



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

DETEKCE VYBRANÝCH TYPŮ SRDEČNÍCH ARYTMÍÍ V EKG

DETECTION OF SELECTED CARDIAC ARRHYTHMIAS IN ECG

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Karolína Němečková

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Marina Ronzhina, Ph.D.

BRNO 2022

Diplomová práce

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

Ústav biomedicínského inženýrství

Studentka: Bc. Karolína Němečková

ID: 195162

Ročník: 2

Akademický rok: 2021/22

NÁZEV TÉMATU:

Detekce vybraných typů srdečních arytmií v EKG

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši v oblasti projevů poruch srdečního rytmu v EKG. Zaměřte se na vzácnější resp. obtížněji diferencovatelné arytmie (např. skupinu supraventrikulárních arytmií). Dále se seznamte s moderními metodami pro automatickou detekci arytmií s využitím hlubokých neuronových sítí. 2) Seznamte se s databází EKG signálů dostupnou na ÚBMI. Předzpracujte signály do podoby vhodné pro automatickou klasifikaci vybraných patologií algoritmem hlubokého učení. 3) Navrhněte konfiguraci sítě, popište jednotlivé vrstvy sítě a nastavení parametrů algoritmu učení. Navržený postup programově realizujte a otestujte v prostředí Python či jiném. 4) Na základě výsledků z bodu 3, proveďte optimalizaci nastavení sítě a případně upravte vstupní data pro dosažení co nejlepšího klasifikačního skóre (např. rozšiřte databázi o záznamy s přidaným šumem či záznamy ze skupin vzácných arytmií apod.). 5) Dosažené výsledky podrobně interpretujte. Například popište, které signály byly algoritmem zařazeny do špatné kategorie a proč. Diskutujte výhody a nevýhody navrženého postupu a možnosti pro jeho vylepšení. 6) Porovnejte výsledky s dostupnými údaji z literatury.

DOPORUČENÁ LITERATURA:

- [1] M.J. CURTIS, C.J. HANCOX, A. FARKAS, et al. The Lambeth Conventions (II): Guidelines for the study of animal and human ventricular and supraventricular arrhythmias. Pharmacology and Therapeutics, Amsterdam: Elsevier Inc., 2013, vol. 139, ed. 2, pp. 213 – 248. ISSN 0163-7258.
- [2] Y.-Y. JO, J.-M. KWON, K.-H. JEON, et al. Detection and classification of arrhythmia using an explainable deep learning model. Journal of Electrocardiology, 2021, vol. 67, pp. 124-132.

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

Tato práce se zabývá klasifikací EKG záznamů se zaměřením na hůře klasifikovatelné arytmie (flutter síní, atrioventrikulární blokáda II. a III. stupně). V teoretické části je uvedena literární rešerše v oblasti metod hlubokého učení, které byly využity pro klasifikaci EKG záznamů, se zaměřením na konvoluční neuronové sítě. Dále je popsána použitá databáze EKG záznamů se stručným popisem detekovaných arytmií. Praktická část provádí implementaci navržených konvolučních neuronových sítí v prostředí Python. Hodnocení kvality klasifikátorů proběhlo pomocí vybraných metrik se zaměřením na F1 skóre. Výsledky jsou na konci práce diskutovány.

KLÍČOVÁ SLOVA

flutter síní, fibrilace síní, atrioventrikulární blokáda, elektrokardiogram, konvoluční neuronová síť

ABSTRACT

This thesis deals with classification of ECG records focusing on less classifiable arrhythmia (atrial flutter, atrioventricular block I. and II. degree). In the theoretical part of the thesis deep learning used in classification of ECG records with a focus on the convolutional neural networks are described. The database of ECG records with a brief description of detected arrhythmias is further described. The practical part implements the proposed convolutional neural network in the Python environment. The evaluation of the arrhythmia detection quality was done using mainly the F1 score. The results were discussed at the end of the thesis.

KEYWORDS

atrial flutter, atrial fibrillation, atrioventricular block, electrocardiogram, convolutional neural network

NĚMEČKOVÁ, Karolína. *Detekce vybraných typů srdečních arytmií v EKG*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2022, 80 s. Diplomová práce. Vedoucí práce: Ing. Marina Ronzhina, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Bc. Karolína Němečková
VUT ID autora: 195162
Typ práce: Diplomová práce
Akademický rok: 2021/22
Téma závěrečné práce: Detekce vybraných typů srdečních arytmií v EKG

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

Brno

.....

podpis autorky*

*Autor podepisuje pouze v tištěné verzi.

PODĚKOVÁNÍ

Ráda bych poděkovala vedoucí diplomové práce Ing. Marině Ronzhině, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Obsah

Úvod	11
1 Detekce arytmií pomocí hlubokých neuronových sítí	12
1.1 1D CNN	12
1.2 2D CNN	16
1.3 Hybridní modely	16
1.4 ResNet	17
1.5 Sítě s moduly pozornosti	19
1.6 Návrh a učení sítě	21
1.7 Metriky hodnotící úspěšnost klasifikace	23
2 Popis analyzovaných dat se zaměřením na detekované arytmie	25
2.1 Atrioventrikulární blokády	27
2.1.1 AVB I.stupně	27
2.1.2 AVB II.stupně	27
2.1.3 AVB III.stupně	28
2.2 Fibrilace síní	29
2.3 Flutter síní	29
3 Programové řešení	31
3.1 Příprava dat	31
3.2 Rozdělení dat do množin	35
3.3 Nevyvážený trénovací dataset a augmentační techniky	36
3.4 Vytvoření popisku, definující zařazení do třídy	44
3.5 Popis navržených architektur sítí	45
3.5.1 Klasifikace do 4 tříd	45
3.5.2 Klasifikace do 5 tříd	53
4 Vyhodnocení	56
5 Diskuze	61
5.1 Klasifikace do 4 tříd - zdroje chyb	61
5.2 Klasifikace do 5 tříd - zdroje chyb	64
5.3 Srovnání úspěšnosti klasifikace s dostupnou literaturou	65
5.4 Výhody/nevýhody a použití navržených modelů	68
Závěr	70
Literatura	71

Seznam symbolů a zkratk	77
Seznam příloh	78
A Příloha A	79

Seznam obrázků

1.1	Architektura CNN [5]	13
1.2	Architektura hybridní sítě [9]	17
1.3	ResNet architektura sítě [12]	18
1.4	Implementace CBAM [37]	21
1.5	Architektura prvotní navržené sítě	23
2.1	Záznam z databáze, SR	25
2.2	Přehled délky záznamů	26
2.3	EKG záznam: AVB I.stupně	27
2.4	EKG záznam: AVB II.stupně	28
2.5	EKG záznam: AVB III.stupně	29
2.6	EKG záznam: Fibrilace síní	30
2.7	EKG záznam: Flutter síní	30
3.1	Frekvenční charakteristika filtru	34
3.2	Filtrace síťového brumu (50 Hz)	34
3.3	Zobrazení zkreslení po filtraci	35
3.4	EKG záznam: Myopotenciálové rušení	35
3.5	Filtrace driftu	36
3.6	Augmentace uměle generovaným šumem	38
3.7	Augmentace flutteru síní	39
3.8	Augmentace atrioventrikulárních blokád	40
3.9	Architektura navržené sítě provádějící klasifikaci do 4 tříd	45
3.10	Volba délky signálu vstupující do sítě, klasifikace do 4 tříd	50
3.11	Volba způsobu prodloužení signálu, klasifikace do 4 tříd	51
3.12	Volba svodů, klasifikace do 4 tříd	52
3.13	Architektura sítě klasifikující EKG záznamy do 5 tříd	53
3.14	Průběh učení sítě pro odlišné kroky učení, klasifikace do 5 tříd	54
4.1	Matice záměn, klasifikace do 4 tříd.	58
4.2	Matice záměn, klasifikace do 5 tříd.	60
5.1	Chybná klasifikace do 4 tříd II	61
5.2	Chybná klasifikace do 4 tříd III	62
5.3	Chybná klasifikace do 4 tříd IV	62
5.4	Chybná klasifikace do 4 tříd V	63
5.5	Návrh klasifikace kaskádou sítí	69
A.1	Přehled všech diagnóz přítomných v databázi	79
A.2	Absolutní a procentuální zastoupení EKG záznamů s různými pato- logickými projevy	80

Seznam tabulek

2.1	Počty delších záznamu obsahující vybrané arytmie	26
3.1	Výsledky na validační množině získané v rámci semestrální práce, klasifikace do 6 tříd	32
3.2	Detailní přehled četností přidanych záznamů	33
3.3	Přehled četností záznamů vybraných arytmií v množinách	37
3.4	Celkové četnosti záznamů v databázi pro vybrané třídy	37
3.5	Výsledky klasifikace (F1 skóre) pro jednotlivé datasey na validační množině.	41
3.6	Počty záznamů vybraného datasetu v jednotlivých třídách	41
3.7	Výsledky klasifikace, augmentace FL	42
3.8	Výsledky učení pro různé trénovací množiny při klasifikaci do 5 tříd .	43
3.9	Tabulka parametrů navržené sítě, klasifikace do 4 tříd	46
3.10	Tabulka hodnot hyperparametrů, klasifikace do 4 tříd	49
3.11	Výsledky klasifikace do 4 tříd na validační množině po přidání pozor- nostního modulu	52
3.12	Tabulka hodnot hyperparametrů, klasifikace do 5 tříd	55
3.13	Výsledky klasifikace do 5 tříd na validační množině po přidání odliš- ných pozornostních modulů	55
4.1	Výsledky klasifikace do 4 tříd, trénovací množina.	56
4.2	Výsledky klasifikace do 4 tříd, validační množina.	57
4.3	Výsledky klasifikace do 4 tříd, testovací množina.	57
4.4	Počet záznamu ve třídách při klasifikaci do 4 tříd.	57
4.5	Výsledky klasifikace do 5 tříd, trénovací množina.	59
4.6	Výsledky klasifikace do 5 tříd, validační množina.	59
4.7	Výsledky klasifikace do 5 tříd, testovací množina.	59
4.8	Počet záznamu ve třídách při klasifikaci do 5 tříd.	60
5.1	Srovnání s literaturou: třídy FIB a FL	66
5.2	Srovnání s literaturou: třídy atrioventrikulárních blokády	67

Úvod

Ve vědecké literatuře nalezneme velké množství článků zabývajících se klasifikací EKG záznamů do různých tříd. Existují však srdeční arytmie, jejichž klasifikací se moc autorů nezabývá. Tento fakt může být odůvodněn malou incidencí těchto arytmií v populaci, z čehož vyplývá problém s nedostatkem dat pro učení navržených algoritmů. Další nevýhodou může být i jejich obtížná diferenciací.

Jedním z možných přístupů klasifikace je skrze ručně extrahované příznaky z EKG záznamů, na základě kterých poté probíhá klasifikace. Kvalita těchto příznaků však výrazně ovlivňuje kvalitu klasifikátoru a pro jejich získání jsou potřeba expertní znalosti dané problematiky. Nevýhodou je také malá robustnost příznaků, která je závislá na mnoha proměnných (např. škálování signálu nebo úroveň šumu). Z těchto důvodů se v dnešní době často volí přístup klasifikace pomocí hlubokých neuronových sítí na jejichž vstup je přiváděn surový či filtrovaný EKG záznam. Na úkor delšího výpočetního času tyto metody poskytují kvalitnější výsledky a vytváří robustnější klasifikátory.

Tato práce je zaměřena na klasifikaci patologií v EKG s využitím hlubokých neuronových sítí se zaměřením na podskupinu výše zmíněných arytmií. Cílem je vytvořit klasifikátor provádějící klasifikaci často opomíjených patologií, a to z důvodu nedostatku dat pro učení modelů či jejich obtížnou diferenciací. Konkrétně se jedná o atrioventrikulární blokády, fibrilaci a flutter síní.

Práce je rozdělena do šesti částí. První část poskytuje úvod do problematiky prostřednictvím vědeckých publikací řešící klasifikaci pomocí metod hlubokého učení. Tato kapitola tedy poskytne čtenáři přehled dnes používaných metod a je zakončena diskuzí obsahující celkové shrnutí získaných informací, které jsou využity v praktické části. Další část se věnuje popisu databáze využité v práci a popisu vybraných patologií s ukázkami z databáze. Následuje praktická část, která se zaměřuje na předzpracování signálů, úpravu databáze, popis architektury a učení klasifikátorů. V další části jsou uvedeny výsledky klasifikace, které jsou na konci práce diskutovány spolu s možnostmi dalšího rozvoje práce.

1 Detekce arytmií pomocí hlubokých neuronových sítí

V rámci teoretické části byla provedena literární rešerše moderních metod pro automatickou detekci arytmií. Základním krokem bylo seznámení se s problematikou, ke kterému sloužily přehledové články. Byly vybrány 4 výzkumné studie ([1]-[4]) sepsány v letech 2019 a 2020, ve kterých byly srovnávány vědecké publikace zabývající se touto problematikou z let 2010 - 2020. Výsledky studií ukazují, že hlavní metodou využívající se pro zpracování EKG záznamů jsou konvoluční neuronové sítě (dále jen CNN). Mezi další často používané sítě patří reziduální neuronové sítě (ResNet), LSTM (z angl. Long Short-Term Memory), RNN (z angl. Recurrent Neural Network) či DBN (z angl. Deep Belief Network). Málokdy je však použit samostatně jen jeden druh architektury. Aby byly využity rozdílné užitečné vlastnosti těchto sítí, autoři často přistupují k jejich kombinaci.

Existuje velké množství článků zabývajících se zpracováním EKG záznamů pomocí hlubokých neuronových sítí v nichž každá část algoritmu může být provedena řadou způsobů. V rešerši bych ráda proto uvedla nejen metody s kvalitními výsledky ale také články, kde autoři přistupují k problematice zajímavějšími způsoby kombinací různých přístupů.

1.1 1D CNN

V dlouhodobém měřítku se dochází k názoru, že CNN (i přes jejich prvotní navržení pro zpracování obrazů) jsou nejlepším možným přístupem ke zkoumanému problému a proto většina článků obsahuje právě tuto metodu, mnohdy obohacenou některými vrstvami, či spojenou s jinými metodami. Atraktivnost této metody může vyplývat např. z mnohem menšího množství učících parametrů v rámci sítě, které vede k rychlejšímu učení.

Autoři článku [5] z roku 2018 přistupují k problematice konstrukcí základní architektury CNN, jejichž cílem je konstrukce sítě s nízkou výpočetní náročností. Metoda volí zpracovávání 10s záznamů, které zařazuje do jednotlivých kategorií. V článku jsou porovnány 3 volby počtu klasifikačních tříd: 17, 15 a 13. Tento přístup volí z důvodu nerovnoměrného zastoupení jednotlivých kategorií, kde 4 skupiny jsou zastoupeny velice málo. Nejlepších výsledků dosahuje právě model s nejméně kategoriemi. Díky nízké výpočetní náročnosti je v článku diskutována i možnost využití metody v mobilních zařízeních a na cloudových uložiscích.

V článku pracují se signály obsahující jeden EKG svod z MIT-BIH Arrhythmia Database, kde se nachází 1000 záznamů od 45 osob se vzorkovací frekvencí 360 Hz.


Pro maximální snížení výpočetní náročnosti nejsou data filtrována. Provedena je pouze úprava izoliny a přeškálování na rozsah od -1 do 1.

Byla navržena 16vrstvá architektura v nichž jsou zahrnuty pouze základní stavební bloky CNN, přičemž konvoluční vrstvy převládají. Konkrétní architektura byla vybrána na základě optimalizace brute force technikou, kde byly voleny různé počty a typy vrstev i jejich parametrů. 16vrstvá síť dosáhla nejlepších výsledků.

Konstrukci sítě můžeme rozdělit do dvou základních stavebních bloků. První část nazveme extraktor příznaků, jejichž komplexita se s narůstajícím počtem skrytých vrstev zvyšuje. Druhá část sítě na základě těchto již vysoce specifických příznaků signál klasifikuje do jedné z kategorií.

Hlavní komponentou prvního bloku jsou samotné konvoluční vrstvy s **ReLU aktivační funkcí**, která se v těchto případech používá nejčastěji. Aktivační funkce obecně provádí transformaci lineární kombinace vstupu a vah neuronů na výstup a provádí aktivaci neuronu. Funkce slouží také pro omezení amplitudy výstupu neuronu a umožňuje síti řešit komplexnější problémy, díky zavedené nelinearitě do výpočtu. [16]

V každé **konvoluční vrstvě** je určitý počet neuronů, který zpracovává vstupní data. Tyto neurony můžeme chápat jako filtry zpracovávající signál operací konvoluce (z toho odvozený název CNN), zaměřující se na konkrétní vlastnosti/části signálu. V každé vrstvě je potřeba specifikovat počet neuronů a jejich rozměr. Tyto parametry určují výslednou velikost a počet aktivačních map, což jsou výstupy z jednotlivých neuronů. Aktivační mapy dále vstupují do aktivační funkce. Výsledkem jsou tzv. příznakové mapy, které jsou výstupem z konvoluční vrstvy. Počet a velikost neuronů v jednotlivých vrstvách výše uvedeného modelu můžeme vidět na Obr.1.1. [17]



Obr. 1.1: Architektura CNN převzato z [5].

Výstup z prvních 2 konvolučních vrstev je normalizován pomocí tzv. **Batch Normalizace** (dále BN), která zajišťuje správné rozložení dat pro optimální funkci

neuronů. Nejprve je provedena normalizace zajištěním nulové střední hodnoty a jednotkového rozptylu. Dalším krokem je transformace normalizovaných dat do vhodného rozsahu. Přičemž síť se postupně učí jak provádět tuto transformaci pro optimální učení sítě. Celý proces je prováděn po menších skupinách vstupujících naráz do sítě nazývajících se **Mini Batche**. BN provádí regularizaci sítě, předchází jejímu přeučení a redukuje závislost na předzpracování dat. Regularizace obecně zvyšuje schopnost sítě zobecnit klasifikaci nad rámce učících dat.

Další vrstva, obecně často navazující na konvoluční je **Max Poolingová** vrstva (vrstva podzorkování, dále MP), která zmenšuje délku vstupu beze změny dimenzionality. Použití této vrstvy vede ke snížení počtu parametrů v dalších vrstvách a tím i výpočetní náročnosti. MP se aplikuje na každou příznakovou mapu zvlášť, kterou postupně prochází oknem a na výstup přenáší nejsilnější příznak. Další možnou variantou může být vrstva **Average Pooling**, která na výstup přivádí průměr z vybraného okna. Nejčastější nastavení délky okna a jeho posunu jsou v případě 1D signálu 2.

Jak data postupují hlouběji do sítě, redukuje se jejich rozměr a stoupá dimenzionalita. Spojnicí mezi dvěma výše zmíněnými pomyslnými bloky extrakce příznaků a klasifikace je tzv. **flatten layer**, transformující multidimenzionální vstupní vektor na jednodimenzionální výstupní vektor.

Vektor vstupuje do části standardní neuronové plně propojené dvouvrstvé sítě. Počet neuronů v druhé vrstvě již odpovídá počtu klasifikačních tříd. Aktivační funkce je v poslední vrstvě změněna na **Softmax**, která mapuje jednotlivé aktivity na predikci pravděpodobnosti zařazení do tříd. Nejvyšší číslo určuje vybranou třídu a suma pravděpodobností zařazení do tříd je v rámci všech tříd 1.

