

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

POKROČILÁ KLASIFIKACE PORUCH SRDEČNÍHO RYTMU V EKG

ADVANCED CLASSIFICATION OF CARDIAC ARRHYTHMIAS IN ECG

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Štěpán Sláma

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Marina Ronzhina, Ph.D.

BRNO 2020



Diplomová práce

magisterský navazující studijní program Biomedicínské inženýrství a bioinformatika

Ústav biomedicínského inženýrství

Student: Bc. Štěpán Sláma

ID: 174530

Ročník: 2

Akademický rok: 2019/20

NÁZEV TÉMATU:

Pokročilá klasifikace poruch srdečního rytmu v EKG

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši v oblasti projevů poruch srdečního rytmu v EKG. Dále se seznamte s moderními metodami pro automatickou detekci nejčastějších srdečních arytmií v EKG. Zaměřte se na moderní metody využívající tzv. 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 strukturu sítě, popište jednotlivé vrstvy sítě a nastavení parametrů algoritmu učení. Navržený postup programově realizujte a otestujte v prostředí MATLAB či jiném. 4) Na základě výsledků z bodu 3, proveďte optimalizaci nastavení sítě a případně upravte vstupní data pro dosažení co nejlepšího klasifikačního skóre. 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] CURTIS, Michael J., Jules C. HANCOX, András 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. roč. 139, vyd. 2, s. 213 – 248. ISSN 0163-7258.
- [2] XIA, Yong, Naren WULAN, Kuanquan WANG, Henggui ZHANG. Detecting atrial fibrillation by deep convolutional neural networks. *Computers in Biology and Medicine*, 2018, 93, pp 84–92.
- [3] SAHOO, Sujit Kumar, Wenmiao LU, Sintiani Dewi TEDDY, Desok KIM, et al. Detection of atrial fibrillation from non-episodic ECG data: a review of methods. In *33rd Annual International Conference of the IEEE EMBS*, Boston, USA, 2011, s. 4992-4995.

Termín zadání: 3.2.2020

Termín odevzdání: 29.5.2020

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 zaměřuje na teoretické objasnění poruch srdečního rytmu a možnosti jejich automatické detekce s využitím sítí hlubokého učení. Pro účely této práce bylo využito celkově 6884 10sekunových záznamů EKG s měřeními osmi svody. Záznamy byly rozděleny do pěti skupin podle srdečních rytmů na skupinu záznamů s fibrilací síní, sinusové rytmy, supraventrikulární rytmy, ventrikulární rytmy a poslední skupinu tvořily záznamy ostatní. Jednotlivé skupiny byly nerovnoměrně zastoupeny a více než 85 % z celkového počtu dat jsou záznamy skupiny sinusového rytmu. Použité klasifikační metody sloužily efektivně jako detektor záznamů nejpočetnější skupiny a nejefektivnější ze všech byl postup tvořený 2D konvoluční neuronovou sítí, do které vstupovala data v podobě skalogramů (klasifikační postup číslo 3). Ta dosahovala výsledků přesnosti (precision) 91 %, úplnosti (recall) 96 % a hodnoty F1-skóre 0,93. Naopak při klasifikaci všech pěti skupin zároveň nebylo dosaženo takto kvalitních výsledků u všech skupin. Nejefektivnějším postupem se jeví varianta sestavena z aplikace PCA na osm vstupních signálů se získáním jednoho signálu výstupního, který se stává vstupem 1D konvoluční neuronové sítě (klasifikační postup číslo 5). Tento postup dosáhl následujících hodnoty F1-skóre: 1) skupina záznamů s fibrilací síní 0,54, 2) skupina sinusových rytmů 0,91, 3) skupina supraventrikulárních rytmů 0,65, 4) skupina ventrikulárních rytmů 0,68, 5) ostatní záznamy 0,65.

Klíčová slova

Elektrokardiogram, poruchy srdečního rytmu, hluboké učení, konvoluční neuronová síť, rekurentní neuronová síť

Abstract

This work focuses on a theoretical explanation of heart rhythm disorders and the possibility of their automatic detection using deep learning networks. For the purposes of this work, a total of 6884 10-second ECG recordings with measured eight leads were used. Those recordings were divided into 5 groups according to heart rhythm into a group of records with atrial fibrillation, sinus rhythms, supraventricular rhythms, ventricular rhythms, and the last group consisted of the others records. Individual groups were unbalanced represented and more than 85 % of the total number of data are sinus rhythm group records. The used classification methods served effectively as a record detector of the largest group and the most effective of all was a procedure consisting of a 2D convolutional neural network into which data entered in the form of scalograms (classification procedure number 3). It achieved results of precision of 91%, recall of 96% and F1-score values of 0.93. On the contrary, when classifying all groups at the same time, there were no such quality results for all groups. The most efficient procedure seems to be a variant composed of PCA on eight input signals with the gain of one output signal, which becomes the input of a 1D convolutional neural network (classification procedure number 5). This procedure achieved the following F1-score values: 1) group of records with atrial fibrillation 0.54, 2) group of sinus rhythms 0.91, 3) group of supraventricular rhythms 0.65, 4) group of ventricular rhythms 0.68, 5) others records 0.65.

Keywords

Electrocardiogram, cardiac rhythm disorders, deep learning, convolution neural network, recurrent neural network

Bibliografická citace:

SLÁMA, Štěpán. *Pokročilá klasifikace poruch srdečního rytmu v EKG* [online]. Brno, 2020 [cit. 2020-05-27]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/126848>. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Marina Ronzhina.

Prohlášení

„Prohlašuji, že svou diplomovou práci na téma Pokročilá klasifikace poruch srdečního rytmu v EKG jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce. Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne **29.5.2020**

.....
podpis autora

Poděkování

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

V Brně dne **29.5.2020**

.....
podpis autora

Obsah

1	Úvod	1
2	Elektrická aktivita srdce	2
3	Elektrokardiogram	5
4	Poruchy srdečního rytmu a převodního systému srdečního	9
4.1	Bradykardie	9
4.2	Extrasystoly	10
4.3	Tachykardie	11
4.4	Fibrilace	12
5	Automatická detekce arytmií	13
6	Hluboké učení	17
6.1	Architektury konvolučních neuronových sítí	23
6.2	1D konvoluční neuronová síť	24
6.3	Rekurentní neuronová síť	26
6.4	Využití hlubokého učení pro detekci arytmií	27
7	Praktická část	30
7.1	Databáze	35
7.2	Předzpracování signálů	35
7.3	Klasifikační postup č. 1	37
7.3.1	Zpracování dat	38
7.3.2	Vytvoření trénovací a testovací sady	40
7.3.3	Klasifikační model	41
7.3.4	Diskuze dílčích výsledků	46
7.4	Klasifikační postup č. 2	47
7.5	Klasifikační postup č. 3	53
7.6	Klasifikační postup č. 4	59
7.7	Klasifikační postup č. 5	63
7.8	Klasifikační postup č. 6	67
7.9	Klasifikační postup č. 7	71
7.10	Srovnání použitých postupů	74
8	Diskuze	83
9	Závěr	86
	Literatura	88
	Seznam zkratk	94

Seznam obrázků

Obr. 6.1 Grafické znázornění velikosti batche, převzato z [3]	18
Obr. 6.2 Grafické znázornění Nestrov momentum, převzato a upraveno z [25].....	19
Obr. 6.3 Schéma konvoluční neuronové sítě, převzato z [31]	20
Obr. 6.4 Konvoluční operace - jak pracuje konvoluce, převzato z [9]	20
Obr. 6.5 Funkce sigmoid a ReLu, převzato z [8]	21
Obr. 6.6 Schéma architektury 1D CNN, převzato z [19]	25
Obr. 6.7 Znázornění 1D a 2D konvoluční vrstvy, převzato z [1]	25
Obr. 6.8 Grafické znázornění RNN, převzato z [10]	26
Obr. 6.9 Schéma LSTM, převzato z [10]	27
Obr. 6.10 Schéma architektury DeepNet publikovaného článku, převzato z [43] ...	28
Obr. 7.1 Grafické souhrnné znázornění klasifikačních postupů použitých v praktické části (autorský obrázek s využitím [10][31])	31
Obr. 7.2 Grafické znázornění klasifikačního postupu č. 1	32
Obr. 7.3 Grafické znázornění klasifikačního postupu č. 2	32
Obr. 7.4 Grafické znázornění klasifikačního postupu č. 3	33
Obr. 7.5 Grafické znázornění klasifikačního postupu č. 4	33
Obr. 7.6 Grafické znázornění klasifikačního postupu č. 5	34
Obr. 7.7 Grafické znázornění klasifikačního postupu č. 6	34
Obr. 7.8 Grafické znázornění klasifikačního postupu č. 7	35
Obr. 7.9 Frekvenční charakteristika použitého filtru pásmové propusti.....	36
Obr. 7.10 Ukázka původního signálu, šumu a jejich překrytí pro porovnání amplitud	37
Obr. 7.11 Grafické znázornění původního spektrogramu a logaritmicky škálovaného spektrogramu (řádky reprezentují frekvence 0 – 250 Hz, sloupce časový úsek 0 – 10 sekund)	39
Obr. 7.12 Grafické znázornění úpravy spektrogramu	40
Obr. 7.13 Grafické znázornění architektury ResNet152, převzato z [14]	42
Obr. 7.14 Průběh učení 1. klasifikačního postupu bez vah	42
Obr. 7.15 Průběh učení 1. klasifikačního postupu s přidáním vahami	44
Obr. 7.16 Grafické znázornění aplikace PCA	47
Obr. 7.17 Příklad výsledných spektrogramů vytvořených ze získaných signálů po aplikaci PCA.....	48
Obr. 7.18 Průběh učení 2. klasifikačního postupu bez vah	49
Obr. 7.19 Průběh učení 2. klasifikačního postupu s přidáním vahami	51
Obr. 7.20 Grafické znázornění vlnky morlet, převzato z [46].....	53

Obr. 7.21 Grafické znázornění originálního signálu (A), originálního skalogramu (B) a upraveného skalogramu do požadovaných rozměru (C)	54
Obr. 7.22 Grafické znázornění architektury Xception, převzato a upraveno z [22]	55
Obr. 7.23 Průběh učení 3. klasifikačního postupu bez vah	56
Obr. 7.24 Průběh učení 3. klasifikačního postupu s přidáním vahami	57
Obr. 7.25 Grafické znázornění signálů získaných aplikací PCA a z nich vytvořených výsledných skalogramů	59
Obr. 7.26 Průběh učení 4. klasifikačního postupu bez vah	60
Obr. 7.27 Průběh učení 4. klasifikačního postupu s přidáním vahami	61
Obr. 7.28 Příklad výsledného signálu po aplikaci PCA	64
Obr. 7.29 Grafické znázornění použité architektury 1D CNN	65
Obr. 7.30 Průběh učení 5. klasifikačního postupu s přidáním vahami	66
Obr. 7.31 Grafické znázornění použité architektury LSTM	68
Obr. 7.32 Průběh učení 6. klasifikačního postupu s přidáním vahami	69
Obr. 7.33 Průběh učení 7. klasifikačního postupu s přidáním vahami	72
Obr. 7.34 Porovnání úspěšnosti jednotlivých klasifikačních postupů na základě hodnoty přesnosti (precision)	75
Obr. 7.35 Porovnání úspěšnosti jednotlivých klasifikačních postupů na základě hodnory úplnosti (recall)	76
Obr. 7.36 Porovnání úspěšnosti jednotlivých klasifikačních postupů na základě hodnoty F1-skóre	78
Obr. 7.37 Grafické znázornění efektivity klasifikačních postupů při detekci skupiny SR na základě hodnoty: (A) přesnosti (precision), (B) úplnosti (recall), (C) F1-skóre	79
Obr. 7.38 Grafické znázornění efektivity klasifikačních postupů na základě hodnoty F1-skóre při detekci dat skupiny: (A) AF, (B) SVR, (C) VR.....	81
Obr. 8.1 Příklad chybně klasifikovaného signálu skupiny SR do skupiny AF	84

Seznam tabulek

Tabulka 5.1 Použitá data metody náhodný les, převzato a upraveno z [42]	15
Tabulka 5.2 Výsledky metody náhodný les, převzato a upraveno z [42]	15
Tabulka 7.1 Přehled použitých dat rozdělených do pěti skupin.....	35
Tabulka 7.2 Matice záměn 1. klasifikačního postupu na trénovacích datech.....	43
Tabulka 7.3 Matice záměn 1. klasifikačního postupu na testovacích datech bez vah	43
Tabulka 7.4 Matice záměn 1. klasifikačního postupu na testovacích datech s přidanými váhami.....	45
Tabulka 7.5 Výsledky efektivity 1. klasifikačního postupu s váhami.....	45
Tabulka 7.6 Matice záměn 2. klasifikačního postupu bez vah.....	50
Tabulka 7.7 Výsledky efektivity 2. klasifikačního postupu bez vah	50
Tabulka 7.8 Matice záměn 2. klasifikačního postupu s přidanými váhami	51
Tabulka 7.9 Výsledky efektivity 2. klasifikačního postupu s přidanými váhami	52
Tabulka 7.10 Matice záměn 3. klasifikačního postupu bez vah	56
Tabulka 7.11 Výsledky efektivity 3. klasifikačního postupu bez vah	57
Tabulka 7.12 Matice záměn 3. klasifikačního postupu s přidanými váhami	58
Tabulka 7.13 Výsledky efektivity 3. klasifikačního postupu s přidanými váhami... ..	58
Tabulka 7.14 Matice záměn 4. klasifikačního postupu bez vah	60
Tabulka 7.15 Výsledky efektivity 4. klasifikačního postupu bez vah.....	61
Tabulka 7.16 Matice záměn 4. klasifikačního postupu s přidanými váhami	62
Tabulka 7.17 Výsledky efektivity 4. klasifikačního postupu s přidanými váhami... ..	63
Tabulka 7.18 Matice záměn 5. klasifikačního postupu s přidanými váhami	66
Tabulka 7.19 Výsledky efektivity 5. klasifikačního postupu s přidanými váhami.....	67
Tabulka 7.20 Matice záměn 6. klasifikačního postupu s přidanými váhami	69
Tabulka 7.21 Výsledky efektivity 6. klasifikačního postupu s přidanými váhami... ..	70
Tabulka 7.22 Matice záměn 7. klasifikačního postupu s přidanými váhami	73
Tabulka 7.23 Výsledky efektivity 7. klasifikačního postupu s přidanými váhami... ..	73
Tabulka 7.24 Matice záměn 7. klasifikačního postupu bez vah	74
Tabulka 7.25 Výpočetní časy klasifikačních modelů	82

1 ÚVOD

Účelem této práce je získat informace v oblasti projevů poruch srdečního rytmu v EKG s využitím vybraných metod automatické detekce. Ty mohou odhalit přítomnost patologií v cévní soustavě. Přesná specifikace poruch srdečního rytmu zároveň umožňuje upřesnění informace, o jakou patologii se jedná, čímž se usnadní práce při řešení patologií kardiovaskulární soustavy.

Za tímto účelem lze využít různé metody automatické detekce, které jsou v optimálním případě schopny odhalit i patologie lidským okem téměř nerozeznatelné. Využívají vytvoření sady příznaků charakterizujících analyzovaný signál EKG na základě, kterého detekují přítomnost patologie a následně ji označí, případně celý záznam zařadí do skupiny dat s vybranou patologií. Základním krokem při takovéto detekci je získání kvalitních příznaků charakterizujících signál, na kterých je schopnost diference signálů závislá.

Tato práce se zabývá inovativním přístupem aplikace sítí hlubokého učení za účelem automatické klasifikace srdečních rytmů. Hluboké učení je podskupinou strojového učení, využívá neuronové sítě uspořádané do vrstev, čímž postupně získává vektor příznaků charakterizující analyzovaná data. Zároveň není většinou vyžadována taková míra předzpracování dat jako v případě klasifikace jinou metodou. Předpokladem je tedy aplikace konvoluční nebo rekurentní sítě, která se na vstupních trénovacích datech naučí rozlišit jednotlivé srdeční rytmy za pomoci příznaků, které sama extrahuje z dostupných dat, a bude schopna s vysokou přesností jednotlivé rytmy klasifikovat.

2 ELEKTRICKÁ AKTIVITA SRDCE

Elektrická aktivita srdce zahrnuje proces tvorby a vedení elektrického vzruchu. Pro funkci tvorby vzruchu využívá specifickou skupinu srdečních vláken, tzv. převodní srdeční soustavu, pro kterou je zároveň charakteristická téměř neschopnost kontrakce. Tuto úlohu zastávají vlákna pracovního myokardu, která přispívají spontánní tvorbou vzruchů zcela výjimečně.

Ke tvorbě vzruchu dochází prostřednictvím šíření akčního potenciálu, který je ovlivněn optimální činností sodíkodraselné pumpy, propustností membrány a schopností difúze. Počátek šíření je odstartován depolarizací membrány. Prudkou změnou membránového napětí způsobenou proudem sodných iontů z extracelulárního prostoru za současného otevření sodných kanálů. Buňky převodního systému setrvávají depolarizovány po dobu několika set milisekund, než dojde k repolarizaci, tedy navrácení membránového napětí na původní hodnotu. Tato fáze akčního potenciálu je označována jako plató. Dochází k ní zvyšující se koncentrací vápenatých, sodných a chloridových iontů v intracelulárním prostředí a také poklesem rychlosti proudění draselných iontů do extracelulárního prostředí. Délka trvání celého akčního potenciálu srdeční buňky je 200 – 400 ms. [32]


Nový akční potenciál podnětem prahové intenzity lze vyvolat až po skončení předchozího akčního potenciálu. Mechanismus, díky kterému je srdeční buňka zcela nedráždivá, je neukončený proces repolarizace membrány. Stav nedráždivosti srdeční buňky se nazývá refrakterita a lze ji rozdělit na fázi absolutní a relativní. Absolutní refrakterní fáze zahrnuje úsek od vzniku depolarizace po první dvě třetiny repolarizace. Charakteristickým znakem je absolutní nedráždivost, kdy není možné podráždění vyvolat ani nadprahovým podnětem. Tato fáze je ukončena poklesem membránového napětí pod hodnotu alespoň -40 mV, kdy nastupuje relativní refrakterní fáze. Během ní již může být vyvoláno podráždění působením podnětu nadprahové intenzity.

Refrakterní fáze má dvojí význam, a to zabránit časnému nástupu vzruchů, které by při příliš rychlém opakování ochromily čerpací funkci srdce, dále pak zabránit vracení či kroužení vzruchů v srdci. [32]

Převodní systém srdeční je specializovanou částí srdeční svaloviny a je tvořen sinoatriálním uzlem, atrioventrikulárním uzlem, Hisovým svazkem, Tawarovými raménky a větvením po síti Purkyňových vláken, což je vidět na obrázku 2.1.

Z buňky na buňku se podráždění přenáší lokálními elektrickými proudy vznikajícími mezi polarizovanými a depolarizovanými oblastmi. Při výskytu podráždění v předsíních či komorách o dostatečné intenzitě dojde k šíření vzruchu po celém srdci prostřednictvím myokardiálních vláken srdeční svaloviny. Tento princip se nazývá „všechno nebo nic“. Tedy buď dojde k podráždění celého srdce nebo v případě podprahového vzruchu nedochází k žádné reakci.

Na rozdíl od ostatních orgánů si srdce tvorbu rytmických podnětů zprostředkovává samo. Jedná se o tzv. schopnost automacie. Tvorba vzruchů je za normálních okolností zajištěna buňkami sinoatriálního uzlu, který je umístěn ve stěně pravé síně pod epikardem poblíž vyústění horní duté žíly. Vzruch se předává celým pracovním myokardem síní. Stěna mezi síněmi a komorami je tvořena vazivovou tkání a plní funkci izolantu. Výjimku zastává pouze jediná možná cesta přes atrioventrikulární uzel neboli AV uzel a Hisův svazek. AV uzel je umístěn ve spodní části pravé síně pod endokardem. Jeho charakteristickým rysem je pomalé vedení vzruchu a to 0.05 m/s. Díky této vlastnosti dochází ke zpomalení přechodu vzruchu ze síní do komor. Zde je vzruch šířen zprvu po mezikomorové přepážce za pomoci Hisova svazku a Tawarových ramének. Ta se následně dělí až do konečné sítě Purkyňových vláken, díky čemuž je zajištěna rychlá aktivace obou komor. [39]



Obr. 2.1 Elektrická aktivace srdce sinoatriálním uzlem, převzato z [17]

3 ELEKTROKARDIOGRAM

Elektrokardiogram, dále jen EKG, je záznam elektrické aktivity srdce, která je snímána pomocí elektrod umístěných nejčastěji na povrchu těla. Měření je prováděno elektrokardiografem. Poskytuje informace o velikosti a směru elektrických proudů a také o frekvenci kontrakcí srdečních svalů. Výsledky měření jsou zapisovány na registrační papír. [18]

V současné době jsou rovněž využívány přístroje obsahující počítačovou techniku s tiskárnou. Takové vybavení umožňuje záznam v digitální podobě, automatickou evaluaci a srovnání s předešlými měřeními. [20]

Standardně se záznam EKG provádí za pomoci dvanácti svodů. Tento počet lze snížit, případně navýšit využitím speciálních elektrod. Svody lze rozčlenit do tří základních skupin na svody končetinové bipolární, unipolární a dále na svody hrudní.

Bipolární končetinové svody, rovněž označované jako Einthovenovy nebo standardní, jsou tvořeny třemi aktivními elektrodami, které se připevňují na pravé horní končetině, levé horní končetině a na levé dolní končetině. Jsou doplněny o jednu zemnicí elektrodu připevněnou na pravé dolní končetině. Výsledkem měření je záznam napětí mezi jednotlivými aktivními elektrodami.


Unipolární končetinové svody, označované jako Goldbergovy, se od bipolárních liší tím, že pro snímání hodnoty napětí je vyžadována pouze jedna aktivní elektroda. Aplikovány jsou tři měřící elektrody, které jsou umístěny na končetinách, stejně jako je tomu v případě Einthovenových svodů.

Identického principu fungování využívají i unipolární hrudní svody, mnohdy nazývané Wilsonovy, provádějící měření za pomoci šesti aktivních elektrod specificky umístěných na hrudníku. Jak již bylo uvedeno výše, mimořádně se doplňuje dvanácti svodové EKG například o svody zadní, pravostranné, etážové, případně jícnové. [20]

Záznam normálního EKG, jenž popisuje obrázek 3.1, je vyobrazen na speciální mřížce usnadňující hodnocení časového rozsahu i velikosti výchylek. Jednotlivé linky reprezentují časový interval 0.04 sekund na ose x a na ose y hodnotu

napětí 0.1 mV Na horizontální ose je tak možné hodnotit dobu trvání jednotlivých výchylek elektrického napětí, zatímco na ose vertikální úroveň změny napětí vyjádřenou v milivoltech.

Samotný elektrokardiogram je tvořen vlnami a kmity o různých velikostech. Vlny představují pozvolné změny napětí a kmity změny prudké. Elektrický podnět šířící se směrem k aktivní elektrodě se projeví pozitivní výchylkou zobrazenou na záznamu EKG směrem vzhůru, zatímco šíření od elektrody výchylkou negativní, která je zobrazena směrem dolů. [20]



Orb. 3.1 Schéma normálního elektrokardiogramu, převzato z [26]

První, nejčastěji pozitivní vlnou EKG, je vlna P. Reprezentuje šíření vzruchu ze sinoatriálního uzlu. První polovina vlny zachycuje aktivitu pravé síně a následně

druhá polovina aktivitu levé síně. Mezi vlastnosti této vlny se řadí zakulacený tvar, krátký časový interval trvání nepřesahující 0,11 sekund a hodnota amplitudy pod 2,5 mm. Což je způsobeno menším množstvím srdeční svaloviny síní.

