isnt-enough-a-comprehensive-introduction-to-optimization-algorithms-in-59670fd5c096>
- [34] KINGMA, Diederik a Jimmy BA. Adam: A method for stochastic optimization: A method for stochastic optimization. *ArXiv preprint arXiv:1412.6980*. 2014.
- [35] KANDEL, Ibrahim a Mauro CASTELLI. The effect of batch size on the generalizability of the convolutional neural networks on a histopathology dataset. *ICT Express* [online]. 2020, **6**(4), 312-315 [cit. 2021-12-29]. ISSN 24059595. Dostupné z: [doi:10.1016/j.ict.2020.04.010](https://doi.org/10.1016/j.ict.2020.04.010)
- [36] LAU, Suki. A Walkthrough of Convolutional Neural Network — Hyperparameter Tuning. In: *Towards Data Science* [online]. 2017 [cit. 2021-12-29]. Dostupné z: <https://towardsdatascience.com/a-walkthrough-of-convolutional-neural-network-7f474f91d7bd>
- [37] ASZEMI, Nurshazlyn a PDD DOMINIC. Hyperparameter optimization in convolutional neural network using genetic algorithms. *Int. J. Adv. Comput. Sci. Appl.* 2019, **10**(6), 269-278.
- [38] GLOROT, Xavier a Yoshua BENGIO. Understanding the Difficulty of Training Deep Feedforward Neural Networks. *Proceedings of Machine Learning Research*. 2010, **9**, 249-256. Dostupné také z: <http://proceedings.mlr.press/v9/glorot10a.html>. Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics.
- [39] BOULILA, Wadii, Maha DRISS, Mohammed AL-SAREM, Faisal SAEED a Moez KRICHEN. *Weight Initialization Techniques for Deep Learning Algorithms in Remote Sensing: Recent Trends and Future Perspectives*. 2021.
- [40] GOYAL, Chirag. How to Initialize Weights in Neural Networks?. In: *Analytics Vidhya* [online]. 2021 [cit. 2022-04-19]. Dostupné z:

<https://www.analyticsvidhya.com/blog/2021/05/how-to-initialize-weights-in-neural-networks/>

- [41] HE, Kaiming, Xiangyu ZHANG, Shaoqing REN a Jian SUN. Deep Residual Learning for Image Recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* [online]. IEEE, 2016, s. 770-778 [cit. 2021-12-30]. ISBN 978-1-4673-8851-1. Dostupné z: doi:10.1109/CVPR.2016.90
- [42] RUIZ, Pablo. Understanding and visualizing ResNets. In: *Towards Data Science* [online]. 2018 [cit. 2021-12-30]. Dostupné z: <https://towardsdatascience.com/understanding-and-visualizing-resnets-442284831be8>
- [43] JING, Enbiao, Haiyang ZHANG, ZhiGang LI, Yazhi LIU, Zhanlin JI, Ivan GANCHEV a Juan MARTÍNEZ. ECG Heartbeat Classification Based on an Improved ResNet-18 Model. *Computational and Mathematical Methods in Medicine* [online]. 2021, **2021**, 1-13 [cit. 2021-12-30]. ISSN 1748-6718. Dostupné z: doi:10.1155/2021/6649970
- [44] CHEN, Zijiao, Zihuai LIN, Peng WANG a Ming DING. Negative-ResNet: noisy ambulatory electrocardiogram signal classification scheme. *Neural Computing and Applications* [online]. 2021, **33**(14), 8857-8869 [cit. 2021-12-30]. ISSN 0941-0643. Dostupné z: doi:10.1007/s00521-020-05635-7
- [45] SIDDHARTH, M. Building Resnet-34 model using Pytorch – A Guide for Beginners. In: *Analytics Vidhya* [online]. 2021 [cit. 2021-12-30]. Dostupné z: <https://www.analyticsvidhya.com/blog/2021/09/building-resnet-34-model-using-pytorch-a-guide-for-beginners/>
- [46] SUN, Li, Yanping LU, Kaitao YANG a Shaozi LI. ECG Analysis Using Multiple Instance Learning for Myocardial Infarction Detection. *IEEE Transactions on Biomedical Engineering* [online]. 2012, **59**(12), 3348-3356 [cit. 2021-12-29]. ISSN 0018-9294. Dostupné z: doi:10.1109/TBME.2012.2213597
- [47] AMORES, Jaume. Multiple instance classification: Review, taxonomy and comparative study. *Artificial Intelligence* [online]. 2013, **201**, 81-105 [cit. 2021-12-29]. ISSN 00043702. Dostupné z: doi:10.1016/j.artint.2013.06.003
- [48] CARBONNEAU, Marc-André, Veronika CHEPLYGINA, Eric GRANGER a Ghyslain GAGNON. Multiple instance learning: A survey of problem characteristics and applications: A survey of problem