Napříč celou sítí jsou v některých vrstvách nastavené tzv. **DropOut** parametry, které udávají pravděpodobnost deaktivace neuronu v jednotlivých vrstvách. Jde o parametry nastavující se pouze ve fázi učení. Každý Mini Batch či epochu se deaktivují jiné neurony, díky čemuž se na každý cyklus učení můžeme dívat jako na nový zmenšený model naší sítě, který učíme. Na konci fáze učení se tyto modely spojí a vznikne finální síť, dosahující lepších výsledků. Využití DropOut parametrů vede opět k regularizaci sítě. [16]

Navržená síť dosáhla vzhledem k její složitosti vysokých hodnot F1 skóre. Pro 13 klasifikačních tříd (sinusový rytmus, PAC, PVC v bigeminické a trigeminické vazbě, FIB, FL (síně i komory), LBBB, RBBB, WPW, AVB II. stupně, stimulované rytmy, IVR) je F1 skóre 0,924. Vzhledem k absenci filtrace se jedná o robustní model, který je poměrně málo výpočetně náročný. Jeden 10s záznam EKG model zpracuje za 0,015 s a proto je reálné i jeho využití v mobilních zařízeních a na cloudech. Ke zvýšení F1 skóre by mohla přispět augmentace či filtrace dat, což by však vedlo ke zvýšení náročnosti trénovacího procesu, a to je nežádoucí. Dalším možným

vylepšením by mohlo být využití některé z automatických metod pro optimalizaci hyperparametrů.

Velice podobné architektury můžeme vidět v člancích zabývajících se klasifikací jednotlivých srdečních cyklů. Např. autoři článku [6] popisují velice podobnou 12-vrstvou CNN navrženou pro klasifikaci cyklů do 5 tříd (SR, LBBB, RBBB, PAC a PVC), která dosahuje F1 skóre 0,971. Acharya a spol. [7] navrhli 9-vrstvou CNN třídící opět jednotlivé srdeční cykly do 5 obecně známých tříd při práci s MIT-BIH databází (N^1, V^2, S^3, F^4, Q^5), kde nejvyšší dosažené F1 skóre bylo 0,973 při trénování s filtrovanými daty. Všechny tři články pracují se stejnou databází. Poslední dva články se snažily vyřešit problém nerovnoměrně rozložených dat augmentací a pro zvýšení klasifikačních schopností provedli filtraci dat.

Výsledky v článku [6] ukazují odolnost sítě proti šumu porovnáním výsledků na filtrovaných a nefiltrovaných datech, které dosahují F1 skóre 0,971 a 0,967. Augmentace byla provedena pouze na základní úrovni kopírováním záznamů z málo zastoupených tříd a promazáváním tříd s hodně záznamy. Vliv augmentace v článku nebyl diskutován.

V článku [7] popisují rozdíl klasifikace při použití filtrovaných a nefiltrovaných dat se stejným výsledkem, kde jednotlivá F1 skóre jsou 0,973 (filtrovaná a augmentovaná data) a 0,969 (nefiltrovaná a augmentovaná data). Augmentace zde byla provedena pro všechny klasifikační třídy kromě SR, kterého bylo nejvíce. Augmentaci provádí změnou směrodatné odchylky a průměrné hodnoty v průběhu normalizace záznamu. Pro srovnání autoři uvádí výsledky sítě trénované na nerovnoměrně rozložených datech, kde pro nefiltrovaná data vyšlo F1 skóre 0,761 a pro filtrovaná 0,762. Na základě těchto výsledků můžeme usoudit, že augmentace nerovnoměrně rozložených dat zvyšuje klasifikační schopnost sítě pro filtrovaná i nefiltrovaná data.

Vě většině článků byla vždy zvolena pevná délka vstupujícího signálu, které se dodrželo i při variabilní délce záznamů přesahující zvolenou délku. Tento přístup může mít za následek ztrátu některých důležitých dat a proto bych ráda zmínila práci [14], kde autoři pracovali s variabilní délkou záznamů. Místo výběru pouze části záznamu o definované délce provedli prodloužení všech záznamů na délku nejdelšího signálu jejich roznásobením čímž zamezili ztrátě informace a zároveň vyřešili potřebou konstantní délky záznamů při práci s CNN. Nevýhodou přístupu je zvýšení náročnosti trénovacího procesu.

¹z angl. Normal beats

²z angl. Ventricular ectopic beats

³z angl. Supraventricular ectopic beats

⁴z angl. Fusion beats

⁵z angl. Unclassified beats

1.2 2D CNN

Soliński a spol. [8] tvoří jednoduchou, nyní však 2D konvoluční síť, kde klasifikují 10s záznamy do 27 tříd. Stavební bloky jsou totožné, pouze jinak poskládané s odlišnými parametry. Ze 4 různých databází použili celkem 43101 12-svodových EKG záznamů různé délky se kterými pracují. Záznamy filtrují mediánovým filtrem a zajišťují nulovou izolínii. Vstup vždy tvoří 2D matice vytvořená naskládáním jednotlivých svodů pod sebe. Data prochází obdobnými stavebními bloky jako v článku [5] s modifikací pro 2D, pro které byly původně navrženy. Záznam je možné klasifikovat do více tříd a proto autoři zvolili v poslední vrstvě **sigmoidální aktivační funkci** s prahovou hodnotou pro zařazení do dané kategorie 0,35. Sigmoidální aktivační funkce provádí transformaci vstupujících proměnných jakéhokoliv rozsahu do rozsahu pravděpodobnosti od 0 do 1. Oproti Softmax aktivační funkci suma napříč neurony nedává 1.

Kvalitu navržené sítě je těžké porovnat s ostatními publikacemi. Článek pochází z Physionet Challenge 2020, kde se úspěšnost hodnotí speciálně navrženou metrikou a žádné jiné dílčí výsledky článek nenabízí. Autoři pouze poukazují na možný problém přeučení sítě z důvodu vyšší úspěšnosti na trénovacích datech.

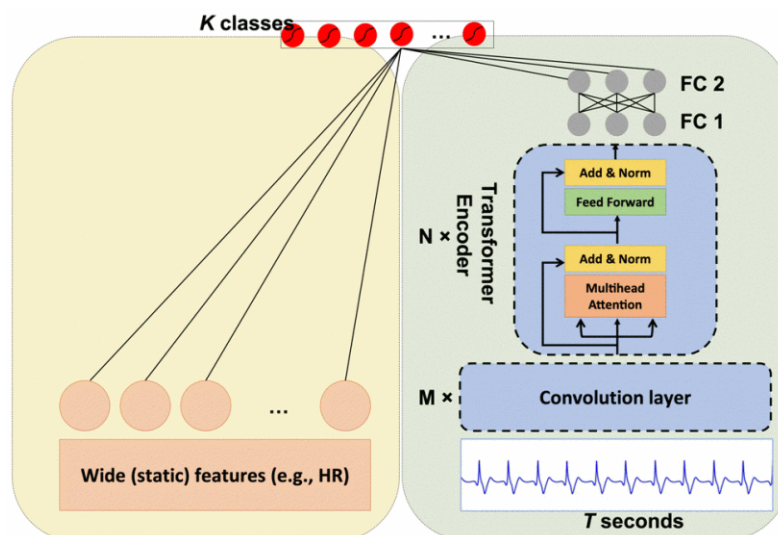
1.3 Hybridní modely

Zajímavý přístup k problematice nabízí autoři článku [9], kteří zkombinovali CNN, standardní plně propojenou síť a tzv. **Transformery** [10]. Oproti předchozím článkům zvolili netradiční přístup klasifikace na základě jak ručně extrahovaných příznaků tak i příznaků vytvořených neuronovou sítí. Základní architekturu můžeme vidět na Obr. 1.2.

Článek byl publikován opět v rámci PhysioNet Challenge 2020 a provádí klasifikaci EKG záznamů do 27 tříd. Přičemž jeden záznam může být zařazen do více tříd zároveň. Předzpracování signálu realizují jeho filtrací pásmovou propustí s mezními frekvencemi 3 a 45 Hz. Signál je následně normalizován do rozsahu od -1 do 1 a převzorkován na 500 Hz. Z každého záznamu je náhodně zvolen 15s úsek.

Extrahováno bylo 300 příznaků z druhého svodu se zaměřením na morfologii i variabilitu srdečního rytmu. Z těchto 300 příznaků bylo vybráno 20 nejrelevantnějších pomocí metody Náhodných lesů. Jelikož výskyt arytmiie často souvisí i s věkem a pohlavím pacienta (a mohly by zvýšit úspěšnost klasifikace), byly i tyto informace přidány. Ručně extrahované příznaky jsou v práci nazvány *wide features*.

Pro získání příznaků pomocí neuronové sítě tzv. *deep features* byl navržen model složený ze 3 částí: a) CNN; b) Transformeru; c) plně propojené neuronové sítě. Předzpracovaný EKG signál vstupuje do první části, kterou je CNN složená ze šesti



Obr. 1.2: Architektura hybridního modelu sítě, převzato z [9].

vrstev. Výstupem je 20x podvzorkovaný a transformovaný signál obsahující nejdůležitější informace obsažené v původním signálu. První krok je zvolen pro zjednodušení a zrychlení následné analýzy.

V druhé části je na začátku umístěno poziční kódování, zaručující zachování informace o návaznosti jednotlivých prvků. Transformer se skládá pouze z enkodérové části obsahující 8 vrstev, která je dostačující pro klasifikaci. Každá z vrstev obsahuje několik základních bloků: i) tzv. *multi head self attention mechanism* (pro více detailů viz 1.5), ii) plně propojené vrstvy, iii) *skip connections*, iv) normalizaci výstupu. Výstup prochází Average Pooling vrstvou do plně propojené sítě. Výstupem této části je 64 *deep features*.

Posledním krokem je zřetězení obou druhů příznaků, které vstupují do poslední plně propojené sítě, která již provádí klasifikaci do 27 tříd. Článek byl vybrán z důvodu netypického přístupu spojení dvou druhů příznaků a využití Transformerů, jakožto možných náhradníků rekurentních neuronových sítí (RNN). Autoři experimentálně nahradili tuto část RNN a výsledky ukázaly rozdíl ve výpočetní náročnosti modelu, což je jednou z výhod Transformerů.

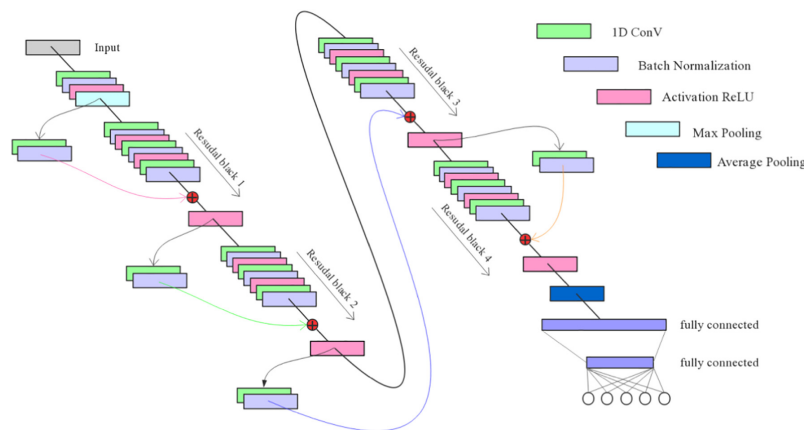
Výsledky navržené sítě jsou opět těžko porovnatelné z důvodu využití odlišné metriky.

1.4 ResNet

Konvoluční neuronové sítě mají obecně dobrý potenciál pro získávání kvalitních a vysoce specifických příznaků pro následnou klasifikaci. Předpokládá se, že se zvyšujícím

se počtem konvolučních vrstev roste kvalita příznaků a tím i učící schopnost sítě. Avšak spolu s narůstajícím počtem vrstev v hlubokých neuronových sítích vznikají problémy mizejícího gradientu, ztráta výkonu a konvergence. V hlubších vrstvách může gradient dosahovat až nulových hodnot, výsledkem čehož nebude docházet k učení těchto vrstev. [11]

Účinné řešení nabídly reziduální neuronové sítě (ResNet), které eliminují tyto problémy pomocí již zmíněných *skip connections*. Jedná se o spoje převádějící důležité informace ve formě příznakových map do hlubších vrstev sítě. Podmínkou převodu je totožná velikost příznakových map v obou vrstvách, protože jejich spojení probíhá formou sumace. Díky těmto spojmům se při učení gradient šíří napříč celou sítí. Zavádění reziduálních bloků nepřidává velký počet parametrů, ale zároveň umožňují učení všech vrstev sítě. [13]



Obr. 1.3: Architektura sítě ResNet, převzato z [12].

Využití pro klasifikaci EKG záznamů představili například Li a spol. [12], kteří klasifikovali jednotlivé srdeční cykly do 5 již zmíněných tříd (N,V,S,F,Q). V článku porovnávali využití 1 nebo 2 svodů EKG a 3 různé modely ResNet s odlišným počtem vrstev (ResNet - 19, ResNet - 25, ResNet - 31). ResNet-31 (viz Obr. 1.3) s dvěma svody dosáhla nejslibnějších výsledků s F1 skóre 0,963. Architektura sítě je složená ze 4 reziduálních bloků. V každém bloku jsou obsaženy 1D konvoluce a také speciální **1x1 konvoluce**, ve které se nekombinují jednotlivé vzorky v rámci dimenze, ale příznaky napříč hloubkou. Rozměr dat po 1x1 konvoluci zůstává stejný, může se měnit jen jejich dimenzionalita. Výsledkem je tedy lineární kombinace vstupních příznaků. *Skip connections* jsou zde tvořeny konvolučními vrstvami a vrstvou Max Pooling. Finální klasifikace je realizována opět pomocí plně propojené neuronové sítě se Softmax aktivační funkcí.

Jing a spol.[11] se zaměřili na zlepšení již navrženého modelu ResNet-18 z článku [13] a jeho aplikaci na EKG. Autoři klasifikují 3s úseky z MIT-BIH Arrhythmia

Database také do 5 tříd s F1 skóre 0,956.

Ukázalo se, že ResNet mají opravdu dobrý potenciál, jako nevýhodu můžeme uvést vyšší výpočetní náročnost z důvodu většího počtu vrstev.

1.5 Sítě s moduly pozornosti

Moduly pozornosti (angl. attention module) byly poprvé představeny v roce 2014 [40]. V článku byl modul využit pro vylepšení kvality strojového překladu. Toto využití je pro předloženou práci irelevantní a další text bude zaměřen na využití této myšlenky ve zpracování EKG záznamů.

Jak je v kapitole 1.1 zmíněno, CNN poskytují velice kvalitní výsledky v problematice klasifikace EKG záznamů. Velkou výhodou těchto sítí je absence potřeby ručního extrahování příznaků, protože samotná CNN postupně s rostoucí hloubkou sítě získává ze surového EKG záznamu vysoce sofistikované příznaky. V tradičních CNN jsou všem vstupním neuronům přiřazeny stejné váhy, avšak z pohledu EKG má každá část cyklu odlišnou důležitost a síť by se měla více zaměřit na úseky s vyšším obsahem informace pro daný klasifikační problém. Například ve chvíli, kdy na vstup sítě bude přicházet záznam, jehož základní rytmus bude sinusový s paroxysmem flutteru síní může klasická síť vyvodit chybný závěr, protože úseku obsahující FL nebude věnována dostatečná pozornost. A právě tento nedostatek řeší pozornostní moduly, které adaptivně váhují jednotlivé příznakové mapy s cílem zdůraznit vysoce informativní úseky (v časové oblasti) a zaměřit se na důležitější příznaky (v kanálové oblasti) a potlačit irelevantní. Výsledkem aplikace pozornostních modulů by mělo být zpřesnění klasifikace sítě, právě díky přidané informaci o důležitých částech záznamu. [30]

Pro přehlednost mohou být pozornostní moduly, využívané při klasifikaci EKG záznamů, rozděleny dle dimenze, se kterou pracují: I) pozornostní moduly zaměřené na časovou posloupnost signálu II) pozornostní moduly zaměřené na kanálovou dimenzi a III) pozornostní moduly CBAM (z angl. convolutional block attention module) kombinující předchozí varianty. [37]

Pozornostní modul zaměřený na časovou posloupnost signálu

Vytvoření tohoto modulu bylo inspirováno 2D prostorovým pozornostním modulem využívaném při zpracování 2D obrazových dat [41]. V případě 1D signálů jsou v rámci časové osy jednotlivým úsekům přiřazeny odlišné váhy v závislosti na množství informace obsažené v konkrétním úseku. Stejně jako CNN se i tento modul v průběhu trénování učí a mění své váhy v závislosti na výsledku klasifikace. Jedná se o moduly, které nejsou příliš rozsáhlé a mohou být implementované do široké

škály architektury. Modul se může skládat např. ze dvou plně propojených neuronových sítí, kde jsou si počty neuronů na vstupu a výstupu rovny a počet neuronů skryté vrstvy je redukován na základě redukčního koeficientu: $N = L/r$, kde N je počet neuronů, L délka vstupního signálu a r redukční koeficient. Do této sítě vstupuje vektor získaný aplikací globálního poolingů napříč kanály. V síti mohou být využity různé aktivační funkce, např. ve skryté vrstvě aktivační funkce hyperbolické tangenty či ReLU a na výstupu Softmax aktivační funkce, která již vytváří výsledné váhy s rozsahem od 0 do 1. Tento výstup je poté prvek po prvku vynásoben s původní příznakovou mapou a pro zamezení problému mizejícího gradientu je výsledek sečten s původní příznakovou mapou. [32] [33]

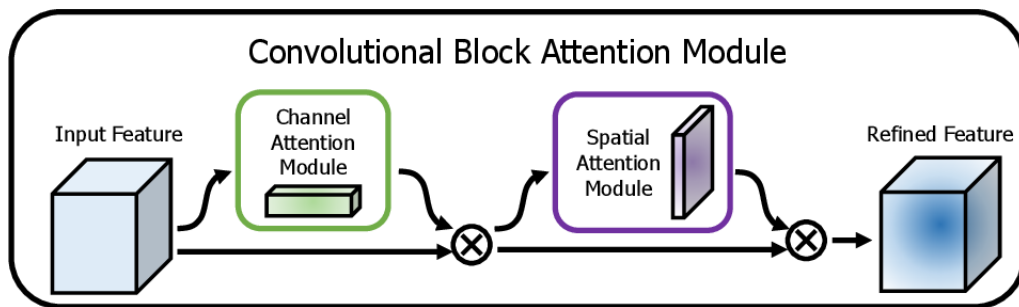
Pozornostní modul zaměřený na informační obsah jednotlivých kanálů

Modul původně také zkonstruován pro obrazová data [35] a následně využit i při zpracování 1D signálů. Na rozdíl od předchozího modulu mají všechny prvky časové posloupnosti totožné váhy. Rozdílné váhy se přiřazují jednotlivým kanálům, čímž se upřednostňují důležitější a informačně výraznější příznaky a naopak jsou potlačovány příznaky irelevantní pro daný klasifikační problém. [36] Stejně jako v předchozím případě se váhy adaptují v průběhu učení sítě. Obdobně jako časový pozornostní modul je většinou jednoduše implementovatelný a může být konstruován podobnou cestou (s rozdílem, že vstupní vektor nebude totožné délky jako signál, ale délka se bude rovnat počtu kanálů). Realizace může být pomocí globální poolingové operace aplikované napříč časovou dimenzí, která z každé příznakové mapy vrátí skalár s globálním receptivním polem. [42]

CBAM (z angl. *convolutional block attention module*)

Oba předchozí moduly se zaměřovaly na odlišné informace. Zatímco časový modul odpovídá na otázku „Kde v signálu nalezneme důležité informace?“, kanálový modul pozornosti odpovídá na otázku „Co jsou důležité informace?“. Protože obě zmíněné informace jsou pro klasifikaci a zpracování dat důležité, CBAM spojuje oba přístupy. [37] Jedná se tedy o model skládající se ze dvou jednoduchých modulů uspořádaných sériově za sebou s možnou implementací v každém konvolučním bloku sítě kterékoliv architektury CNN (viz. Obr 1.4). Z pohledu implementace má modul oproti výše uvedeným drobné změny, avšak princip zůstává stejný.