Dalším sledovaným úsekem je interval P-Q případně P-R. Počátkem intervalu je nástup vlny P a ukončen bývá začátkem kmitu Q. V případě absence kmitu Q se interval prodlužuje po začátek kmitu R. Standardní doba trvání je 0,12 s až 0,20 s. Vzruch se během této fáze šíří přes atrioventrikulární uzel, ve kterém je zpomalen. Díky čemuž nedojde k současné systole síní a komor. Vzruch následně postupuje Hisovým svazkem a Tawarovými raménky až na myokard komor, kde způsobí depolarizaci nejprve levé a následně pravé komory. [39]

Na EKG se elektrické síly projeví v podobě rychlých a ostrých kmitů, souhrnně nazývaných jako komplex QRS, rovněž označovaný jako depolarizační fáze komorového elektrokardiogramu. Komplex QRS je standardně složený z negativních kmitů Q a S a výrazného pozitivního kmitu R s tím, že kmity následují v pořadí Q, R, S. Běžně nepřesahuje doba celého komplexu jednu desetinu sekundy. [20]

Následující úsek, označován jako S-T, je vymezen ukončením kmitu S a nástupem vlny T. Jedná se o interval izoelektrické linie způsobený celkovou depolarizací komor, případně vzájemným vyrovnáním elektrických sil končící depolarizace a počínající repolarizace. [18]

Průběh ovšem není zcela vodorovný a za patologický je označen v případě, že odchylka od izoelektrické roviny dosahuje minimálně jeden milivolt v případě končetinových a dva milivoly v případě hrudních svodů. [20]

Poslední standardně se vyskytující výchylkou je zakulacená vlna T, zobrazující repolarizaci komor. Její tvorba je na rozdíl od QRS komplexu doprovázena spotřebováváním energie. Tato vlna se vyznačuje fyziologickou variabilitou, na jejímž výsledném tvaru mají podíl metabolické, hemodynamické a fyziologické vlivy, mezi které lze zařadit horečku, anoxii, iontovou dysbalanci, fyzickou zátěž a další. [18]

V některých případech se po vlně T vyskytuje výchylka nízké hodnoty napětí, která bývá označována jako vlna U. Nejpravděpodobnější příčinou výskytu vlny U je

repolarizace Purkyňových vláken, jejichž fáze plató trvá déle, díky čemuž se zamezí možnému zpětnému šíření vzruchu. [39]

4 PORUCHY SRDEČNÍHO RYTMU A PŘEVODNÍHO SYSTÉMU SRDEČNÍHO

„Arytmie je definována jako porucha v pravidelnosti srdečního rytmu. Průměrná hodnota fyziologické srdeční frekvence u zdravého dospělého člověka se pohybuje kolem 70 tepů za minutu.“ [29]

Srdeční rytmus lze rozlišit podle počátku depolarizace. Za normální stav se považuje šíření depolarizace ze SA uzlu, takový rytmus je označován jako sinusový. Jak bylo výše uvedeno, může dojít k počátku depolarizace z různých důvodů v jiné části srdce. Název rytmu se pak odvozuje od části srdce, ze které se depolarizace šíří a porucha srdečního rytmu či převodního systému srdečního se označuje jako arytmie. [13]

Vznik abnormálních srdečních rytmů je lokalizován do těchto tří míst – myokardu síní (včetně SA uzlu), oblasti AV uzlu a myokardu komor. Tedy rytmus označovaný jako síňový začíná v síních, sinusový v SA uzlu, AV nodální neboli junkční v AV uzlu a rytmus komorový v komorách. Ke vzniku abnormálního srdečního rytmu může dojít také v SA uzlu.

Podle místa, ze kterého pochází srdeční rytmus, se rytmy dělí na supraventrikulární a komorové. Pod pojem supraventrikulární rytmy jsou sdruženy sinusový, síňový a junkční rytmus. V případě jakéhokoliv z nich dochází ke standardnímu šíření depolarizace přes Hisův svazek na komory, což se projeví úzkými QRS komplexy v záznamu EKG. Zatímco komorové rytmy jsou specifické pomalým progresem depolarizace pomocí Purkyňových vláken, časový interval QRS komplexu je tak prodloužený.

V srdeční svalovině může také dojít k výskytu tzv. abnormálních rytmů, mezi které se řadí bradykardie, extrasystoly, tachykardie a fibrilace. [13]

4.1 Bradykardie

Dle výsledné srdeční frekvence je za bradykardii označována srdeční frekvence nižší než 60 tepů za minutu s tím, že se jedná o frekvenci nepřiměřeně nízkou vzhledem

k dalším okolnostem týkajícím se pacienta, jako je jeho fyzická aktivita či věk. Z hlediska elektrokardiografické klasifikace se jedná o poruchy srdečního rytmu vzniklé poruchou vzniku elektrického vzruchu nebo poruchou vedení vzruchu převodním systémem. [24]

Fakt, že depolarizace není závislá pouze na SA uzlu, je jistou formou prevence proti bloádě šířící se depolarizace, pomalé funkci uzlu, případně jeho afunkci. Za normálních okolností je nutné, aby preventivní mechanismy nebyly aktivní. Tato podmínka je zajištěna skutečností, že SA uzel má nejvyšší frekvenci depolarizace.

V případě selhání depolarizace v oblasti SA uzlu přejme tuto úlohu jedno z ložisek v síních nebo některé místo v oblasti AV uzlu s frekvencí padesáti spontánních depolarizací za minutu. Jestliže depolarizace vychází z ložisek v síních, zajištěný rytmus se nazývá náhradní síňový a je typický abnormální vlnou P a nezměněným QRS komplexem. Je-li rezervní místo lokalizováno v oblasti AV uzlu, dochází k zavedení junkčního náhradního rytmu, ve kterém vlny P chybějí nebo jsou zakryty QRS komplexem.

Jestliže první ani druhé místo nezajistí přechod depolarizace na komory z důvodu jejich chybného fungování nebo při bloádě v oblasti Hisova svazku, úkol vykoná jedno z komorových ložisek. Ta jsou schopna poskytnout přibližně třicet depolarizací za minutu a výsledný rytmus se nazývá náhradní komorový rytmus. Jeli důvodem kompletní AV bloáda, na záznamu EKG jsou zachovány vlny P s výskytem vln přibližně 145 za minutu a QRS komplexy mají výrazně neobvyklou podobu s frekvencí výskytu přibližně patnáct za minutu. [13]

4.2 Extrasystoly

Extrasystoly jsou předčasné depolarizace vyvolané některou z částí srdce. Lze je rozdělit na síňové, junkční a komorové. Takový stah může být rovněž označen jako ektopický nebo předčasný. [13]

„Ojediné předčasné supraventrikulární stahy vznikají buď v síních anebo v blízkosti AV uzlu. V prvním případě se nazývají síňové předčasné stahy (nebo předčasné síňové kontrakce) a v druhém případě junkční předčasné stahy.“ [38]

Podoba síňových a junkčních extrasystol na EKG se ve vzhledu neliší

od příslušných náhradních rytmů, odlišují se předčasným příchodem extrasystoly a opožděním náhradního rytmu. [13]

„Komorové extrasystoly jsou předčasné komorové stahy vznikající elektrickou depolarizací z ektopického centra myokardu pod úrovní Hisova svazku.“ [28]

Komorové extrasystoly jsou od komorových náhradních rytmů odlišné. Projevují se širokým QRS komplexem libovolné podoby. Jejich výskyt není tak běžný a je převážně nepodstatný. Riziková je ovšem jejich přítomnost na začátku vlny T, čímž mohou přivodit fibrilaci komor. [13]

4.3 Tachykardie

Z hlediska rozdělení podle výsledné srdeční frekvence je za tachykardii označována arytmie o srdeční frekvenci vyšší než 100 tepů za minutu.

Z pohledu elektrokardiografické klasifikace jsou tachykardie děleny na supraventrikulární a komorové. Za supraventrikulární jsou označovány tachykardie, u kterých je místem vzniku arytmie či část okruhu arytmie lokalizována na úrovni síní. Jedná se tedy o tachykardie pocházející z SA uzlu, ze síní, oblasti AV uzlu a arytmie nacházející se v přítomnosti přídatných drah. U komorových tachykardií je místo vzniku či okruh arytmie lokalizována na úroveň komor. [24]

V případě tachykardií dochází k opětovné depolarizaci v různých částech srdce. Podstatným krokem při rozpoznávání těchto poruch je detekce vlny P. Síňová tachykardie se projevuje četností depolarizace síní vyšší než 150 za minutu. Vlny P lze pozorovat i na vlnách T předchozích stahů, zatímco QRS komplexy bývají zachovány beze změny. Jakmile přesáhne frekvence hodnotu 250 depolarizací síní za minutu, je daná porucha klasifikována jako flutter síní. Projevuje se absencí izoelektrické linie mezi vlnami P.

Jelikož tachykardie mohou vznikat také poblíž AV uzlu, na záznamu EKG jsou pak vlny P viditelné poblíž komplexu QRS nebo nejsou viditelné vůbec s tím, že komplex QRS je i v tomto případě v normálním tvaru.

Posledním typem jsou komorové tachykardie. EKG záznam je charakteristický širokými komplexy QRS abnormálního tvaru a složitou identifikací vln P a T. [13]

4.4 Fibrilace

Poruchy nazývané fibrilace jsou specifickým typem odlišujícím se od ostatních tím, že nedochází k synchronním kontrakcím svalových vláken síní nebo komor, jako tomu bylo v předchozích případech. Při fibrilacích tedy nedochází pouze ke změně frekvence depolarizace. Zásadním projevem jsou samovolné kontrakce svalových vláken, ať už v síních nebo komorách. Podle této lokalizace se rozlišují fibrilace na síňové a komorové.

První z uvedených se projevuje na záznamu EKG především absencí vlny P. V některých případech může být chvějící se linie doplněna o výchyly připomínající flutter. Depolarizační vlny v různé intenzitě kontinuálně zahlcují AV uzel a Hisovým svazkem se šíří depolarizace v nepravidelných intervalech. Pro převod AV uzlem z hlediska šíření depolarizace platí pravidlo všechno nebo nic s tím, že depolarizační vlny pokračující do Hisova svazku nejsou pravidelné a komory se proto nestahují pravidelně. Avšak zbytek šíření depolarizační vlny v komorách probíhá standardně, proto si QRS komplexy zachovávají běžný tvar. [13]

Komorová fibrilace je arytmií vedoucí k náhlé zástavě oběhového systému projevující se absencí organizované komorové aktivity. V EKG záznamu se neobjeví QRS komplexy a na obrazu EKG se zobrazí nepravidelné kmity různých amplitud. [20]

5 AUTOMATICKÁ DETEKCE ARYTMÍÍ

Důvodem využití automatické detekce arytmíí je rozeznání jednotlivých poruch přítomných v záznamu EKG, které nemusí být pro pozorovatele vždy jednoduché z hlediska přítomnosti šumu v záznamu, a také nepravidelnosti srdečního rytmu. Je založena na aplikaci počítačové analýzy pro efektivní detekci arytmíí. Počítačová analýza postupně provádí extrahování příznaků, výběr příznaků a na závěr provede klasifikaci záznamu nejčastěji aplikací SVM nebo dopředné neuronové sítě, eventuálně hluboké neuronové sítě. [5]

Nejpodstatnější částí je samotné extrahování příznaků, které provádí transformaci vstupních dat na sadu příznaků. Tímto postupem lze získat i jinak skryté informace, významné pro účinnou klasifikaci. Většina technik extrakce příznaků využívá při transformacích časovou případně frekvenční oblast. Mezi příznaky z časové oblasti se řadí doba trvání jednotlivých vln a kmitů, RR intervaly a další. Frekvenčními metodami je například Fourierova transformace. Její aplikace umožňuje odvodit spektrální hustotu a další informace. Ovšem samostatné zpracování těchto informací nezajistí kvalitní klasifikaci, proto se využívají především časově frekvenční metody, nejčastěji vlnková transformace. Zásadním faktorem k úspěšnému vytvoření efektivní sady příznaků pro analýzu dat je výběr mezi lineární a nelineární transformační metodou. [5]

Lineární metody dosahují vysoké přesnosti klasifikace na datech s minimální úrovní šumu a na datech zašuměných jejich přesnost klesá. Jeden z mnoha postupů využívající lineární metody je sestaven z následujících částí. V prvním kroku se data předzpracovávají. Především se odstraňuje šum a rozměřují se jednotlivé vlny. Následně bývá aplikovaná vlnková transformace DWT provádějící rozklad signálu na komponenty od nízkých po vysoké frekvence pomocí banky filtrů. Na závěr je před samotnou klasifikací počet příznaků redukován pomocí PCA (analýza hlavních komponent) na počet podle zvoleného příznakového prostoru. [5]

PCA neboli analýza hlavních komponent je metoda sloužící především ke zjednodušení popisu skupiny korelovaných znaků. Využívá lineární transformace původních znaků v nové, tzv. hlavní komponenty, kde každá hlavní komponenta je

tvořen lineární kombinací původních znaků. Jednotlivé hlavní komponenty jsou charakteristické úrovní variability neboli rozptylem a jsou seřazeny od komponent s největším rozptylem po ty s rozptylem nejmenším. Dané pořadí vyjadřuje důležitost komponent. Nejvyšší důležitost má tedy první komponenta, která zároveň nese nejvíce informací o úrovni rozptylu původních dat. Rozptyl jednotlivých původních znaků reprezentuje jejich efektivitu při rozlišení objektů. Znaky s minimálním rozptylem tedy, při rozlišení objektů takřka nepomáhají. Cílem využití PCA bývá nejčastěji snížení počtu znaků se současným zachováním informace z původních dat, využitím několika hlavních komponent. Jednou z výhod metody PCA je fakt, že hlavní komponenty jsou nekorelované. Následná analýza tak hodnotí namísto velkého počtu znaků nižší počtem nekorelovaných hlavních komponent. Své uplatnění nalézá PCA například při kompresi obrazů, v metodách rozpoznávání tváří a mnoha dalších aplikacích. [41]

Nelineární metody zajišťují získání skrytých informací z EKG i při použití na zašuměných datech. Od metod lineárních se liší například v předzpracování dat bez nutnosti odstraňování šumu ze signálu. Redukci dimenzí a získání vhodné příznakové sady realizují aplikací ICA (analýza nezávislých komponent). [5]

Získané příznaky mohou být využity pro klasifikaci v dopředné neuronové síti nebo SVM samostatně, ale také je možné provést kombinaci příznaků z metody lineární a nelineární a dosáhnout tak vyšší přesnosti klasifikace. [5]

Automatickou detekci a klasifikaci arytmií lze rovněž realizovat s využitím dalších metod umělé inteligence, a to aplikací tzv. metody náhodného lesa. Náhodný les lze uplatnit při řešení různých problémů za použití odlišných postupů. Jeden z nich se skládá ze tří hlavních podoblastí a je dále blíže popsán. Jedná se o podoblast předzpracování dat, získání a výběr příznaků a na závěr natrénování sítě s cílem detekce jednotlivých poruch. Předzpracování signálu využívá diskrétní vlnkovou transformaci s Haarovou vlnkou. Zaměřuje se na odstranění frekvencí 0 – 0.7 Hz korespondujících se driftem izoliny a vysokofrekvenčního šumu v rozmezí frekvencí 90 – 180 Hz. Následuje extrahování různých klasifikačních příznaků, včetně délky RR intervalů, směrodatné odchylky, koeficientů vlnkové dekompozice atd. Před samotným vstupem dat do modelu náhodného lesa je provedena analýza hlavních komponent neboli PCA pro redukci dimenzionality, která je popsána výše.

Náhodný les je flexibilní metoda často dosahující vysoké přesnosti se zachováním rychlého učení. Zavedením náhody zajišťuje prevenci před přeučení. Celý náhodný les je tvořen mnoha rozhodovacími stromy, které jsou trénovány každý na jiné sadě dat. Při testování modelu a také případné klasifikaci nových dat je založeno zařazení vzorku do vybrané třídy modelem náhodného lesa na výsledcích jednotlivých stromů. [42]

Takto popsaná metoda byla trénována na 50 978 záznamech, obsahujících jeden srdeční úder a testována na 49 699 záznamech. Data byla předem rozdělena do pěti nerovnoměrně zastoupených skupin, popsaných v tabulce číslo 5.1.

Tabulka 5.1 Použitá data metody náhodný les, převzato a upraveno z [42]

Trénovací skupiny	N	S	V	F	Q
Počet trénovacích dat	45 826	943	3787	414	9
Procentuální zastoupení skupin	89,89 %	1,85 %	7,43 %	0,81 %	0,02 %
Testovací skupiny	N	S	V	F	Q
Počet testovacích dat	44218	1836	3220	388	7
Procentuální zastoupení skupin	89,03 %	3,70 %	6,48 %	0,78 %	0,01 %

Natrénovaná síť dosahovala úspěšnosti 92.31 %, specificity 89,98 % a senzitivity pouze 37.47 %. Přesné výsledky klasifikace jsou uvedeny v tabulce číslo 5.2.

Tabulka 5.2 Výsledky metody náhodný les, převzato a upraveno z [42]

Matice záměn		Třídy předikované modelem				
		N	S	V	F	Q
Skutečné třídy	N	43 059	61	573	525	0
	S	1756	35	44	1	0
	V	467	5	2744	4	0
	F	261	0	116	11	0
	Q	4	0	3	0	0

Takovéto výsledky potvrzují problematiku nevyváženého zastoupení dat, které se projevuje naučením znaků jedné třídy na úkor většiny zbývajících tříd. [42]

Odlišný postup automatické detekci bez nutnosti dlouhé přípravy dat a sady příznaků umožňuje aplikace hlubokých konvolučních neuronových sítí, jejichž fungování je dále podrobněji popsáno. [45]

6 HLUBOKÉ UČENÍ

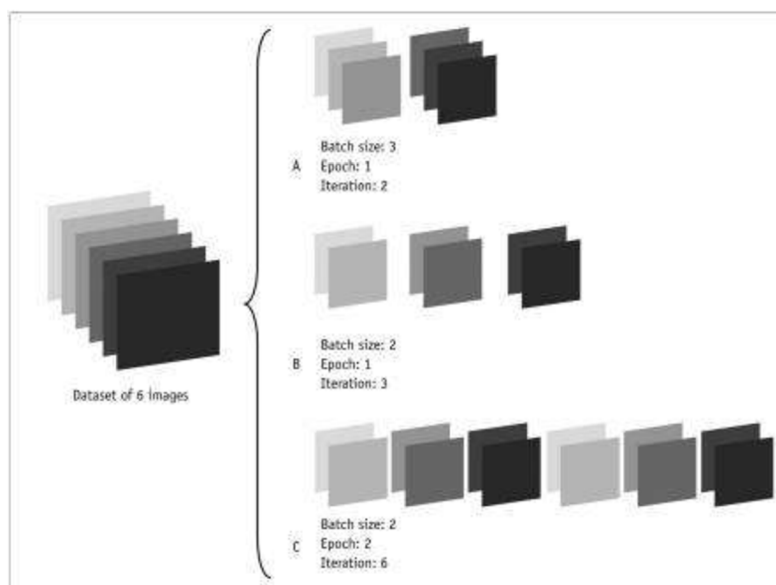
Hluboké učení je podskupinou strojového učení, které je součástí umělé inteligence. Cílem umělé inteligence je automatizace intelektuálních úloh běžně řešených lidmi.

Strojové učení je podmnožinou přístupů zabývajících se komplikovanějšími problémy a snahou nalézt jejich řešení bez nutnosti specifikování pravidel předem. Mezi ně lze zařadit klasifikaci obrazů, rozpoznávání řeči a mnoho dalších. Na rozdíl od klasického programování, kde byly vstupními parametry pravidla a data a výsledkem byly odpovědi, jsou v případě strojového učení vstupem zkoumaná data a očekávané odpovědi. Výstupem jsou pravidla, která lze využít k získání odpovědí na nová data. [16]

Specifickou oblast strojového učení tvoří hluboké učení. Tento přístup využívá tvorby modelů, někdy nazývané také jako sítě, jež jsou složeny ze vstupní vrstvy, po které následují skryté vrstvy, jejichž počet je pro různé architektury rozdílný a zakončeny jsou vrstvou výstupní. Hluboké učení využívá učení se ve vrstvách se získáním více validnější informace. Hloubka modelu reprezentuje počet automaticky se učících vrstev v průběhu trénování. V současné době dosahují počtu desítek až stovek. Tyto vrstvy provádějí postupnou úpravu vstupních dat. Úpravy nejčastěji vedou k získání výstupních dat v podobě vektoru příznaků, umožňujícího například klasifikaci dat. Samotný princip úpravy vstupních dat se u různých modelů hlubokého učení liší. Operace, které jednotlivé vrstvy se vstupními daty provádí, jsou dány váhami vrstvy. Váhy jsou proto někdy označovány jako parametry dané vrstvy. Nastavení veškerých vah v síti, které se vzájemně ovlivňují, je cílem učení sítě. Na začátku procesu učení jsou hodnoty vah vybrány náhodně. Proces učení je řízen ztrátovým skórem vzdálenosti mezi očekávaným výstupem, který je předem známý, a predikovaným výstupem získaným jako výstup sítě. Principem učení je snížit ztrátové skóre pomocí optimalizátoru, čehož je dosaženo zpětnou úpravou vah. [4][11]

Optimalizace tedy popisuje hledání ideálního nastavení vah pro každou vrstvu sítě a lze ji provést za pomoci různých algoritmů. Prvním je stochastický gradientní sestup neboli SGD. Jedná se o algoritmus aplikovatelný pro hluboké učení


a bývá nejčastěji voleným algoritmem. SGD lze dále dělit na tři varianty, podle množství použitých tréninkových dat při výpočtu gradientu. První varianta se nazývá vanilla gradient a pro výpočet kritériální funkce udávající úpravy vah používá veškerá tréninková data. Algoritmus je pomalý a k aktualizaci vah dochází jednou za trénovací epochu. Druhá varianta provádí aktualizaci pro každý soubor z tréninkových dat, čímž se stává výpočetně náročná. Poslední a zároveň nejoblíbenější varianta provádí výpočet aktualizace každých m vzorků. Jedná se o tzv. mini-batche. Aktualizace vah pro každou podmnožinu dat (batch) provádějí i oba dále uvedené algoritmy. Velikost batche reprezentuje pevně daný počet trénovacích dat využitých při jedné učící epoše, jak naznačuje následující obrázek číslo 6.1. Hodnota velikosti batche se nejčastěji nastavuje na hodnoty v rozmezí od 1 do 128. Nastavení závisí na databáze dat, počtu vah v modelu a také dostupné velikosti paměti GPU. [3]



Obr. 6.1 Grafické znázornění velikosti batche, převzato z [3]

Optimalizační algoritmus ADAM neboli adaptivní odhad momentu, využívá pro dosažení přesnějšího nastavení výpočet dvou momentů gradientu, čímž umožňuje i práci s velkým objemem dat. A rovněž poslední uvedený algoritmus tzv. NADAM, adaptivní odhad momentu zrychlený pomocí Nesterov momentu. Tento postup je také možné označit jako variantu algoritmu ADAM, který zařazením

momentu Nestrov do výpočtu dosahuje nižší fluktuace gradientu. Princip Nestrov momentu je vyobrazen na obrázku číslo 6.2. [37]

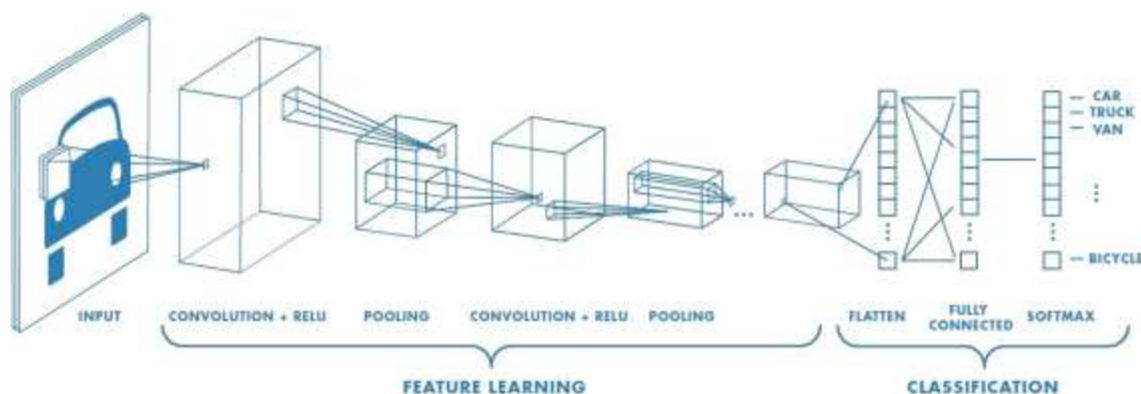


Obr. 6.2 Grafické znázornění Nestrov momentum, převzato a upraveno z [25]

Výsledkem celého procesu, po mnoha trénovacích cyklech, je síť s váhami nastavenými tak, aby ztrátová funkce byla minimální a výstup sítě se blížil očekávanému výstupu. Taková síť je označena za natrénovanou. [4][11]

Výhodami takto tvořené sítě je nejen lepší výkon, ale také snazší řešení problémů. Na rozdíl od metod strojového učení v případě hlubokého učení není nutné předem extrahovat příznaky tzv. feature engineering, dále není vyžadováno tak výrazné předzpracování počátečních vstupních dat, jako v případě mělkého strojového učení. Klíčovou vlastností hlubokého učení je fakt, že učení se provádí ve všech vrstvách najednou. Dochází tak k současnému přizpůsobování všech příznaků, které na sobě závisí. Díky těmto vlastnostem se stává hluboké učení úspěšnějším než ostatní metody strojového učení.