- characteristics and applications. *Pattern Recognition*. Elsevier, 2018, **77**, 329-353. ISSN 0031-3203.
- [49] PAL, Anabik, Zhiyun XUE, Kanan DESAI, Adekunbiola AINA F BANJO, Clement ADEPITI, L. LONG, Mark SCHIFFMAN a Sameer ANTANI. Deep multiple-instance learning for abnormal cell detection in cervical histopathology images. *Computers in Biology and Medicine* [online]. 2021, **138** [cit. 2021-12-29]. ISSN 00104825. Dostupné z: doi:10.1016/j.compbiomed.2021.104890
- [50] ILSE, Maximilian, Jakub TOMCZAK a Max WELLING. Attention-based deep multiple instance learning. In: *International conference on machine learning*. PMLR, 2018, s. 2127-2136. ISSN 2640-3498.
- [51] DAS, Kausik, Sailesh CONJETI, Abhijit ROY, Jyotirmoy CHATTERJEE a Debdoot SHEET. Multiple instance learning of deep convolutional neural networks for breast histopathology whole slide classification. In: *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)* [online]. IEEE, 2018, s. 578-581 [cit. 2021-12-29]. ISBN 978-1-5386-3636-7. Dostupné z: doi:10.1109/ISBI.2018.8363642
- [52] SUNASRA, Mohammed. Performance Metrics for Classification problems in Machine Learning. In: *Medium* [online]. 2017 [cit. 2022-04-17]. Dostupné z: <https://medium.com/@MohammedS/performance-metrics-for-classification-problems-in-machine-learning-part-i-b085d432082b>
- [53] GO, Alan, Kristi REYNOLDS, Jingrong YANG et al. Association of Burden of Atrial Fibrillation With Risk of Ischemic Stroke in Adults With Paroxysmal Atrial Fibrillation: The KP-RHYTHM Study: The KP-RHYTHM Study. *JAMA Cardiology*. 2018, **3**(7), 601-608. ISSN 2380-6583. Dostupné z: doi:10.1001/jamacardio.2018.1176
- [54] 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. 2020-04-23]. ISSN 00104825. Dostupné z: doi:10.1016/j.compbiomed.2017.12.007
- [55] WANG, Xingyao, Caiyun MA, Xiangyu ZHANG, Hongxiang GAO, Gari CLIFFORD a Chengyu LIU. Paroxysmal Atrial Fibrillation Events Detection from Dynamic ECG Recordings: The 4th China Physiological Signal Challenge 2021. *PhysioNet* [online]. 2021 [cit. 2022-04-21]. Dostupné z: doi:10.13026/ksya-qw89