V člancích můžeme najít implementaci modulu do řady různorodých síťových architektur, kde autoři uvádí, že výsledkem implementace modulu je zpřesnění klasifikace sítě, avšak pouze malá část autorů uvádí srovnání výsledků klasifikace sítě s/bez pozornostního modulu. Většinou jsou uváděny výsledky porovnávající odlišné architektury na základě kterých nelze určit vliv samotných přidaných modulů. I přes



Obr. 1.4: Ukázka implementace CBAM [37].

tento nedostatek sítě s přidáním modulu v článcích často dosahují lepších výsledků (např. [30, 31, 39], kde se vylepšení pohybuje v rámci desetin až jednotek procent).

Autoři článku [38] implementující CBAM uvádějí výsledky klasifikace sítě (průměrné F1 skóre): bez modulu (0,819), pouze s částí kanálové pozornosti (0,827), časové pozornosti (0,825) a s aplikací kompletního modulu (0,835). Zde implementace CBAM vylepšila klasifikaci sítě o necelé 2%. YAO a spol. [33] uvádí výsledky s/bez aplikace časového pozornostního modulu (průměrné F1 skóre) 0,772/0,812, kde modul zvýšil kvalitu klasifikátoru o 4%.

1.6 Návrh a učení sítě

Při návrhu sítě je potřeba nastavit velké množství parametrů, jejichž optimalizace zabere spoustu času. Proto budou některé parametry sítě voleny na základě informací získaných výše. Z toho důvodu je zde uvedena tato kapitola shrnující získané informace.

Základním kamenem pro většinu architektur zabývajících se klasifikací EKG signálu jsou právě CNN. V návaznosti na to základní architektura této práce bude založena také na CNN. Samotná podoba sítě bude záležet na optimalizaci. Aktivační funkce převládají Relu ve skrytých vrstvách a Softmax na výstupu sítě. Další možnou volbou je sigmoidální aktivační funkce v případě zařazení dat do více tříd zároveň.

Pro formální určení kvality klasifikátoru se využívají kritériální funkce. U klasifikačních problémů, obsahujících v poslední vrstvě Softmax aktivační funkci, je nejčastěji volena křížová entropie (cross-entropy), která může být vypočítána jako

$$L_i = \sum_{c=1}^C y_{i,c} \cdot \log(\hat{y}_{i,c}) \quad (1.1)$$

kde C značí počet tříd, y skutečnou třídu a \hat{y} predikovanou třídu.[18] Výslednou

chybu pro danou epochu či Mini Batch získáme sumací všech dílčích chyb. V průběhu učení se snažíme minimalizovat rozdíl výsledku predikovaného sítí a aktuálním zařazením a tedy minimalizovat kritériální funkci.

Ve fázi učení naprostá většina sítí (popisující tuto část) prováděla učení parametrů pomocí algoritmu zpětného šíření chyby (angl. back propagation, dále jen BP), kdy je minimum chybové funkce získáváno metodou gradientního sestupu (angl. gradient descend, dále jen GD), většinou v modifikacích vylepšující samotnou metodu. Nejčastěji používaný algoritmus napříč články je **ADAM** (z angl. Adaptive Moment Estimation), který řeší nedostatky klasické GD, jako je problém s nastavením učicího kroku, problém s nulovým gradientem a lokálními extrémy. Tyto nedostatky řeší přidáním parametru hybnosti do výpočtu, v rámci které je posun v dalším kroku vždy ovlivňován kroky předchozími. Aby nedocházelo k neustále kumulaci těchto posunů jsou exponenciálně zapomínány. Dalším velkým problémem je inicializace učebního kroku (angl. learning rate), který při chybném nastavení nedovoluje konvergenci k minimu. V rámci algoritmu ADAM je krok učení adaptivně upravován v závislosti na velikosti gradientu, čímž se snižuje dopad prvotního nastavení kroku učení.

K výpočtu může být přidána **L2 regularizace** (váhové zapomínání), která zabraňuje přeučení sítě. Princip je takový, že k celkové kritériální funkci je přičtena hodnota odvozená od velikostí vah vynásobená parametrem λ , čímž se omezuje samotná velikost vah a zamezuje se tak přeučení sítě na trénovacích datech. Parametr λ je v článcích nastavován s velkým rozsahem od 0,0001 až 5. Další často volenou regularizací sítě je volba **DropOut** parametru (v článcích 0.1 - 0.5) a zařazení **BN** za vybrané vrstvy (viz výše).

K učení ve všech článcích přistupují pomocí tzv. **Mini Batchu**, což jsou skupiny dat, v rámci kterých probíhá učení. Váhy sítě jsou upravovány každých n iterací, kde n je počet záznamů v Mini Batchi. Učení se opakuje podle vybraného počtu epoch. Výhoda tohoto přístupu je možnost paralelizace výpočtu. Mini Batche jsou v pracích voleny s velkým rozsahem od 10 až 1024 signálů s počtem epoch pohybujících se kolem 50. Jejich volba ovlivňuje rychlost i dobu učení sítě. Výjimečně jsou v článcích aplikována pravidla umožňující předčasné ukončení v případě stagnace výsledku po několika epoch. Tento přístup šetří trénovací čas a omezuje přeučení.


Při návrhu sítě dostáváme velký počet parametrů, které musíme nastavit, nebo které se optimalizují ve fázi učení. Pokud se jedná o základní architekturu sítě, typy vrstev a jejich parametry, parametry potřebné pro učení metodou ADAM, krok učení, atd. mluvíme o tzv. **hyperparametrech**. Ty se musí nastavit vždy na začátku a v průběhu učení se již nemění. Každá jejich změna vede k učení celé sítě od začátku. Existují různé přístupy nalezení ideálních hyperparametrů od brute force technik až po sofistikované automatizované metody. I přes vysokou časovou nároč-

nost je nejčastěji voleným přístupem brute force, kdy autoři vycházejí z apriorní znalosti rozsahu hodnot parametrů a v tomto prostoru náhodně hledají optimální (zde korektněji suboptimální) kombinaci hyperparametrů.

Hlavní parametry optimalizující se v průběhu učení jsou váhy neuronů všech vrstev, se kterými se násobí vstup. Váhy musíme na začátku trénování inicializovat. Volba metody inicializace má vliv na průběh učení sítě. Inicializaci vah zmiňuje pouze článek [9] uvádějící metodu Xavier [15], která provádí inicializační nastavení vah sítě na základě počtu vstupů do neuronu a výstupů z neuronu tak, aby zachovala nulovou střední hodnotu a vhodný rozptyl pro aktivační funkci v rámci prvního kroku učení.

Na Obr.1.5 je prvotní představa modelu sítě provádějící klasifikaci do 7 tříd (SR, FIB, FL, AVB I., II., III. stupně a Ostatní) obsahující právě hůře diferencovatelné arytmie. Návrh byl navržen na základě publikací (viz výše). Na začátek jsem se rozhodla navrhnout co nejjednodušší model, zahrnující pouze základní stavební bloky CNN, který bude postupně upravován.

V rámci celé kapitoly bylo čerpáno také z [16], [17], [18].



Obr. 1.5: Původní navržená architektura sítě klasifikující do 6 tříd (SR, FIB, FL, AVB I, II a III, Ostatní).

1.7 Metriky hodnotící úspěšnost klasifikace

Pro hodnocení průběhu učení a následně i kvality finálního modelu jsou potřeba metriky kvantifikující jeho klasifikační schopnosti. V závislosti na druhu úlohy volíme druh metrik.

Jako základní prvek pro vyhodnocení slouží **matice záměn**. Jedná se o matici, kde řádky a sloupce představují skutečné třídy a predikce (viz. Obr. 4.1). Tato matice poskytuje velice přehlednou informaci o kvalitě klasifikátoru a také umožňuje důkladnější analýzu (např. detekci problematictějších skupin). Uvnitř matice se udávají počty: falešně pozitivních, falešně negativních, skutečně pozitivních a skutečně

negativních predikcí. Na základě těchto čísel jsme pak schopni jejich kombinací získávat další metriky, popisující model z odlišných pohledů. Důležité je také zmínit, že matici záměn můžeme získat pouze v případě, kdy každý vzorek spadá pouze do jedné třídy.

Senzitivita nebo také **recall** poskytuje informaci o tom, jak dobře model detekuje skutečně pozitivní vzorky. V medicínském prostředí se jedná o důležitý ukazatel. Pro úspěšnou léčbu je důležité včas zachytit danou patologii.

$$\text{Senzitivita} = \frac{TP}{TP + FN} \quad (1.2)$$

Specificita na druhou stranu udává informaci o tom, jak správně se klasifikují skutečně negativní vzorky.

$$\text{Specificita} = \frac{TN}{TN + FP} \quad (1.3)$$

Přesnost (accuracy) udává celkovou úspěšnost klasifikátoru, tedy kolik vzorků ze všech zařadil do správné třídy. Ve chvíli, kdy je pouze malé procento skutečně pozitivních vzorků může přesnost dosahovat vysokých čísel díky velkému počtu skutečně negativních výsledků, což může být zavádějící. Z toho důvodu se nejedná o vhodnou metriku v případě nerovnoměrně zastoupených dat.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1.4)$$

Přesnost (precision) udává poměr skutečně pozitivních vzorků ku všem, které byly predikovány jako pozitivní. Také známa jako pozitivní prediktivní hodnota.

$$\text{Precision}(PPV) = \frac{TP}{TP + FP} \quad (1.5)$$

F1 skóre je harmonický průměr mezi přesností (precision) a senzitivitou (recall). Ve chvíli nerovnoměrně zastoupených dat je vhodnou volbou, protože v jeho výpočtu není počet skutečně negativních vzorků. Dle potřeb může být vzorec upraven nastavením odlišného poměru mezi přesností a senzitivitou, čímž je možné specifikovat co je pro danou úlohu důležitější. Často je právě F1 skóre metrikou udávající výslednou predikční schopnost modelu.

$$F1\text{skóre} = 2 * \frac{PPV * Se}{PPV + Se} \quad (1.6)$$


V rámci celé podkapitoly bylo čerpáno z [18].

2 Popis analyzovaných dat se zaměřením na detekované arytmie

Hlavní data byla poskytnuta firmou MDT-Medical Data Transfer, s.r.o.. Jedná se o firmu poskytující pacientům měřicí přístroje umožňující neustálé snímání srdeční aktivity. Data jsou po naměření odeslána na server firmy díky čemuž je zajištěna neustálá kontrola srdeční aktivity pacientů.

Firma disponuje různými druhy přístrojů, u kterých se liší typ monitorace (příložné kartičky, epizodní/kontinuální záznamníky) i délka jednotlivých záznamů. V popisované databázi tedy najdeme záznamy různých délek (od 5 sekund do necelých 3 minut).

Databáze obsahuje 60579 EKG záznamů získaných od pacientů (příklad viz. Obr. 2.1). Anotace je provedena popisem rytmu (13 tříd) a popisem morfologických změn (16 tříd) viz. Obr. A.1. Získání konkrétní diagnózy je pak možné také kombinací jednotlivých položek (např. položky SVR a TACHY indikují supraventrikulární tachykardii). [28]




Obr. 2.1: Ukázka EKG z databáze, sinusový rytmus.

Samotné záznamy jsou uloženy ve formátu CSV a další soubor ve formátu JSON poskytuje základní informace o pacientovi, měření, akviziční jednotce a také základní rozměření signálu. Každý záznam poskytuje 3 svody (svody I, II a aVF) s jednotnou vzorkovací frekvencí a kvantováním napříč všemi záznamy (250 Hz a $1\mu\text{V}/\text{LSB}$).

Průměrný věk pacientů v databázi je 60 ± 17 let a proto můžeme považovat databázi v rámci věkových kategorií za poměrně rozmanitou a z pohledu zastoupení obou pohlaví za homogenní (28805 mužů a 31774 žen).

Na Obr. A.2 můžeme vidět počty záznamů z různých tříd seřazené dle výskytu v databázi. Jak je z grafu patrné, každý záznam může patřit do více skupin zároveň. Rozdělení do jednotlivých tříd není rovnoměrné a můžeme říct, že odpovídá incidenci srdečních poruch v populaci.

Jak už bylo zmíněno dříve, databáze obsahuje záznamy o různé délce. Aby bylo možné v další části práce sjednotit délku záznamu, kterou CNN vyžadují, byla provedena analýza délky dat (viz Obr.2.2). Na základě zjištěných informací byly vybrány dvě možné délky záznamů, 10 s (2 500 vzorků) a 40 s (10 000 vzorků). Druhá hodnota je na histogramu méně patrná, avšak vzala se v potaz pro minimalizaci ztráty dat z méně zastoupených kategorií. Pro informaci je dále uvedena tabulka 2.1 udávající počty delších záznamů s výskytem vybraných arytmií. Vhodná délka bude vybrána v praktické části na základě výsledků učení.



Obr. 2.2: Rozložení délek záznamů napříč databází (zobrazeny jsou pouze délky s četností přesahující 10 vzorků).

Tab. 2.1: Počty delších záznamu obsahující vybrané arytmie (d představuje délku signálů ve vzorcích).

	d > 10 000	d > 2 500
Fibrilace síní	310	5734
Flutter síní	20	350
AVB I.	11	487
AVB II.	0	15
AVB III.	2	18


Práce se zaměřuje na detekci vzácnějších resp. obtížněji diferencovatelných arytmií (FIB, FL a skupinu atrioventrikulárních blokády). Jejich zastoupení můžeme opět vidět na Obr.A.2, dostatečně zastoupená je skupina FIB a částečně i AVB I.stupně (16,92%, 4,37%), avšak u AVB II., III. stupně a FL jsou počty záznamů velice malé. Právě z toho důvodu bývá těžké vytvořit kvalitní klasifikátor pro vybrané arytmie.

2.1 Atrioventrikulární blokády

Na rozhraní síní a komor je umístěn atrioventrikulární uzel (AV uzel), který slouží k rychlému převodu vzruchu ze síní na komory. Fyziologicky je tento uzel jediným vodivým místem mezi síněmi a komorami. Při AV blokádách zde dochází k poruchám přenosu vedení. AV blokády se dělí do 3 kategorií na základě toho, zda je vedení ze síně na komory opožděné, občasné, či úplně zablokované.[20] Blokády nižšího stupně (AVB I.stupně a AVB II.stupně typu Mobitz I) se mohou u mladých lidí běžně objevovat ve spánku a bývají obvykle způsobené zvýšeným tonem vagu. Pro pacienta tyto arytmie nemusí představovat vážnější ohrožení. Oproti tomu AV blokády vyššího stupně (AVB II. stupně typu Mobitz II a AVB III.stupně) se řadí mezi závažné arytmie, vyžadující lékařskou péči, protože mohou způsobit Adamsův-Stokesův záchvat nebo náhlou smrt. Mezi nejčastější příčiny AV blokád patří např. idiopatická fibróza AV uzlu/ Tawarových ramének. [19]

2.1.1 AVB I.stupně

Na EKG záznamu se informace o převodu vzruchu mezi síní a komorou vyčte z délky PQ intervalu. Fyziologická hodnota PQ intervalu je 120 - 210 msec, při prodloužení nad 210 msec hovoříme o AV blokádě I. stupně (viz Obr. 2.3). Při AVB I.stupně dochází tedy pouze ke zpomalení vedení a pojem „blokáda“ není ve skutečnosti správný. Jedná se obvykle o asymptotickou benigní poruchu, s možným přechodem do vyššího stupně blokády. [19] [20]



Obr. 2.3: Ukávka EKG z databáze, AVB I.stupně.


2.1.2 AVB II.stupně

Při AVB II. stupně dochází k občasné poruše vedení vzruchu ze síně na komory (viz Obr. 2.4). V záznamu je přítomna P vlna bez QRS komplexu (vzruch není převeden

na komory). Při pravidelném opakování blokace můžeme uvést údaj o délce cyklu, ve kterém se blokáda opakuje (poměr všech vzruchů v cyklu ku převedeným vzruchům). AV blokádu II. stupně dělíme na dva typy.

AV blokáda Mobitz I (Wenckebachův typ), u které pozorujeme postupné prodlužování vedení (PQ interval roste), až dojde k výpadku převodu vedení ze síní na komory. Po nepřevedeném komplexu se cyklus restartuje a začne znovu [20]. Jak již bylo zmíněno, AVB II. stupně typu Wenckebach může být benigní, hlavně v případech, kdy se jedná o mladé lidi a blokáda se vyskytuje ve spánku. V takových případech je výskyt přisuzován zvýšenému tonu vagu. Pokud se blokáda objeví u starších lidí v denní době prognóza bývá podobná jako AVB Mobitz II.


AV blokáda Mobitz II se projevuje poruchou vedení ze síní na komory bez předchozího prodlužování PQ intervalu. Blokáda bývá často způsobena poruchou vedení v Tawarových raménkách, což vede na širší QRS komplexy. Při lokaci blokády pod AV uzlem bývá prognóza závažnější. [19]



Obr. 2.4: Ukázka EKG z databáze, AVB II.stupně.

2.1.3 AVB III.stupně

Při úplné (kompletní) blokádě (viz Obr. 2.5) dochází k přerušení kontaktu mezi síní a komorou. Síňová aktivita je stále řízena SA uzlem a běží beze změny. V komorách nastává asystolie, avšak po dostatečné dlouhé době se aktivují náhradní rytmy z ektopických ložisek. Aktivace ektopického ložiska záleží na lokaci AV blokády. Pokud k přerušení došlo na úrovni AV uzlu pak se ektopické ložisko nachází v distální části AV junkce - junkční rytmus (rychlejší). Při blokádě umístěné pod AV uzlem (infranodální) jsou ektopická ložiska náhradního rytmu na pravém či levém Tawarově raménku – idioventrikulární rytmus (pomalejší, širší QRS komplexy).



Obr. 2.5: Ukázka EKG z databáze, AVB III.stupně.


2.2 Fibrilace síní

Fibrilace síní (viz Obr. 2.6) patří mezi nejčastější poruchy srdečního rytmu v populaci. Jedná se o supraventrikulární arytmii, kdy v síni vznikají mikroentry okruhy (mnohočetné elektrické vzájemně se překrývající aktivace) s frekvencí 350-600/min. Takto extrémně rychlá a chaotická elektrická aktivita má za následek ztrátu efektivní kontrakce síní a snížení jejich hemodynamického efektu. Na EKG pozorujeme P vlny o velmi rychlé frekvenci (často aberovaného tvaru), nebo, v případě příliš nízké voltáže vln, pouze izolinní bez patrných P vln. Amplituda P vln je charakteristická pro každý svod (např. na svodu V1 mohou být velmi hrubé P vlny vzbuzující dojem flutteru síní).

Při tak rychlé frekvenci není AV uzel schopen převést všechny vzruchy na komory. Frekvence komor je tedy závislá na vodivých vlastnostech AV uzlu, které se v průběhu dne mění. I přes poměrně konstantní vodivé vlastnosti AV uzlu nedochází k pravidelnému převodu vzruchu ze síní na komory. Některé vzruchy jsou blokovány, jiné se převedou pouze částečně, a to vede k zablokování AV uzlu. Výsledkem je naprosto nepravidelná aktivita komor, která je typickým ukazatelem fibrilace síní. Při předpokladu absence dalších poruch vedení jsou QRS komplexy při fibrilaci síní štíhlé. Často je příčina idiopatická. Známými příčinami jsou infarkt myokardu, hypertenze, hypertyreóza a další. Dle délky trvání můžeme fibrilaci rozdělit na paroxysmální, persistující a permanentní (chronická). [19]

2.3 Flutter síní


Flutter síní vzniká mechanismem makroentry, který v síni koluje. Tím, že jde pouze o jeden reentry okruh (typicky uvnitř pravé síně s šířením proti směru hodinových ručiček) je aktivita síní pravidelná s frekvencí kolem 300/min. Na EKG se projevuje



Obr. 2.6: Ukázka EKG z databáze, fibrilace síní.

tzv. vlnami f, které mají tvar „zubů pily“ (viz Obr. 2.7). Aktivita komor je určena rychlostí vedení AV uzlu, často se uvádí poměr převodu ze síní na komory (počet P vln na jeden převedený komplex). Při rychlé frekvenci AV vedení může dojít i k převodu 1:1 a výsledné frekvenci komorové aktivity až 300/min. Při vyšších frekvencích je pak problematické flutter síní rozpoznat.