Konvoluční neuronová síť neboli CNN je jedním z modelů hlubokého učení a schéma sítě je uvedeno na obrázku číslo 6.3. Slouží především k počítačovému vidění, které umožňuje klasifikaci obrazů. Jak již bylo výše zmíněno, sítě jsou tvořeny jednotlivými vrstvami. Mezi základní vrstvy CNN patří konvoluční, aktivační, sdružování dle maxima neboli max-pooling a také vrstva výpadku tzv. dropout. [11]



Obr. 6.3 Schéma konvoluční neuronové sítě, převzato z [31]

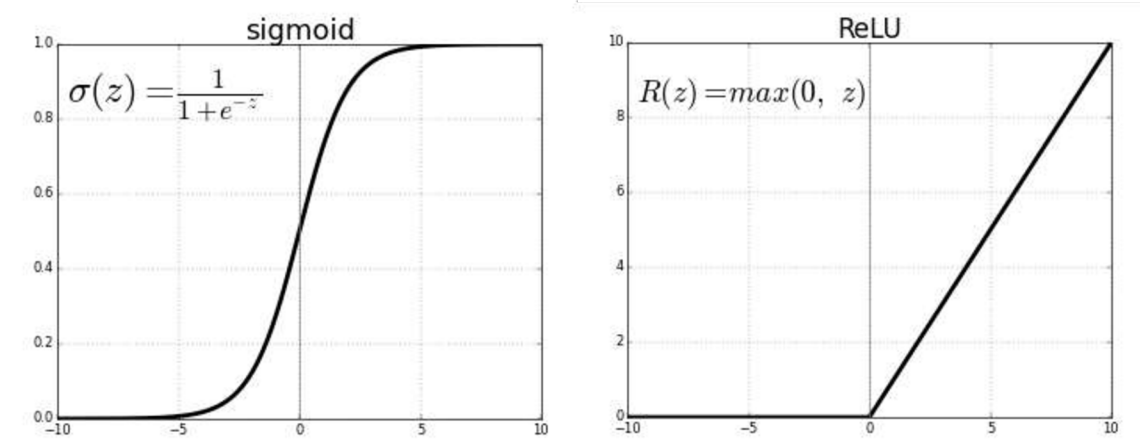
Konvoluční vrstva za pomoci malých 2D oken o velikosti například 3 x 3 nachází lokální vzory ve vstupní matici dat. Jednotlivé vzory jsou zapamatovány a dále se nemění. Pokud se daný vzor opakuje, síť ho rozpozná, ale nemusí se ho znovu učit. Díky této vlastnosti nevyžaduje CNN tak velké množství trénovacích dat. Druhou významnou vlastností této vrstvy je schopnost naučení se prostorové hierarchii vzorů. Kdy v prvních vrstvách se naučí malé lokální vzory, jako jsou například hrany. Následující vrstvy dokáží jednoduše rozeznat rohy a další vrstvy již samotné objekty. Tímto způsobem se síť naučí komplexnější a abstraktnější vzory.

Průběh konvoluce je následující. Z mapy vstupních příznaků jsou pomocí procházejícího 2D okna získány 3D reprezentace okolních příznaků. Následně jsou převedeny do 1D vektoru, ve kterém délka představuje výstupní hloubku a se zachovaným prostorovým umístěním na závěr vytvoří mapu výstupních příznaků. Ta má oproti vstupní mapě menší rozměry šířky a výšky, dojde ovšem k požadovanému zvětšení hloubky. Celý postup graficky vysvětluje obrázek číslo 6.4. [11]



Obr. 6.4 Konvoluční operace - jak pracuje konvoluce, převzato z [9]

Aktivační vrstva je úzce spjata s ostatními vrstvami, neboť se používá jako tzv. mezivrstva. Základem jsou aktivační funkce jako například sigmoidální či softmax, které vstupní hodnoty převedou na hodnoty v rozmezí 0 až 1. Další velmi často užívanou je usměrněná lineární jednotková funkce – ReLU, právě ta je doporučena pro použití ve většině dopředných neuronových sítí. Jedná se o po částech lineární funkci a společně se sigmoidální funkcí jsou vyobrazeny na obrázku číslo 6.5. Tato vlastnost umožňuje např. snazší optimalizaci za pomoci gradientních metod, jejím použitím na výstup lineární transformace získáme transformaci nelineární. Ze vstupních hodnot uvažujeme pouze nezáporné, čímž získáme pouze kladné skalární hodnoty. Funkce sigmoidální a softmax se aplikují především ve spojení s finální vrstvou. Zajišťují výstup v podobě pravděpodobnosti, s jakou se zkoumaná data řadí k vybrané třídě. [11]



Obr. 6.5 Funkce sigmoid a ReLU, převzato z [8]

Vrstva sdružování dle maxima neboli max-pooling provádí zmenšení výšky a šířky dle velikosti příslušného okna. Podobně jako ve vrstvě konvoluční, také zde prochází mapu vstupních příznaků okno a to nejčastěji s krokem 2, které má rozměry 2 x 2. Z každého okna je následně vybrána maximální hodnota bez další transformace. Důvodem aplikace této vrstvy je snížení počtu koeficientů mapy příznaků, a především zajištění prostorové hierarchie příznaků. V případě vynechání této vrstvy by se síť nemusela naučit rozpoznat objekty z důvodu nedostatku informace, neboť okno v hlubší vrstvě by pokrylo pouze malou

oblast původního vstupu, což by mohlo vést k neschopnosti správné klasifikace. Dalším důsledkem vynechání této vrstvy je velký počet parametrů, který by mohl vést k přeučení. Alternativním řešením vrstvy max-pooling je aplikace vrstvy sdružující dle průměru, tedy average pooling, která na místo lokálního maxima aplikuje průměrnou hodnotu dané oblasti. Tento postup ovšem nedosahuje tak dobrých výsledků. [11]

Vrstva výpadku neboli dropout slouží k regularizaci neuronové sítě, čímž snižuje možnost přeučení. Je založena na zajištění změn v množině vstupních příznaků v průběhu učení, k čemuž dochází náhodným zachováním vstupních příznaků, zatímco ostatní jsou vynulovány. Množství vynulovaných se odvíjí od nastavení parametru výpadku, který bývá často v rozmezí 0.2 až 0.5. Parametr udává pravděpodobnost toho, že neuron bude aktivní.

Efektivita sítě se zvyšuje zařazením speciálních vrstev, jako je například 1×1 konvoluční vrstva, batch-normalizační vrstva, případně využití tzv. skip connection a jiných inovací. Cílem 1×1 konvoluční vrstvy je kombinování příznaků do hloubky, zatímco k jejich kombinaci v prostoru šířky a výšky nedochází. Z tohoto důvodu je na výstupu hodnota šířky a výšky nezměněna, na rozdíl od hloubky, u níž velmi často dochází ke zmenšení. Jedná se tedy o redukci počtu příznaků, což napomáhá ke zrychlení učení sítě. Výstupem dané vrstvy je nová příznaková mapa vytvořená lineární kombinací vstupních příznaků. [36]

Batch-normalizační vrstva slouží k optimalizaci sítě hlubokého učení. Nejedná se ovšem o optimalizační algoritmus, nýbrž o metodu adaptivní reparametrizace dat, která se využívá při učení velmi hlubokých sítí. Cílem vrstvy je normalizace dat po jednotlivých podskupinách vzorků o velikosti odpovídající velikosti batche. Zajišťuje především snazší a rychlejší učení sítě. [11]

Skip connection propojuje vybrané vrstvy. Zprostředkovává kratší cestu umožňující přeskocit některé skryté vrstvy. Výsledkem je přidání extra kopií výstupů prvních vrstev k výsledkům pozdějších skrytých vrstev. Zároveň zmírňuje problém s vymýváním gradientu. Ten lze ve stručnosti popsat jako nesnadné určení směru nastavení gradientu, který by vedl k efektivní úpravě jednotlivých vah v průběhu učení sítě. [11]

6.1 Architektury konvolučních neuronových sítí

Specifické nastavení jednotlivých vrstev, jejich uspořádání a vzájemné propojení vedlo k vytvoření jednotlivých architektur konvolučních neuronových sítí rozlišujících se především na základě inovací v podobě aplikace nových vrstev.

Jedna z prvních architektur je AlexNet z roku 2012. Tato síť je sestavena z pěti konvolučních vrstev, vrstev max-poolingu a tří plně propojených vrstev zakončených aktivační funkcí softmax. Jednotlivé konvoluční vrstvy nemají shodné nastavení. Hloubka okna závisí na hloubce vstupních dat. Výška a šířka okna v první vrstvě má rozměry 11 x 11 a druhé vrstvě 5 x 5, zatímco zbývající tři vrstvy využívají okna o velikosti 3 x 3. Specifickou vlastností vrstvy max-poolingu je tzv. overlapping pooling, díky kterému jsou výstupy ze sousedních max-poolingů sečteny. Běžně se jednotlivá sousedství o předem určené velikosti $z \times z$ nepřekrývají. Za podmínky velikost okna max-poolingu $s \times s$ nastaveného na hodnotu $s = z$. AlexNet využívá nastavení $s < z$, nejčastěji $s = 2$ a $z = 3$, čímž se sníží chybovost sítě, ale především dochází méně často k jejímu přeučení. K prevenci přeučení je využívána také vrstva dropout aplikována v prvních dvou plně propojených vrstvách. Výsledkem je velmi rychlá a jednoduchá síť. [21]

Druhou architekturou je VGG z roku 2014. Jedná se rovněž o sériové zapojení dosahující hloubky šestnácti až devatenácti vrstev. Na rozdíl od AlexNetu využívají všechny konvoluční vrstvy okno o šířce a výšce 3 x 3 a max-pooling standardní nastavení okna 2 x 2 krokem 2. Síť je rovněž zakončena třemi plně propojenými vrstvami a poslední aktivační funkcí je softmax. [33]

Dále lze uvést například ResNet, jenž byla prvně představena v roce 2015 a je přibližně osm krát hlubší než VGG. Využitými novinkami jsou vrstvy tzv. bottlenecku, batch-normalizace a reziduálních bloků, zejména pro snížení problému s vymýváním gradientu. [15]


Koncem roku 2017 byla tato architektura aktualizována v ResNetXt, v němž jsou jednotlivé bloky rozšířeny o paralelní homogenní větve, které jsou často tvořeny 1 x 1, následně 3 x 3 a opět 1 x 1 konvolučními vrstvami. Výsledky z jednotlivých větví jsou vždy na konci bloku sečteny v jeden výstup. Paralelní větve umožňují efektivnější optimalizace, než kdybychom provedli stejnou mírou

rozšíření do hloubky. Inovace této architektury umožňují při zachované složitosti zvýšení komplexnosti a zlepšení schopnosti klasifikace. [44]

V roce 2015 byla uvedena architektura Inception v první variantě a stala se jednou z prvních sítí využívající bloky s paralelními větvemi, které na rozdíl od ResNetu nejsou homogenní. Zároveň využívá bottleneck, batch-normalizaci a dva pomocné klasifikátory, které slouží především k prevenci před vymytím gradientu. Poslední úprava ve verzi číslo 4 vyšla roce 2017. Hlavním změnou je připojení reziduálních bloků do každého stávajícího bloku. Přínosem této verze je například zvýšení rychlosti učení. [35]

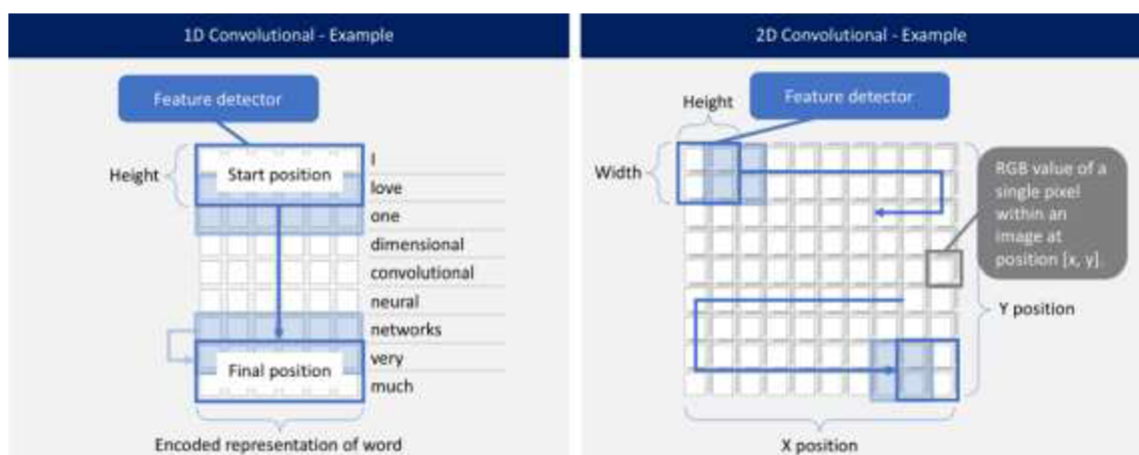
6.2 1D konvoluční neuronová síť

Hluboké konvoluční neuronové sítě bývají běžně navrženy k aplikaci vstupních 2D dat, jako jsou obrázky a video vstupující po jednotlivých snímcích atd. Z toho důvodu jsou často označovány jako 2D CNN. 1D konvoluční neuronové sítě neboli 1D CNN jsou jejich modifikovanou alternativou, jejichž architektura je znázorněna na obrázku číslo 6.6. V mnoha případech je využití 1D CNN vhodnější než aplikace původní 2D CNN, jako například při práci s 1D signály. 1D CNN jsou schopny řešit náročné úlohy pro 1D signály i při realizaci mělkých sítí, tedy s menším počtem skrytých vrstev. Mělkou architekturu je podstatně snazší natrénovat i implementovat. Na rozdíl od 2D CNN, které pro řešení stejné úlohy často vyžadují hluboké sítě a jejich realizace je rovněž podmíněna kvalitním hardwarem. [19]



Obr. 6.6 Schéma architektury 1D CNN, převzato z [19]


1D CNN má rovněž nižší výpočetní náročnost v porovnání se 2D CNN. Díky těmto výhodám je možné využít 1D CNN například k analýze v reálném čase, práci na mobilních zařízeních atd. 1D konvoluční síť se od 2D konvoluční sítě liší, kromě hloubky sítě a velikostí oken jednotlivých vrstev, především možností pohybu okna v CNN, které se může pohybovat vždy pouze v jedné dimenzi, podél časové osy, což je zobrazeno na obrázku 6.7. [19]



Obr. 6.7 Znázornění 1D a 2D konvoluční vrstvy, převzato z [1]

6.3 Rekurentní neuronová síť

Další specifickou metodou hlubokého učení jsou po konvolučních neuronových sítích rekurentní neuronové sítě neboli RNN. Její obecnou stavbou je neuronová síť různých architektur zpracovávající vstupy do výstupů a smyčka umožňující předávat informaci z výstupu jednoho kroku na vstup kroku dalšího a zároveň ovlivňovat nastavení aktuálního kroku. Pro účely přesnějšího popisu je možné si rekurentní síť představit jako více po sobě jdoucích kopií stejné sítě, které si postupně předávají informace v podobě výstupu z předchozí sítě, graficky znázorněno obrázkem 6.8. [10]




Obr. 6.8 Grafické znázornění RNN, převzato z [10]

Vstupní data jsou nejčastěji v podobě 1D vektoru o libovolné délce, jde např. o slova, věty atd. Využití RNN sítí je ovšem spojeno s problémem tzv. dlouhodobé závislosti. Ten nastává v případě, kdy doba mezi důležitou informací a okamžikem její nutnosti je příliš dlouhá. RNN by tak v případě dlouhých vstupních řetězců nebyla velmi užitečná, neboť s přibývajícím délkou se zároveň zvyšuje pravděpodobnost ztráty důležité informace. Především danému problému se snaží speciální typ rekurentních sítí tzv. Long-Short Term Memory, zkráceně LSTM.

Zatímco klasické RNN přiřazují nové informace k těm stávajícím a jejich následné úpravy provádějí bez ohledu na to, která informace je důležitá a která není, LSTM za pomoci modifikací dat násobením a sčítáním selektivně uschovává v paměti informace důležité, a naopak zapomíná ty, jenž tolik důležité nejsou. Celá architektura LSTM je tvořena jednotkami provádějící řešení základních problémů, jako je např. analýza jednotlivých vzorků a určování jejich důležitosti v ohledu

k celkové analýze. Architektura je znázorněna na obrázku číslo 6.9, kde bloky A označují jednotky sítě LSTM. Vstupem jednotlivých jednotek nejsou pouze nová data, ale také stav jednotky předchozího kroku. Právě znalost těchto stavů umožňuje efektivní manipulaci s daty, generování výstupních dat a také nových stavů jednotek. Ani LSTM se ovšem zcela problému s dlouhými sekvencemi nevyhne. Jako další problém, obecně rekurentních sítí, je složitá paralelizace práce z důvodu zpracování sekvence vzorek po vzorku. Nejčastějším využitím RNN je pro analýzu textu, např. překlad, dokončování vět, transformace textu na řeč atd. [10]



Obr. 6.9 Schéma LSTM, převzato z [10]

6.4 Využití hlubokého učení pro detekci arytmií


Hluboké učení pro automatickou detekci arytmií využívá například konvoluční neuronové sítě, jejichž podrobnější popis je uveden výše.

Další možností jsou rovněž výše popsání rekurentní neuronové sítě, provádějící postupnou analýzu signálu v čase s využitím smyčky, která uchovává po určitou dobu informaci o již prozkoumaných vzorcích sledovaného záznamu EKG. Efektivita sítě se díky zavedené paměti zvyšuje. Výhodou rekurentních sítí je rovněž možnost analýzy EKG signálu libovolné délky. Pro tyto účely je využíváno nejen LSTM, ale také její modifikace, jako například GRU. Tato modifikace s méně parametry přináší nižší výpočetní a paměťovou náročnost, zároveň dosahuje v některých případech stejně dobrých výsledků.

Jednotlivé metody se nemusí aplikovat samostatně, ale mohou tvořit hybridní sítě sestavené z konvoluční neuronové sítě pro získání příznakového vektoru ze vstupních dat pomocí konvolučních a max-pooling vrstev. Výsledný vektor následně vstupuje do rekurentní sítě a podle jejího typu označujeme hybridní síť jako CNN – RNN, CNN – LSTM nebo CNN – GRU. [12]

Za konkrétní příklad využití hlubokého učení lze uvést metodu vytvořenou k detekci záznamů s fibrilací síní. Metoda je složena ze tří částí: 1) předzpracování dat, 2) transformace signálů do 2D matice, 3) klasifikace dat pomocí CNN. Na začátku je EKG záznam rozdělen do 5sekundových záznamů. Ze kterých jsou dále v rámci předzpracování pomocí filtrace pásmovou propustí zachovány pouze frekvence od 0,5 do 50 Hz, čímž se snaží odstranit šum a pohyb izolinií.

Předzpracování rozděluje EKG signál do 5sekundových záznamů a dále pomocí pásmové propusti zanechává pouze frekvence od 0,5 do 50 Hz, čímž se snaží odstranit šum a pohyb izolinií. K zajištění transformace dat do potřebné 2D matice je aplikována na dostupná data krátkodobá Fourierova transformace. Vytváří spektrogram pomocí pohybujícího se Hammingova nebo Gaussianova okna. Pro každé okno vypočítá spektrum a zajistí tak časově frekvenční informace o signálu. Další variantou je využití rozkladu signálu použitím vlnkové transformace do dvanácti výstupních signálů. Zajistí tak data ve dvoudimenzionální podobě, která zároveň nesou časově frekvenční informace. Takto připravená data vstupují do hluboké konvoluční neuronové sítě nazývané DeepNet, jejíž architektura je pro příklad vstupních dat v podobě spektrogramů vyobrazena na obrázku 6.10. [43]



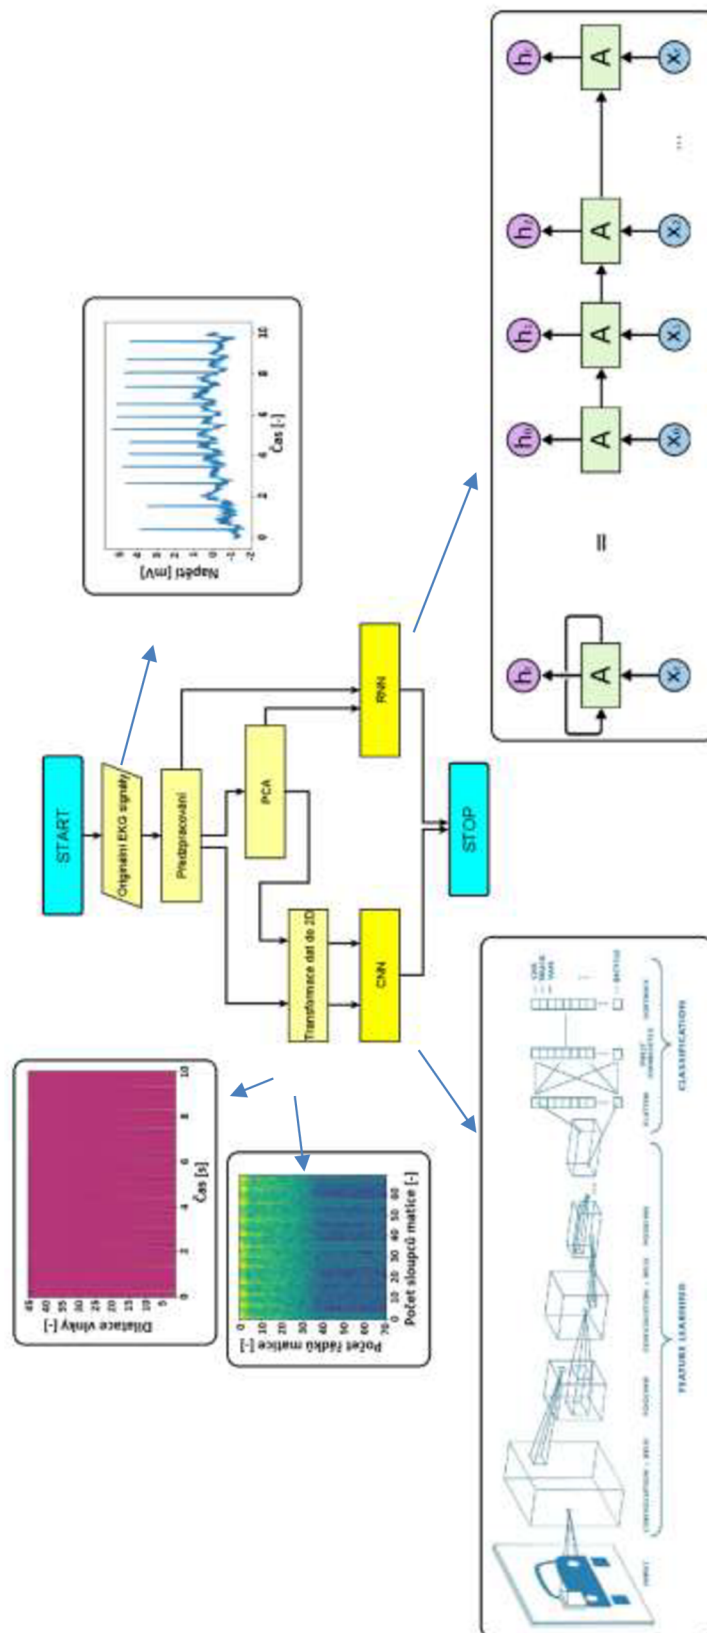
Obr. 6.10 Schéma architektury DeepNet publikovaného článku, převzato z [43]

Sít tvořena šestnácti skrytými vrstvami, je zakončená dvěma plně propojenými vrstvami, využívající optimalizační algoritmus SGD. Pro využití vstupních dat z rozkladu vlnkovou transformací jsou rozměry oken jednotlivých vrstev přizpůsobeny nerovnoměrnému rozložení dat ve vstupní matici, kde je výrazně větší počet sloupců než řádků. Zatímco v původní variantě sítě mají veškerá okna konvolučních vrstev rozměry 5 x 5, po přizpůsobení novým datům mají okna rozměry v první konvoluční vrstvě 3 x 11, ve druhé konvoluční vrstvě 2 x 11 atd. Rozměry oken jsou rovněž pozmeněny pro vrstvy max-poolingu, např. z okna 3 x 3 na okno o rozměrech 2 x 3.