- [56] PhysioBank Annotations. In: *PhysioNet* [online]. [cit. 2022-05-10]. Dostupné z: <https://archive.physionet.org/physiobank/annotations.shtml>
- [57] DHAIRYA, Kumar. Introduction to Data Preprocessing in Machine Learning. In: *Towards Data Science* [online]. 2018 [cit. 2021-12-21]. Dostupné z: <https://towardsdatascience.com/introduction-to-data-preprocessing-in-machine-learning-a9fa83a5dc9d>
- [58] ALHINAI, Noura. Chapter 1 - Introduction to biomedical signal processing and artificial intelligence. *Developments in Biomedical Engineering and Bioelectronics*. Academic Press, 2020, s. 1-28. ISSN 25897527. Dostupné z: [doi:https://doi.org/10.1016/B978-0-12-818946-7.00001-9](https://doi.org/10.1016/B978-0-12-818946-7.00001-9)
- [59] PAN, Qing, Xinyi LI a Luping FANG. Data Augmentation for Deep Learning-Based ECG Analysis. LIU, Chengyu a Jianqing LI, ed., Chengyu LIU, Jianqing LI. *Feature Engineering and Computational Intelligence in ECG Monitoring* [online]. 1. Singapore: Springer Singapore, 2020, s. 91-111 [cit. 2021-12-18]. ISBN 978-981-15-3824-7. Dostupné z: [doi:10.1007/978-981-15-3824-7_6](https://doi.org/10.1007/978-981-15-3824-7_6)
- [60] WEN, Qingsong, Liang SUN, Fan YANG, Xiaomin SONG, Jingkun GAO, Xue WANG a Huan XU. Time Series Data Augmentation for Deep Learning: A Survey. In: *Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence* [online]. California: International Joint Conferences on Artificial Intelligence Organization, 2021, s. 4653-4660 [cit. 2021-12-17]. ISBN 978-0-9992411-9-6. Dostupné z: [doi:10.24963/ijcai.2021/631](https://doi.org/10.24963/ijcai.2021/631)
- [61] NONAKA, Naoki a Jun SEITA. RandECG: Data Augmentation for Deep Neural Network based ECG classification: Data Augmentation for Deep Neural Network based ECG classification. *人工知能学会全国大会論文集*. 2021, **2021**, 21202-21202. Dostupné z: [doi:10.11517/pjsai.JSAI2021.0_2N1IS2a02](https://doi.org/10.11517/pjsai.JSAI2021.0_2N1IS2a02)
- [62] NOVOTNA, Petra, Tomas VICAR, Jakub HEJC, Marina RONZHINA a Jana KOLAROVA. Deep-Learning Premature Contraction Localization in 12-lead ECG From Whole Signal Annotations. *Computing in Cardiology 2020: Computers in Cardiology* [online]. Rimini, Italy: Computing in Cardiology 2020, 2020, 1-4 [cit. 2021-12-30]. ISSN 2325-887X. Dostupné z: [doi:10.22489/CinC.2020.193](https://doi.org/10.22489/CinC.2020.193)
- [63] SÖRNMO, Leif a Pablo LAGUNA. *Bioelectrical signal processing in cardiac and neurological applications*. Boston: Elsevier Academic Press, 2005. ISBN 978-0-12-437552-9.

- [64] PRABHAKARARAO, Eedara a Samarendra DANDAPAT. Multiscale convolutional neural network for detecting paroxysmal atrial fibrillation from single lead ECG signals. In: *2020 IEEE Applied Signal Processing Conference (ASPCON)* [online]. IEEE, 2020, s. 339-343 [cit. 2022-05-17]. ISBN 978-1-7281-6882-1. Dostupné z: doi:10.1109/ASPCON49795.2020.9276690
- [65] PING, Yongjie, Chao CHEN, Lu WU, Yinglong WANG a Minglei SHU. Automatic Detection of Atrial Fibrillation Based on CNN-LSTM and Shortcut Connection. *Healthcare* [online]. 2020, **8**(2) [cit. 2022-05-17]. ISSN 2227-9032. Dostupné z: doi:10.3390/healthcare8020139
- [66] HU, Yating, Tengfei FENG, Miao WANG, Chengyu LIU a Hong TANG. Detection of Paroxysmal Atrial Fibrillation from Dynamic ECG Recordings Based on a Deep Learning Model. *SSRN Electronic Journal* [online]. [cit. 2022-05-17]. ISSN 1556-5068. Dostupné z: doi:10.2139/ssrn.4098696

SEZNAM ZKRATEK

Adam	adaptive moment estimation
ANN	umělé neuronové sítě (artificial neural networks)
AV	atrioventrikulární
AVNRT	AV nodální reentry tachykardie
AVRT	AV reentry tachykardie
CNN	konvoluční neuronové sítě (convolutional neural networks)
EKG	elektrokardiogram
FiS	fibrilace síní
FN	falešně negativní (false negative)
FP	falešně pozitivní (false positive)
GAP	global average pooling
GMP	global max pooling
ILSVRC	ImageNet Large Scale Visual Recognition Challenge
LSTM	long short-term memory
MAE	L1 regularizace (mean absolute error)
MSE	L2 regularizace (mean square error)
MIL	multi-instanční učení (multiple-instance learning)
NAG	Nestrov accelerated gradient
PAC	síňové extrasystoly (premature atrial contraction)
PPH	pozitivní prediktivní hodnota (precision)
PVC	komorové extrasystoly (premature ventricular contraction)
ReLU	rectified linear unit
SA	sinoatriální
SGD	stochastický gradientní sestup (stochastic gradient descent)
SR	sinusový rytmus
SVT	supraventrikulární tachykardie
TN	skutečně negativní (true negative)
TP	skutečně pozitivní (true positive)
WPW	Wolffův-Parkinsonův-Whiteův syndrom