Příčiny jsou totožné jako u fibrilace síní, flutter síní je také často idiopatický. Velmi často se setkáváme s přechody mezi fibrilací síní a flutterem síní. [19] [21]



Obr. 2.7: Ukázka EKG z databáze, flutter síní.

3 Programové řešení

Modely sítě provádějící klasifikaci EKG záznamů jsou navrženy v programovacím jazyce Python (verze 3.9), který je použitý ve vývojovém prostředí Spyder 5. Pro výpočty byla využita grafická karta NVIDIA GeForce 940M. Python byl zvolen díky široké podpoře knihoven pro práci s hlubokými neuronovými sítěmi. Využity byly hlavně knihovny:

- Pytorch (verze 1.10.0) - knihovna pro vývoj a práci s hlubokými neuronovými sítěmi s podporou grafických akceleratorů [22]
- NumPy (verze 1.21.2) - knihovna poskytující infrastrukturu pro práci s vektory [23]
- Pandas (verze 1.3.4) - knihovna využívaná pro manipulaci a analýzu dat [24]
- Matplotlib (verze 3.5.0) - vykreslovací knihovna [25]
- JSON (verze 4.0.2) - knihovna pro práci s daty ve formátu JSON
- SciPy (verze 1.7.1) - knihovna využívaná pro vědecké a technické výpočty, zde převážně pro práci se signály [26]

V kapitole budou postupně popisovány dva vytvořené modely, kdy jeden provádí klasifikaci do 4 tříd (SR, FIB, FL a Ostatní) a druhý model provádí klasifikaci do 5 tříd (SR, AVB I, AVB II, AVB III a Ostatní). Do skupiny Ostatní vždy spadají všechny patologie vyskytující se v databázi mimo arytmie vybrané pro klasifikaci.

3.1 Příprava dat

Pro automatickou klasifikaci vybraných patologií algoritmem hlubokého učení je potřeba data vhodně předzpracovat. Jak již bylo zmíněno, poskytnutá data byla ve formátu CSV a spolu s nimi byl poskytnut soubor formátu JSON obsahující všechny doplňkové informace. Pro další práci byla data ponechána ve formátu CSV a JSON soubor byl upraven na jednoduchou tabulku obsahující vždy ID záznamu a odpovídající diagnózu, pro rychlou orientaci v záznamech.

Zvýšení počtu dat v málo zastoupených třídách

V rámci semestrální práce (na níž navazuje tato diplomová práce) byla pro klasifikaci arytmií použita architektura analogická s architekturou popisovanou dále (viz kapitola 3.5). Avšak úspěšnost klasifikace nedosahovala slibných výsledků (viz tabulka 3.1). Jedním z hlavních důvodů bylo zřejmě nedostatečné zastoupení některých skupin (flutter síní, AVB II. a III. stupně). Proto v této navazující práci provádím rozšíření databáze.

Databáze byla obohacena o data z veřejných databází a také o další data poskytnuta firmou MDT s.r.o. Přidání dat se týkalo pouze málo zastoupených zájmových patologií - FL, AVB II. a III. stupně. Z internetových zdrojů byla vybrána databáze z PhysioNet Challenge 2021, spojující 8 databází ze čtyř zemí světa napříč třemi kontinenty. [27]

Tab. 3.1: Výsledky získané v rámci semestrální práce: CNN, klasifikace do 6 tříd, validační množina. Nízké F1 skóre u skupin FL, AVB I, AVB II a AVB III je dáno nízkým počtem trénovacích dat v těchto skupinách.

	Se	Sp	PPV	ACC	F1
SR	0,748	0,839	0,579	0,818	0,653
FIB	0,793	0,963	0,814	0,934	0,804
FL	0,422	0,979	0,271	0,969	0,330
AVB I	0,807	0,941	0,386	0,936	0,522
AVB II,III	0,227	0,998	0,294	0,995	0,256
Ostatni	0,440	0,938	0,892	0,670	0,590
Prumer	0,573	0,943	0,539	0,887	0,526

Pro práci byla data získána pouze ze 6 vybraných databází:

- China Physiological Signal Challenge 2018 (CPSC 2018) - záznamy délky 6-144 sekund se vzorkovací frekvencí 500 Hz
- Physikalisch-Technische Bundesanstalt (PTB) - záznamy délky 10-120 sekund se vzorkovací frekvencí 500/1000 Hz
- Physikalisch-Technische Bundesanstalt (PTB-XL) - záznamy délky 10-120 sekund se vzorkovací frekvencí 500/1000 Hz
- Georgia database - záznamy délky 5-10 sekund se vzorkovací frekvencí 500 Hz
- Chapman University, Shaoxing People's Hospital (Chapman-Shaoxing) - záznamy délky 10 sekund se vzorkovací frekvencí 500 Hz
- Ningbo First Hospital (Ningbo) - záznamy délky 10 sekund se vzorkovací frekvencí 500 Hz

Přehled počtu přidávaných záznamů z jednotlivých databází poskytuje tabulka 3.2.

Všechny přidávané záznamy byly převedeny do formátu CSV a JSON tabulka byla aktualizována. Důležité je také zmínit, že v případě FL a AVB II. stupně není přítomno více záznamů od jednoho pacienta, avšak v případě AVB III. stupně bylo z důvodu nedostatku dat od některých pacientů vybráno i více záznamů.

Tab. 3.2: Detailní přehled četností přidávaných záznamů.

	FL	AVB II	AVB III
PhysioNet Challenge	2918	149	127
MDT s.r.o	—	1015	233
Celkem	2918	1154	360

Ráda bych také zmínila, že data přidávaná z MDT jsem sama vybírala a proto jsou přítomny pouze ty záznamy u kterých jsem si byla jistá přítomností daných arytmií. Toto může v hodnocení kvality klasifikátoru vést k přehnaně optimistickým výsledkům, zvláště u třídy AVB II, kde bylo přidáno 1015 záznamů. Na druhou stranu bych ráda podotkla, že tento krok by neměl vnášet chybu do učení, protože s klasifikací záznamů mám zkušenosti v rámci zaměstnání, kde provádím hodnocení EKG záznamů.

Filtrace dat


Zajímavé složky EKG se ve spektrální oblasti pohybují do 100 Hz. Aby nebyla ztracena důležitá data a zároveň byla co nejvíce snížena výpočetní náročnost, byla vzorkovací frekvence zvolena 250 Hz. Protože data původní databáze jsou nasnímána se stejnou vzorkovací frekvencí, byla převzorkována pouze přidávaná data.

V závislosti na vybrané klasifikační úloze a dostupnosti jednotlivých svodů v databázích, byl jako hlavní zvolen svod II. V případě flutteru a fibrilace síní jsou právě na tomto svodu často dobře patrné rozdílné f vlny. Svod by měl kvalitně diferencovat tyto patologie. Díky dobře patrným P vlnám je vhodnou volbou také při klasifikaci AVB. Pro možnost porovnání klasifikačních výsledků sítě v případě učení s více svody byl pro každý záznam uložen také svod aVF, který má podobné vlastnosti.


Nasnímané surové EKG záznamy vždy obsahují řadu rušivých elementů. Častými zdroji rušení v EKG jsou: i) **síťový brum** (50/60 Hz, Obr.3.2), ii) **kolísání nulové linie signálu** (asi do 2Hz, Obr.3.5) a iii) **myopotenciály** (nad 100 Hz klidové EKG, nad 10 Hz zátěžové EKG, Obr.3.4). Pro zvýšení přesnosti klasifikace je vhodné toto rušení eliminovat.

Pro filtraci síťového brumu byl vybrán IIR filtr 2.řádu typu pásmová zádrž s velmi úzkým pásmem - notch filtr.[43] Pro minimální dopad jeho nelineární fázové charakteristiky je provedena dopředná i zpětná filtrace, která má za následek také zdvojnásobení řádu filtru.[44] Frekvenční charakteristika notch filtru je zobrazena na Obr.3.1. Výsledky filtrace pak ukazují Obr.3.2 a 3.3.

Filtrace driftu signálu byla provedena odečtením tzv. klouzavého průměru, který byl získán konvolucí signálu a Blacmanova okna, které bylo upraveno tak, aby suma hodnot okna dávala 1. [34] Tato metoda je používána jako jednoduchý filtr typu




Obr. 3.1: Frekvenční charakteristika úzkopásmového filtru typu pásmová zádrž.




Obr. 3.2: Filtrace síťového brumu pomocí úzkopásmového filtru typu pásmová zádrž.

dolní propust, který je rychlý a snadno použitelný. Po vyzkoušení několika možností bylo zvoleno okno délky 500 vzorků (2 s), které vhodně vystihuje pozvolné kolísání signálu. Výsledek filtrace je zobrazen na Obr. 3.5.

Nakonec je každý záznam normalizován odečtením střední hodnoty a dělením směrodatnou odchylkou.



Obr. 3.3: Detailnější pohled na signály před a po filtraci pro záznam obsahující síťový brum (dole) a záznam bez výraznějšího rušení (nahore).




Obr. 3.4: Myopotenciálové rušení v EKG.

3.2 Rozdělení dat do množin

Pro učení, validaci a vyhodnocení kvality sítě je potřeba data rozdělit do tří nepřekrývajících se množin. Celá databáze byla rozdělena v poměru 70% signálů trénovací množina, 15% signálů testovací množina a 15% signálů validační množina.

Pro zajištění rovnoměrného rozdělení zájmových skupin se data nejprve rozdělila podle obsažené patologie (AVB I.,II.,III. stupně, FIB, FL, SR). Záznamy s odlišnými patologiemi byly zařazeny do skupiny Ostatní. Nejprve byly vybrány záznamy, obsahující v diagnóze pouze danou patologii a poté záznamy s různými kombinacemi patologií. Rozdělování probíhalo vždy od nejméně zastoupených patologií, aby se



Obr. 3.5: Filtrace driftu, od signálu byl odečten průměr získaný konvolucí signálu s klouzavým oknem, původní signál(nahoře), filtrovaná signál(dole).

zajistilo, že právě ty budou rozděleny správně (zabránění např. přesunu všech AVB II. stupně pouze do jedné skupiny z důvodu současného výskytu FL). Takto vytvořené skupiny se postupně procházely a podle zvoleného poměru náhodně rozdělily do množin. Ve finále byla každá množina náhodně promíchána.

Výstupem jsou tři proměnné (test, train, valid) obsahující názvy souborů v jednotlivých množinách. Přehled četnosti záznamů v rámci jednotlivých množin i celkové četnosti uvádí tabulky 3.3 a 3.4. Z důvodu přítomnosti více záznamů od jednotlivých pacientů v případě AVB III. stupně proběhla ještě úprava množiny test, aby neobsahovala data od pacientů, kteří jsou obsaženi v trénovací množině. Výskyt těchto záznamů ve validační množině nebyl upraven.

3.3 Nevyvážený trénovací dataset a augmentační techniky

Cílem této kapitoly je nalezení vhodných datasetů pro učení navržených modelů (viz kapitola 3.5). V rámci kapitoly budou uvedeny způsoby úpravy nehomogenních datasetů, jejichž využití bude na konci kapitoly vyhodnoceno, na základě výsledků klasifikace EKG záznamů s využitím modelů naučených na upravených datasetech. Ke klasifikaci budou využity modely v různých fázích optimalizace, finální výsledky klasifikace však budou uvedeny až v rámci kapitoly 4.

Tab. 3.3: Přehled četností záznamů vybraných arytmií v množinách.

	Trénovací		Testovací		Validační	
	[—]	[%]	[—]	[%]	[—]	[%]
SR	9713	21,25	2082	21,25	2082	21,25
FIB	7196	15,75	1546	15,78	1541	15,73
FL	2797	6,12	603	6,16	603	6,15
AVB I	1862	4,08	398	4,06	401	4,09
AVB II	920	2,01	195	1,99	197	2,01
AVB III	336	0,74	72	0,73	72	0,73
Ostatní	22866	50,05	4900	50,02	4901	50,03
Celkem	45690	100,00	9796	100,00	9797	100,00

Tab. 3.4: Celkové četnosti záznamů v databázi pro vybrané třídy.

	SR	FIB	FL	AVB I	AVB II	AVB III	Ostatní	Celkem
Počet	13877	10283	4003	2661	1312	480	32667	65283

Z tabulek 3.3 a 3.4 vidíme, že data využitá v této práci nemají rovnoměrné zastoupení počtu záznamů v rámci jednotlivých tříd. Tento jev je typický pro všechna medicínská data, kde převládají data od zdravých pacientů. Protože se tato práce zaměřuje právě na arytmiie, jejichž incidence v populaci není příliš vysoká, je obtížné najít dostatek dat pro zajištění rovnoměrného rozložení napříč třídami. Jak články [6] a [7] v kapitole 1.1 uvádí, při tomto rozložení se síť lépe učí a dosahuje tak lepších výsledků.

Nejjednoduššími a také napříč literaturou nejčastěji používanými technikami, řešící problém nevyváženého trénovacího datasetu, jsou undersampling (odstranění záznamů ze třídy s vysokou četností) a oversampling (rozkopírování méně zastoupených tříd). Undersampling může být problematický ve chvíli, kdy dojde k odstranění některých kritických dat z třídy, avšak z důvodu velkého nepoměru velikosti tříd byly využity obě techniky. Aby nebyly získány přehnaně optimistické výsledky, je potřeba oversampling dat provádět až po rozdělení do množin. Tím nedojde k výskytu stejného signálu ve více množinách.

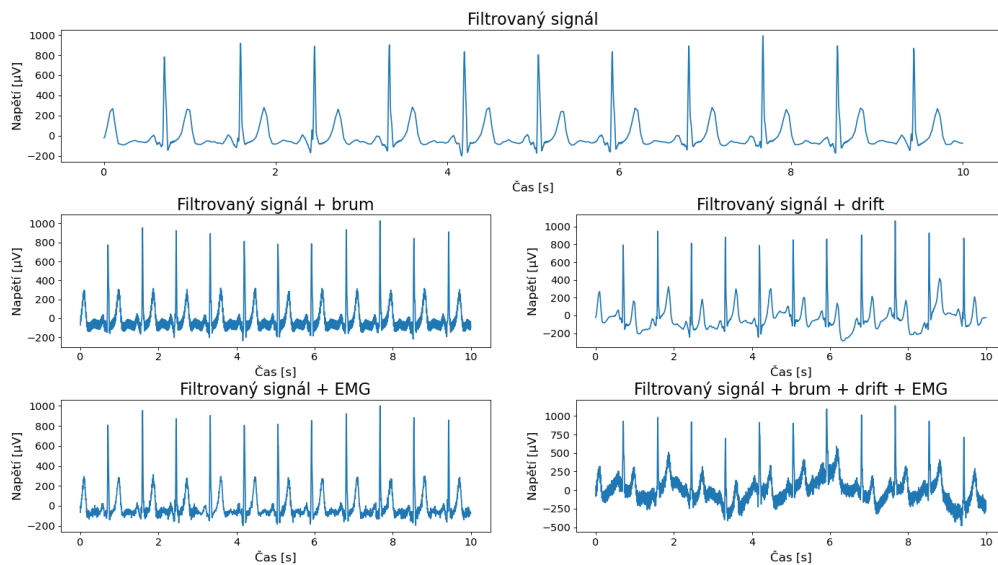
Cílem použití obou technik bylo získání nejlepšího trénovacího datasetu pro učení sítě. V případě nehomogenních dat síť často upřednostňuje více zastoupené třídy a díky jejich četnosti i výsledky dosahují vysokých hodnot, což může být zavádějící pro určení kvality klasifikátoru. Učení však vždy závisí na konkrétní databázi a poměru dat v databázi.

Kromě jednoduchého roznásobování existují také **augmentační techniky**, ne-

boli techniky obohacující dataset vytvářením nových signálů ze signálů již existujících. Pokud se místo jednoduchého roznásobování využijí sofistikovanější augmentační techniky, měla by sít dosahovat lepších výsledků (data by měla přinášet více užitečné informace).

V této práci byly využity augmentační techniky získané z publikace [45], obsahující více informací o návrhu a implementaci použitých metod. Celkem bylo využito 5 augmentačních technik, kdy jedna se zaměřuje na augmentaci jakéhokoliv signálu a zbylé 4 jsou pro augmentaci vybraných arytmii. Konkrétně se jedná o FL, AVB II. stupně (typ Mobitz I i Mobitz II) a AVB III. stupně, které jsou v databázi málo zastoupeny.


První využitou technikou, která by mohla vést k vylepšení klasifikační schopností sítě a je možné ji využít na augmentaci jakýchkoliv signálů, je přičítání náhodně uměle generovaného šumu k vybraným záznamům. K signálu je možné přičíst 3 druhy šumu: 50 Hz brum, kolísání nulové izolinie (do 1 Hz) a myopotenciály (30-150 Hz). Přičítání všech druhů šumu funguje opět náhodně a vždy se může vybrat jakákoliv kombinace, s náhodně vybranou amplitudou generovanou v určitém rozsahu. Použití pro signál obsahující pouze sinusový rytmus ukazuje obrázek 3.6.



Obr. 3.6: Vybraný signál u kterého je provedena augmentace šumem nejprve pro každý druh šumu zvlášť a nakonec jsou všechny způsoby spojeny.

V případě klasifikace do 4 tříd (tj. SR, FIB, FL a Ostatní) byla využita augmentace třídy FL. Použitá augmentační technika ze vstupního signálu obsahující FL vytvoří „nový“ signál náhodným přeházením jeho částí (viz Obr. 3.7). Začátky a konce segmentů korespondovaly s vrcholy QRS komplexů, aby se zabránilo nežá-

doucím přechodovým efektům v místě spojení segmentů (viz [45]). Takto vytvořené záznamy poté mohou nahradit jednoduché kopírování.



Obr. 3.7: Augmentace flutteru síní náhodným přeházením jeho částí.

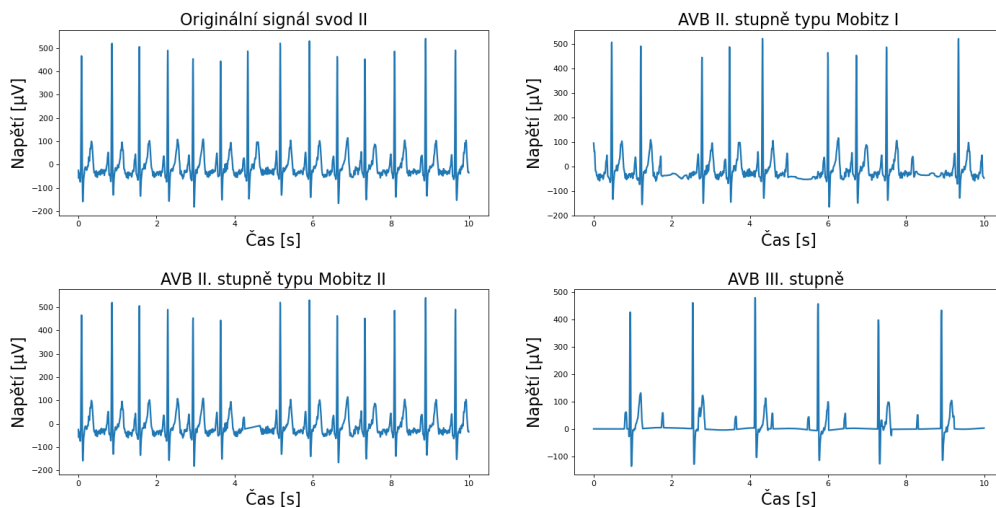
Pro klasifikaci do 5 tříd (tj. SR, AVB I, II, III a Ostatní) byly využity zbylé techniky provádějící umělou transformaci sinusového rytmu na AVB (II. i III. stupně) založenou na empirické znalosti augmentované arytmie (ukázky augmentace viz 3.8). V záznamu obsahujícím pouze sinusový rytmus byly detekovány klíčové body a na jejich základě proběhla úprava částí signálu, odpovídajících aktivitě síní a aktivitě komor, aby se signál připodobnil charakteristickému průběhu pro AVB.