Pro kompletaci celého postupu bylo nutné provést natrénování sítě a její otestování. Za těmito účely byl vybrán soubor 162 536 5sekundových záznamů, ve kterém první skupinu tvoří 61 924 záznamů s fibrilací síní a zbylých 100 612 dat je druhá skupina, složena nejen ze záznamů sinusového rytmu ale také záznamů s různými jinými arytmiemi. Z důvodu zajištění rovnoměrného zastoupení obou skupin byl náhodným výběrem snížen počet dat ve druhé skupině na stejný počet, který je ve skupině první. Konvoluční neuronové sítě tak byly natrénovány na 111 462 záznamech a následně otestovány na 12 386 záznamech. Popsaná metoda dosáhla v případě detekce fibrilace síní následujících výsledků, při použití spektrogramů byla hodnota celkové přesnosti (accuracy) 98,29 %, senzitivity 98,34 % a specificity 98,24 %. V případě transformace dat do 2D matice za pomoci vlnkové transformace dosáhla výsledků celkové přesnosti 98,63 %, senzitivity 98,79 % a specificity 97,87 %. Realizovaný postup detekce fibrilace síní je považován za rychlou, přesnou a efektivní metodou. [43]

7 PRAKTICKÁ ČÁST

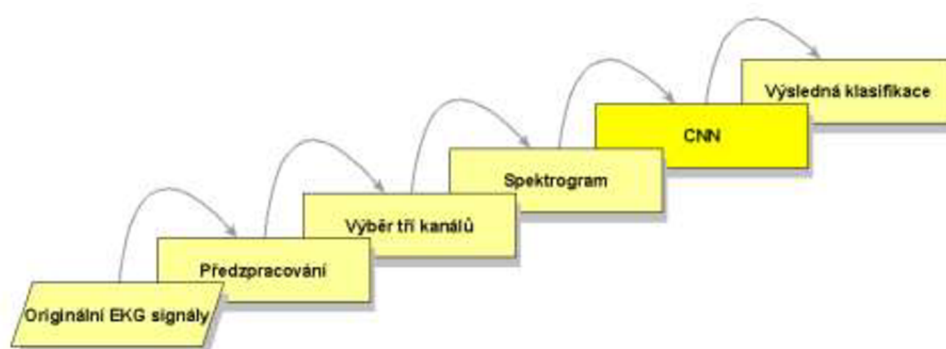
Klasifikační postupy byly implementovány v jazyce Python v prostředí Google Colab Pro. Níže jsou popsány postupy navržené pro řešení dané problematiky, které souhrnně znázorňuje obrázek číslo 7.1. Sestavují se z přípravy dat do požadované podoby a následné analýzy využívající sítě hlubokého učení, které slouží k automatické klasifikaci záznamů EKG do pěti skupin. Jedná se o skupinu s odlišnými rytmy. První skupinou jsou rytmy s fibrilací síní, dále sinusové rytmy, supraventrikulární rytmy, ventrikulární rytmy a poslední skupinu tvoří ostatní signály a také šum. Závěrem práce je diskuze o dosažených výsledcích, zhodnocení potenciálu sítí hlubokého učení pro klasifikaci poruch v záznamech EKG a možné inovace stávajících postupů.



Obr. 7.1 Grafické souhrnné znázornění klasifikačních postupů použitých v praktické části (autorský obrázek s využitím [10][31])

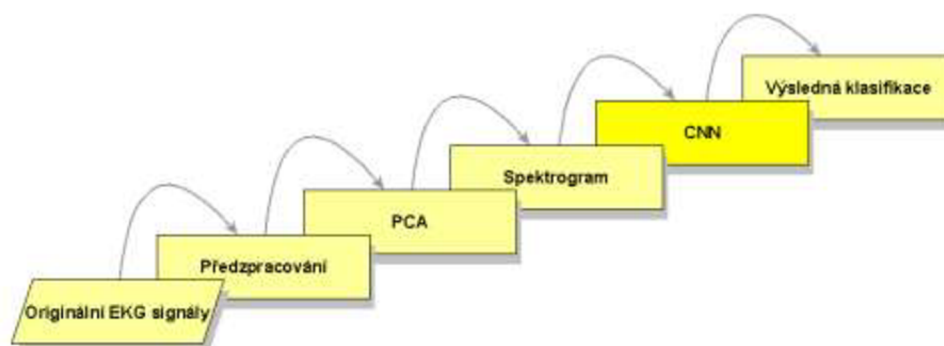
Jak již bylo výše uvedeno, řešení automatické klasifikace záznamů EKG bylo realizováno více postupy. Všechny využívají stejná na UBMI dostupná data, která se nejprve předzpracují a následně se jednotlivé postupy analýzy od sebe více či méně diferencují.

Klasifikační postup č. 1 využívá po předzpracování signálů pouze vybrané kanály, ze kterých jsou vytvořeny 2D reprezentace v podobě spektrogramů, které následně vstupují do předučené konvoluční neuronové sítě. Diagram znázorňující tento postup je na obrázku číslo 7.2.



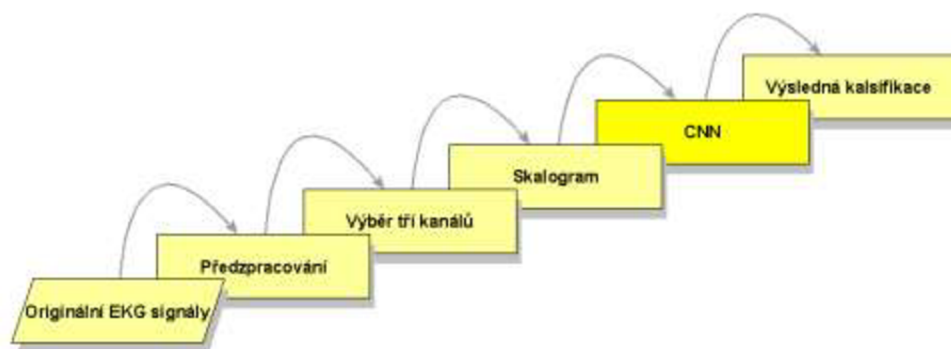
Obr. 7.2 Grafické znázornění klasifikačního postupu č. 1

Klasifikační postup č. 2 na předzpracované signály všech dostupných EKG svodů aplikuje PCA se ziskem pouze tří signálů. Následně z těchto tří signálů vytvoří spektrogramy, které opět vstupují do předučené konvoluční neuronové sítě. Grafické znázornění v podobě diagramu je na obrázku číslo 7.3.



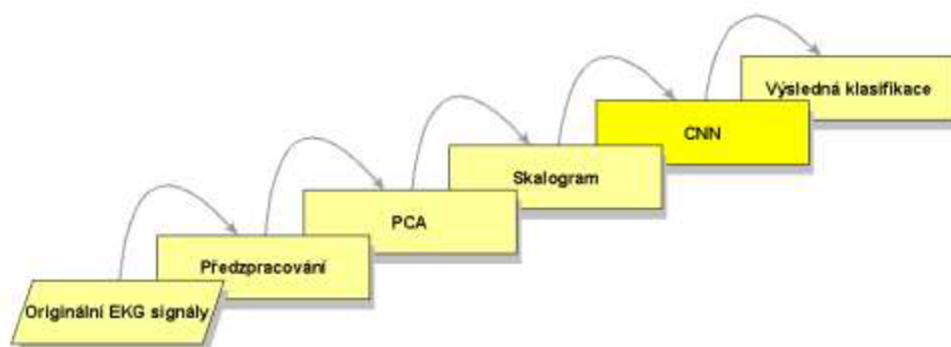
Obr. 7.3 Grafické znázornění klasifikačního postupu č. 2

Klasifikační postup č. 3 taktéž z předzpracovaných signálů využívá pouze vybrané tři kanály, pro které vytváří jejich skalogramy. Tento postup je také zakončen klasifikací za pomoci předučené konvoluční neuronové sítě a graficky je vyobrazen na obrázku číslo 7.4.



Obr. 7.4 Grafické znázornění klasifikačního postupu č. 3

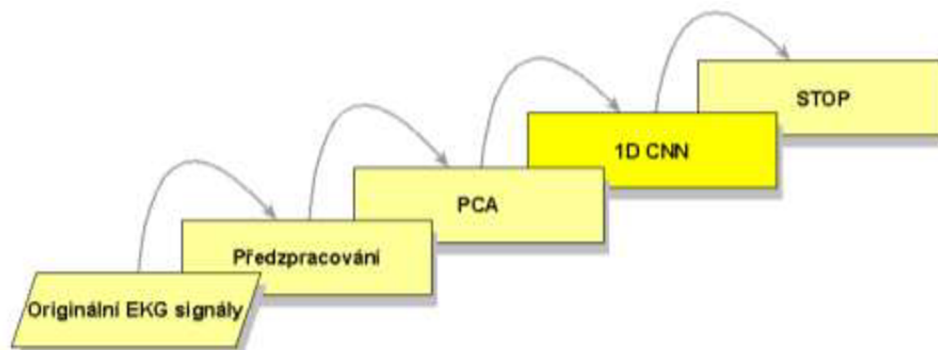
Klasifikační postup č. 4 opět využívá pro získání tří signálů reprezentujících dané měření aplikaci PCA na předzpracované signály všech EKG kanálů. Ze získaných tří signálů jsou sestaveny jejich skalogramy a jako jeden obraz vstupují do předučené konvoluční neuronové sítě. Na obrázku číslo 7.5 je tento postup graficky znázorněn.



Obr. 7.5 Grafické znázornění klasifikačního postupu č. 4

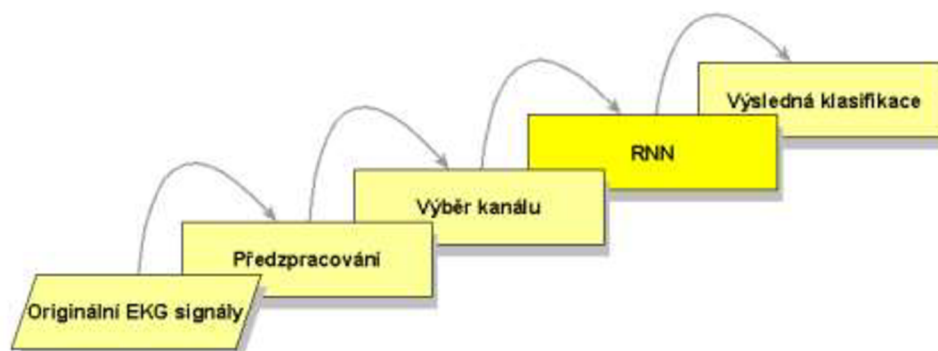
Klasifikační postup č. 5 transformuje předzpracovaná data pomocí PCA do podoby jednoho signálu reprezentujícího dané měření a klasifikaci realizuje

1D konvoluční neuronovou sítí. Na následujícím obrázku číslo 7.6 je vyobrazen vývojový diagram tohoto postupu.

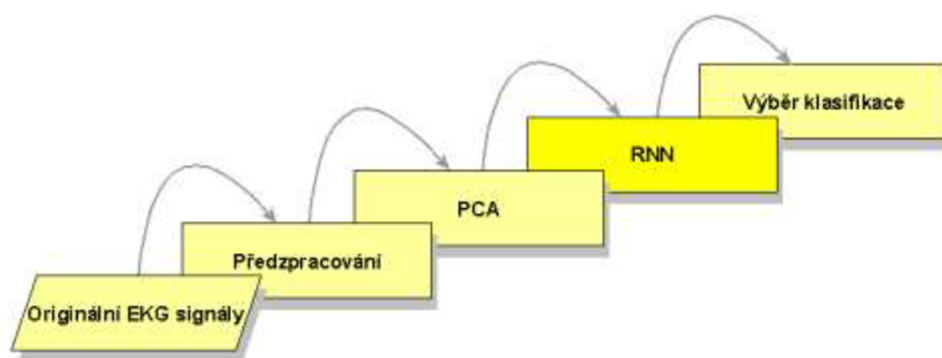


Obr. 7.6 Grafické znázornění klasifikačního postupu č. 5

Klasifikační postupy č. 6 a 7 využívají pro závěrečnou klasifikaci rekurentní neuronovou síť, konkrétně LSTM. Do ní v případě šestého postupu vstupují tři vybrané kanál předzpracovaných EKG signálů a v případě sedmého postupu jsou signály ze všech kanálů transformovány pomocí PCA a až poté vstupují do klasifikační sítě. Vývojové diagramy popisující stavbu těchto metod jsou vyobrazeny na obrázku číslo 7.7 a 7.8.



Obr. 7.7 Grafické znázornění klasifikačního postupu č. 6



Obr. 7.8 Grafické znázornění klasifikačního postupu č. 7

7.1 Databáze

Pro účely vypracování diplomové práce bylo k dispozici 6 884 deseti sekundových záznamů EKG s měřeními osmi svody. Jedná se o končetinové svody II a III a šest základních hrudních svodů, tedy svody V1 až V6. Záznamy byly rozděleny do pěti skupin podle rytmů. Rytmus s fibrilací síní tvoří první skupinu (v práci označovaná také jako AF), další skupinou jsou sinusové rytmy (SR), následuje skupina se supraventrikulárními rytmy (SVR). Předposlední skupinou rytmy ventrikulární (VR) a skupina poslední je označena jako ostatní (Ostatní), obsahuje signály tvořené šumem, uměle vytvořenými harmonickými funkcemi atd. Jednotlivé skupiny nejsou v celkové databázi rovnoměrně zastoupeny a největší podíl tvoří záznamy sinusového rytmu. Pro přehlednost je množství jednotlivých záznamů po rozdělení do skupin popsáno v následující tabulce 7.1.

Tabulka 7.1 Přehled použitých dat rozdělených do pěti skupin


Skupiny dat	AF	SR	SVR	VR	Ostatní
Počet záznamů	553	5942	194	102	88
Procentuální zastoupení skupin [%]	8.04	86.38	2.82	1.48	1.28

7.2 Předzpracování signálů

Jednotlivé záznamy bývají do jisté míry postiženy šumem vzniklým například na rozhraní elektroda – kůže, signály svalové aktivity nebo například driftem

izolinie. Z toho důvodu je vhodné provést alespoň základní předzpracování signálu před transformací dat nebo vstupem do sítí hlubokého učení.

Pro účely předzpracování dat byly využity filtry pásmové propusti pro frekvence od 0.5 do 50 Hz. Tyto frekvence byly zvoleny za účelem odstranění šumu a driftu izolinie. Rovněž jsou podloženy na základě literatury zabývající se podobnou problematikou [43]. Pro filtraci byl použit tzv. Butterworth filtr 5. řádu, který má frekvenční charakteristiku vyobrazenou na obrázku číslo 7.9. Jedná se o jednoduchý filtr s plochou odezvou v propustné části bez vlnění, jak dokládá literatura [7].



Obr. 7.9 Frekvenční charakteristika použitého filtru pásmové propusti


Takto navržený filtr byl aplikován za účelem odstranění většiny šumu se současným zachováním frekvencí charakteristických pro jednotlivé vlny a kmity v záznamu EKG.

Součástí předzpracování dat před trénováním sítí hlubokého učení je také augmentace dat neboli rozšíření trénovací množiny.

Augmentace se využívá především v případě malého počtu vstupních dat. Její aplikací jsou přidány do celkové databáze vzorky, která v ideálním případě nejsou pouhá kopie původních dat, ze kterých vycházejí. Nově vzniklá data jsou určitým způsobem pozměněná data původní. Upravena využitím například zrcadlení, rotace, posunutí, škálování nebo přidáním šumu. Takováto forma navýšení počtu učících dat vede k získání kvalitnějšího modelu, v porovnání s modelem naučeným pouze na originálních datech. [40]

V našem případě byla databáze před augmentací rozdělena na dvě části. Část trénovacích dat a část testovacích dat. Augmentace s přidáním šumu byla

aplikována pouze na trénovací data, a to na méně zastoupené skupin. Jednalo se tedy o rozšíření všech skupin trénovacích dat, kromě skupiny SR, která tvoří přibližně 85 % všech dostupných záznamů. Augmentování probíhalo postupným náhodným výběrem z originálních dat, do té doby než dosáhla množina dat konkrétní třídy předem zvoleného počtu záznamů. Jednotlivá data byla pozměněna od původních přidáním Gaussovského šumu se střední hodnotou a desetinásobkem rozptylu předzpracovaného signálu. Snížení rozptylu bylo provedeno z důvodu omezení velikosti amplitudy šumu tak, aby zcela nezakryl důležité informace předzpracovaného signálu.



Obr. 7.10 Ukázka původního signálu, šumu a jejich překrytí pro porovnání amplitud

Z obrázku 7.10 je na základě amplitudy šumu a signálu patrné, že úroveň šumu nepřekrývá signál (zároveň vede k odlišení jednotlivých kopií původního signálu). Tímto postupem byla zajištěna databáze předzpracovaných signálů, která byla použita v jednotlivých metodách k trénování klasifikační sítě.


7.3 Klasifikační postup č. 1

Postup číslo 1 využívá předzpracovaná dat, ze kterých pro následnou práci využívá vybrané svody II, V1 a V5. Svody II a V1 byly dříve doporučeny, jako vhodné

pro rozlišení arytmí [23]. Zároveň byly svody II, V1 a V5 vybrány na základně anatomického vztahu se snahou využít elektrody zobrazující jednotlivé části povrchu srdce. Svod II zobrazuje spodní povrch srdce, svod V1 přední povrch srdce a svod V5 zajišťuje zobrazení z postranního povrchu srdce. [27]. Důvodem výběru právě tří svodů je pevně daný formát dat vstupujících do použité konvoluční neuronové sítě v podobě $224 \times 224 \times 3$.

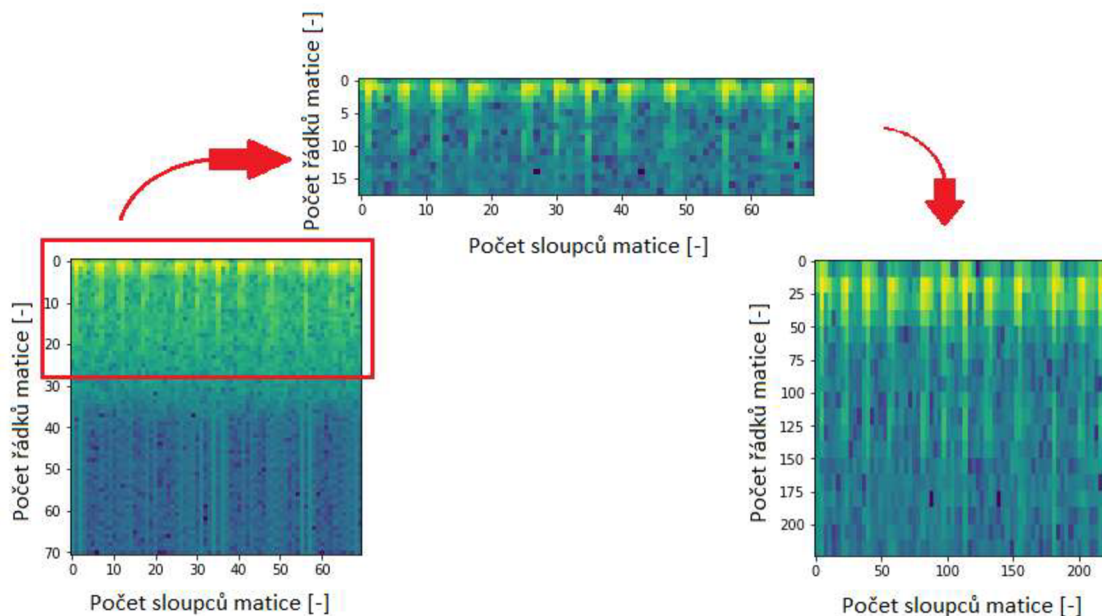
7.3.1 Zpracování dat

Filtrovaná data, augmentována s přidáním šumu, přímo vstupovala do připravené funkce sloužící ke tvorbě spektrogramu. Výsledný spektrogram nezávisí pouze na vstupních datech, ale také na nastavených parametrech funkce. Jako nejdůležitější parametry lze uvést typ okna, jeho velikost a také míra překrývání oken. V našem případě bylo využito běžně užívané Hammingovo okno [43] o velikosti 140 vzorků za účelu dosažení matice se stejným počtem řádků i sloupců, a to především z toho důvodu, že její velikost bude dále interpolována na rozměry 224×224 . Překrytí oken bylo nastaveno na hodnotu poloviny okna a získán výsledný spektrogram (ilustrační příklad je na obrázku číslo 7.11). Zvolené parametry velikosti okna a překrytí oken tak zajistilo 70 spekter, díky čemuž má originální matice spektrogramu rozměry 71×70 . Pro naše účely využíváme především nízké frekvence, které jsou charakteristické pro vlny P, QRS komplex atd. Z toho důvodu je dále spektrogram upraven do podoby logaritmicky škálovaného spektrogramu, která zvýrazní pásmo nízkých frekvencí na úkor pásma vysokých frekvencí [2].



Obr. 7.11 Grafické znázornění původního spektrogramu a logaritmičticky škálovaného spektrogramu (řádky reprezentují frekvence 0 – 250 Hz, sloupce časový úsek 0 – 10 sekund)

Poslední úpravou před interpolací spektrogramu do požadované podoby byl výběr pouze prvních 31 řádků spektrogramu z celkových 71 řádků. Jedná se o frekvence, které jsou pro naše účely validní, a především je většina frekvencí ze zbylých dvou třetin spektrogramu již dříve filtrována. Zachována je tedy část spektrogramu popisující frekvence od 0 do 110 Hz, které jsou propouštěny pásmovou filtrací z důvodu pomalého přechodu mezi propuštěnými a filtrovanými frekvencemi. Druhá část spektrogramu tak nemá důležité informace vhodné k další analýze. Jak je patrné na ilustračním obrázku číslo 7.12 .



Obr. 7.12 Grafické znázornění úpravy spektrogramu

Na závěr je spektrogram rozšířen na požadovanou vstupní velikost převedené sítě 224 x 224 a chybějící hodnoty jsou doplněny interpolací metodu nejbližšího souseda. Před samotným vstupem do sítě hlubokého učení je nutné provést standardizaci dat. Se snahou předejít stavu, kdy vlivem rozdílného škálování ovlivní některá data model více a jiná méně. Standardizace byla provedena jednotlivě pro každý spektrogram, kdy byla od každého pixelu odečtena průměrná hodnota matice spektrogramu a výsledek podělen směrodatnou odchylkou.

Pro každé měření jsou tedy vytvořeny 3 spektrogramy, které se spojí do podoby 3D obrazu s rozměry 224 x 224 x 3, čímž je dosažen požadovaný formát vstupních dat pro převedenou konvoluční neuronovou síť. Ta je po rozdělení dat na trénovací a testovací sadu posledním krokem tohoto postupu.

7.3.2 Vytvoření trénovací a testovací sady


Za účelem trénování a testování klasifikačního modelu byl soubor všech dostupných dat rozdělen na dva menší sady. První označen jako trénovací set obsahoval 80 % ze všech dostupných dat a zbylých 20 % dat bylo uschováno pro následné testování sítě. Rozdělení bylo provedeno pro každou třídu zvlášť, aby bylo zajištěno rozdělení dat na set trénovací a testovací v poměru 4:1 pro všechny třídy. Z důvodu nerovnoměrného zastoupení jednotlivých tříd, které je blíže popsáno v kapitole 7.1,

bylo provedeno navýšení počtu dat v méně zastoupených skupinách s přidáním šumu. První třída obsahující záznamy s fibrilací síní byla zvětšena třikrát, třída supraventrikulárních rytmů čtyřikrát, třídy rytmů ventrikulárních a ostatních signálů šestkrát. Počet záznamů ve třídě sinusových rytmů byl snížen z původních přibližně 4700 záznamů na 3000 záznamů, za účelem zachování dostatečného množství informace a zároveň částečnému vybalancování počtu jednotlivých tříd. Trénovací set byl tedy přizpůsoben za účelem kvalitnějšího naučení sítě se schopností rozeznávat data ze všech tříd. Testovací set dat nepodstupoval žádné rozšíření méně zastoupených tříd a z toho důvodu nebylo nutné k jednotlivým záznamům přidávat šum.

Rozdělení dat je prováděno před zahájením trénování každého klasifikačního modelu. V některých následujících postupech byl mírně upraven poměr trénovací a testovací sady. Bylo například vyzkoušeno navýšení počtu trénovacích vzorků za účelem dosažení kvalitnějšího trénování modelu. Naopak některé postupy obsahují více testovacích dat, aby výsledek natrénování nebyl zkreslen malým množstvím dat, na kterých je model testován.