Augmentační techniky pro skupinu atrioventrikulárních bloků vytváří signály pro AVB II. stupně typu Mobitz I i typu Mobitz II. Bohužel pro takto detailní kalsifikaci nebyl nalezen dostatek dat pro učení sítě a při augmentaci jsou tyto dvě skupiny spojeny.

Dále budou uvedeny výsledky učení na navržených architekturách (viz kapitola 3.5) pro klasifikaci do 4 a 5 tříd (v různých fázích optimalizace) pro upravené trénovací množiny využívající výše popsané techniky. Cílem je nalézt trénovací dataset vedoucí k nejlepším výsledkům.

Datasey pro klasifikaci do 4 tříd

Pro získání nejlepšího trénovacího datasetu pro kalsifikaci do 4 tříd (SR, FIB, FL a Ostatní) z pohledu počtu signálů, bylo vyzkoušeno 5 trénovacích datasetů využívajících odlišné poměry technik undersamplingu a oversamplingu. Vyzkoušeny byly



Obr. 3.8: Ukázka augmentace AVB ze signálu obsahující sinusový rytmus.

jak datasety, kde bylo pomocí oversamplingu a undersamplingu zaručeno rovnoměrné zastoupení dat v rámci tříd, tak i nehomogenně zastoupené datasety.

Počty záznamů v jednotlivých množinách byly vybrány s ohledem na četnosti tříd FIB a FL v trénovací množině (viz tabulka 3.3). Vyšší počty záznamů v rámci tříd byly vybrány také z důvodu vyšší variability a pro získání reprezentativního vzorku hlavně v rámci třídy Ostatní, obsahující velké množství patologií.

- **Dataset0** - všechny data o stejné četnosti jako třída FL (cca 2700 záznamů)
- **Dataset1** - SR, FIB, Ostatní četnost cca 5000 každá třída, FL neupravena (2797 záznamů)
- **Dataset2** - SR, FIB, Ostatní četnost cca 5000 každá třída, FL rozkopírována na stejný počet
- **Dataset3** - SR, FIB, Ostatní četnost cca 8000 každá třída, FL neupravena
- **Dataset4** - SR, FIB, Ostatní četnost cca 8000 každá třída, FL rozkopírována na stejný počet

Z výsledků v tabulce 3.5 můžeme vidět, že rozdíl v případě využití 8000 nebo 5000 záznamů v každé třídě již není velký a nejlepších výsledků dosahuje **Dataset1**. Konkrétní počty záznamů ve třídách v tomto datasetu uvádí tabulka 3.6. Výsledky odpovídajících si množin v případě nehomogenních a rozkopírovaných dat jsou poměrně stejné. Tento fakt je možné vysvětlit tak, že nehomogenita v datech není tak vysoká, aby výrazně ovlivnila proces učení sítě.

Tab. 3.5: Výsledky klasifikace (F1 skóre) pro jednotlivé datasety na validační množině.

	SR	FIB	FL	Ostatní	Průměr
Dataset0	0,773	0,756	0,716	0,706	0,738
Dataset1	0,815	0,757	0,731	0,796	0,775
Dataset2	0,800	0,767	0,729	0,799	0,774
Dataset3	0,802	0,769	0,703	0,786	0,765
Dataset4	0,809	0,774	0,724	0,790	0,774

Tab. 3.6: Počty záznamů vybraného datasetu v jednotlivých třídách.

	SR	FIB	FL	Ostatní
Počet	5000	5076	2797	5546

Jak bylo ukázáno v tabulce 3.5, výsledky pro nehomogenní dataset a dataset s rozkopírovanými záznamy dosahují podobných výsledků. Otázkou je, zda přidání augmentovaných dat místo jednoduchého kopírování, či augmentace šumem přispěje ke zlepšení. Dataset1 byl v těchto krocích upraven tak, že byly přidány nově vytvořené záznamy a byla využita augmentace šumem.

- **Dataset1A** - Dataset1 + třída FL augmentována šumem
- **Dataset1B** - Dataset1 + přidány augmentované záznamy FL do počtu 5000
- **Dataset1C** - Dataset1B + třída FL augmentována šumem

Ve chvíli využití augmentace šumem, byl ke všem záznamům třídy FL přičten náhodně generovaný šum a tyto záznamy byly filtrovány. Myšlenka byla taková, že i po filtraci by mohlo dojít ke změně signálu a síť by tento signál mohla považovat za nový.

Výsledky v tabulce 3.7 ukazují podrobný popis úspěšnosti klasifikace třídy FL, pomocí vybraných 5 metrik na validační množině. Protože se jednalo pouze o augmentaci tříd FL a u ostatních tříd nebyly pozorovány významné změny, jsou uvedené výsledky pouze pro tuto třídu.

Předpokládala jsem, že využitím augmentace dojde ke zlepšení klasifikace třídy FL, díky přidání odlišných informací místo jednoduchého kopírování. Dále bylo předpokládáno, že přičtení šumu pomůže ke generalizaci modelu a záznamy s přidaným šumem, byť kopírované, budou sítí brány jako nové záznamy. Výsledky ukazují, že nejvyšších hodnot klasifikace jak u F1 skóre, tak u senzitivity, která je v případě predikce arytmií důležitým ukazatelem, dosahuje původní dataset.

Výsledky ukázaly, že předpoklad změny signálu v případě filtrace po přičtení

Tab. 3.7: Výsledky klasifikace na validační množině pro datasety s použitím různých kombinací augmentačních technik. Pro možnost srovnání je zde uveden i výsledek klasifikace na původním datasetu.

	Se	Sp	PPV	ACC	F1
Dataset1	0,759	0,934	0,706	0,903	0,731
Dataset1A	0,739	0,938	0,713	0,903	0,726
Dataset1B	0,757	0,931	0,695	0,900	0,725
Dataset1C	0,036	0,993	0,500	0,826	0,067

šumu nemusí být správný. Na základě tohoto zjištění byla provedena úprava učení a šum byl náhodně přičítán ke všem záznamům v kroku načítání dat (tj. pro každou epochu záznam obsahoval jiný náhodně generovaný šum) bez následné filtrace, avšak ani zde nedošlo ke zlepšení výsledků.

U Dataset1C obsahující augmentované FL s uměle přidaným šumem, můžeme pozorovat velice odlišné výsledky. Po celou dobu učení úspěšnost klasifikace této třídy na validačních datech nepřesáhla 20%, na druhou stranu u trénovacích dat bylo pozorováno velké zrychlení učení, kdy 95% úspěšnosti bylo dosaženo během prvních epoch (rychlé přeučení sítě beze změny nastavení oproti ostatním datasetům). Byl vyzkoušen i odlišný přístup augmentace šumem. Místo úpravy třídy FL přidáním pevného šumu (tj. pro každý signál jeden náhodně generovaný šum), který během učení vždy pro konkrétní signál zůstal stejný, byl šum přičítán během načítání dat (tzn. pro každou epochu se přičetl jiný náhodně generovaný šum). Také byla snížena pravděpodobnost přičtení myopotenciálového rušení, které není filtrováno. Žádná změna však nevedla k lepšímu výsledku. Je možné, že v záznamech bylo příliš uměle přidaných dat a tak byla síť naučena na charakteristiku těchto uměle přidaných informací, než na samotný tvar signálu.

Datasety pro klasifikaci do 5 tříd

Protože v rámci klasifikace do 5 tříd byly nepoměry dat výraznější (viz tabulka 3.3), byly kroky hledání optimálního počtu signálu ve třídách a použití augmentace spojené. Experimentálně bylo vytvořeno 9 odlišných datasetů se kterými bylo provedeno učení:

- **Dataset0** - SR, Ostatní 2000 záznamů každá třída, AVB nechány původní počty
- **Dataset1** - v každé třídě cca 2000 záznamů, pouze kopírování
- **Dataset2** - v každé třídě cca 2000 záznamů, augmentace AVB
- **Dataset3** - v každé třídě cca 3500 záznamů, pouze kopírování
- **Dataset4** - Dataset2, místo kopírování augmentace AVB

- **Dataset5** - v každé třídě cca 5000 záznamů, kopírování (AVB II 2x, AVB III 3x) i augmentace AVB (3000 záznamů pro AVB II i AVB III)
- **Dataset6** - Dataset5 + 2000 záznamů ve třídě SR i Ostatní, místo augmentovaných záznamů pouze kopírované
- **Dataset7** - Dataset5 + 2000 záznamů ve třídě SR i Ostatní
- **Dataset8** - Dataset7 - AVB pouze původní data

Protože při klasifikaci do 4 tříd nebyl prokázán kladný vliv augmentace šumem, v tomto případě nebyla aplikována. Větší datasey nebyly přidány kvůli časové náročnosti učení.

Kvůli přehlednosti bylo pro vyhodnocení použito pouze F1 skóre pro všechny třídy zvlášť a také jejich průměr.

Tab. 3.8: Výsledky učení pro různé trénovací množiny při klasifikaci do 5 tříd (použitá metrika F1 skóre).

	SR	AVB I	AVB II	AVB III	Ostatní	Průměr
Dataset0	0,834	0,712	0,862	0,702	0,767	0,775
Dataset1	0,835	0,693	0,831	0,670	0,745	0,755
Dataset2	0,836	0,712	0,854	0,715	0,769	0,777
Dataset3	0,838	0,687	0,869	0,667	0,749	0,762
Dataset4	0,844	0,688	0,862	0,723	0,769	0,777
Dataset5	0,849	0,719	0,860	0,720	0,771	0,784
Dataset6	0,840	0,717	0,877	0,717	0,779	0,786
Dataset7	0,856	0,718	0,879	0,721	0,795	0,794
Dataset8	0,855	0,719	0,878	0,732	0,794	0,795

V některých případech můžeme vidět (viz tabulka 3.8), že augmentace dosahuje lepších výsledků než kopírování, ale s rostoucím počtem záznamů se rozdíl zmenšuje. Zajímavé však je, že nejlepších výsledků dosahuje **Dataset8**, v rámci kterého nebyla použita žádná technika augmentace a jedná se o velmi nehomogenní dataset. Protože jsou výsledky pro datasey 7 a 8 podobné, byl vybrán Dataset8, neobsahující žádná uměle přidaná data.

I přes všechna očekávání se ukázalo, že snaha o vytvoření homogenního datasetu je v tomto případě poměrně zbytečná a navržené klasifikátory dosahují dobrých výsledků i bez úpravy homogenity datasetu. Velký vliv na to však může mít rozšíření databáze.

3.4 Vytvoření popisku, definující zařazení do třídy

Pro získání klasifikačních popisků jsou potřeba proměnné získané v předchozích kapitolách (množiny test, train, valid) a tabulka ve formátu JSON, která obsahuje názvy všech souborů a jejich diagnostické zařazení.

Na začátku postupu je potřeba podle tabulky A.1 definovat klasifikační třídy, do kterých chceme data rozdělit. Proměnné obsahující jména souborů se pak iterativně prochází a kontroluje se vždy na základě jednoduchých podmínek, zda signál obsahuje danou patologii (podle diagnózy v souboru formátu JSON). Každý záznam může patřit pouze do jedné skupiny a v případě výskytu více patologií současně se vybere nejzávažnější.

V rámci semestrální práce, byla prováděna klasifikace do 6 skupin, s možností multilabel klasifikace (SR, FIB, FL, AVB I, AVB II + AVB III, Ostatní patologie). Protože u této úlohy nebylo dosaženo dobrých výsledků (viz tabulka 3.1), byl celý problém rozdělen do dvou nepřekrývajících se klasifikačních úloh:

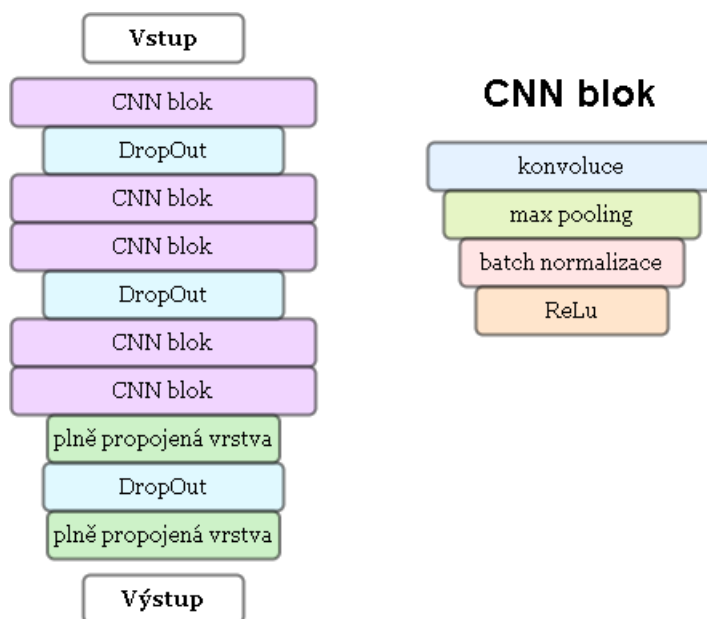
- SR, FIB, FL, Ostatní
- SR, AVB I, AVB II, AVB III, Ostatní

Výsledkem této části je soubor formátu CSV, obsahující na jednom řádku název souboru a jeho zařazení zapsané pomocí tzv. *one-hot* kódování. V případě *one-hot* kódování je místo jedné skalární hodnoty, definující výslednou třídu, vytvořen binární vektor o délce odpovídající počtu tříd, kde 1 označuje vybranou třídu.

3.5 Popis navržených architektur sítě

3.5.1 Klasifikace do 4 tříd

Na základě literární rešerše a optimalizačních kroků byla navržena architektura CNN (viz Obr.3.9), provádějící klasifikaci EKG do 4 vybraných tříd (SR, FIB, FL, Ostatní). Výchozím krokem byla prvotní představa, získaná na základě provedené rešerše (Obr.1.5). Ta byla postupně modifikována kombinací nejrůznějších vrstev a nastavených parametrů, převzatých převážně z literatury. Klasifikace EKG záznamů, pomocí níže popsaného modelu, dosahovala nejvyšších výsledků.



Obr. 3.9: Architektura navržené sítě provádějící klasifikaci do 4 tříd (SR, FIB, FL a Ostatní).

Popis vrstev sítě

Napříč celou architekturou se opakuje 5 základních stavební bloků CNN: i) konvoluční vrstva, ii) Batch normalizace, iii) max pooling, iv) Dropout a v) plně propojená vrstva. Konkrétní hodnoty jednotlivých vrstev jsou vidět v tabulce 3.9, kde **K** značí počet jader, **DO** délku okna a **S** krok posunu okna.

V síti se nachází 5 **konvolučních vrstev**, které představují hlavní část architektury. Konvoluční vrstvy signál postupně transformují na příznaky, které jsou využity pro finální klasifikaci. Tato transformace byla popsána již v kapitole 1.1 a proto zde bude diskutován pouze výběr parametrů.

Tab. 3.9: Rozpis parametrů jednotlivých vrstev sítě pro klasifikaci do 4 tříd (SR, FIB, FL, Ostatní).

Vrstva	Typ vrstvy	K	DO	S	Výstup
0	Vstup	—	—	—	5000×2
1	Konvoluční	32	51	2	2475×32
2	Max Pooling	—	2	2	1237×32
3	Batch Norm	—	—	—	
4	Konvoluční	64	25	2	607×64
5	Max Pooling	—	2	2	303×64
6	Batch Norm	—	—	—	
7	Konvoluční	128	15	1	289×128
8	Max Pooling	—	2	2	144×128
9	Batch Norm	—	—	—	
10	Konvoluční	128	5	1	140×128
11	Max Pooling	—	2	2	70×128
12	Batch Norm	—	—	—	
13	Konvoluční	64	3	1	68×64
14	Max Pooling	—	2	2	34×64
15	Batch Norm	—	—	—	
16	Flatten layer	—	—	—	2176×1
17	FC layer	250	—	—	250
18	FC layer	50	—	—	50
19	Výstup	—	—	—	4

Počty jader, které určují dimenzionalitu signálu, byly vybrány opět spíše heuristicky s ohledem na literaturu, výpočetní náročnost a výsledky optimalizace. Délka okna filtrů byla v první vrstvě volena s ohledem na fyziologickou interpretaci vybrané délky. První konvoluce provádí operaci vždy pro okno délky 51 vzorků, které pro vzorkovací frekvenci 250 Hz znamená časové rozpětí 200 msec, v rámci něhož je obsažena celá P vlna a je to hodnota hraniční fyziologické délky PQ intervalu. S postupně se zkracujícím signálem se zkracuje i délka okna.

Max poolingové vrstvy postupně zkracují signál a vybírají na výstup nejvýraznější příznaky. Protože na vstup přichází poměrně dlouhý signál, redukce délky signálu je prováděna také nastavením vyššího posunu konvolučního okna (viz sloupec S v tabulce 3.9).

Po první a třetí konvoluční vrstvě a také mezi plně propojenými vrstvami je umístěna vrstva **DropOut** s nastaveným parametrem 0,5, který udává s jakou pravděpodobností budou neurony deaktivovány.

BN je součástí regularizace sítě. Výstup konvolučních vrstev upravuje pomocí vzorce

$$y = \frac{x - E[x]}{\sqrt{Var[x] + \epsilon}} * \gamma + \beta \quad (3.1)$$

tak, že mají nulovou střední hodnotu a jednotkový rozptyl. Ve vzorci vystupují střední hodnota ($E[x]$) a rozptyl ($Var[x]$), které jsou počítány pro každý Mini Batch a uchovávají se v průběhu celého učení pro využití ve validační a testovací fázi. γ a β jsou parametry transformace optimalizující se v průběhu učení. Síť se tedy postupně učí, jak upravit rozsah dat, aby neurony pracovaly nejlépe.

Výstupem poslední konvoluční vrstvy je 64 příznakových vektorů délky 34 vzorků. Pro vstup do plně propojené vrstvy se příznakové mapy musí převést na jeden příznakový vektor. Ten vstupuje do série plně propojených vrstev provádějící klasifikaci. Výstupem je vektor čtyř čísel, kde každé značí pravděpodobnost zařazení signálu do konkrétní třídy.

V celé síti jsou použity dva druhy **aktivační funkce** a to ReLu aktivační funkce (viz 3.2, kde α značí aktivaci), ve všech konvolučních a první plně propojené vrstvě a Softmax aktivační funkce (viz 3.3, kde α značí aktivaci a K počet tříd), v poslední plně propojené vrstvě, která na výstupu poskytuje pravděpodobnost zařazení záznamu do konkrétní třídy.

$$f(\alpha) = \max(0, \alpha) \quad (3.2)$$

$$f(\alpha) = \frac{e^{\alpha_i}}{\sum_{j=1}^K e^{\alpha_j}} \quad (3.3)$$

Učení sítě

Pro práci s daty byla využita datová třída knihovny Pytorch *utils.data.Dataset* zjednodušující manipulaci s daty a umožňující jejich přehledné zpracování. Třída vytváří objekt datové sady, se kterým je pak následně možné jednoduše manipulovat v rámci učení sítě pomocí třídy *utils.data.DataLoader* (viz dále). Knihovna Pytorch umožňuje pracovat s daty již obsaženými, nebo vytvořit vlastní. Pro vytvoření vlastního datasetu je potřeba přepsat tři funkce třídy. První funkce (`__init__()`) pouze inicializuje proměnné, se kterými bude dále pracovat, mezi hlavní patří:

- soubor formátu CSV, obsahující ID záznamů a jejich zařazení do třídy
- kořenová složka se záznamy
- proměnné definující délku signálu, způsob prodloužení kratších signálů a počet použitých svodů

Druhá funkce (`__len__()`) vrací počet signálů v dané množině a v poslední funkci (`__getitem__()`) je implementováno předzpracování dat a získání konkrétního vzorku na základě vloženého indexu.

Celá třída *Dataset* byla navržena tak, aby umožňovala širokou variabilitu v nastavení parametrů, ovlivňujících výsledné učení sítě.

Obecný postup načítání signálu je následující: podle indexu se načte signál a k tomu odpovídající label, počet svodů signálu vstupujícího do sítě se upraví dle definované hodnoty (1/2). Pokud je signál kratší, než definovaná délka, je doplněn nulami/rozkopírován na požadovanou délku. V opačném případě je zkrácen. Protože při zkrácení signálu může dojít ke ztrátě informací, je zvolen vždy prostřední úsek signálu, aby se zvýšila pravděpodobnost záchytu patologie.

V učící fázi využijeme třídu *Dataset* a s ní spojenou třídu *DataLoader*. Nejprve je vytvořen objekt třídy *Dataset*, přes který se bude přistupovat k datům pomocí *DataLoaderu*. Ten vytvoří iterátor s definovaným počtem prvků v každém Mini Batchi, podle nastavených hyperparametrů (tabulka 3.10) a pomocí indexů bude vybírat hodnoty z *Datasetu*.

Učení probíhá pomocí dvou vnořených *for* cyklů, které provádí iteraci přes epochy a Mini Batche. Úprava učících parametrů sítě probíhá vždy až po průchodu celého Mini Batche. Pro úpravu vah je potřeba nejprve určit chybu predikce, pomocí kritériální funkce, která je zde vypočtena pomocí křížové entropie (angl. *cross entropy loss function*) implementované z knihovny *PyTorch*. Jedná se o nejčastěji volenou kritériální funkci v klasifikačních problémech.

Na základě získané chyby proběhne úprava vah pomocí algoritmu ADAM, který

Tab. 3.10: Hodnoty hyperparametrů, klasifikace do 4 tříd.

Maximální počet epoch	35
Mini Batch	64
Učící krok	0.001
Regularizační parametr λ	1,00E-05

je v dnešní době nejčastěji používán. Jde o poměrně robustní algoritmus, který mimo klasický gradientní sestup přidává do výpočtu hybnost. Díky hybnosti je posun do minima ovlivňován vždy i předchozími kroky, které jsou exponenciálně zapomínané. Další výhodou je adaptivní úprava učebního kroku v průběhu iterací, na základě velikosti gradientu. V rámci algoritmu je potřeba nastavit 3 hyperparametry (β_1 , β_2 , a λ). β_1 a β_2 byly ponechány na výchozí hodnotě 0,9 a 0,999, v obou případech se jedná o parametry exponenciálního zapomínání předchozích gradientů.

Parametr λ nepatří přímo k algoritmu ADAM, ale byl přidán v rámci implementace L2 regularizace do vzorce. V rámci L2 regularizace je k chybové funkci přičítána hodnota, která je závislá na hodnotě vah sítě, vynásobená právě hodnotou λ . λ určuje vliv velikosti vah na učení. Cílem je opět zamezit přeučení sítě, konkrétně omezením velikosti vah.

Proces učení se opakuje pro předem stanovený počet epoch, kdy na konci každé epochy proběhne predikce na validační množině. V průběhu učení se vždy ukládá nejlepší dosažené průměrné F1 skóre, pro vybrané třídy. Ve chvíli, kdy se dosáhne lepšího F1 skóre, se vypíše tabulka úspěšnosti predikce na validační množině a proběhne uložení modelu. Tento přístup umožňuje finální klasifikaci s využitím nejlepšího modelu získaného v průběhu učení.

Optimalizace nastavení sítě


Hyperparametry sítě byly postupně upravovány spíše heuristicky a na základě literární rešerše (viz kapitola 1.6), kdy napříč celým procesem optimalizace sítě byly vyzkoušeny různé kombinace hyperparametrů, založené na apriorní znalosti jejich rozsahu. Pokud nastavení vedlo ke zlepšení výsledků, hodnoty byly upraveny. Nastavení dosahující nejlepších výsledků uvádí tabulka 3.10. Výsledky dosažené pomocí modelu s odlišně nastavenými hyperparametry nemohou být porovnány mezi sebou, protože učení vždy probíhalo na odlišných učebních množinách, nebo s různým nastavením ostatních parametrů.

Mimo sledování vlivu přítomnosti odlišných druhů vrstev v síti a hledání jejich nejlepší kombinace, byl zkoumán i vliv pořadí těchto vrstev na výsledné učení, pro-

tože právě zde se často literatura neshodovala (př. pořadí CNN a BN, Max Pooling a BN, ReLu a BN, atd.). Finální pořadí ukazuje Obr. 3.9. Nejvýrazněji se změnilo učení modelu ve chvíli umístění poolingové vrstvy před BN, kdy došlo ke zrychlení učení sítě a také k mírnému zkrácení doby učení, beze změny úspěšnosti klasifikace.

Dataset byl navržen tak, aby poskytoval uživateli větší variabilitu co se úpravy signálu, vstupujícího do sítě, týče. Konkrétně se jednalo o nastavení délky signálu vstupujícího do sítě, počet svodů a způsob doplnění kratších signálů na požadovanou délku.


V návaznosti na kapitolu 2 (tabulka 2.1 a Obr. 2.2) byly vyzkoušeny 3 délky signálů, které se vybraly podle zastoupení jednotlivých délek v datasetu: 10000 vzorků (40 s), 5000 vzorků (20 s) a 2500 vzorků (10 s). Na základně výsledků, které zobrazuje graf 3.10 byla vybrána délka 5000 vzorků. Mezi výsledky pro délku 10000 vzorků a 5000 vzorků nejsou vidět markantní rozdíly a tak byla zvolena varianta, snižující celkovou výpočetní náročnost i dobu učení.



Obr. 3.10: Průběh učení sítě na validační množině pro 3 vybrané délky vstupujícího signálu, klasifikace do 4 tříd.

Články, popisující zpracování dat s odlišnou délkou, používaly dvě možnosti prodloužení kratších signálů. Doplnění nulami na požadovanou délku a rozkopírování signálu. Graf 3.11 zobrazuje výsledky učení pro obě varianty. Výsledná síť dosahuje lepších výsledků při doplnění nulami.

Existují arytmie, pro jejichž detekci volba svodů nehraje příliš důležitou roli. V případě diferenciace FIB a FL, může volba silně ovlivnit výsledky klasifikace. Tyto dvě patologie je často možné odlišit, až na základě informace, poskytnuté více




Obr. 3.11: Průběh učení sítě na validační množině pro 2 odlišné možnosti doplnění kratších signálů na požadovanou délku: a) doplnění nulami, b) rozkopírování signálu, klasifikace do 4 tříd.

svody. Bylo vyzkoušeno učení sítě pouze s jedním svodem (II) a učení na základě dvou svodů (II a aVF). Oba vybrané svody by měli poskytovat kvalitní informaci, pro detekci vybraných arytmií. Výsledky ukazuje graf 3.12, kde vidíme zlepšení klasifikace v případě výběru dvou svodů. Mimo mírné zlepšení klasifikačních schopností sítě, volba 2 svodů urychlila konvergenci k minimu.

Obhacení pozornostním modulem

Po získání modelu sítě, dosahujícího nejlepších výsledků, byl k této síti přidán pozornostní modul, inspirovaný článkem [37]. Aplikace modulu by měla vést ke zvýšení klasifikačních schopností sítě, a to díky „zvýraznění“ důležitých částí signálu a zdůraznění příznakových map, přinášejících více informací v rámci vybrané klasifikační úlohy. Pozornostní modul byl implementován dvěma způsoby, v prvním byl modul vložen za každou konvoluční vrstvu a ve druhém byl vložen pouze před poslední blok plně propojených sítí. Bylo provedeno testování celého modulu a poté pouze jeho částí (kanálová a časová pozornost). Výsledky ukazuje tabulka 3.11, ze které můžeme usoudit, že implementace těchto modulů nevedla k velkým změnám klasifikace a úspěšnost se stále pohybuje kolem hodnot podobných dříve získaným modelem, bez pozornostního modulu. V průběhu aplikace modulu byly vyzkoušeny různá místa umístění v rámci CNN bloku, avšak nic nevedlo k výraznému zlepšení. Proto ve finální architektuře nebude pozornostní modul aplikován.



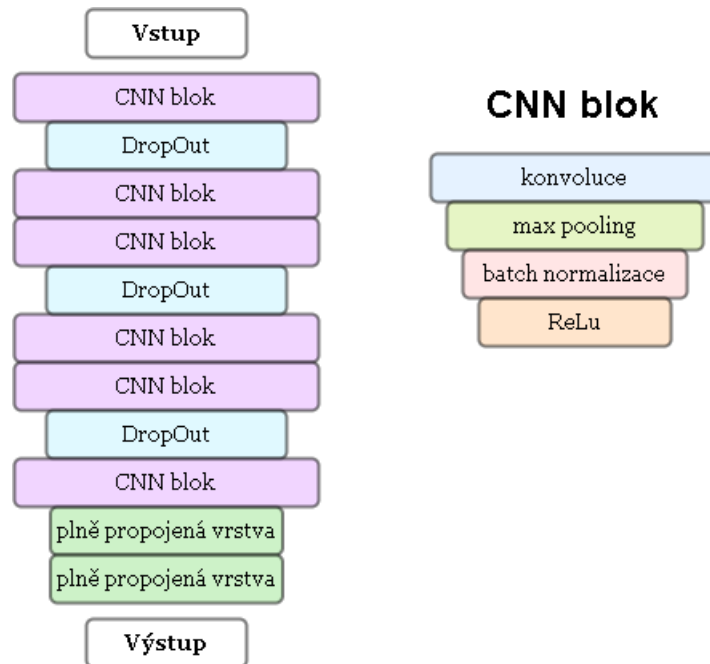
Obr. 3.12: Průběhu učení sítě na validační množině pro 2 odlišné volby svodů, klasifikace do 4 tříd.

Tab. 3.11: Výsledky klasifikace do 4 tříd (F1 skóre) na validační množině po přidání odlišných pozornostních modulů (ČP - pouze část časové pozornosti CBAM modulu, KP - pouze část kanálové pozornosti CBAM modulu).

	FL	FIS	Celkové
CNN	0,749	0,723	0,774
Přidáno ke každému bloku			
CNN + CBAM	0,704	0,743	0,768
CNN + ČP	0,734	0,761	0,774
CNN + KP	0,726	0,749	0,768
Přidáno před klasifikační blok			
CNN + CBAM	0,693	0,759	0,770
CNN + ČP	0,732	0,764	0,776
CNN + KP	0,704	0,779	0,774

3.5.2 Klasifikace do 5 tříd

Velice podobnou architekturu, jako v případě klasifikace do 4 tříd, má i model navržený pro klasifikaci EKG záznamů do 5 tříd (SR, AVB I, II, III a Ostatní). Byl vybrán stejnými kroky jako v případě 3.5.1, klasifikace vybraným modelem dosahovala nejlepších výsledků (viz Obr.3.13).




Obr. 3.13: Architektura sítě klasifikujících EKG záznamy do 5 tříd (SR, AVB I, AVB II, AVB III a Ostatní).

Jednotlivé vrstvy jsou totožné s modelem klasifikujícím záznamy do 4 tříd (SR, FIB, FL, Ostatní), kde byl také konkrétně rozepsán průchod signálu sítí (viz tabulka 3.9) a proto zde tyto informace neuvádím. Napříč architekturou jsou pouze drobné změny a to v přidání 1 konvoluční vrstvy a změně umístění a hodnot parametrů Dropout vrstev (v průběhu optimalizace byly vyzkoušeny různé kombinace změn a tyto vedly ke zlepšení klasifikačních schopností sítě). Proces učení je také totožný jako v případě kapitoly 3.5.1.

Optimalizace nastavení sítě

Nastavení **hyperparametrů** (viz tabulka 3.12) probíhalo jako v případě první sítě. Protože byl vybrán vysoce nehomogenní dataset, byla provedena ještě následná optimalizace. Byly vyzkoušeny různé kombinace hyperparametrů na základě apriorních informací o jejich nastavovaném rozsahu.

Učící krok byl nastaven v rozsahu od 0,1 do 0,0001. V případě nastavení kroku učení 0,1, nedocházelo k učení sítě a po 10. epoše bylo zastaveno. V případě ostatních nastavených hodnot již byl vidět proces učení. Nejlepší výsledky byly získány při nastavení kroku učení na 0,001. Celkové F1 skóre na validační množině ukazuje graf 3.14. I přes vlastnost algoritmu ADAM, umožňující úpravu kroku učení na základě velikosti gradientu, byla vyzkoušena změna kroku učení po vybrané epoše. Na základě grafů učení vedla ke zvýšení výsledného F1 skóre a proto byla ponechána.



Obr. 3.14: Průběh učení sítě na validační množině pro 3 odlišné kroky učení, klasifikace do 5 tříd.

V případě změny velikosti Mini Batche, byly nastaveny hodnoty 8, 16, 32 a 64. I přes fakt, že se jedná o nehomogenní dataset se ukázalo, že změna velikosti Mini Batche nemá na výsledky větší vliv. Pro jednotlivá nastavení nedocházelo k výrazným změnám výsledků. Nakonec byl vybrán Mini Batch velikosti 32, u kterého byla úspěšnost klasifikace nejvyšší (rozdíl F1 skóre v rámci desetin až jednotek procent).

Nejspíše z důvodu většího počtu dat a jejich výrazné nehomogenity, byla potřeba zvýšit maximální počet epoch na 50. Bylo vyzkoušeno zkrácení dat vstupujících do sítě (5000 vzorků a 2500 vzorků), avšak v těchto případech úspěšnost klasifikace výrazně klesla. Pokles úspěšnosti přisuzují faktu, že některé vypadlé QRS komplexy byly přítomny na okrajích záznamu. Ořezání záznamů poté mohlo způsobit jejich odstranění.

Protože se jedná o výrazně nehomogenní dataset, bylo provedeno učení, v rámci kterého byly nastaveny odlišné váhové koeficienty pro jednotlivé třídy. Váhy byly využity v kroku výpočtu chyby klasifikátoru. Cílem bylo, aby při chybné klasifikaci,

v rámci méně zastoupené skupiny, byla chyba brána s vyšší vahou. Tím by mělo docházet k rovnoměrnému učení všech tříd. Váhy byly vypočteny na základě četností tříd s využitím funkce `compute_class_weight` knihovny *Scikit-learn*. Výpočet dává do poměru počet záznamů dané třídy ku celkovému počtu záznamů v množině. Výsledky klasifikace takto naučené sítě dosahovaly mnohem nižších hodnot.

Tab. 3.12: Hodnoty hyperparametrů, klasifikace do 5 tříd.

Maximální počet epoch	50
Mini Batch	32
Učící krok	0.001
Snížení rychlosti učení	0.1
Perioda snížení rychlosti učení	30
Regularizační parametr λ	1,00E-05

Obohacení pozornostním modulem

I v tomto případě byla vyzkoušena implementace pozornostního modulu. Výsledky ukazuje tabulka 3.13. Ani v tomto případě aplikace modulu nevedla k významnému zlepšení klasifikace sítě a proto modul nebyl implementován.

Tab. 3.13: Výsledky klasifikace do 5 tříd (F1 skóre) na validační množině po přidání odlišných pozornostních modulů (ČP - pouze část časové pozornosti CBAM modulu, KP - pouze část kanálové pozornosti CBAM modulu).

	AVB I	AVB II	AVB III	Celkové
CNN	0,695	0,872	0,720	0,770
Přidáno ke každému bloku				
CNN + CBAM	0,686	0,875	0,724	0,763
CNN + ČP	0,676	0,872	0,659	0,769
CNN + KP	0,680	0,846	0,712	0,758
Přidáno před klasifikační blok				
CNN + CBAM	0,682	0,862	0,682	0,755
CNN + ČP	0,679	0,876	0,718	0,763
CNN + KP	0,672	0,878	0,670	0,760

4 Vyhodnocení

Po získání finálních architektur sítí byly modely naučeny na trénovacích datech (viz kapitola 3.3). Modely byly uloženy při získání nejvyššího průměrného F1 skóre pro vybrané třídy na validačních množinách (FIS a FL u klasifikace do 4 tříd, všechny stupně AVB u klasifikace do 5 tříd). Dále byly uloženy matice záměn a soubory se jmény záznamů, které byly chybně klasifikovány. Spolu se jmény chybně klasifikovaných záznamů byly uloženy také sítě predikované a skutečné třídy těchto záznamů. Uložené modely byly využity pro klasifikaci dat z testovacích množin.

F1 skóre bylo vybráno jako vhodná metrika pro nerovnoměrně zastoupená data. Finální výsledky jsou popsány pomocí více metrik, kde každá se zaměřuje na odlišný popis úspěšnosti klasifikace.

Klasifikace do 4 tříd

Nejvyššího průměrného F1 skóre, pro třídy FIB a FL na validační množině, bylo dosaženo po 21. epoše učení. Model byl uložen spolu s maticemi záměn a proběhla klasifikace na testovacích datech. Výsledky učení pomocí vybraných metrik ukazují tabulky 4.1 - 4.3, pro validační a testovací množinu jsou uvedeny i matice záměn (viz Obr. 4.1). Validační i testovací množiny byly po původním rozdělení zmenšeny z důvodu rovnoměrnějšího zastoupení dat a snížení časové náročnosti. Zmenšení bylo provedeno pouze pro skupiny SR a Ostatní. Četnosti jednotlivých tříd v obou množinách uvádí tabulka 4.4.

Tab. 4.1: Výsledky klasifikace do 4 tříd, trénovací množina.

	Se	Sp	PPV	ACC	F1
SR	0,869	0,943	0,824	0,925	0,846
FIB	0,725	0,950	0,819	0,896	0,769
FL	0,877	0,913	0,784	0,904	0,828
Ostatní	0,771	0,942	0,825	0,898	0,797
Průměr	0,811	0,937	0,813	0,906	0,810

Z uvedených tabulek vidíme, že výsledky v rámci trénovací množiny dosahují vyšších hodnot, než u validační a testovací množiny. Tento rozdíl však nedosahuje tak vysokých hodnot, aby se jednalo o přeučený model. Je logické, že data, na kterých byla síť trénována, jsou lépe klasifikovány než data, které síť ještě neviděla. Největší rozdíl můžeme vidět v rámci třídy FL (cca 14% rozdíl mezi trénovací a testovací množinou), což můžeme přisuzovat vysoké variabilitě vzhledu FL a tím i jeho obtížné detekci. Celkový rozdíl mezi trénovací a testovací množinou se pohybuje kolem 8%.

Tab. 4.2: Výsledky klasifikace do 4 tříd, validační množina.

	Se	Sp	PPV	ACC	F1
SR	0,844	0,921	0,764	0,903	0,802
FIB	0,683	0,955	0,822	0,892	0,746
FL	0,820	0,924	0,696	0,906	0,753
Ostatní	0,770	0,895	0,806	0,850	0,787
Průměr	0,779	0,924	0,772	0,888	0,772

Tab. 4.3: Výsledky klasifikace do 4 tříd, testovací množina.


	Se	Sp	PPV	ACC	F1
SR	0,830	0,910	0,781	0,888	0,805
FIB	0,639	0,953	0,843	0,866	0,727
FL	0,788	0,902	0,612	0,884	0,689
Ostatní	0,713	0,885	0,706	0,837	0,710
Průměr	0,743	0,913	0,736	0,869	0,733

Testovací množina dosahuje oproti validační množině nižších výsledků. Tento fakt je způsoben optimalizačními kroky, které se řídily dle výsledků validační množiny. Model byl také uložen ve chvíli dosažení nejvyšších výsledků právě na validační množině a je tedy pochopitelné, že výsledky na této množině budou o něco lepší.

Tab. 4.4: Počet záznamu ve třídách při klasifikaci do 4 tříd.