7.3.3 Klasifikační model

Jako klasifikační síť byla použita konvoluční neuronová síť ResNet152v2 s váhami přednastavenými za použití databáze obrázků ImageNet (grafické znázornění architektury sítě je na obrázku číslo 7.13). Tato síť je velmi hluboká neboť je tvořena 152 vrstvami se současným využitím skip connection, jenž je pro ResNet charakteristické. K takto předučené síti je přidáno ukončení sítě specifické pro řešený problém. Jedná se o vrstvu poolingů využívanou téměř vždy při aplikaci předučené sítě, namísto plně propojené vrstvy. Dále na ni navazují dvě plně propojené vrstvy proložené Dropout vrstvou s 50% pravděpodobností deaktivace daného uzlu. První plně propojená vrstva, jejímž výstupem je vektor 32 příznaků s aktivační funkcí ReLu, je rozšířena o regularizaci vah a regularizaci biasu, který vyjadřuje posun aktivační funkce po ose x. Pro obě regularizace je aplikována suma absolutních hodnot a suma čtverců. Druhá a zároveň poslední vrstva sítě využívající aktivační funkci softmax již udává výstup v podobě vektoru pravděpodobností příslušností k daným třídám.



Obr. 7.13 Grafické znázornění architektury ResNet152, převzato z [14]

Trénování sítě bylo provedeno jak s využitím přidávaných vah jednotlivým třídám, tak i bez nich. Sít byla nejprve trénována bez využití vah, které se aplikují především v případě nerovnoměrného zastoupení jednotlivých tříd a upřesňují síti, na které třídy se má zaměřit. Pro trénování sítě bylo využito 5882 spektrogramů, na kterých se síť učila 100 epoch s využitím batche o velikosti 32. Průběh učení je reprezentován na následujícím obrázku číslo 7.14 popisující změnu přesnosti (Accuracy) a změnu chyby (Loss) s přibývajícím počtem epoch.



Obr. 7.14 Průběh učení 1. klasifikačního postupu bez vah

Takto natrénovaná síť v průběhu svého učení dosáhla úspěšnosti 60 % a nejlépe se učila nejpočetnější třídu, tedy záznamy se sinusovým rytmem a třídu s nejodlišnějšími daty. Tento fakt dokazuje i matice záměn trénovacích dat, sestavená v tabulce číslo 7.2.

Tabulka 7.2 Matice záměn 1. klasifikačního postupu na trénovacích datech

Matice záměn		Třídy predikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	142	1149	11	22	2
	SR	44	2938	1	1	16
	SVR	188	333	99	0	0
	VR	19	274	0	199	0
	Ostatní	18	119	1	8	298


Na základě trénování bylo možné hodnotit síť za dobře naučenou pro rozlišení záznamů 2. třídy a zároveň se natrénovaná síť učila i rozlišit ostatní třídy, kde ovšem nedosahovala dobrých výsledků. Na základě těchto poznatků bylo provedeno testování sítě za pomoci testovacího setu, tvořeného 1566 záznamy nerovnoměrně zastoupených skupin. Nejvyšší úspěšnost na základě výsledků F1-skóre s hodnotou 0.87, úplnosti (recall) 0.97 a přesnosti (precision) 0.78 dosahovala síť dle předpokladů u skupiny SR. Jednotlivé výsledky jsou popsány v následující tabulce číslo 7.3.

Tabulka 7.3 Matice záměn 1. klasifikačního postupu na testovacích datech bez vah

Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	23	269	2	6	0
	SR	23	1147	4	10	4
	SVR	13	24	2	0	0
	VR	1	11	0	8	0
	Ostatní	0	11	0	1	7

Druhé nastavení parametrů sítě se od prvního lišilo přidáním vah jednotlivým třídám, které úřednostňovaly především třídu AF, částečně také třídy SVR, VR a třídu Ostatní. Zatímco váhy pro nejpočetnější skupinu SR byly menší než 1, čímž způsobovaly, že záznamy této třídy byly pro síť méně atraktivní.

V tomto případě bylo využito pro jednotlivé třídy těchto vah: AF: 4, SR: 0,89, SVR: 2,5, VR: 1,1, Ostatní: 1,7. Průběh učení se od průběhu bez využití vah lišil především změnou přesnosti (accuracy) v závislosti na přibírajících epochách, který je vyobrazen na obrázku číslo 7.15. Přesnost na trénovacích datech postupně stoupla a změna chyby (loss) s přibírajícím počtem epoch klesala.



Obr. 7.15 Průběh učení 1. klasifikačního postupu s přidávanými vahami

Z obrázku číslo 7.15 je rovněž patrná fluktuace přesnosti i úrovně chyby testovacích dat, ta je způsobena především nerovnoměrným zastoupením vzorků testovací sady. V případě, že se síť naučí lépe na záznamy se sinusovým rytmem na testovací sadě, se tento fakt projeví prudkým růstem přesnosti. Zatímco upřednostnění jakékoliv jiné třídy, případně více tříd před třídou se sinusovými rytmy vede k jejich lepšímu naučení a současně k poklesu celkové přesnosti na testovací sadě. Dosažené výsledky s nastavenými váhami jsou popsány v tabulce 7.4.

Tabulka 7.4 Matice záměn 1. klasifikačního postupu na testovacích datech s přidávanými váhami

Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	224	53	17	6	0
	SR	354	799	23	7	5
	SVR	17	8	14	0	0
	VR	7	5	0	8	0
	Ostatní	7	5	0	0	7

Toto nastavení tedy vedlo k síti s hodnotou celkové přesnosti 67 %. Z matice záměn je patrné, že aplikace vah vedla k naučení sítě respektující všechny třídy, na rozdíl od varianty bez přidávaných vah třídám. Nejlepších výsledků na základě přesnosti (precision) dosáhl model v případě třídy SR s hodnotou 0.92. Nejvyšší hodnoty úplnosti (recall) s hodnotou 0.75 pro třídu AF a nejvyšší F1-skóre opět v případě třídy SR. Celkové výsledky jsou uvedeny v tabulce 7.5.

Tabulka 7.5 Výsledky efektivity 1. klasifikačního postupu s váhami

Úspěšnost modelu	Přesnost (precision)	Úplnost (recall)	F1 - skóre	Počet dat
AF	0.37	0.75	0.49	300
SR	0.92	0.67	0.78	1180
SVR	0.26	0.36	0.30	39
VR	0.38	0.40	0.39	20
Ostatní	0.58	0.37	0.45	19

Na základě výsledků je tedy patrné, že největší problém měl klasifikační model se zaměňováním některých záznamů skupiny SR za data skupiny AF. To může být způsobeno kvalitním natrénováním modelu pro rozpoznání sinusového rytmu a v případě síňových extrasystol nebo jiných projevů již daný záznam považuje

za data skupiny AF. Stejně tak komorové předčasné stahy i ty ojedinělé mohou být důvodem, kvůli kterému síť predikuje některé záznamy do skupin SVR a VR.

7.3.4 Diskuze dílčích výsledků

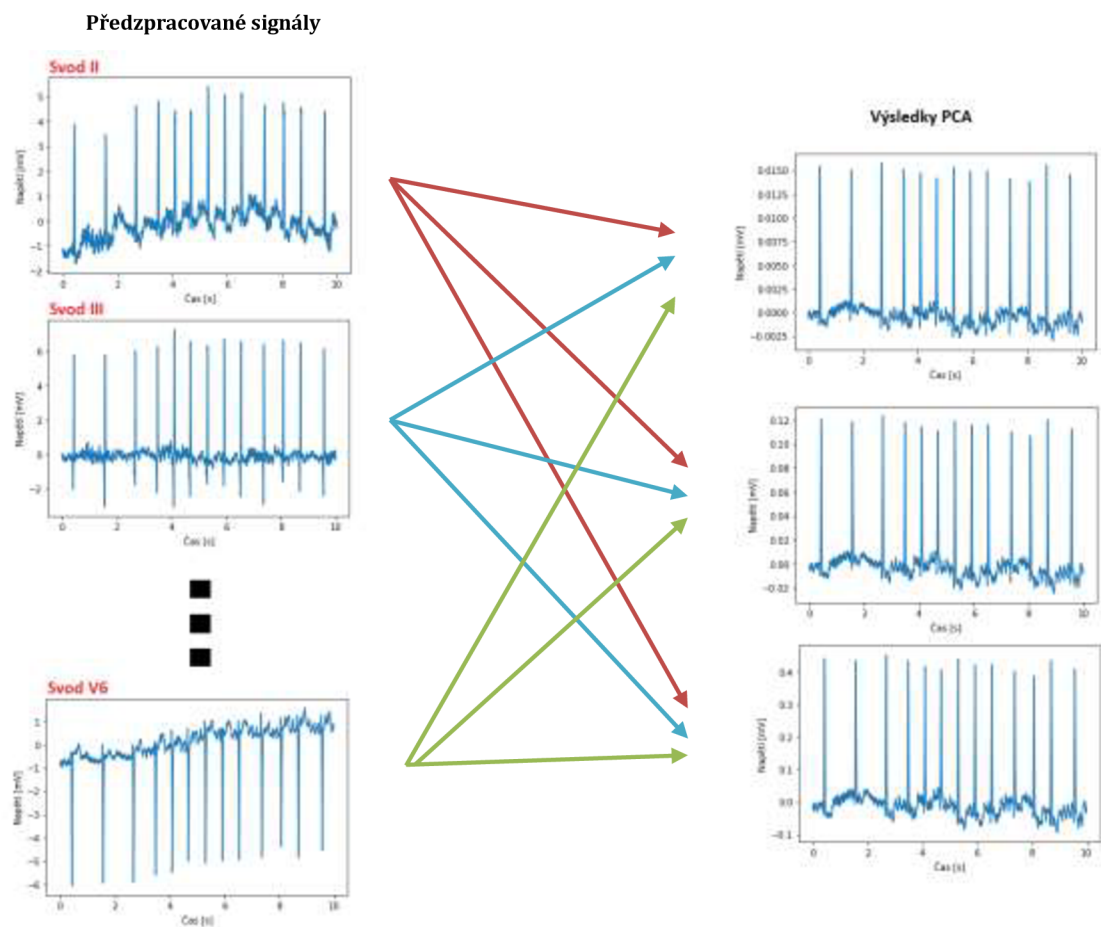
Z uvedených údajů lze vyvodit, že úspěšnost metody se odvíjí z kvality dostupných dat, nastavení jednotlivých parametrů a také požadovaného cíle. Z výsledků především první varianty bez využití vah je zřejmé, že model se učí především rozeznávat dostatečně zastoupené třídy. V případě nerovnoměrně zastoupených skupin je tak nutné zajistit alespoň částečné vyrovnání, které bylo provedeno i v metodě číslo 1. Cílem úpravy množství dat bylo snížit počet dat náhodným výběrem nejzastoupenější třídy a zároveň navýšit počet dat ve třídách méně zastoupených. Z důvodu předejít situace, kdy se síť naučí rozpoznávat pouze data z jedné třídy. Zároveň nebylo žádoucí provést navýšení počtu dat méně zastoupených skupin například ze 100 dostupných měření na 6000. V takovém případě by se ve výsledné třídě každý vzorek mnohonásobně opakoval. Využitá augmentace tak zajistila data v poměru přibližně 22,5 : 51,0 : 10,5 : 8,4 : 7,5 z původního poměru 8,0 : 86,4 : 2,8 : 1,5 : 1,3.

Dalším parametrem vhodným k diskuzi je využití a nastavení vah, které způsobí, že model věnuje dané třídě „větší pozornost“. Při výpočtu kritériální funkce v průběhu učení je výpočet chyby ovlivněn aplikací váženého průměru na základě použitých vah jednotlivých tříd. Z dosažených výsledků je patrný rozdíl v učení při použití vah tříd a bez nich. Pokud nejsou využity váhy tříd a trénovací set nemá vyrovnané zastoupení tříd, síť se učí dobře nejpočetnější třídu. Jakmile byla třídám přiřazena váha, snažil se je model rovněž naučit, i když docházelo k chybám.

Postup číslo 1 dokazuje možné využití konvolučních neuronových sítí za účelem detekce různých srdečních rytmů. Což dokládá výsledek použití sítě bez přidání vah, ve kterém pouze 3 % záznamů se sinusovým rytmem nebylo správně detekováno a zařazeno. Oproti tomu aplikace vah dokazuje, že je CNN schopna učit se jednotlivé třídy a provádět tak klasifikaci do více tříd zároveň. Pro tyto účely by bylo ideální rovnoměrnější zastoupení všech tříd.

7.4 Klasifikační postup č. 2


Druhá metoda využívá jako vstupní data předzpracované ekg signály všech svodů. Na rozdíl od postupu číslo 1 popsaného v kapitole 7.3, neprovádí výběr svodů, které použije pro následnou analýzu. Informace ze všech svodů transformuje za analýzy hlavních komponent neboli PCA se získkem tří výstupních signálů, tří hlavních komponent popisující největší rozptyl v datech. Příklad využití PCA je vyobrazen na obrázku číslo 7.16.



Obr. 7.16 Grafické znázornění aplikace PCA

Pro všechny tři takto vytvořené signály jsou opět sestaveny jejich spektrogramy (vyobrazené na obrázku číslo 7.17) stejným postupem a se stejnými parametry jako v případě první metody. Jednotlivé získané spektrogramy nerepresentují časově frekvenční průběh pouze vybraných svodů, ale tří hlavních

komponent ze všech dostupných svodů. Výsledné spektrogramy jsou následně spojeny ve 3D matici formátu 224 x 224 x 3 a po standardizaci připraveny ke vstupu do konvoluční neuronové sítě.




Obr. 7.17 Příklad výsledných spektrogramů vytvořených ze získaných signálů po aplikaci PCA

Druhý postup rovněž využívá jako klasifikační síť ResNet152v2 s přednastavenými váhami na základě databáze obrázků ImageNet a následné doplnění sítě jako u prvního postupu.

Pro účely trénování sítě v postupu číslo 2 byly určeny 2/3 dat a jedna třetina všech dat byla uschována jako testovací set pro závěrečné testování. V případě trénovacího setu byla provedena augmentace původního počtu dat se ziskem trojnásobného počtu dat AF, počet dat skupiny SVR byl navýšen čtyřikrát a velikost skupiny VR a Ostatní byla navýšena rovněž čtyřikrát. Množství dat ve skupině SR zůstalo v nezměněném počtu, který činil 3961 záznamů, čím byl zajištěno zastoupení skupin v poměru 17,4 : 62,2 : 8,1 : 6,4 : 5,9. Za účelem vyzkoušení dvou přístupů bylo opět provedeno trénování a testování modelu bez přidání vah jednotlivým třídám a následně i s přidáními váhami. Průběh trénování

bez přidání vah je vyobrazen na obrázku číslo 7.18 v podobě grafu závislosti přesnosti (accuracy) na přibírajícím počtu epoch a také v grafu závislosti hodnoty chyby (loss) na počtu epoch. Využitých epoch pro trénování bylo 100, jako optimalizer byl využit Nadam s velikostí batche 64.



Obr. 7.18 Průběh učení 2. klasifikačního postupu bez vah

V grafech na obrázku číslo 7.18 jsou opět patrné skokové rozdíly hodnot přesnosti v případě testovacích dat. Ty jsou způsobeny především nerovnoměrným zastoupením skupin v testovacím setu. Jakmile se model naučí lépe rozlišovat skupinu SR, dosahuje přesnost testovacích dat k 80 %, což je způsobeno tím, že přibližně 80 % testovacího setu je tvořeno záznamy skupiny SR. Jakmile se model natrénuje i jiné skupiny, dojde k poklesu aktuální hodnoty přesnosti testovacích dat. V grafu přesnosti modelu (Model accuracy) jsou rovněž patrné výrazné propady k přesnosti přibližně 20 %. Ty jsou způsobeny aktuálním natrénováním sítě, která upřednostňuje ostatní skupiny před skupinou SR. Záznamy skupiny SR tvořící většinu testovacích dat jsou pak rozděleny mezi ostatní skupiny, což způsobí dočasný výrazný pokles přesnosti.

Natrénovaná síť byla otestována na 2411 datech a její úspěšnost klasifikace je popsána v tabulce číslo 7.6 a bližší výsledky natrénování sítě pro jednotlivé skupiny jsou uvedeny v tabulce číslo 7.7. Z výsledků je patrné, že síť se velmi dobře natrénovala na nejpočetnější skupinu SR. Ostatní skupiny se sítí nenatrénovala kvalitně rozeznávat. Takovou skupinou je například skupinu VR, zatímco skupiny AF a SVR nerozeznává vůbec.

Tabulka 7.6 Matice záměn 2. klasifikačního postupu bez vah

Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	0	287	0	13	0
	SR	3	1846	0	132	0
	SVR	2	58	0	5	0
	VR	0	14	0	20	0
	Ostatní	1	25	0	3	2


Podrobná data úspěšnosti modelu na jednotlivých skupinách potvrzují kvalitní klasifikaci záznamů sinusového rytmu, které zařazuje do správné skupiny SR.

Tabulka 7.7 Výsledky efektivity 2. klasifikačního postupu bez vah

Úspěšnost modelu	Přesnost (precision)	Úplnost (recall)	F1 - skóre	Počet dat
AF	0,00	0,00	0,00	300
SR	0,83	0,93	0,88	1981
SVR	0,00	0,00	0,00	65
VR	0,12	0,59	0,19	34
Ostatní	1,00	0,06	0,12	31

Naučený model metody číslo 2 bez přidání vah jednotlivých tříd je tedy vhodný k využití například za účelem detektoru záznamů sinusového rytmu. Pro účely klasifikace do více tříd není toto nastavení vhodné.

Poté byl model trénován a testován znovu, tentokrát inovován o přidání vah jednotlivým třídám. Průběh trénování za dobu 100 epoch s využitím optimalizátoru Nadam s velikostí batche 64 je vyobrazen na obrázku číslo 7.19.



Obr. 7.19 Průběh učení 2. klasifikačního postupu s přidáním vahami

Stejně jako v případě trénování modelu bez přidání vah je i zde patrná fluktuace hodnoty přenosti (accuracy) pro testovací data, způsobená opět nerovnoměrným zastoupením skupin v testovací sadě. Natrénovaná síť byla opět testována na přibližně 2400 datech. Výsledky klasifikace, které jsou popsány v tabulce číslo 7.8, naznačují úspěšnou detekci a klasifikaci většiny dat skupiny SR. Zároveň přispěla aplikace vah tříd k natrénování modelu tak, aby již detekoval alespoň v některých případech všechny skupiny.

Tabulka 7.8 Matice záměn 2. klasifikačního postupu s přidáním váhami

Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	126	165	9	0	0
	SR	387	1544	17	33	0
	SVR	27	26	12	0	0
	VR	12	8	0	14	0
	Ostatní	14	10	1	2	4

Výsledky popisující efektivitu klasifikace jednotlivých tříd, jsou uvedeny v tabulce číslo 7.9. Z nich je patrné, že přidáním vah tříd do trénování sítě došlo ke snížení efektivity detekce záznamů se sinusovým rytmem z původně chybně zařazených 7 % na celkových 22 % chybně zařazených záznamů se sinusovým rytmem. Zároveň se ovšem zvýšila efektivita detekce ostatních zkoumaných rytmů.

Tabulka 7.9 Výsledky efektivity 2. klasifikačního postupu s přidáním vahami

Úspěšnost modelu	Přesnost (precision)	Úplnost (recall)	F1 - skóre	Počet dat
AF	0,22	0,42	0,29	300
SR	0,88	0,78	0,83	1981
SVR	0,31	0,18	0,23	65
VR	0,29	0,41	0,34	34
Ostatní	1,00	0,13	0,23	31

Ze všech získaných výsledků lze dojít k závěru, že v případě tvorby detektoru záznamů sinusového rytmu dosahovala lepší hodnoty úplnosti varianta modelu, který byl trénován bez přidání vah. Ta ovšem dosahovala nižší hodnoty přesnosti a F1 – skóre. Není tedy snadné označit efektivnější variantu detekce sinusového rytmu. Aplikace modelu trénovaného s využitím vah tříd nevedla k tak kvalitním výsledkům klasifikace do více tříd. Potvrdila však možné využití konvolučních neuronových sítí pro klasifikaci spektrogramů do více skupin najednou.

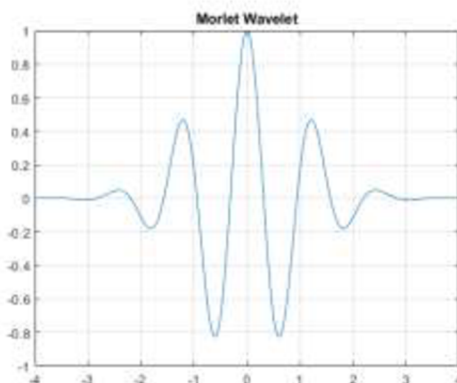
Při tvorbě celého postupu byla snaha o zachování co největšího množství informace ze vstupních dat a také bylo vyzkoušeno více možných nastavení různých parametrů. Například využití PCA se získáním tří signálů, které je uplatněno i v některých následujících postupech, je aplikováno z důvodu snahy využít co největší množství informace ze všech svodů, bez nutnosti výběru pouze tří svodů, které by charakterizovaly celý záznam. V mnoha případech jsou si výsledné signály po PCA velmi podobné a tak namísto zachování co největšího množství informace, dochází k analýze tří téměř stejných signálů lišících se například velikostí amplitudy. Tvorba spektrogramů byla spojena s testováním různých oken, šířek a míry překrytí oken, které bylo následně nastaveno na základě doporučení z literatury [43]. Jedny z posledních parametrů, které bylo nutné nastavit na co možná nejideálnější hodnoty jsou spojeny s trénováním klasifikátoru. Jedná se o velikost batche, počet epoch a v případě postupu s využitím vah tříd, také hodnoty příslušných vah. V případě batche byly testovány také velikosti od 32 přes 64, 128 po 256, které nevedly ani k lepším výsledkům ani ke snížení fluktuace přesnosti v průběhu učení. Počet trénovacích epoch byl nastaven na hodnotu 100 epoch

z důvodu časové náročnosti a také z důvodu minimálních změn od přibližně 80. epochy.

7.5 Klasifikační postup č. 3

Třetí postup z předzpracovaných dat využívá opět pouze tři kanály II, V1 a V5 každého 10sekundového záznamu. Od předchozích postupů se odlišuje především typem použité transformace dat z 1D do 2D podoby.

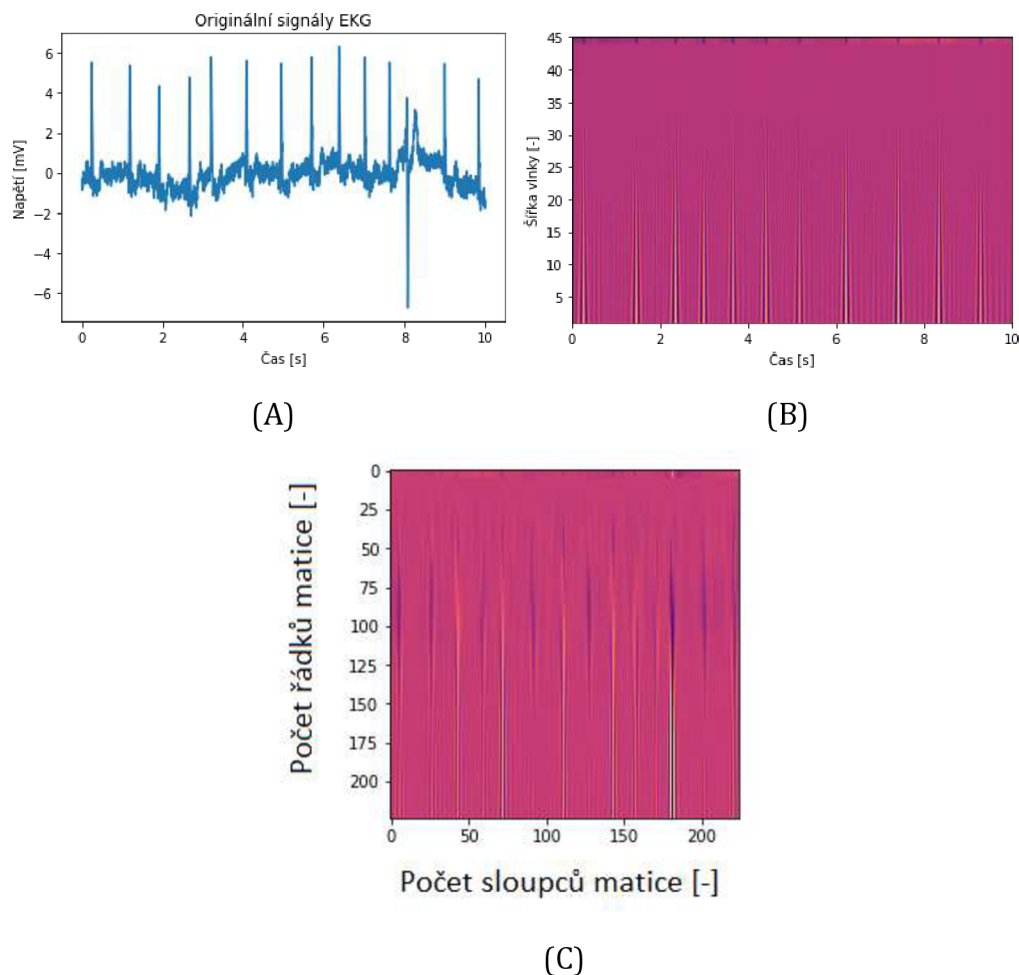
Filtrovaná a standardizovaná data transformuje do podoby 2D reprezentace za pomoci spojitě vlnkové transformace neboli CWT. Výsledkem této transformace je skalogram, jehož parametry jsou závislé především na použité mateřské vlnce a aplikovaných šířkách mateřské vlnky. V této metodě byla využita mateřská vlnka Morlet vyobrazena na obrázku číslo 7.20 se šířkami od 45 do 1 použitými pro transformaci, jejíž výběr byl proveden na základě literatury zabývající extrakcí příznaků pro strojové učení [6]. Jedná se o vlnku, která je svým průběhem podobná vlnám P a T a také QRS komplexu. Výsledek její aplikace se projeví jako vysoké koeficienty CWT odpovídající vysoké korelaci mezi daným úsekem signálu a mateřskou vlnkou.



Obr. 7.20 Grafické znázornění vlnky morlet, převzato z [46]

Velikost výsledných skalogramů, které jsou znázorněny na obrázku číslo 7.21, je změněna z původních rozměru 45 x 2500 na rozměr 224 x 224 ze stejného důvodu jako v předchozích metodách, tedy úprava dat na požadovanou velikost pro vstupu do CNN. Tento průběh je dán aplikací spojitě vlnkové transformace

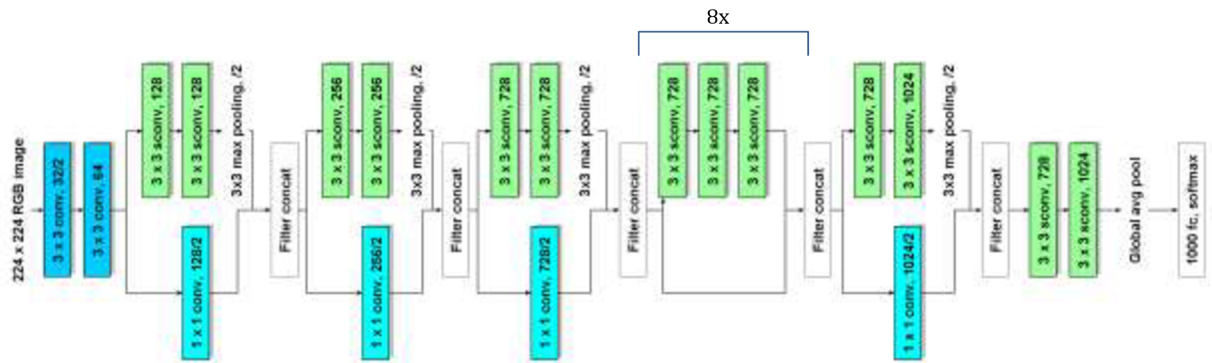
se získem počtu nových signálů, který se shoduje s počtem šířek mateřské vlnky. Obraz je tak nutné výrazně upravit, což zapříčiní zúžení veškerých vzorů podle osy x, a rozšíření z původních 45 řádků na finálních 224 se v obraze rovněž projeví, což je v obrázku číslo 7.21 patrné.



Obr. 7.21 Grafické znázornění originálního signálu (A), originálního skalogramu (B) a upraveného skalogramu do požadovaných rozměru (C)

Poslední část této metody tvoří předučená konvoluční neuronová síť Xception, jejíž váhy jsou opět přednastaveny na základě obrázků databáze ImageNet. Architektura Xception, jejíž popis je vyobrazen na obrázku 7.22, vychází z Inception a do své sítě zahrnuje tzv. hloubkově oddělitelnou konvoluci. Provádí prostorovou korelaci pro každá kanál zvlášť a následně za pomoci 1 x 1 konvoluce zajistí korelaci skrze kanály. Tento princip lze popsat jako detekce

korelací ve 2D prostoru s následnou detekcí korelací v 1D prostoru. Inspirací k využití sítě Xception byla literatura zabývající se podobnou problematikou, která současně označuje architekturu Xception na základě jejich výsledků za efektivnější klasifikátor než VGGNet-19, ResNet-101 a DenseNet-201 [2].




Obr. 7.22 Grafické znázornění architektury Xception, převzato a upraveno z [22]

Předučená síť je opět doplněna o vrstvu poolingů, dvě plně propojené vrstvy proložené vrstvou Dropout. Parametry doplněných vrstev jsou stejné jako nastavení v případě předchozích metod.

Za účelem trénování sítě byly 2/3 dat zařazeny do trénovacího setu, ve kterém se následně prováděla augmentace méně zastoupených skupin, a 1/3 dat byla zařazena do setu testovacího. Všechny skupiny až na skupinu SR byly následně rozšířeny na pětinasobný počet původních dat a tak tvořilo trénovací set přibližně 7000 dat.

Rozhodovací síť byla na těchto datech trénována po dobu 100 epoch s využitím optimalizátoru Nadam s velikostí batche 256. Trénování bylo zprvu realizováno bez použití vah a mělo průběh uvedený na obrázku číslo 7.23, na kterém je popsána změna přesnosti (accuracy) a také hodnoty chyby (loss) v závislosti na počtu epoch.



Obr. 7.23 Průběh učení 3. klasifikačního postupu bez vah

Po dokončení trénování po 100 epochách byla síť testována na testovacím setu tvořeném 2295 daty, rozložených v nerovnoměrně zastoupených skupinách. Klasifikace byla provedena s výsledky uvedenými v tabulce číslo 7.10. Ze kterých je patrné, že takto nastavená klasifikační síť, učená bez použití vah, se z dat tvořený popsaným postupem natrénovala především data ze skupiny SR. Vzhledem k tomu, že skupina SR je mnohem více zastoupená než ostatní skupiny, výsledná hodnota přesnosti (accuracy) je dokonce vyšší než na trénovacích datech. Data skupiny AF síť není takřka schopna detekovat, na rozdíl od zbývajících skupin, které částečně rozlišuje.

Tabulka 7.10 Matice záměn 3. klasifikačního postupu bez vah


Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	11	146	24	2	1
	SR	16	1908	38	3	16
	SVR	5	31	29	0	0
	VR	0	10	2	22	
	Ostatní	0	6	3	5	17

Přesné výsledky efektivity sítě pro klasifikaci jednotlivých skupin jsou uvedeny v tabulce číslo 7.11, ze kterých lze označit klasifikátor za efektivní detektor sinusového rytmu.

Tabulka 7.11 Výsledky efektivity 3. klasifikačního postpu bez vah

Úspěšnost modelu	Přesnost (precision)	Úplnost (recall)	F1 - skóre	Počet dat
AF	0.34	0.06	0.10	184
SR	0.91	0.96	0.93	1981
SVR	0.30	0.45	0.36	65
VR	0.69	0.65	0.67	34
Ostatní	0.50	0.55	0.52	31

Klasifikační síť byla trénována podruhé. Tentokrát bylo navíc využito přidanych vah jednotlivým třídám, upřednostňující především všechny skupiny před skupinou SR. Nastavení epoch, optimalizátoru i velikosti batche se zachovalo. Průběh trénování je vyobrazen na obrázku číslo 7.24. Zachycena je změna přesnosti (accuracy) a hodnoty chyby (loss) s přibývajícím počtem epoch. Při popisu průběhu přesnosti není vyobrazena současně i hodnota přesnosti pro testovací set (test). Důvodem je vysoká fluktuace přesnosti testovacího setu a velmi nízký rozsah změn přesnosti na trénovacím setu (train). Při jejich společném vykreslení by nebyl průběh hodnot přesnosti na trénovacím setu dobře rozlišitelný.



Obr. 7.24 Průběh učení 3. klasifikačního postupu s přidáním vahami

Natrénovaná síť byla opět testována na stejném testovacím setu a při klasifikaci dosahovala výsledků uvedených v tabulce číslo 7.12.

Tabulka 7.12 Matice záměn 3. klasifikačního postupu s přidávanými váhami

Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	97	51	31	5	0
	SR	672	1216	62	25	6
	SVR	24	8	33	0	0
	VR	7	2	2	23	0
	Ostatní	5	0	3	7	16

Z dosažených výsledků je patrné trénování vedoucí ke snaze o rozlišení jednotlivých skupin. Zároveň tento krok vede ke zhoršení původní efektivity při detekci záznamů sinusového rytmu, při trénování bez využití přidávaných vah třídám. Mnoho záznamů ze skupiny SR je považováno za záznamy skupiny AF, což lze považovat za největší problém modelu. Výsledná efektivita při klasifikaci jednotlivých tříd je popsána v tabulce číslo 7.13.

Tabulka 7.13 Výsledky efektivity 3. klasifikačního postupu s přidávanými váhami

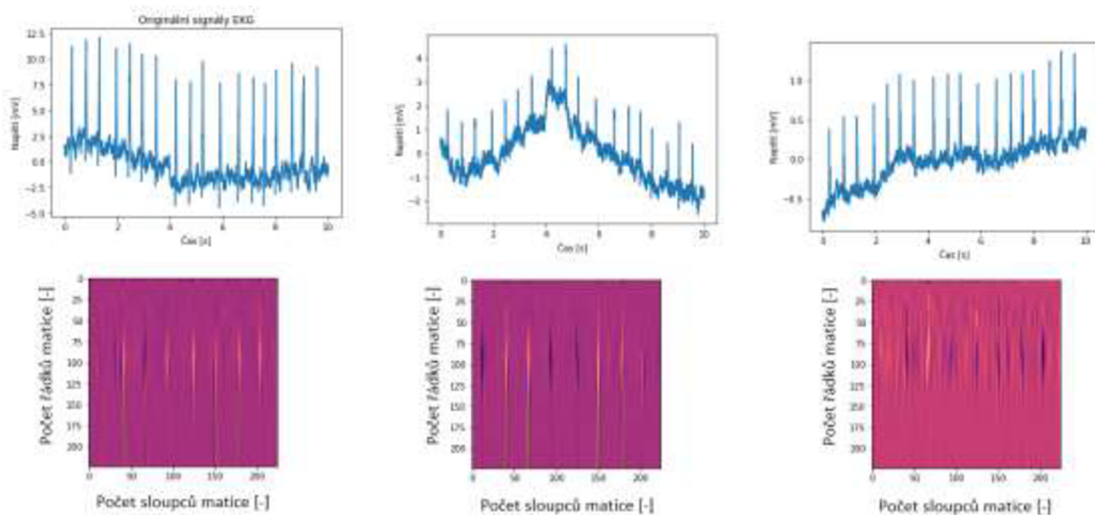
Úspěšnost modelu	Přesnost (precision)	Úplnost (recall)	F1 - skóre	Počet dat
AF	0,12	0,53	0,20	184
SR	0,95	0,61	0,75	1981
SVR	0,25	0,51	0,34	65
VR	0,38	0,68	0,49	34
Ostatní	0,73	0,52	0,60	31

Klasifikace do více skupin zároveň ovšem není dostatečně přesná ani v případě trénování sítě s přidávanými váhami třídám. Daný postup by tedy při trénování bez přidávaných vah bylo možné využít jako kvalitní detektor sinusového rytmu. V případě použitých vah jednotlivým třídám se ovšem nemusí jednat o jejich ideální nastavení a tak by s ideálními hodnotami vah mohlo být dosaženo o něco lepšího výsledku klasifikace do více skupin.

7.6 Klasifikační postup č. 4

Čtvrtý postup je posledním postupem využívající 2D CNN jako klasifikační síť. Na rozdíl od třetího postupu využívá všechny svody, které po standardizaci signálů zpracovává metodou PCA se získáním tří signálů charakterizujících každý záznam. Tento postup je stejný jako u druhého postupu.

Následně jsou tyto signály transformovány do podoby skalogramů. K transformaci je využita stejná funkce a nastavení jako v případě třetí metody. Využívá tedy CWT s mateřskou vlnkou morlet a dilatace od 45 do 1. Rozměry výsledného skalogramu jsou opět převedeny na požadovanou velikost určenou doporučenými vstupními rozměry CNN. Z vytvořených skalogramů, představených na obrázku 7.25, je posléze sestaven 3D obraz o rozměrech 224 x 224 x 3, který se stává vstupem CNN.




Obr. 7.25 Grafické znázornění signálů získaných aplikací PCA a z nich vytvořených výsledných skalogramů

Klasifikační síť je tvořena přepracovanou sítí Xception doplněnou opět o požadované vrstvy jako v předchozích metodách. Zároveň se jedná o poslední postup využívající 2D konvoluční neuronovou síť ke klasifikaci.

Síť byla trénována na trénovací sadě, která tvoří 2/3 ze celého datasetu. Jednotlivé skupiny jsou nerovnoměrně zastoupeny a z toho důvodu byla provedena augmentace méně zastoupených skupin (AF, SVR, VR, Ostatní) na 5násobný počet

jejich dat. Výsledná trénovací sada tak byla tvořena přibližně 8000 daty, ze kterých je 50 % dat ze skupiny SR, 22 % ze skupiny AF a ostatní tři skupiny zajišťují zbylých 28 % dat. Síť byla trénována s aplikací optimalizátoru NADAM, velikostí batche hodnoty 256, po dobu 100 epoch. Prvně byla síť trénována bez přidání vah jednotlivým třídám. Průběh trénování je zachycen na obrázku číslo 7.26 popisující změnu hodnoty přesnosti (accuracy) a hodnoty chyby (loss) na trénovacím (train) a testovacím (test) setu v závislosti na počtu epoch.



Obr. 7.26 Průběh učení 4. klasifikačního postupu bez vah

Po dokončení trénování byla síť otestována a výsledky klasifikace do více tříd na testovacím setu jsou zapsány v tabulce číslo 7.14.

Tabulka 7.14 Matice záměn 4. klasifikačního postupu bez vah

Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	33	242	17	8	0
	SR	81	1861	1	24	14
	SVR	26	35	3	0	1
	VR	1	16	0	17	0
	Ostatní	3	6	0	3	19

Z výsledků klasifikace je patrné, že je síť schopna rozlišit a správně klasifikovat záznamy se sinusovým rytmem a přibližně v polovině případů také


záznamy skupiny VR a skupiny Ostatní. Záznamy skupiny AF a SVR síť neumí správně klasifikovat. Efektivitu sítě pro jednotlivé skupiny blíže popisuje tabulka číslo 7.15.

Tabulka 7.15 Výsledky efektivity 4. klasifikačního postupu bez vah

Úspěšnost modelu	Přesnost (precision)	Úplnost (recall)	F1 - skóre	Počet dat
AF	0.23	0.11	0.15	300
SR	0.86	0.94	0.90	1981
SVR	0.14	0.05	0.07	65
VR	0.33	0.50	0.40	34
Ostatní	0.56	0.61	0.58	31

Natrénovaná síť bez využití přidaných vah vybraným třídám poskytuje možnost efektivní detekce záznamů sinusového rytmu a s větší mírou chyby dokáže klasifikovat i některé záznamy ventrikulárních rytmu a signály ze skupiny Ostatní.

Stejně sestavená síť byla opět trénována, tentokrát ovšem s využitím nastavení vah jednotlivých tříd. Hodnoty vah byly voleny s úmyslem dosáhnout co nejefektivnějšího klasifikátoru do více tříd zároveň a z toho důvodu zvýhodňovaly ostatní skupiny na úkor skupinu SR. Průběh trénování je v podobě grafů závislosti přesnosti (accuracy) a hodnoty chyby (loss) na počtu epoch zaznamenan na obrázku číslo 7.27.



Obr. 7.27 Průběh učení 4. klasifikačního postupu s přidanými vahami

Na průběhu trénování je patré, že když se síť natrénuje lépe klasifikovat záznamy skupiny SR, prudce se zvýší celková přesnost na testovacím setu. Pokud ovšem síť upřednostní klasifikaci ostatních skupin před skupinou SR, dojde k výraznému poklesu celkové přesnosti na testovacím setu, ve kterém tvoří data skupiny SR 82 %. Výsledky klasifikace dat při testování jsou zapsány v tabulce číslo 7.16.

Tabulka 7.16 Matice záměn 4. klasifikačního postupu s přidány váhami

Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	212	55	20	13	0
	SR	981	843	39	118	0
	SVR	34	6	20	5	0
	VR	10	4	2	18	0
	Ostatní	11	1	4	3	12

Klasifikační síť s aktuálním nastavením výrazně upřednostňuje skupinu AF, ovšem ani v případě klasifikace záznamů této skupiny není přesná. Použití vah současně vedlo k výraznému zhoršení schopnosti klasifikace záznamů skupiny SR, což lze současně považovat za největší problém modelu. Klasifikační model se natrénuje přesněji detekovat odlišnosti od sinusového rytmu, což způsobí zvýšený výskyt chybného predikování třídy dat ze skupiny SR a v případě výskytu abnormalit v síních nebo komorách zařadil tyto záznamy do skupiny AF nebo VR, ačkoliv se nemusí přímo jednat o rytmy s fibrilací síní nebo ventrikulární rytmus. Výsledky efektivity klasifikace pro jednotlivé skupiny jsou zapsány v tabulce číslo 7.17.

Tabulka 7.17 Výsledky efektivity 4. klasifikačního postupu s přidáním váhami

Úspěšnost modelu	Přesnost (precision)	Úplnost (recall)	F1 - skóre	Počet dat
AF	0,17	0,71	0,27	300
SR	0,93	0,43	0,58	1981
SVR	0,24	0,31	0,27	65
VR	0,11	0,53	0,19	34
Ostatní	1,00	0,39	0,56	31


Z dosažených výsledků je zřejmé, že aplikace vah jednotlivých tříd do procesu trénování sítě nevedla k zisku výrazně lepšího klasifikátoru a zároveň zhoršila schopnost sítě efektivní detekci záznamů sinusového rytmu. V případě klasifikace záznamů s fibrilací síní je síť v 70 % detekovala a klasifikovala správně, zároveň do této skupiny zařadila i mnoho záznamů, na kterých fibrilace síní není. Je tedy zřejmé, že v případě optimálního nastavení všech parametrů a vyšším zastoupením skupiny AF, v porovnání s nejzastoupenější skupinou, by byla klasifikační síť schopna klasifikovat tyto záznamy přesněji.

Jedním z důvodů těchto chyb může být chybné nastavení vah tříd, které by při nalezení optimálních hodnot vedlo k lepším výsledkům. Při současném nastavení tohoto postupu je tedy vhodnější využít postup pouze jako detektor záznamů skupiny SR, při kterém je klasifikační síť trénována bez využití vah tříd.

7.7 Klasifikační postup č. 5


Vstupem pátého postupu jsou předzpracované signály všech svodů. Signály nevyžadují pro další analýzu transformaci do 2D podoby. Nutný je ovšem zisk pouze jednoho signálu, ať už výběrem jednoho svodu, případně aplikací PCA jako tomu bylo v tomto případě.

Výstupem analýzy hlavních komponent je tedy jeden signál zastupující každé měření, jehož příklad je vyobrazen na obrázku číslo 7.28. Takovýto signál se stává vstupem klasifikační sítě.




Obr. 7.28 Příklad výsledného signálu po aplikaci PCA

Na rozdíl od všech dosavadních postupů využívá pátý postup jako klasifikační síť modifikovanou alternativu 2D konvolučních neuronových sítí tzv. 1D CNN, blíže vysvětlenou v kapitole 6.2. Samotná síť je tvořena sedmi konvolučními vrstvami s následujícími parametry. První dvě vrstvy jsou tvořeny 256 filtry s délkou okna 15 v první vrstvě a 12 ve vrstvě druhé. Další vrstvy sestaveny ze 128 filtrů a postupně klesající délkou okna od délky 9 po délku okna rovnu třem. Všechny konvoluční vrstvy využívají aktivační funkci ReLu a za každou konvoluční vrstvou následuje vrstva max-poolingu s velikostí okna 3 a vrstva Dropout s pravděpodobností deaktivace ve 40 %. Síť je následně zakončena vrstvou poolingů využívající celkový průměr a výsledek je vstupem pro poslední vrstvu, kterou je plně propojená vrstva s aktivační funkcí softmax. Grafické znázornění architektury celého modelu je vyobrazena na obrázku číslo 7.29.



Obr. 7.29 Grafické znázornění použité architektury 1D CNN

Tato vytvořená síť byla trénována na 6140 datech, ze kterých 3000 tvořila data skupiny SR. Za pomoci augmentace dat byly všechny ostatní skupiny rozšířeny na pětinasobek původního množství dat, čímž byl zajištěn poměr jednotlivých skupin přibližně 30,0 : 49,0 : 10,5 : 5,5 : 5,0. Model byl trénován 250 epoch a využíval optimalizátoru Nadam s nastavenou velikostí batche na hodnotu 256. Při trénování bylo rovněž využito vah tříd výrazně upřednostňující všechny skupiny před skupinou SR. Průběh učení sítě je reprezentován vývojem celkové přesnosti (accuracy) a hodnoty chyby (loss) v závislosti na přibývajícím počtu epoch. Grafické znázornění je uvedeno na obrázku číslo 7.30.



Obr. 7.30 Průběh učení 5. klasifikačního postupu s přidávanými vahami

Z grafického znázornění průběhu učení je patrná výrazná fluktuace hodnoty přesnosti. Tu se nepodařilo odstranit ani při odlišném nastavení velikosti batche, které se testovalo od hodnoty 32 po hodnotu 512. Ani změna rychlosti učení optimalizátoru Nadam z původní hodnoty 0,001 na hodnotu až o 2 řády nižší také nevedla ke snížení fluktuace. Natrénovaný model byl otestován na testovacím setu tvořeným 2295 záznamy. Dosahoval celkové přesnosti 85 % a výsledky klasifikace do jednotlivých skupin jsou uvedeny v tabulce číslo 7.18.

Tabulka 7.18 Matice záměn 5. klasifikačního postupu s přidávanými vahami

Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	153	25	4	2	0
	SR	220	1688	26	21	26
	SVR	10	8	46	1	0
	VR	3	0	0	30	1
	Ostatní	1	2	0	0	28

Z dosažených výsledků je patrné, že se síť natrénovala k detekci záznamů nejen nejpočetnější skupiny, ale dokáže klasifikovat i ostatní skupin. Konkrétní úspěšnost, které síť dosahuje při klasifikaci jednotlivých skupin, je uvedena v tabulce číslo 7.19.

Tabulka 7.19 Výsledky efektivity 5. klasifikačního postupu přidanými váhami

Úspěšnost modelu	Přesnost (precision)	Úplnost (recall)	F1 - skóre	Počet dat
AF	0,40	0,83	0,54	184
SR	0,98	0,85	0,91	1981
SVR	0,61	0,71	0,65	65
VR	0,56	0,88	0,68	34
Ostatní	0,51	0,90	0,65	31

Konkrétní výsledky i přes určitou úroveň chyby potvrzují efektivitu postupu při klasifikaci do více skupin. Je tedy možné tento postup využít nejenom k detekci vybraného rytmu, ale přímo ke klasifikaci mezi naučené rytmy.


Při tvorbě postupu číslo pět bylo využito mnoha poznatků nastavení parametrů z předchozích postupů, jako například aplikace PCA, nastavení učících parametrů modelu atd. Odlišné bylo nastavení velikosti oken jednotlivých 1D konvolučních vrstev, které byly postupně snižovány s přibývajícím počtem vrstev. Inspirací při tvorbě této sítě byl postup zabývající se podobnou problematikou, popsany ve článku [30], který rovněž dosáhl vytvoření modelu vhodného k detekci vybraných rytmů. Dalším specifíkem dané metody byly hodnoty vah jednotlivých tříd využívané při trénování sítě, jenž se nastavovaly experimentálně.

7.8 Klasifikační postup č. 6

Šestý postup, stejně jako například postup pátý, využívá PCA k získání požadovaného počtu signálů ze všech svodů, které jsou již předzpracovány. Z původních osmi signálů každého měření jsou aplikací PCA získány 3 signály nesoucí informace ze všech svodů. Jak již bylo výše uvedeno, tyto signály se v některých případech výrazně neliší, i přesto byly zvoleny 3 signály se snahou poskytnout větší množství informace.