	SR	FIB	FL	Ostatní	Celkem
Validační	1000	995	603	1041	3639
Testovací	1000	1006	603	1000	3595

Z matice záměn (viz Obr. 4.1) vidíme, že mezi nejčastější zdroje chyb klasifikace patří záměna tříd FIB a FL, přičemž klasifikace záznamů ze třídy FIB do třídy FL převládají. Druhým nejvýraznějším zdrojem chyb je záměna tříd SR a Ostatní. Podrobnější rozbor chybně klasifikovaných záznamů viz kapitola 5.



(a) Validační množina

(b) Testovací množina

Obr. 4.1: Matice záměn, klasifikace do 4 tříd.

Klasifikace do 5 tříd

Stejný proces vyhodnocení, jako v případě klasifikace do 4 tříd, proběhl i zde. Model byl uložen při získání nejvyššího průměrného F1 skóre pro všechny třídy AVB. Nejvyššího výsledku bylo dosaženo při 35. epoše, kdy byl model spolu s maticemi záměn uložen. Výsledky učení uvádí tabulky 4.5 - 4.7, pro validační a testovací množiny jsou uvedeny i matice záměn (viz Obr. 4.2). I zde proběhlo zmenšení validační i testovací množiny, pro snížení časové náročnosti. V tomto případě byla upravena pouze třída Ostatní. Četnosti jednotlivých tříd v obou množinách uvádí tabulka 4.8.

Tab. 4.5: Výsledky klasifikace do 5 tříd, trénovací množina.


	Se	SP	PPV	ACC	F1
SR	0,891	0,882	0,836	0,886	0,862
AVB I	0,862	0,982	0,848	0,969	0,855
AVB II	0,913	0,997	0,941	0,994	0,927
AVB III	0,770	0,998	0,872	0,994	0,818
Ostatní	0,817	0,905	0,867	0,867	0,841
Průměr	0,851	0,953	0,873	0,942	0,861

Tab. 4.6: Výsledky klasifikace do 5 tříd, validační množina.

	Se	SP	PPV	ACC	F1
SR	0,909	0,839	0,813	0,869	0,859
AVB I	0,802	0,964	0,672	0,951	0,731
AVB II	0,858	0,997	0,923	0,991	0,889
AVB III	0,716	0,997	0,806	0,992	0,758
Ostatní	0,736	0,917	0,865	0,841	0,796
Průměr	0,804	0,943	0,816	0,929	0,807

Tab. 4.7: Výsledky klasifikace do 5 tříd, testovací množina.

	Se	SP	PPV	ACC	F1
SR	0,902	0,834	0,807	0,864	0,852
AVB I	0,793	0,970	0,705	0,955	0,746
AVB II	0,850	0,997	0,930	0,990	0,888
AVB III	0,693	0,997	0,836	0,992	0,758
Ostatní	0,742	0,909	0,853	0,839	0,793
Průměr	0,796	0,941	0,826	0,928	0,807



Obr. 4.2: Matice záměn, klasifikace do 5 tříd.

Pokud porovnáme výše uvedené výsledky na jednotlivých množinách vidíme, že trénovací množina dosahuje mírně vyšších hodnot, než validační a testovací. Tento jev byl popsán již při klasifikaci do 4 tříd. V tomto případě jsou rozdíly mezi množinami menší.

Nejvýraznější rozdíl vidíme u třídy AVB I, kde se výsledky klasifikace u trénovací a validační množiny liší o necelých 12%. Můžeme vidět, že AVB II napříč všemi množinami dosahuje vyšších hodnot, což bude způsobeno právě přidáním „pouze pěkných“ záznamů v kroku rozšíření databáze (viz 3.1).

V tomto případě jsou výsledky na testovací a validační množině srovnatelné.

Tab. 4.8: Počet záznamu ve třídách při klasifikaci do 5 tříd.

	SR	AVB I	AVB II	AVB III	Ostatní	Celkem
Validační	2082	398	243	82	2000	4805
Testovací	2082	397	234	88	2000	4801

Z matice záměn (viz Obr. 4.2) vidíme, že nejčastějším zdrojem chyb je záměna tříd SR a Ostatní. Dále dochází k častější záměně mezi třídou AVB I a třídami SR a Ostatní. U tříd AVB II a III jsou vidět především záměny se třídou Ostatní. Podrobnější rozbor chybně klasifikovaných záznamů viz kapitola 5.


5 Diskuze

5.1 Klasifikace do 4 tříd - zdroje chyb

Po získání matice záměn byla provedena analýza nejčastějších chyb. Kód byl upraven tak, aby při ukládání finálního modelu byly uloženy i soubory obsahující seznam špatně klasifikovaných záznamů a spolu s nimi i skutečnou a predikovanou třídu. Takový soubor byl uložen pro validační i testovací množinu.


Častým zdrojem chyb je, dle očekávání, záměna FIB a FL (viz matice záměn z Obr. 4.1). Jak již bylo zmíněno dříve, z hlediska manifestace v EKG se jedná o arytmie podobného charakteru, které jsou za určitých okolností problematicky diferencovatelné. Při tvorbě označení tříd bylo dáno, že v případě přítomnosti obou arytmií zařazení proběhne podle závažnější, kterou je v tomto případě fibrilace síní. Ukázalo se, že většina záznamů obsahující obě arytmie byla zařazena špatně. Důvodem mohlo být malé množství těchto dat (cca 0,09% z celkového počtu signálů), takže síť nebyla schopna se tuto informaci naučit.

Častěji docházelo k predikci třídy FL na místo FIB, což také zapříčiňuje nižší hodnotu PPV u skupiny FL. Možným zdrojem chyb u této predikce mohl být vyšší počet záznamů ve třídě FIB, či artefakty připomínající f vlny typické pro flutter síní (viz 5.1). Z osobních zkušeností (autorka pracuje jako biomedicínský technik v MDT s.r.o, ze které pochází analyzovaná data) mohou říci, že artefakty mnohdy vypadají velice přesvědčivě jako f vlny a jsou rozpoznány až na základě kontextu z delších záznamů.




Obr. 5.1: Vybrané 2 svody signálu s FIB chybně zařazeného modelem do třídy FL.

Méně častým problémem byla predikce FIB namísto FL, kde zdrojem chyb mohla být vysoká TF, která rozpoznání může komplikovat (obr.5.2), přítomnost silnějšího rušení (obr. 5.3), nebo skutečnost, že záznamů obsahující FL bylo 3x méně než FIB a tak byla třída FIB upřednostňována.




Obr. 5.2: Vybrané 2 svody signálu s FL chybně zařazeného modelem do třídy FIB.



Obr. 5.3: Vybrané 2 svody signálu s FL chybně zařazeného modelem do třídy FIB.

Další četnější skupinou chyb tvoří záměna tříd SR a Ostatní. V případě některých arytmí je hranice mezi těmito dvěma skupinami velice malá. Do třídy SR se

nejčastěji zařazovaly signály, obsahující změny úrovně a morfologie ST úseku (diagnózy MI a STCHNG, viz obr. 5.4), které nemusí být výrazné a bradykardie, kde změna diagnózy záleží na rozdílech tepové frekvence v rámci jednotek. Mezi další patologie, častěji se vyskytující v těchto chybně zařazených záznamech, patřily PAC (síňové extrasystoly). V tomto případě je detekce poměrně subjektivní a záleží na hodnotiteli, zda se orientuje podle změny morfologie P vlny, či mu stačí zkrácení RR intervalu. Poslední častěji se vyskytující diagnózou byla AVB I. stupně, kde opět záleží na hodnotiteli, zda usoudí, že se jedná pouze o prodloužený PQ interval např. v nočních hodinách, nebo jestli se již jedná o AVB I. stupně.



Obr. 5.4: Vybrané 2 svody signálu ze skupiny Ostatní (diagnóza MI) chybně zařazeného modelem do třídy SR.

Třída Ostatní se také zařazovala do tříd FL a FIB a v těchto případech se jednalo převážně o supraventrikulární tachykardie.

5.2 Klasifikace do 5 tříd - zdroje chyb

Stejně jak v případě klasifikace do 4 tříd (tj. SR, FIB, FL a Ostatní), byla na základě matice záměn (viz Obr. 4.2) a souborů se jmény špatně klasifikovaných záznamů provedena podrobná analýza výsledků. Nejčastějším zdrojem chyb v případě klasifikace do 5 tříd (tj. SR, AVB I, II, III a Ostatní), je již zmíněný zdroj chyb v kapitole 5.1 a to záměna tříd Ostatní a SR. Po podrobnější analýze diagnóz těchto chybně zařazených záznamů se ukázalo, že zdroje chyb jsou stejné, jako v předchozí kapitole a proto dále nebude tento zdroj chyb diskutován.

Dalšími poměrně častými zdroji chyb byly záměny týkající se třídy AVB I. Velice často docházelo k záměnám třídy AVB I za třídy SR a Ostatní. V případě záměny tříd SR a AVB I může být důvodem subjektivní přístup k hodnocení. Obdobně jako v případě bradykardie a SR je hranice mezi AVB I a prodlouženým PQ intervalem, který ještě spadá do třídy SR, nepatrná. Velice záleží na hodnotiteli, kde si určí hranici.

Záměny v rámci tříd AVB I a Ostatní měly asi největší vliv na nízkou hodnotu PPV u třídy AVB I, což značí velký počet falešně pozitivních signálů. Při analýze diagnóz těchto skupin chyb, nebyla vysledována žádná převažující patologie, způsobující chybu klasifikace. Vysoká četnost záznamů zařazených do třídy AVB I místo třídy Ostatní může být způsobena také přítomností prodlouženého PQ intervalu (jako v případě třídy SR), který ještě nebyl zařazen do třídy AVB I.

U tříd AVB II a AVB III je častějším zdrojem chyb klasifikace do třídy Ostatní. Tato chybná klasifikace je způsobena převážně přítomností fibrilace/flutteru síní v záznamech, které ztěžují rozpoznání atrioventrikulárních bloků. Dále je pozorována občasná záměna AVB II a AVB III. Zdroj chyb může být opět přikládán subjektivnímu hodnocení záznamů, kdy v některých případech byl výpadek více QRS komplexů za sebou hodnocen již jako kompletní atrioventrikulární blokáda, ale v jiných případech jako AVB II. stupně.

5.3 Srovnání úspěšnosti klasifikace s dostupnou literaturou

Níže uvedené články, se kterými je provedeno srovnání, se v celém procesu návrhu a učení sítě liší v rámci několika důležitých metrik. Články využívají odlišné databáze, provádějí klasifikaci do různého počtu tříd, některé články provádějí zpracování jednotlivých srdečních cyklů. Každý z těchto faktů ovlivňuje výsledky klasifikace a proto níže uvedené srovnání s literaturou je pouze orientační.

Pro srovnání s literaturou bylo vybráno F1 skóre, které jsem využívala v celé práci. V některých článcích tato metrika nebyla uvedena a tak, pokud byly uvedeny potřebné informace, byla dopočítána s použitím vzorce 1.6.

Klasifikace do 4 tříd

Výsledky navržené sítě srovnané s dostupnou literaturou ukazuje tabulka 5.1. Napříč články bylo obtížné najít ty, které uváděly úspěšnost klasifikace pro jednotlivé třídy zvlášť, aby bylo možné porovnat úspěšnost pouze vybraných tříd. Dalším úskalím bylo najít články, uvádějící úspěšnost klasifikace pomocí F1 skóre, nebo aspoň uvádějící matici záměn pro možné dopočítání. Z těchto důvodů se mi nepovedlo najít články odlišných architektur a ve vybraných pracích převažuje kombinace CNN a LSTM.

RAJPURKAR a spol. [46] provádí klasifikaci do 14 tříd pomocí 34-vrstvé CNN využívající reziduální spoje. Autoři využívají databázi MIT-BIH. Síť zpracovává 30s záznamy a provádí predikci pro každou sekundu záznamu. Autoři dosahují F1 skóre pro FIB a FL 0,667 a 0,679, což je trochu horší než výsledek dosažený v této práci.

Další vybrané sítě vždy kombinují CNN a rekurentní neuronovou síť (LSTM).

IVANOVIC a spol. [49] vytvořili síť provádějící klasifikaci pouze do 3 skupin. Přístupují k problematice méně častým způsobem a jako vstup do sítě slouží sekvence RR intervalů. V práci je využita soukromá databáze, kde každý signál pochází od jiného pacienta. Autoři dosahují F1 skóre 0,861 (třída FIB) a 0,854 (třída FL), které jsou již vyšší než F1 skóre dosažené v této práci.

Velice dobrých výsledků dosahují PETMEZAS a spol. [47] s F1 skóre 0,971 (třída FIB) a 0,889 (třída FL). Klasifikace je prováděna do 4 tříd pro každý srdeční cyklus s využitím MIT-BIH databáze. Autoři dosáhli kvalitních výsledků, které jsou vyšší než výsledky získané v této práci.

CHEN a spol. [48] kteří také kombinují CNN a LSTM používají jako vstup do sítě mimo 10s EKG úseky také RR intervaly. Klasifikace je prováděna do 6 tříd a opět je využita MIT-BIH databáze. Zde jsou výsledky pro obě skupiny velice rozdílné. U FIB dosahují vyšších výsledků s F1 skóre 0,963, ale v případě FL je dosažené F1

skóre 0,545, což je nižší než v této práci. U skupiny FL je v publikaci senzitivita 50% a je tedy možné, že velké množství záznamů je špatně klasifikováno jako fibrilace síní.

Tab. 5.1: Srovnání s literaturou: třídy FIB a FL (použitá metrika F1 skóre).

Publikace	Architektura	Počet tříd	FIB	FL
RAJPURKAR a spol. [46]	CNN	14	0,667	0,679
PETMEZAS a spol. [47]	CNN+LSTM	4	0,971	0,889
CHEN a spol. [48]	CNN+LSTM	6	0,963	0,545
IVANOVIC a spol. [49]	CNN+LSTM	3	0,861	0,854
Navržená síť	CNN	4	0,727	0,689

Klasifikace do 5 tříd

Napříč články se mi nepodařilo najít síť, která by prováděla klasifikaci do všech tří vybraných tříd zároveň a proto bylo vybráno více článků tak, aby vždy alespoň 2 prováděly klasifikaci vybrané třídy. Tabulka 5.2 ukazuje úspěšnost klasifikace vybraných patologií napříč články.

Pro porovnání klasifikace AVB I. stupně byly vybrány publikace podobné architektury kombinující vždy CNN a LSTM. Prvním článkem jsou výherci China Physiological Signal Challenge 2018. CHEN a spol. [53] navrhli síť provádějící klasifikaci do 9 tříd a u AVB I. stupně dosáhli F1 skóre 0,865. LIANG a spol. [50] klasifikující záznamy do stejných tříd s využitím stejné databáze dosahují F1 skóre 0,872. V obou případech jsou výsledky výrazně vyšší než v této práci.

RAJPURKAR a spol. [46] již byly popsány při klasifikaci do 4 tříd. Dosažené výsledky v této práci jsou 0,731 (třída AVB II) a 0,852 (třída AVB III). JO a spol. [52] provádějící klasifikaci do 9 tříd pomocí XDM (angl. explainable deep learning model), který vysvětluje podle čeho provedl dané rozhodnutí klasifikace s využitím tzv. citlivostních map, dosahují F1 skóre 0,754 (třída AVB II) a 0,866 (třída AVB III). V obou případech navržená práce dosahuje lepších výsledků u klasifikace AVB II a horších výsledků u AVB III.

Tab. 5.2: Srovnání s literaturou: třídy atrioventrikulárních blokád (použitá metrika F1 skóre).

Publikace	Architektura	Počet tříd	AVB I	AVB II	AVB III
RAJPURKAR a spol. [46]	CNN	14	—	0,731	0,852
LIANG a spol. [50]	CNN + LSTM	9	0,872	—	—
JO a spol. [52]	XDM	9	—	0,754	0,866
CHEN a spol. [53]	CNN + LSTM	9	0,865	—	—
Navržená síť	CNN	5	0,746	0,888	0,758

5.4 Výhody/nevýhody a použití navržených modelů

Nejprve bych ráda začala obecně výhodami a nevýhodami využití hlubokých neuronových sítí. Hlavní výhodou tohoto přístupu je možnost na vstup sítě vkládat surový signál, bez potřeby výběru příznaků, jejichž kvalita silně ovlivňuje úspěšnost klasifikace. Známou nevýhodou hlubokých neuronových sítí je na druhou stranu nemožnost interpretace výsledků, kdy nejsme schopni říci, na základě čeho sít provedla rozhodnutí. Tuto nevýhodu se snaží řešit právě moduly pozornosti.

Zvolený postup klasifikace pomocí dvou samostatných sítí má své výhody i nevýhody. Rozdělením problému došlo ke zjednodušení klasifikace a mohly být navrženy dva menší, méně výpočetně náročné, modely. Na druhou stranu, pokud spojíme celkovou výpočetní náročnost, jde nejspíše o model složitější.

U každé sítě bylo možné v rámci optimalizace upravit vstupní signál odlišným způsobem v závislosti na výsledku klasifikace. Například u FL a FIB dosahovalo využití dvou svodů lepších výsledků a to nejspíše díky lepší diferenciaci f vln na základě informace z odlišných svodů. V případě klasifikace AVB dva svody nebyly potřeba a většina přidanych záznamů z databáze MDT ani více svodů neobsahovala. Rozdíl v nastavení vstupních dat byl i v délce, kdy u FL a FIB stejných výsledků dosahovala poloviční délka záznamů, avšak u AVB došlo k výraznému snížení úspěšnosti sítě a proto musela být ponechána délka 10000 vzorků.

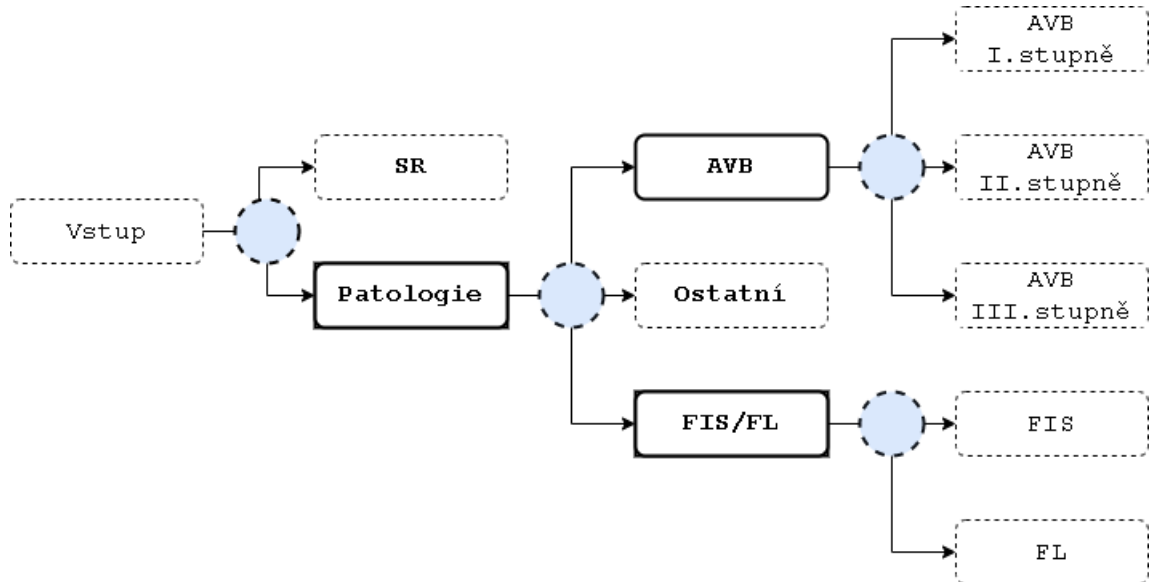
Prvotní architektura provádějící klasifikace do 7 tříd dovolovala, aby každý záznam mohl být zařazen do více tříd zároveň. V takovém případě by bylo velice obtížné zjistit, mezi kterými třídami probíhaly hlavní záměny a celkově by nebylo možné zobrazit matici záměn. Rozdělením do dvou sítí byla analýza chyb zjednodušena.

Nejvýraznější nevýhodou zvoleného postupu je potřeba dvojité optimalizace, která je časově náročná.