Klasifikační síť je v tomto postupu realizována rekurentní neuronovou sítí, a proto se opět neprovádí transformace dat do podoby spektrogramu, skalogramu, či jiné reprezentace. RNN konkrétně architektura LSTM je sestavena z následujících

částí. Síť je tvořena 4 vrstvami a každá vrstva je tvořena jiným počtem jednotek. První dvě jsou složeny z 512 jednotek, následující z 256 a poslední vrstva tvořena 128 jednotkami. Jednotlivé vrstvy jsou proloženy DropOut vrstvami. Celá architektura, jejíž schéma je znázorněno na obrázku číslo 7.31, je ukončena třemi plně propojenými vrstvami. Výstupem první FC vrstvy je vektor 512 příznaků, výstup druhé FC vrstvy má délku vektoru příznaků 64 a z důvodu klasifikace do pěti tříd má poslední FC vrstva opět délku 5.



Obr. 7.31 Grafické znázornění použité architektury LSTM

Za účelem trénování klasifikační sítě byla sestavena trénovací sada dat získaná ze 2/3 původních dat. Ta byla navíc rozšířena augmentací méně zastoupených skupin. Výsledný počet trénovacích dat tak po rozšíření všech skupin na 5násobek, výjma skupiny SR, u které bylo omezeno množství dat na 3000 záznamů, činil 6140 záznamů. Všechny 5 skupin tvořících trénovací set bylo přibližně v následujícím poměru 30,0 : 49,0 : 10,5 : 5,5 : 5,0. Model byl na tomto setu dat trénován po dobu 750 epoch. Pro efektivní učení byl využit optimizer Nadam. Velikost batche byla nastavena na hodnotu 400 a se snahou vytvořit co nejefektivnější klasifikátor, byly využity také váhy jednotlivých tříd. Grafy popisující průběh učení jsou vyobrazeny na obrázku číslo 7.32. Popisují hodnotu přesnosti (accuracy) a hodnotu chyby (loss) v závislosti na počtu epoch.



Obr. 7.32 Průběh učení 6. klasifikačního postupu s přidávanými váhami

Na obrázku číslo 7.32 popisující průběh celkové hodnoty přesnosti je patrný pokles hodnoty na testovací sadě z původních skoro 90 % přesnosti na hodnotu 75 %. Důvodem je postupné trénování sítě, která se učí klasifikovat nejen skupinu SR, ale i ostatní skupiny. Dochází k poklesu hodnoty celkové přesnosti na testovacím setu, model se stává více efektivní pro klasifikaci do více skupin a zároveň s tím mírně klesá přesnost klasifikace záznamů skupiny SR.

Natrénovanou síť se testovalo na 2295 datech. Podle výsledků klasifikace, které jsou také uvedeny v tabulce číslo 7.20, se dobře naučila detekovat záznamy sinusového rytmu a také je ve většině případů správně klasifikovala do skupiny SR. Záznamy ostatních skupin síť rovněž detekovala, ale na rozdíl od klasifikace skupiny SR dosahovala v případě ostatních skupin velké chybovosti.

Tabulka 7.20 Matice záměn 6. klasifikačního postupu s přidávanými váhami

Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	94	78	9	2	1
	SR	253	1590	81	49	8
	SVR	10	27	27	1	0
	VR	6	8	2	16	2
	Ostatní	5	10	1	1	14

Klasifikátor byl tedy nejefektivnější při detekci záznamů sinusového rytmu, zatímco rozpoznávání záznamů ostatních skupin bylo úspěšné přibližně v 50 % případech. Přesné výsledky efektivity postupu při klasifikaci jednotlivých skupin jsou uvedeny v tabulce číslo 7.21.

Tabulka 7.21 Výsledky efektivity 6. klasifikačního postupu s přidáním vahami

Úspěšnost modelu	Přesnost (precision)	Úplnost (recall)	F1 - skóre	Počet dat
AF	0,26	0,51	0,34	184
SR	0,93	0,80	0,86	1981
SVR	0,23	0,42	0,29	65
VR	0,23	0,47	0,31	0,34
Ostatní	0,56	0,45	0,50	31

Realizovaný postup je vhodný především k detekci sinusového rytmu a současně má potenciál při klasifikaci do více skupin. Zároveň výsledky a průběh učení naznačují možnost, že klasifikační model je předimenzovaný, tedy obsahuje příliš mnoho jednotek. Další možnou úpravou by bylo podvzorkování signálu, aby se důležité informace ze začátku signálu měly vliv i na analýzu konce signálu.

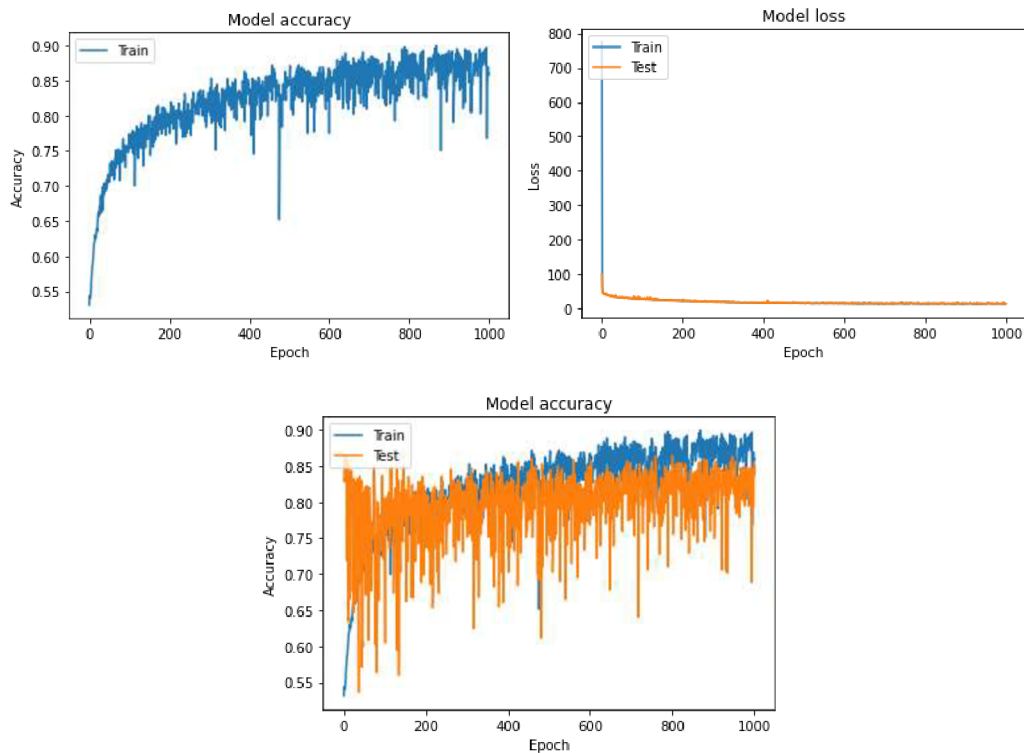
Nové parametry, které bylo nutné testovat a nastavit na ideální hodnotu, jsou spojeny s tvorbou architektury sítě a následně jejím trénováním. Za účelem zachovat větší množství informace ze vstupních dat, byla trénovací data tvořena třemi signály a tento počet je možné dále upravovat. Výběr právě tří signálů je spojen s výběrem tří nejhodnotnějších svodů a také větším množstvím použité informace než v případě výběru pouze jednoho signálu, což je možnost, která by se v případě aplikace RNN nabízela. Dalším důležitým krokem byla tvorba sítě inspirovaná na základě literatury [34], aplikující rovněž větší množství vrstev LSTM za účelem klasifikace záznamů EKG. Posledním parametrem nutným k aktualizaci pro daný postup byly přidány váhy třídám zvýhodňující především skupiny SVR, VR a skupinu Ostatní. Ty byly opět aplikovány za účelem dosažení co nejefektivnějšího modelu sloužícího ke klasifikaci do více tříd zároveň. Toho bylo

s určitou mírou chyby dosaženo, jelikož se síť natrénovala schopnosti rozlišit přibližně polovinu záznamů správně i v případě nejméně úspěšné skupiny.

7.9 Klasifikační postup č. 7

Sedmý postup se od předchozího šestého příliš neliší. Ke změně dochází hned na začátku, kde namísto využití všech svodů a následné aplikaci PCA jsou vybrány pouze tři svody. Jedná se opět o svody II, V1 a V5, které se stávají vstupními daty klasifikační sítě LSTM. Architektura sítě je rovněž realizována stejně jako v šestém postupu.

Pro trénování klasifikační sítě byla připravena trénovací sada dat získaná z 90 % původních dat a dále rozšířena augmentací méně zastoupených skupin. Výsledný počet trénovacích dat tak po rozšíření skupiny AF na čtyřnásobek, omezení počtu dat skupiny SR na 4000 záznamů a rozšíření ostatních skupin na pětinasobek, činil 7249 záznamů. Všechny zastoupené skupiny v trénovacím setu byly přibližně v poměru 20,5 : 55,0 : 12,0 : 6,5 : 5,5. Využitím trénovací sady byl model trénován po dobu 1000 epoch a úprava vah jednotlivých vrstev byla zajišťována optimizérem Nadam s nastavenou velikostí batche na hodnotu 256. Při trénování byly opět využity váhy tříd a to za účelem dosažení co nejefektivnějšího výsledku klasifikátoru. Průběh učení je znázorněn na obrázku číslo 7.33 popisující průběh celkové přesnosti (accuracy) naučení sítě a hodnoty chyby (loss) v závislosti na přibývajícím počtu epoch.



Obr. 7.33 Průběh učení 7. klasifikačního postupu s přidávanými vahami

Pro přehlednost je navíc vyobrazen průběh hodnoty přesnosti pro trénovací sadu samostatně, na kterém je možné pozorovat postupné zlepšení od původní celkové přesnosti 55 % po výslednou celkovou přesnost 85 %. Na průběhu hodnoty přesnosti v případě testovacích dat a částečně i trénovacích lze pozorovat výraznou fluktuaci při procesu učení. Pro odstranění tohoto problému byly vyzkoušeny různé hodnoty velikosti batche, dále i odlišné typy optimalizátorů jako například Adam i snížení rychlosti učení. Změny ovšem nevedly ke snížení míry fluktuace bez poklesu celkové hodnoty přesnosti, neboť je tento problém způsoben především nerovnoměrným zastoupením skupin testovací sady. Z toho důvodu je i pro další postup využíváno stávající nastavení.

Natrénovaná síť na testovacích 687 datech nedosahovala perfektních výsledků jako klasifikátor do pěti různých skupin. Současně byla schopna efektivně detekovat a správně klasifikovat záznamy skupiny SR. Při klasifikaci do ostatních skupin se chyba zvyšovala, přesto zajistila správnou klasifikaci i nejméně naučené skupiny přibližně ve 40 % případů. Výsledky klasifikace dané sítě jsou uvedeny v tabulce číslo 7.22.

Tabulka 7.22 Matice záměn 7. klasifikačního postupu s přidávanými váhami

Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	22	33	0	0	0
	SR	30	535	18	7	4
	SVR	0	12	7	0	0
	VR	0	3	0	7	0
	Ostatní	0	3	1	0	5

Nejlépeších výsledků dosahoval tento postup při řešení problému detekce a klasifikace sinusových rytmů. Efektivita klasifikace jednotlivých skupin je popsána v tabulce číslo 7.23.

Tabulka 7.23 Výsledky efektivity 7. klasifikačního postupu s přidávanými váhami

Úspěšnost modelu	Přesnost (precision)	Úplnost (recall)	F1 - skóre	Počet dat
AF	0,42	0,40	0,41	55
SR	0,91	0,90	0,91	594
SVR	0,27	0,37	0,31	19
VR	0,50	0,70	0,58	10
Ostatní	0,56	0,56	0,56	9

Takto realizovaný postup není ideální využít ke klasifikaci pro všechny skupiny. Zároveň je zřejmé, že při optimálním nastavení veškerých parametrů a s větším množstvím dat méně zastoupených skupin, by v klasifikaci do všech skupin mohlo dojít ke zlepšení současných výsledků. Klasifikační síť s aktuálním nastavením by mohla být využita pro detekci sinusového rytmu, ovšem i v této úloze chybovala v 10 % případů. Pokud by bylo záměrem vytvořit právě tento detektor, snazší realizací by bylo provést trénování sítě bez přidávaných vah tříd, u kterých je nutné najít jejich ideální hodnoty. V takovém případě natrénovaná síť

po 1000 epochách se stejně nastavenými parametry jako je velikosti batche, výběr optimalizéru atd. provedla klasifikaci jejíž výsledky jsou uvedeny v tabulce 7.24.

Tabulka 7.24 Matice záměn 7. klasifikačního postupu bez vah


Matice záměn		Třídy předikované modelem				
		AF	SR	SVR	VR	Ostatní
Skutečné třídy	AF	21	28	3	1	2
	SR	24	527	41	2	0
	SVR	1	14	4	0	0
	VR	1	5	1	2	1
	Ostatní	1	3	0	0	5

Z výsledků je patrné, že takto natrénovaný model tedy není vhodný pro klasifikaci do více skupin. Pro účely detektoru záznamů sinusového rytmu dosahuje přesnosti (precision) o hodnotě 0,91, úplnost (recall) dosahuje hodnoty 0,89 a F1-skóre je 0,90. Výsledky efektivity klasifikace dat skupiny SR se tedy výrazně neliší od výsledků sítě, která se trénovala s přidávanými váhami skupin a zároveň nebylo nutné určit hodnoty těchto vah.

7.10 Srovnání použitých postupů

Jednotlivé postupy dosahují rozdílných výsledků jak v případě řešení klasifikace záznamů do pěti skupin, tak i při jejich potencionálním využití v podobě detekce vybraného rytmu. Pro následující porovnání jsou vybrána nastavení, jenž vedla k co nejlepší klasifikaci do více tříd současně.

Výsledky přesnosti (precision) klasifikace jednotlivých postupů do pěti skupin jsou za účelem porovnání vyobrazeny na obrázku číslo 7.34.




Obr. 7.34 Porovnání úspěšnosti jednotlivých klasifikačních postupů na základě hodnoty přesnosti (precision)

Z výsledků přesnosti lze poznamenat, že všechny modely dosahují vysoké přesnosti při klasifikaci SR. To znamená, že jednotlivé modely označí záznam skupiny AF, SVR, VR nebo Ostatní za data skupiny SR. Po porovnání výsledků lze označit za nejúspěšnější metodu číslo 5 (PCA → 1D CNN), u které dosahuje přesnost vysokých hodnot, a to současně u všech skupin (především SR). Další metoda, která dosahuje dobrých výsledků přesnosti je metoda číslo 7 (3 EKG → LSTM). Hodnoty přesnosti rovněž dosahují vysokých hodnot, až na skupinu SVR. Tento výsledek značí, že naučená síť považuje za záznamy skupiny SVR i mnoho záznamů ostatních skupin. Nízké hodnoty přesnosti většiny klasifikačních postupů všech skupin s výjimkou skupiny SR značí nižší schopnost správné klasifikace spojené se zařazením záznamů ostatních skupin do skupiny analyzované.

Dalším parametrem, na základě kterého lze porovnat úspěšnost metod při klasifikaci do více tříd současně, je hodnota úplnosti neboli recall. Porovnání je

realizováno v grafické podobě na obrázku číslo 7.35 a vysoká hodnota značí, že data vybrané skupiny dokáže ve většině případů model správně označit za data příslušné skupiny. Tedy například v případě nízké hodnoty úplnosti pro skupinu AF jsou v mnoha případech data skupiny AF klasifikována do jiných skupin.




Obr. 7.35 Porovnání úspěšnosti jednotlivých klasifikačních postupů na základě hodnory úplnosti (recall)

Za nejúspěšnější postup na základě hodnoty úplnosti všech tříd lze označit číslo 5 (PCA → 1D CNN). Ve kterém klasifikační síť detekovala data příslušných skupiny s více než 80% hodnotou úplnosti. Výjimku tvoří skupina SVR, u které bylo téměř 30 % dat skupiny SVR klasifikováno jako data jiných skupin, a hodnota úplnosti tak byla přibližně 70 %. Další klasifikační postupy z hlediska hodnoty úplnosti nedosahují tak kvalitních výsledků současně u všech skupin. V případě některých metod jsou sice hodnoty úplnosti přibližně rovnoměrně zastoupené u všech skupin, ovšem dosažené hodnoty jsou značně nižší. Například postup číslo 3 (3 EKG → skalogram → CNN), který zařadí data

například skupiny AF s více než 50% přesností mezi záznamy skupiny AF a stejně tomu je u dalších skupin. Dalším takovýmto postupem je číslo 6 (PCA → LSTM), u kterého dosahují všechny skupiny hodnoty úplnosti mezi 40 % a 50 %, až na skupinu SR, u které není pouze 20 % záznamů skupiny SR zařazeno do správné skupiny. Odlišného výsledku dosáhly postupy 1, 2, 4 a 7, v jejichž případě rozezná klasifikační síť data příslušné skupiny s vysokou přesností, popsanou hodnotou úplnosti, pouze pro omezený počet skupin. Příkladem může být postup číslo 7 (3 EKG → LSTM), který data skupiny SR v 90 % klasifikuje za data skupiny SR a data skupiny VR jako data skupiny VR v 70 %, ovšem při klasifikaci ostatních skupin je zařazeno správně méně než 60 % pro každou skupinu. Provádí tedy korektní detekci dat dvou skupin a zbývající skupiny klasifikuje s vysokou mírou chyby.


Posledním parametrem udávající míru přesnosti pro porovnání jednotlivých postupů při více skupinové klasifikaci je hodnota F1 – skóre. Graf s číslem 7.36 popisuje dosažené hodnoty jednotlivých postupů při klasifikaci pěti skupin. Nejlepších výsledků opět dosáhl postup číslo 5. Zároveň je patrné, že výsledky využívající 2D konvoluční neuronové sítě dosahují horších výsledků F1 – skóre než postupy 5 (PCA → 1D CNN), 6 (PCA → LSTM) a 7 (3 EKG → LSTM) a stejně jako u předchozích parametrů i hodnota F1-skóre je nejvyšší u všech klasifikačních postupů při klasifikaci skupiny SR.




Obr. 7.36 Porovnání úspěšnosti jednotlivých klasifikačních postupů na základě hodnoty F1-skóre

Za účelem klasifikace do jednotlivých tříd současně je vybrán jako nejúspěšnější klasifikační postup číslo 5 na základě hodnot F1-skóre, úplnosti a přesnosti.


Jednotlivé postupy lze také porovnat na základě jejich schopnosti detekce vybraného rytmu, kterým je rytmus nejpočetnější skupiny. Ten se jednotlivé klasifikační sítě natrénují identifikovat a správně klasifikovat. V našem případě se jedná o záznamy se sinusovým rytmem. Za účelem hodnocení úspěšnosti postupů jako detektoru dat skupiny SR jsou vybrány první 4 postupy trénované bez přidání vah jednotlivých skupin a zbylé 3 trénované s přidáními váhami jednotlivým skupinám. Na základě výsledků úspěšnosti detekce a klasifikace dat skupiny SR se žádný postup výrazně neliší od ostatních. Porovnání postupů je graficky znázorněno na obrázku 7.37 za pomoci tří grafů, reprezentujících dosažené hodnoty přesnosti, úplnosti a F1-skóre všech klasifikačních postupů.



(A)



(B)




(C)

Obr. 7.37 Grafické znázornění efektivity klasifikačních postupů při detekci skupiny SR na základě hodnoty: (A) přesnosti (precision), (B) úplnosti (recall), (C) F1-skóre


Z grafické reprezentace je zřejmé, že všechny uvedené postupy jsou schopny provádět detekci sinusového rytmu. Na základě hodnoty přesnosti (precision) je neúspěšnější postup číslo 5 (PCA → 1D CNN) s hodnotou 98 %. Dalšími úspěšnými postupy s hodnotou přesnosti nad 90 % jsou metody číslo 3, 6 a 7. Srovnání metod na základě dosažené úplnosti (recall) označuje za nejúspěšnější 1. postup (3 EKG → spektrogram → CNN). Všechny metody využívající klasifikační síť 2D konvoluční neuronovou síť dosáhly hodnoty úplnosti nad 90 %, na rozdíl od zbývajících metod. Ty dosahovaly hodnot mezi 80 % a 90 % úplnosti. Posledním parametrem, na základě kterého jsou metody při detekci dat skupiny SR porovnány, je hodnota F1 – Skóre. Všechny postupy dosáhly při klasifikaci dat skupiny SR hodnoty F1-skóre mezi 0,85 a 0,95. Nejúspěšnější je metoda 3. postup (3 EKG → skalogram → CNN) s hodnotu F1-skóre 0,93 a dále metody 5. a 7. dosáhly F1 – skóre s hodnotou vyšší než 0.9. Za účelem detektoru dat skupiny SR lze označit za nejefektivnější klasifikační postup číslo 3.

Konkrétní porovnání úspěšnosti postupů při klasifikace do více skupin na základě F1 skóre hodnotící klasifikaci jednotlivých skupin je vyobrazeno na obrázku číslo 7.38 v podobě tří grafů. Ty postupně znázorňují hodnotu F1 skóre dosaženou jednotlivými postupy při klasifikaci skupiny AF, SVR a VR.



(A) - AF

(B) - SVR



(C) - VR

Obr. 7.38 Grafické znázornění efektivity klasifikačních postupů na základě hodnoty F1-skóre při detekci dat skupiny: (A) AF, (B) SVR, (C) VR

Grafické znázornění dosažených výsledků tak přehledněji popisuje nižší míru efektivity klasifikace do více skupin. Z výsledků je patrné, že nejúspěšnějším je 5. postup, jenž dosahoval nejvyššího F1-skóre u všech skupin. Dále také, že efektivita postupů je pro jednotlivé skupiny rozdílná. Jako například 7. klasifikační postup (3 EKG → LSTM) jenž při klasifikaci skupiny VR dosahoval hodnoty F1-skóre 0,58, ovšem v případě skupiny AF bylo F1-skóre 0,41 a pro skupinu SVR bylo pouze 0,31. Výsledky tedy potvrzují náročnost klasifikace do více skupin současně, a to především při snaze dosažení kvalitních výsledků u všech skupin. Což dokládají i výsledky nejefektivnějšího 5. postupu, který měl v případě skupiny VR F1-skóre 0,68, zatímco u skupiny AF pouze 0,54.

Klasifikační postupy lze porovnat i jiným způsobem než na základě dosažených výsledků, porovnáním podle **časové náročnosti**. Jelikož se časová náročnost odvíjí také od použitého hardwaru, výkonné výpočetní zařízení je schopno aplikovat realizované klasifikační postupy v jiném čase. Uvedené výpočetní doby byly stanoveny při aplikaci klasifikačních postupů v Google Colab Pro a jsou zaneseny do tabulky číslo 7.25. Jedná se o orientační výpočetní časy od zahájení předzpracování dat po dokončení 100. trénovací epochy klasifikačního modelu při současném nastavení všech parametrů. Tato doba je označena jako celkový výpočetní čas a je doplněna o informaci, kolik minut z celkového výpočetního času trvalo trénování jednotlivých klasifikačních modelů.

Tabulka 7.25 Výpočetní časy klasifikačních modelů

Klasifikační metody	Celkový výpočetní čas	Doba trénování modelu	Architektura klasifikačního modelu
1	1h 7 min	50 min	ResNet152V2
2	1h 8 min	50 min	ResNet152V2
3	2h 12 min	35 min	Xception
4	2h 12 min	35 min	Xception
5	22 min	16,5 min	1D CNN
6	8 min	2 min	LSTM
7	8 min	2 min	LSTM

Nejrychlejší jsou klasifikační postupy číslo 6 a 7, u kterých je velmi rychlé i trénování modelu v porovnání s ostatními postupy. Nejvíce času je u postupů 5, 6 a 7 ušetřeno eliminací transformace dat do 2D matice. V případě prvních 4 postupů by bylo možné ušetřit čas optimálnější transformací dat a také výběrem architektury, která není tak hluboká a její doba trénování je tak nižší.

8 DISKUZE


Optimalizace většího množství klasifikačních postupů je časově náročná a vyžaduje i jisté zkušenosti při nastavování určitých parametrů. Těmi jsou například poměr dat po rozdělení na trénovací a testovací sadu, míra augmentace dat, výběr vhodných frekvencí a míra předzpracování dat, v případě postupů využívající jako klasifikační síť 2D CNN i nastavení parametrů vedoucích k vhodné transformaci dat do 2D matice. Další parametry, které je nutné nastavit tak, aby se co nejvíce blížily k optimálnímu nastavení, jsou spojeny s klasifikačními sítěmi a je to počet vrstev, počet filtrů v jednotlivých konvolučních vrstvách, počet jednotek vrstev RNN, ale také počet trénovacích epoch, výběr optimalizátoru, velikosti batche, při aplikaci vah jednotlivých tříd také tyto váhy, které byly v našem případě u jednotlivých modelů nastavovány ručně na základě výsledků s předchozí hodnotou vah.