Protože chceme, aby mohl být každý záznam ideálně klasifikován v rámci obou skupin arytmií je otázkou, jak může probíhat celková klasifikace. V tomto kroku je nejvhodnějším řešením provést paralelní klasifikaci, kdy záznam vstupuje do obou sítí současně a výsledná klasifikace je získána spojením dílčích výsledků. V dnešní době, kdy jsou počítače již poměrně výkonné, nemusí být tento postup klasifikace problematický.

Pokud by však bylo žádoucí klasifikaci provádět sériově, existuje další možnost realizace. Tento postup byl prvotním nápadem, jak realizovat klasifikátor, avšak z důvodu potřeby mnohanásobné optimalizace sítí byl zavržen. Jednalo by se o kaskádu primitivních klasifikátorů (viz Obr. 5.5), kdy na vstup přichází signál, který prochází postupně sítěmi v závislosti na obsažené patologii. Zda by signál mohl být zařazen pouze do jedné, či více tříd je již otázka konkrétní realizace. Výhodou to-

hoto postupu je specializace klasifikátorů, kde každý provádí velice základní třídění úzké skupiny patologií. Důležité je zmínit, že výsledná chyba celkového klasifikátoru by velice záležela na chybě prvního klasifikátoru a postupným průchodem dalšími klasifikátory by se kumulovala.



Obr. 5.5: Návrh klasifikace EKG záznamu kaskádou sítí (modře jsou označeny jednotlivé klasifikátory).

Závěr

Cílem této práce bylo představit program pro klasifikaci vzácnějších resp. obtížněji diferencovatelných arytmií. V teoretické části je obsažena literární rešerše v oblasti detekce arytmií pomocí hlubokých neuronových sítí, se zaměřením na konvoluční neuronové sítě. Literární rešerše je zakončena kapitolou shrnující získané vědomosti pro jejich využití v praktické části. Dále je uveden popis a statistický rozbor databáze, která byla v práci využita, na kterou navazuje popis vybraných arytmií. Konkrétně se jednalo o fibrilaci síní, flutter síní a atrioventrikulární blokády.

Prvotním plánem bylo navrhnout architekturu provádějící klasifikaci všech vybraných arytmií, avšak z důvodu nedosažení kvalitních výsledků v rámci semestrální práce byl tento problém rozdělen. Byly navrženy dvě architektury konvoluční neuronové sítě provádějící klasifikaci do 4 tříd (sinusový rytmus, fibrilace síní, flutter síní a Ostatní) a do 5 tříd (sinusový rytmus, atrioventrikulární blokáda I. stupně, II. stupně, III. stupně a Ostatní). Bylo provedeno vhodné předzpracování dat vstupujících do obou sítí a optimalizace hyperparametrů. Následně proběhlo učení modelů. Orientace probíhala na základě výsledků získaných na validační množině. Při získání nejlepšího průměrného F1 skóre pro zájmové arytmie byl model uložen a byla provedena klasifikace dat testovací množiny.

Výsledná F1 skóre na testovací množině pro vybrané arytmie jsou 0,727 (fibrilace síní), 0,689 (flutter síní), 0,746 (atrioventrikulární blokáda I. stupně), 0,888 (atrioventrikulární blokáda II. stupně) a 0,758 (atrioventrikulární blokáda III. stupně).

Hlavní cíle práce, tedy návrh a realizace modelu provádějící klasifikaci vybraných patologií, byly splněny. Možností navázání na tuto práci je hned několik. Poměrně velký prostor ke zlepšení nabízí proces optimalizace hyperparametrů, v rámci kterého byly parametry získány experimentálně na základě apriorních znalostí z literatury, bez použití sofistikovanějších metod. V rámci využité databáze by bylo vhodné provést další rozšíření nejméně zastoupených tříd (flutter síní, atrioventrikulární blokády).

V rámci obohacení sítě pozornostními moduly by bylo vhodné vyzkoušet jiné druhy modulů pozornosti. Jako poslední bych ráda uvedla možnost zařadit mimo část provádějící klasifikaci záznamů také lokalizaci vybraných arytmií. Z časových důvodů se práce touto problematikou nezabývá.

Literatura

- [1] PARVANEH, Saman, Jonathan RUBIN, Saeed BABAEIZADEH a Minnan XU-WILSON. Cardiac arrhythmia detection using deep learning: A review.. Journal of Electrocardiology [online]. 2019, 57, S70-S74 . ISSN 00220736.
- [2] SOMANI, Sulaiman, Adam J RUSSAK, Felix RICHTER, et al. Deep learning and the electrocardiogram: review of the current state-of-the-art. EP Europace [online]. 2021, 23(8), 1179-1191 . ISSN 1099-5129.
- [3] EBRAHIMI, Zahra, Mohammad LONI, Masoud DANESHTALAB a Arash GHAREHBAGHI. Dispersion Characteristics of Multilayered Slotlines – a Simple Approach. A review on deep learning methods for ECG arrhythmia classification. Expert Systems with Applications: X [online]. 2020, 7 . ISSN 25901885.
- [4] KHAN, Ali Haider, Muzammil HUSSAIN, Muhammad Kamran MALIK a Atif KHAN. Wavelet Spectrum Thresholding Rules. Arrhythmia Classification Techniques Using Deep Neural Network. Complexity [online]. 2021, 2021, 1-10 . ISSN 1099-0526.
- [5] YILDIRIM, Özal, Paweł PŁAWIAK, Ru-San TAN a U. Rajendra ACHARYA. Arrhythmia detection using deep convolutional neural network with long duration ECG signals. Computers in Biology and Medicine [online]. 2018, 102, 411-420 . ISSN 00104825.
- [6] WU, Mengze, Yongdi LU, Wenli YANG, Shen Yuong WONG a Wenfeng MOU. A Study on Arrhythmia via ECG Signal Classification Using the Convolutional Neural Network. Frontiers in Computational Neuroscience [online]. 2021, 14, 105-112 . ISSN 1662-5188.
- [7] ACHARYA, U. Rajendra, et al. A deep convolutional neural network model to classify heartbeats. Computers in biology and medicine, 2017, 89: 389-396.
- [8] SOLIŃSKI, Mateusz, et al. 12-lead ECG Arrhythmia Classification Using Convolutional Neural Network for Mutually Non-Exclusive Classes. In: 2020 Computing in Cardiology. IEEE, 2020. p. 1-4.
- [9] NATARAJAN, Annamalai, Yale CHANG, Sara MARIANI, Asif RAHMAN, Gregory BOVERMAN, Shruti VIJ a Jonathan RUBIN. A Wide and Deep Transformer Neural Network for 12-Lead ECG Classification [online]. 2020-12-30.
- [10] VASWANI, Ashish, et al. Attention is all you need. Advances in neural information processing systems, 2017, 30.

- [11] JING, Enbiao, Haiyang ZHANG, ZhiGang LI, Yazhi LIU, Zhanlin JI, Ivan GANCHEV a Juan Pablo MARTÍNEZ. ECG Heartbeat Classification Based on an Improved ResNet-18 Model. Computational and Mathematical Methods in Medicine [online]. 2021, 2021, 1-13. ISSN 1748-6718.
- [12] LI, Zhi, Dengshi ZHOU, Li WAN, Jian LI a Wenfeng MOU. Heartbeat classification using deep residual convolutional neural network from 2-lead electrocardiogram. Journal of Electrocardiology [online]. 2020, 58, 105-112 . ISSN 00220736.
- [13] HE, Kaiming, et al. Deep residual learning for image recognition. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. p. 770-778.
- [14] KAMALESWARAN, Rishikesan, Ruhi MAHAJAN a Oguz AKBILGIC. A robust deep convolutional neural network for the classification of abnormal cardiac rhythm using single lead electrocardiograms of variable length. Physiological Measurement [online]. 2018, 39(3) . ISSN 1361-6579.
- [15] GLOROT, Xavier; BENGIO, Yoshua. Understanding the difficulty of training deep feedforward neural networks. In: Proceedings of the thirteenth international conference on artificial intelligence and statistics. JMLR Workshop and Conference Proceedings, 2010. p. 249-256.
- [16] NIELSEN, Michael A. Neural Networks and Deep Learning [online]. Determination Press, 2015 .
- [17] HAYKIN, Simon S. Neural networks and learning machines. 3rd ed. Upper Saddle River: Pearson Education, c2009. ISBN 978-0131471399.
- [18] PATTERSON, Josh a Adam GIBSON. Deep learning: a practitioner's approach. Beijing: O'Reilly, 2017. ISBN 978-1-491-91425-0.
- [19] BENNETT, David H. Srdeční arytmie: praktické poznámky k interpretaci a léčbě. 8.vydání. Praha: Grada, 2014. ISBN 978-802-4751-344.
- [20] ŠTEJFLA, DRSC., Prof. MUDr. Miloš, Doc. MUDr. Josef ŠUMBERA, CSC. a Prof. MUDr. Pavel BRAVENÝ, CSC. Základy elektrokardiografie. Brno: Masarykova univerzita v Brně, lékařská fakulta, 1991. ISBN 8021002654.
- [21] FIALA, Martin. Dopočené postupy pro diagnostiku a léčbu supraventrikulárních tachyarytmií [online]. Kardiocentrum Nemocnice Podlesí Třinec, , 1-37 .

- [22] PASZKE, Adam, et al. Pytorch: An imperative style, high-performance deep learning library. *Advances in neural information processing systems*, 2019, 32.
- [23] HARRIS, Charles R., et al. Array programming with NumPy. *Nature*, 2020, 585.7825: 357-362.
- [24] MCKINNEY, Wes, et al. Data structures for statistical computing in python. In: *Proceedings of the 9th Python in Science Conference*. 2010. p. 51-56.
- [25] HUNTER, John D. Matplotlib: A 2D graphics environment. *Computing in science & engineering*, 2007, 9.03: 90-95.
- [26] VIRTANEN, Pauli, et al. SciPy 1.0: fundamental algorithms for scientific computing in Python. *Nature methods*, 2020, 17.3: 261-272.
- [27] REYNA, Matthew A., et al. Will two do? Varying dimensions in electrocardiography: the PhysioNet/Computing in Cardiology Challenge 2021. In: *2021 Computing in Cardiology (CinC)*. IEEE, 2021. p. 1-4.
- [28] HEJČ J., et al. Odborná zpráva k projektu TJ02000331: Vývoj modelů pro víceúrovňovou klasifikaci poruch srdečního rytmu v EKG záznamech, 2021, pp. 22.
- [29] HE, Kaiming, Xiangyu ZHANG, Shaoqing REN a Jian SUN. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification: *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. 2015, , pp. 1026-1034.
- [30] GAO, Yibo, Huan WANG a Zuhao LIU. A Novel Approach for Atrial Fibrillation Signal Identification Based on Temporal Attention Mechanism [online]. IEEE, 2020, 2020, 316-319 . ISBN 978-1-7281-1990-8.
- [31] GAO, Yibo, Huan WANG a Zuhao LIU. An end-to-end atrial fibrillation detection by a novel residual-based temporal attention convolutional neural network with exponential nonlinearity loss. *Knowledge-Based Systems* [online]. IEEE, 2021, 2020, 212, 316-319 . ISBN 978-1-7281-1990-8. ISSN 09507051.
- [32] JIA, Yingjie, Haoyu JIANG, Ping YANG a Xianliang HE. An End-to-end Deep Learning Scheme for Atrial Fibrillation Detection. *Knowledge-Based Systems* [online]. IEEE, 2021, 2020-12-30, 212, -. ISBN 978-1-7281-1990-8. ISSN 09507051.
- [33] YAO, Qihang, Ruxin WANG, Xiaomao FAN, Jikui LIU a Ye LI. Multi-class Arrhythmia detection from 12-lead varied-length ECG using Attention-based

- Time-Incremental Convolutional Neural Network. *Information Fusion* [online]. IEEE, 2020, 2020-12-30, 53, 174-182 . ISBN 978-1-7281-1990-8. ISSN 15662535.
- [34] VICAR, Tomas, Petra NOVOTNA, Jakub HEJC, Oto JANOUSEK a Marina RONZHINA. Cardiac Abnormalities Recognition in ECG Using a Convolutional Network with Attention and Input with an Adaptable Number of Leads. *2021 Computing in Cardiology (CinC)* [online]. IEEE, 2021, 2021-9-13, 53, 1-4 . ISBN 978-1-6654-7916-5. ISSN 15662535.
- [35] HU, Jie, Li SHEN, Samuel ALBANIE, Gang SUN a Enhua WU. Squeeze-and-Excitation Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence* [online]. IEEE, 2020, 2021-9-13, 42(8), 2011-2023 . ISBN 978-1-6654-7916-5. ISSN 0162-8828.
- [36] CHEN, Wei, Ke SHI, Samuel ALBANIE, Gang SUN a Enhua WU. Multi-scale Attention Convolutional Neural Network for time series classification. *Neural Networks* [online]. IEEE, 2021, 2021-9-13, 136(8), 126-140 . ISBN 978-1-6654-7916-5. ISSN 08936080.
- [37] WOO, Sanghyun, Jongchan PARK, Joon-Young LEE, In So KWEON, Fan WU, Huaiyu ZHU a Yun PAN. CBAM: Convolutional Block Attention Module. *Computer Vision – ECCV 2018* [online]. Cham: Springer International Publishing, 2018, 2018-10-06, 136(8), 3-19. *Lecture Notes in Computer Science*. ISBN 978-3-030-01233-5. ISSN 08936080.
- [38] ZHANG, Jing, et al. ECG-based multi-class arrhythmia detection using spatio-temporal attention-based convolutional recurrent neural network. *Artificial Intelligence in Medicine*, 2020, 106: 101856.
- [39] WANG, Yongchao, Bin XIAO, XiuLi BI, Weisheng LI, Junhui ZHANG a Xu MA. Pay Attention and Watch Temporal Correlation: A Novel 1-D Convolutional Neural Network for ECG Record Classification [online]. 2019-12-30.
- [40] BAHDANAU, Dzmitry; CHO, Kyunghyun; BENGIO, Yoshua. Neural machine translation by jointly learning to align and translate. *arXiv preprint arXiv:1409.0473*, 2014.
- [41] JADERBERG, Max, et al. Spatial transformer networks. *Advances in neural information processing systems*, 2015, 28.
- [42] LI, Feiteng, Jiaquan WU, Menghan JIA, Zhijian CHEN a Yu PU. Automated Heartbeat Classification Exploiting Convolutional Neural Network With

- Channel-Wise Attention. *IEEE Access* [online]. 2019, 7, 122955-122963 . ISSN 2169-3536.
- [43] ORFANIDIS, Sophocles J. Introduction to signal processing. Prentice-Hall, Inc., 1995. ISBN 978-0-13-209172-5.
- [44] GUSTAFSSON, F. Determining the initial states in forward-backward filtering. *IEEE Transactions on Signal Processing* [online]. 44(4), 988-992. ISSN 1053587X.
- [45] ŠANDOVÁ, Hana. Algoritmy pro zlepšení detekce vybraných arytmií v EKG [online]. Brno, 2022. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Petra Novotná.
- [46] RAJPURKAR, Pranav, HANNUN, Awni Y., Masoumeh HAGHPANAHI, Codie BOURN a Andrew Y. NG. Cardiologist-Level Arrhythmia Detection with Convolutional Neural Networks. *ArXiv* [online]. 2017
- [47] PETMEZAS, Georgios, et al. Automated atrial fibrillation detection using a hybrid CNN-LSTM network on imbalanced ECG datasets. *Biomedical Signal Processing and Control*, 2021, 63: 102194.
- [48] CHEN, Chen, Zhengchun HUA, Ruiqi ZHANG, Guangyuan LIU a Wanhui WEN. Automated arrhythmia classification based on a combination network of CNN and LSTM. *Biomedical Signal Processing and Control* [online]. 2020, 57. ISSN 17468094.
- [49] IVANOVIC, Marija D., et al. Deep learning approach for highly specific atrial fibrillation and flutter detection based on RR intervals. In: 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2019. p. 1780-1783.
- [50] LIANG, Yongbo, Shimin YIN, Qunfeng TANG, Zhenyu ZHENG, Mohamed ELGENDI a Zhencheng CHEN. Deep Learning Algorithm Classifies Heartbeat Events Based on Electrocardiogram Signals. *Frontiers in Physiology* [online]. 2020, 11. ISSN 1664-042X.
- [51] CHEN, Yu-Jhen, Chien-Liang LIU, Vincent S. TSENG, Yu-Feng HU a Shih-Ann CHEN. Large-scale Classification of 12-lead ECG with Deep Learning [online]. IEEE, 2019, 2019, 1-4. ISBN 978-1-7281-0848-3.

- [52] JO, Yong-Yeon, Joon-myung KWON, Ki-Hyun JEON, et al. Detection and classification of arrhythmia using an explainable deep learning model. *Journal of Electrocardiology* [online]. 2021, 67, 124-132. ISSN 00220736.
- [53] CHEN, Tsai-Min, et al. Detection and classification of cardiac arrhythmias by a challenge-best deep learning neural network model. *Iscience*, 2020, 23.3: 100886.

Seznam symbolů a zkratek

ACC	přesnost (z angl. accuracy)
ADAM	Adaptive Moment Estimation
FIB	fibrilace síní
FL	flutter síní
AVB	atrioventrikulární blokáda
BN	batch normalizace
CNN	konvoluční neuronová síť (z angl. Convolutional Neural Network)
DNN	hluboká neuronová síť (z angl. Deep Neural Network)
EKG	elektrokardiogram
GD	gradientní sestup (z angl. Gradient Descend)
LSTM	long-short term memory
LSB	the least significant bit
PPV	pozitivní prediktivní hodnota
ResNet	residuální neuronová síť (z angl. Residual Neural Network)
RNN	rekurentní neuronová síť (z angl. Recurrent Neural Network)
Se	senzitivita
Sp	specifická
SR	sinusový rytmus

Seznam příloh


A Příloha A

79

A Příloha A

Typ diagnózy	Kódové označení v databázi	Vysvětlení diagnózy	Poznámka
Rytmus	SR	Sinusový rytmus	
	AFIB	Fibrilace síní	
	AFL	Flutter síní	
	ARH	Síňový rytmus	
	SVR	Supraventrikulární rytmus	
	JEB	Junkční rytmus	* Vždy v kombinaci s bradykardií a supraventrikulárním rytmem
	VRHY	Komorový rytmus	
	VSTIM	Komorová stimulace	
	ASTIM	Síňová stimulace	
	TACHY	Tachykardie	
	BRADY	Bradykardie	
	ARRHY	Arytmie	
	Noise	Šum	
	Morfologie	1AVB	Atrioventrikulární blok 1°
2AVB		Atrioventrikulární blok 2°	
3AVB		Atrioventrikulární blok 3°	
SAB		Sinoatriální blok	
PAC		Síňová extrasystola	
PVC		Komorová extrasystola	
ABI		Síňová bigeminie	* Vždy v kombinaci se síňovými extrasystolami
ATI		Síňová trigeminie	* Vždy v kombinaci se síňovými extrasystolami
VBI		Komorová bigeminie	* Vždy v kombinaci s komorovými extrasystolami
VTI		Komorová trigeminie	* Vždy v kombinaci s komorovými extrasystolami
IVB		Nespecifický intraventrikulární blok	
RBBB		Blokáda pravého raménka Tawarova	
LBBB		Blokáda levého raménka Tawarova	
VPE		Preexcitace komor	* Např. v podobě WPW syndromu aj.
STCHNG		Změna morfologie STT úseku	* Často jako projev srdeční ischemii/infarktu myokardu apod.
MI		Infarkt myokardu	* Změny týkající se především úrovně ST úseku (elevace/deprese), morfologie QRS komplexů (změna Q) či morfologie T vlny

Obr. A.1: Přehled všech diagnóz přítomných v databázi spolu se specifickým kódovým označením [28]



Obr. A.2: Absolutní a procentuální zastoupení EKG záznamů s různými patologickými projevy v databázi [28]