V rámci jednotlivých klasifikačních postupů byly vyzkoušeny různé hodnoty těchto parametrů. V některých případech byl použit i rozdílný poměr počtu trénovací a testovací sady dat. Cílem bylo dosáhnout lepšího trénování modelu, případně důvěryhodnějšího výsledku testování, ačkoliv tento krok nezajišťuje zcela ideální podmínky pro vzájemné zhodnocení modelů.

Z dosažených výsledků je zřejmý potenciál hlubokého učení při klasifikaci srdečních rytmů a také detekci vybraného rytmu. Pro účely detekce vybraného rytmu mohou být použita i data nerovnoměrně zastoupených skupin, pokud je nejpočetnější skupinu ta, na jejíž data bude cílem vytvořit detektor. Za účelem klasifikace do více tříd zároveň by bylo ideální rovnoměrné zastoupení všech skupin. Takové zastoupení v případě srdečních rytmů, ovšem není zajištěno ani v populaci. Pokud by tedy byly skupiny zastoupeny ve stejném poměru, v jakém se vybrané rytmy vyskytují v populaci, klasifikační modely by se velmi pravděpodobně natrénovaly pouze na detekci nejpočetnější skupiny a nebyly by schopny ostatní rytmy klasifikovat. Právě nedostatek záznamů některých skupin lze považovat za hlavní problém při tvorbě klasifikačního modelu, od kterého je požadována klasifikace do více tříd. Jakmile by byly dostupné hojně a rovnoměrně zastoupené všechny skupiny, které by model klasifikoval,

pravděpodobně by to vedlo ke zlepšení i všech vypracovaných klasifikačních postupů.

Použitím argumentace a vah jednotlivých tříd se podařilo tento problém částečně eliminovat. Klasifikační modely tak částečně rozlišovaly jednotlivé rytmy, zároveň velmi často klasifikovaly data například skupiny SR za data jiných skupin, jakmile byly odlišné od většiny záznamů skupiny SR, jako příklad je uveden záznam na obrázku číslo 8.1.



Obr. 8.1 Příklad chybně klasifikovaného signálu skupiny SR do skupiny AF

Na tomto příkladu je patrné zkreslení signálu způsobené pravděpodobně šumem vyšších frekvencí, který zakrývá běžný průběh izoliny a v některých případech i vlnu P, zároveň se nejedná ani na základě anotace lékařů o signál s fibrilací síní. Signál se tím diferencuje od většiny dat skupiny SR. A právě snížení přesnosti klasifikace dat nejpočetnější skupiny při trénování klasifikace do více tříd je dalším problémem, který je současně spojen s problémem nerovnoměrného zastoupením jednotlivých skupin. Po trénování klasifikace do více skupin jsou některé záznamy nejpočetnější skupiny odlišné od většiny dat své skupiny a na základě některého projevu je začne model klasifikovat chybně do jiné skupiny.

Na závěr bylo provedeno také porovnání s publikovanými pracemi zabývajícími se rovněž klasifikací EKG záznamů. Porovnála se uvedená hodnota

dosažené celkové přesnosti (accuracy) klasifikace. Za tímto účelem byl zvolen nejúspěšnější klasifikační postup číslo 5 s hodnotou celkové přesnosti (accuracy) přibližně 85 %. Porovnán byl s klasifikační metodou využívajícího náhodného lesa pro klasifikaci do pěti skupin (tento postup je blíže popsán v kapitole 5) a také postup aplikující rovněž model hlubokého učení, který ovšem klasifikoval pouze do dvou tříd a byl tak pouze detektorem vybraného rytmu, jehož záznamy tvořily celou jednu skupinu (detailnější popis v kapitole 6.4). Dosažené výsledky v porovnání s těmito postupy nejsou zcela ideální, neboť postup využívající náhodného lesa dosáhl celkové přesnosti přibližně 92 % a postup se sítí hlubokého učení dokonce 98 %, ovšem klasifikace do více tříd zároveň je v porovnání s binární klasifikací pro model složitější.

Největší potenciál mají tedy dle dosažených výsledků v této problematice postupy využívající 1D CNN a také RNN. Jedním z důvodů je například eliminace nutnosti přípravy dat ve 2D matici, která musí být navíc při využití efektivnějších předučených sítí v požadovaných rozměrech a jejich tvorba při větším množství dat je rovněž časovou zátěží. RNN jsou navíc přímo specializovány na analýzu sekvencí, a proto se přímo nabízí jejich využití při práci s 1D EKG signály.

Za účelem dosažení vyšší efektivity při klasifikaci do více tříd by mohla vést k dobrým výsledkům kombinace jednotlivých postupů. Vytvořením tedy podobné varianty jako je náhodný les, jenž využívá větší množství klasifikátorů se ziskem jednoho přesnějšího výsledku.

Další variantou inovace jsou hybridní sítě složené z konvoluční a následně rekurentní neuronové sítě. Podle využitých architektur získávají název CNN – LSTM, CNN – GRU atd. V poslední době se také vyvíjí a nabývají na oblíbenosti také tzv. transformery, které využívají konvoluční neuronové sítě inovované o paměť důležitých informací. Lze tak předpokládat jejich rozšíření i na problematiku klasifikace srdečních rytmů či poruch.

9 ZÁVĚR

Při realizaci klasifikačních postupů se podařilo vytvořit sedm variant, které jsou schopny efektivní detekce dat nejpočetnější skupiny, kterou jsou záznamy sinusového rytmu. Nejefektivnějším byl postup tvořený 2D konvoluční neuronovou sítí, do které vstupovaly předzpracované signály transformované do 2D matice ve formě skalogramů. Tento postup dosahoval hodnoty přesnosti (precision) 0,91, úplnosti (recall) 0,96 a hodnotou F1-skóre 0,93.

Cíle, kterého se nepodařilo zcela dosáhnout, bylo vytvoření klasifikačního postupu schopného klasifikace pěti skupin dat s vysokou přesností predikce všech tříd. Nejblíže se tomuto cíli přiblížil 5. klasifikační postup s hodnotami přesnosti (precision) vyššími než 40 % u všech skupin, úplnosti (recall) nad 70 % u všech skupin a hodnotou F1-skóre vyšší než 0,6 u všech skupin kromě záznamů s fibrilací síní, u kterých byla hodnota F1-skóre pouze 0,54.

Z výsledků je patrné, že vytvoření klasifikačního postupu schopného efektivní klasifikace více skupin nebylo zcela dosaženo. Zároveň lze z výsledků označit za efektivnější klasifikátory pro více skupin ty využívající RNN a 1D CNN na rozdíl od postupů aplikujících transformaci dat do 2D matice a následnou 2D CNN. Co ovšem nelze z výsledků potvrdit, je vliv aplikace PCA na výsledky trénování klasifikačních sítí. Nelze tedy stanovit, zda využití signálů získaných za pomoci PCA vede vždy k efektivnějšímu trénování sítě či nikoliv. Stejně tak nelze označit efektivnější volbu transformace dat do 2D matice, jelikož metody využívající spektrogramy jako vstupní data klasifikační sítě dosahovaly o něco vyšších hodnot přesnosti (precision), zatímco postupy využívající skalogramy měly vyšší hodnoty úplnosti (recall).

Při klasifikaci většího počtu skupin nejúspěšnějším 5. klasifikačním postupem bylo dosaženo celkové přesnosti (accuracy) přibližně 85 %. V porovnání s jinými publikovanými pracemi, které dosáhly celkové přesnosti 92 % rovněž při klasifikaci do 5 skupin a 98 % při klasifikaci pouze do dvou skupin, lze označit námi vytvořený postup za variantu, která má určitý potenciál k dalšímu rozvoji.

Stávající postupy by bylo možné inovovat o nové způsoby úpravy dat před vstupem do neuronových sítí nebo samotnou úpravou sítí s využitím hybridních sítí, kombinací jednotlivých postupů inspirovanou náhodným lesem nebo aplikací transformerů.

Literatura

- [1] ACKERMANN, Nils. Introduction to 1D Convolutional Neural Networks in Keras for Time Sequences. Medium [online]. 2019, 4 Sep 2018 [cit. 2020-05-26]. Dostupné z: <https://blog.goodaudience.com/introduction-to-1d-convolutional-neural-networks-in-keras-for-time-sequences-3a7ff801a2cf>
- [2] BYEON, Yeong-Hyeon a Keun-Chang KWAK. Pre-Configured Deep Convolutional Neural Networks with Various Time-Frequency Representations for Biometrics from ECG Signals. Applied Sciences [online]. 2019, 9(22), 1 - 24 [cit. 2020-05-26]. DOI: 10.3390/app9224810. ISSN 2076-3417. Dostupné z: <https://www.mdpi.com/2076-3417/9/22/4810>
- [3] DO, Synho, Kyoung Doo SONG a Joo Won CHUNG. Basics of Deep Learning: A Radiologist's Guide to Understanding Published Radiology Articles on Deep Learning. Korean Journal of Radiology [online]. 2020, 21(1), 9 [cit. 2020-05-26]. DOI: 10.3348/kjr.2019.0312. ISSN 1229-6929. Dostupné z: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6960318/>
- [4] DOZAT, Timothy. Incorporating Nesterov Momentum into Adam. International Conference on Learning Representations [online]. 2016, 2016, 1 - 4 [cit. 2019-12-30]. Dostupné z: <https://openreview.net/pdf?id=OM0jvwB8jIp57ZJjtNEZ>
- [5] ELHAJ, Fatin A., Naomie SALIM, Arief R. HARRIS, Tan Tian SWEE a Taqwa AHMED. Arrhythmia recognition and classification using combined linear and nonlinear features of ECG signals. Computer Methods and Programs in Biomedicine [online]. 2016, 2016(127), 52-63 [cit. 2020-05-28]. DOI: <https://doi.org/10.1016/j.cmpb.2015.12.024>. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0169260715301097>
- [6] FARAGGI, Marisa a Karim SAYADI. Time series features extraction using Fourier and Wavelet transforms on ECG data | OCTO Talks ! OCTO Talks ! | Le blog d'OCTO Technology, cabinet de conseil et de réalisation IT [online]. 23. 11. 2019 [cit. 2020-05-26]. Dostupné z: <https://blog.octo.com/en/time-series-features-extraction-using-fourier-and-wavelet-transforms-on-ecg-data/>
- [7] GAIKWAD, Kaustubh Manik a Mahesh Shrikant CHAVAN. Removal of high frequency noise from ECG signal using digital IIR butterworth filter [online]. IEEE, 2014, 2014, , 121-124 [cit. 2020-05-26]. DOI: 10.1109/GCWCN.2014.7030861. ISBN 978-1-4799-6298-3. Dostupné z: <http://ieeexplore.ieee.org/document/7030861/>
- [8] GAMAL, Eslam. What is the ReLU layer in CNN? In: Quora [online]. 7. 5. 2020 [cit. 2020-05-26]. Dostupné z: <https://www.quora.com/What-is-the-ReLU-layer-in-CNN>

- [9] GANESH, Prakhar. Types of Convolution Kernels : Simplified. In: Towards Data Science [online]. 2019, 8. 10. 2019 [cit. 2020-05-26]. Dostupné z: <https://towardsdatascience.com/types-of-convolution-kernels-simplified-f040cb307c37>
- [10] GIACAGLIA, Giuliano. How Transformers Work - Towards Data Science: The Neural Network used by Open AI and DeepMind. Medium – Get smarter about what matters to you [online]. 11 May 2019 [cit. 2020-05-26]. Dostupné z: <https://towardsdatascience.com/transformers-141e32e69591>
- [11] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. Deep learning. Cambridge, Massachusetts: The MIT Press, [2016]. ISBN 0262035618.
- [12] G, Swapna, Soman K P a Vinayakumar R. Automated detection of cardiac arrhythmia using deep learning techniques. Procedia Computer Science [online]. 2018, 132, 1192-1201 [cit. 2019-12-30]. DOI: 10.1016/j.procs.2018.05.034. ISSN 18770509. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S187705091830766X>
- [13] HAMPTON, John R. EKG stručně, jasně, přehledně. Vyd. 2., rozš. Praha: Grada, 1996. ISBN 80-247-0960-0.
- [14] HAN, Seung Seog, Gyeong Hun PARK, Woohyung LIM, Myoung Shin KIM, Jung Im NA, Ilwoo PARK, Sung Eun CHANG a Manabu SAKAKIBARA. Deep neural networks show an equivalent and often superior performance to dermatologists in onychomycosis diagnosis: Automatic construction of onychomycosis datasets by region-based convolutional deep neural network. PLOS ONE [online]. 2018, 13(1), 14 [cit. 2020-05-26]. DOI: 10.1371/journal.pone.0191493. ISSN 1932-6203. Dostupné z: <https://dx.plos.org/10.1371/journal.pone.0191493>
- [15] HE, Kaiming, Xiangyu ZHANG, Shaoqing REN a Jian SUN. Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [online]. IEEE, 2016, 2016, , 770-778 [cit. 2019-12-30]. DOI: 10.1109/CVPR.2016.90. ISBN 978-1-4673-8851-1. Dostupné z: <http://ieeexplore.ieee.org/document/7780459/>
- [16] CHOLLET, François. Deep learning v jazyku Python: knihovny Keras, Tensorflow. Praha: Grada Publishing, 2019. Knihovna programátora (Grada). ISBN 978-80-247-3100-1.
- [17] JOST, Norbert. Transmembrane ionic currents underlying cardiac action potential in mammalian hearts. Advances in cardiomyocyte research [online]. 2009, 2009, 1-45 [cit. 2020-05-26]. Dostupné z: https://www.researchgate.net/publication/249962676_Transmembrane_ionic_currents_underlying_cardiac_action_potential_in_mammalian_hearts/stats

- [18] KHAN, M. I. Gabriel. EKG a jeho hodnocení. Praha: Grada, 2005. ISBN 80-247-0910-4.
- [19] KIRANYAZ, Serkan, Onur AVCI, Osama ABDELJABER, Turker INCE, Moncef GABBOUJ a Daniel J. INMAN. 1D Convolutional Neural Networks and Applications: A Survey [online]. 2019, 9 May 2019, , 1-20 [cit. 2020-05-26]. Dostupné z: <https://arxiv.org/abs/1905.03554>
- [20] KOLÁŘ, Jiří a Josef KAUTZNER. Základy elektrokardiografie arytmií a akutních koronárních syndromů: 1902-2002 : léčebné zásady. Praha: Akcenta, 2002. ISBN 80-862-3204-2.
- [21] KRIZHEVSKY, Alex, Ilya SUTSKEVER a Geoffrey E. HINTON. ImageNet classification with deep convolutional neural networks. Communications of the ACM [online]. 2017, 60(6), 84-90 [cit. 2019-12-30]. DOI: 10.1145/3065386. ISSN 00010782. Dostupné z: <http://dl.acm.org/citation.cfm?doid=3098997.3065386>
- [22] LEONARDO, Matheus Macedo, Tiago J. CARVALHO, Edmar REZENDE, Roberto ZUCCHI a Fabio Augusto FARIA. Deep Feature-Based Classifiers for Fruit Fly Identification (Diptera: Tephritidae). 2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI) [online]. IEEE, 2018, 2018, 2018, 41-47 [cit. 2020-05-26]. DOI: 10.1109/SIBGRAPI.2018.00012. ISBN 978-1-5386-9264-6. Dostupné z: <https://ieeexplore.ieee.org/document/8614309/>
- [23] LIU, Shing-Hong, Da-Chuan CHENG a Chih-Ming LIN. Arrhythmia Identification with Two-Lead Electrocardiograms Using Artificial Neural Networks and Support Vector Machines for a Portable ECG Monitor System. Sensors [online]. 2013, 13(1), 813-828 [cit. 2020-05-26]. DOI: 10.3390/s130100813. ISSN 1424-8220. Dostupné z: <http://www.mdpi.com/1424-8220/13/1/813>
- [24] LUKÁŠ, Karel a Aleš ŽÁK. Chorobné znaky a příznaky: diferenciální diagnostika. Praha: Grada, 2014. ISBN 978-80-247-5067-5.
- [25] MAHAPATRA, Abhinav. [ML advanced]Momentum in machine learning? What is Nesterov momentum? – mc.ai. In: Mc.ai – Aggregated news around AI and co. [online]. 13 Jan 2019 [cit. 2020-05-27]. Dostupné z: <https://mc.ai/ml-advancedmomentum-in-machine-learning-what-is-nesterov-momentum/>
- [26] MALMIVUO, Jaakko a Robert PLONSEY. Bioelectromagnetism. 15. 12-Lead ECG System. Bioelectromagnetism - Principles and Applications of Bioelectric and Biomagnetic Fields [online]. 1995-10-05, , 387-404 [cit. 2020-05-28]. DOI: 10.1093/acprof:oso/9780195058239.001.0001. Dostupné z: https://www.researchgate.net/publication/321019966_Bioelectromagnetism_15_12-Lead_ECG_System

- [27] MEEK, Steve. ABC of clinical electrocardiography: Introduction. I---Leads, rate, rhythm, and cardiac axis. *BMJ* [online]. 2002, 324(7334), 415-418 [cit. 2020-05-26]. DOI: 10.1136/bmj.324.7334.415. ISSN 09598138. Dostupné z: <http://www.bmj.com/cgi/doi/10.1136/bmj.324.7334.415>
- [28] MORAVEC, Ondřej, Tomáš SKÁLA a Petr HEINC. Kdy a jak léčit komorové extrasystoly v interní ambulanci. *Interní medicína pro praxi*. 2014, 2014(3), 123-126.
- [29] NOVÁKOVÁ, Zuzana a Miroslav NOVÁK. Fyziologie převodního systému srdečního, mechanismy vzniku arytmií. *Praktické Lékárenství*. 2007, 2007(5), 225-228.
- [30] OCHIAI, Keiichi, Shu TAKAHASHI a Yusuke FUKAZAWA. Arrhythmia Detection from 2-lead ECG using Convolutional Denoising Autoencoders [online]. 2018, , 1 - 7 [cit. 2020-05-26]. Dostupné z: https://www.kdd.org/kdd2018/files/deep-learning-day/DLDay18_paper_16.pdf
- [31] PATRICK, Mensah Kwabena, Adebayo Felix ADEKOYA, Ayidzoe Abra MIGHTY a Baagyire Y. EDWARD. Capsule Networks – A survey. *Journal of King Saud University - Computer and Information Sciences* [online]. 2019, 25 September 2019, 2019, 1-16 [cit. 2020-05-28]. DOI: <https://doi.org/10.1016/j.jksuci.2019.09.014>. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1319157819309322?via%3Dihub>
- [32] POKORNÝ, Jaroslav, ed. *Přehled fyziologie člověka*. 3. přeprac. vyd. Praha: Karolinum, 2002. ISBN 80-246-0229-6.
- [33] SIMONYAN, Karen a Andrew ZISSERMAN. Very Deep Convolutional Networks for Large-Scale Image Recognition [online]. 2014, 2015, 1 - 14 [cit. 2019-12-30]. Dostupné z: <https://arxiv.org/pdf/1409.1556.pdf>
- [34] SINGH, Shraddha, Saroj Kumar PANDEY, Urja PAWAR a Rekh Ram JANGHEL. Classification of ECG Arrhythmia using Recurrent Neural Networks. *Procedia Computer Science* [online]. 2018, 132, 1290-1297 [cit. 2020-05-26]. DOI: 10.1016/j.procs.2018.05.045. ISSN 18770509. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1877050918307774>
- [35] SZEGEDY, Christian, Sergey IOFFE, Vincent VANHOUCKE a Alex ALEMI. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. Thirty-First AAAI Conference on Artificial Intelligence [online]. 2017, 2017, 1 - 7 [cit. 2019-12-30]. Dostupné z: <https://www.aaai.org/ocs/index.php/AAAI/AAAI17/paper/download/14806/14311>

- [36] SZEGEDY, Christian, WEI LIU, YANGQING JIA, et al. Going deeper with convolutions. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [online]. IEEE, 2015, 2015, , 1-9 [cit. 2019-12-30]. DOI: 10.1109/CVPR.2015.7298594. ISBN 978-1-4673-6964-0. Dostupné z: <http://ieeexplore.ieee.org/document/7298594/>
- [37] TAHMASSEBI, Amirhessam, Amir H. GANDOMI, Simon FONG, Anke MEYER-BAESE, Simon Y. FOO a Ivan OLIER. Multi-stage optimization of a deep model: A case study on ground motion modeling. PLOS ONE [online]. 2018, 13(9) [cit. 2020-05-26]. DOI: 10.1371/journal.pone.0203829. ISSN 1932-6203. Dostupné z: <https://dx.plos.org/10.1371/journal.pone.0203829>
- [38] THALER, Malcolm S. EKG a jeho klinické využití. Praha: Grada, 2013. ISBN 978-80-247-4193-2.
- [39] TROJAN, Stanislav. Lékařská fyziologie. Vyd. 3., dopl. a rozš. Praha: Grada, 1999. ISBN 80-716-9788-5.
- [40] UHER, Václav. Trénovatelné metody pro automatické zpracování biomedicínských obrazů. Brno, 2018. Dostupné také z: https://www.vutbr.cz/studenti/zav-prace/detail/113381?zp_id=113381. Dizertační práce. VUT. Vedoucí práce Radim Burget.
- [41] WALCZYNSKO, Martin. Analýza EEG signálu pomocí analýzy hlavních komponent (PCA). Brno, 2008. Bakalářská práce. VUT. Vedoucí práce Milan Rychtárik.
- [42] WANG, Zhizhong, Hongyi LI, Chuang HAN, Songwei WANG a Li SHI. Arrhythmia Classification Based on Multiple Features Fusion and Random Forest Using ECG. Journal of Medical Imaging and Health Informatics [online]. 2019, 9(8), 1645-1654 [cit. 2020-05-26]. DOI: 10.1166/jmihi.2019.2798. ISSN 2156-7018. Dostupné z: <https://www.ingentaconnect.com/content/10.1166/jmihi.2019.2798>
- [43] XIA, Yong, Naren WULAN, Kuanquan WANG a Henggui ZHANG. Detecting atrial fibrillation by deep convolutional neural networks. Computers in Biology and Medicine [online]. 2018, 93, 84-92 [cit. 2020-05-25]. DOI: 10.1016/j.compbiomed.2017.12.007. ISSN 00104825. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0010482517304043>
- [44] XIE, Saining, Ross GIRSHICK, Piotr DOLLAR, Zhuowen TU a Kaiming HE. Aggregated Residual Transformations for Deep Neural Networks. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [online]. IEEE, 2017, 2017, , 5987-5995 [cit. 2019-12-30]. DOI: 10.1109/CVPR.2017.634. ISBN 978-1-5386-0457-1. Dostupné z: <http://ieeexplore.ieee.org/document/8100117/>

- [45] 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*. 2018, 102(102), 411-420. DOI: 10.1016/j.compbiomed.2018.09.009. ISSN 00104825. Dostupné také z: <https://linkinghub.elsevier.com/retrieve/pii/S0010482518302713>
- [46] Morlet wavelet - MATLAB morlet. In: *MathWorks - Makers of MATLAB and Simulink - MATLAB & Simulink* [online]. [cit. 2020-05-26]. Dostupné z: <https://www.mathworks.com/help/wavelet/ref/morlet.html>

Seznam zkratek

ADAM	adaptive moment estimation – adaptivní odhad momentu (optimalizátor rychlosti učení)
AV	atrioventrikulární
CNN	convolutional neural network – konvoluční neuronová síť
CWT	spojitá vlnková transformace
DWT	discrete wavelet transform – diskrétní vlnková transformace
EKG	elektrokardiogram, elektrokardiografie
GPU	grafický procesor
GRU	gated recurrent unit (druh rekurentní sítě)
ICA	independent component analysis – analýza nezávislých komponent
LSTM	long short-term memory (druh rekurentní sítě)
NADAM	nesterov-accelerated adaptive moment estimation (optimalizátor rychlosti učení)
PCA	principal component analysis – analýza hlavních komponent
ReLU	rectified linear unit – usměrněná lineární funkce
RNN	recurrent neural network – rekurentní neuronová síť
SA	sinoatriální
SGD	stochastický gradientní sestup
SVM	support vector machines – podpůrné vektorové stroje
ÚBMI	ústav biomedicínského inženýrství
VGG	Visual geometry group – oddělení Oxfordské univerzity pro počítačové vidění