

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2023

Bc. Ondřej Blaude



# 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

## **AUTOMATICKA DIAGNOSTIKA 12SVODOVE HO EKG POMOCI HLUBOKE HO UC ENI**

AUTOMATIC DIAGNOSIS OF THE 12-LEAD ECG USING DEEP LEARNING

**DIPLOMOVÁ PRÁCE**

MASTER'S THESIS

**AUTOR PRÁCE**

AUTHOR

**Bc. Ondřej Blaude**

**VEDOUCÍ PRÁCE**

SUPERVISOR

**prof. Ing. Valentine Provazník,  
Ph.D.**

**BRNO 2023**

# Diplomová práce

magisterský navazující studijní program **Bioinženýrství**

Ústav biomedicínského inženýrství

**Student:** Bc. Ondřej Blaude

**ID:** 202406

**Ročník:** 2

**Akademický rok:** 2022/23

**NÁZEV TÉMATU:**

## **Automatická diagnostika 12svodového EKG pomocí hlubokého učení**

**POKYNY PRO VYPRACOVÁNÍ:**

1) Seznamte se s metodami klasifikace záznamů elektrické aktivity srdce (EKG) zahrnující normální a abnormální rytmy. 2) Prostudujte strukturu a obsah doporučené databáze EKG záznamů z platformy PhysioNet. 3) Navrhněte blokové schéma klasifikačního systému zahrnujícího předzpracování signálů pro potlačení šumu, učení zvolené hluboké sítě a klasifikaci do zvoleného počtu tříd normálních/abnormálních rytmů. 4) Realizujte softwarově předzpracování a zobrazení signálů. 5) Implementujte zvolenou hlubokou neuronovou síť a ověřte její funkčnost. 6) Provedte analýzu dat se statistickým vyhodnocením správnosti klasifikace. 7) Výsledky vhodným způsobem prezentujte a diskutujte.

**DOPORUČENÁ LITERATURA:**

- [1] Ribeiro, A. H. et al. Automatic diagnosis of the 12-lead ECG using a deep neural network. Nature Communications 11, 1760, 2020.
- [2] Zheng, J. et al. A large scale 12-lead electrocardiogram database for arrhythmia study (version 1.0.0). PhysioNet, 2022.

**Termín zadání:** 6.2.2023

**Termín odevzdání:** 22.5.2023

**Vedoucí práce:** prof. Ing. Valentine Provazník, Ph.D.

**doc. Ing. Radim Kolář, 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 diplomová práce má za cíl prozkoumat problematiku automatické diagnostiky EKG, a to na dvanáctisvodových záznamech. V kapitole první je krátce popsán úvod k srdci a měření jeho elektrické aktivity, navíc jsou zde krátce popsány abnormality, které budou v práci klasifikovány. Ve druhé kapitole je popsáno, jak bylo EKG diagnostikováno dříve, tedy klasickými metodami, které předcházely hlubokému učení. Zde jsou i zmíněny některé nedostatky, které tyto metody mají právě oproti hlubokému učení. Část třetí již věnuje pozornost hlubokému učení samotnému, jeho přínosu a výhodám ve srovnání s metodami klasickými. Popsány jsou zde i konvoluční neuronové sítě a jejich jednotlivé bloky, později je věnována pozornost i vybraným architekturám, které byly v některých studiích použity. Kapitola čtvrtá se již zaměřuje na praktickou část, v níž jsou podrobněji popsána použitá data z databáze PhysioNet, navržený algoritmus a jeho realizace. V páté kapitole jsou výsledky diskutovány a srovnány výsledky dostupných publikací se související problematikou.

## Klíčová slova

EKG, diagnostika, hluboké učení, CNN, 1D konvoluční neuronová síť, umělá inteligence, strojové učení, standardní dvanáctisvodové EKG, klasifikace, podvzorkování signálů, reziduální blok, Physionet databáze, F1 skóre

## **Abstract**

The aim of this diploma thesis is to investigate the problematics of automatic ECG diagnostics, namely on twelve-lead recordings. In the first chapter the heart and its electrical activity measurement is described shortly. In addition to that, the abnormalities which are going to be classified in this thesis are also briefly described. In the second chapter, it is described how the ECG was diagnosed earlier, by classical methods that preceded deep learning. Some of the shortcomings that the classical methods have compared to deep learning are also described here. The third part already pays attention to deep learning itself, and its contribution and advantages compared to classical methods. Convolutional neural networks and their individual blocks are also described here, later attention is paid to selected architectures that were used in some studies. The fourth chapter already focuses on the practical part, in which the data used from the PhysioNet database, the proposed algorithm and its implementation are described in more detail. In the fifth chapter the results are discussed and compared to the corresponding publications.

## **Keywords**

ECG, diagnostics, deep learning, CNN, 1D convolutional neural network, artificial intelligence, machine learning, standard twelve-lead ECG, classification, signal downsampling, residual block, Physionet database, F1 score

BLAUDE, Ondřej. *Automatická diagnostika 12svodového EKG pomocí hlubokého učení* [online]. Brno, 2023. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/150990>. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Valentine Provazník.

## Prohlášení

Prohlašuji, že svou diplomovou práci na téma „Automatická diagnostika 12svodového EKG pomocí hlubokého učení“ jsem vypracoval samostatně pod vedením prof. Ing. Valentýny Provazník, Ph.D. 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.

Brno .....

.....

podpis autora

## Poděkování

Rád bych poděkoval vedoucí své práce, paní prof. Ing. Valentýně Provazník, Ph. D. za odborné vedení, trpělivost, konzultace a podnětné návrhy k práci. Děkuji i svojí mamince, za její podporu.

Brno .....

.....

podpis autora



# Obsah

Úvod.....	3
1 Elektrokardiografie (EKG) a srdce .....	4
1.1 Srdce .....	4
1.2 Fyziologie srdce .....	4
1.2.1 Převodní systém srdeční.....	4
1.3 Elektrokardiografie .....	4
1.3.1 EKG křivka .....	4
1.3.2 Standardní dvanáctisvodové EKG .....	5
1.4 Vybrané abnormality na EKG křivce .....	7
1.4.1 Sinusová bradykardie .....	7
1.4.2 Sinusová tachykardie .....	7
1.4.3 Flutter síní .....	8
2 Standardní metody diagnostiky EKG.....	9
2.1 Metody předzpracování signálů.....	9
2.2 Metody extrakce a volby příznaků.....	9
2.2.1 Extrakce lineárních příznaků pomocí PCA.....	9
2.2.2 Extrakce nelineárních příznaků pomocí ICA .....	10
2.2.3 Kombinace lineárních a nelineárních příznaků.....	11
2.3 Metody klasifikace.....	11
2.3.1 Umělá neuronová síť .....	11
2.3.2 Support Vector Machine .....	11
2.3.3 Náhodný les.....	12
2.4 Limitace klasických metod diagnostiky EKG .....	12
3 Hluboké učení .....	13
3.1 Hluboké neuronové sítě .....	13
3.2 Konvoluční neuronové sítě .....	13

3.2.1	1D konvoluční neuronové sítě .....	13
3.3	Základní bloky konvolučních neuronových sítí.....	14
3.3.1	Konvoluční vrstva .....	14
3.3.2	Pooling .....	15
3.3.3	Plně propojená vrstva.....	15
3.4	Pokročilé bloky konvolučních neuronových sítí .....	16
3.4.1	Reziduální blok .....	16
3.4.2	DropOut.....	16
3.4.3	BatchNorm .....	17
3.5	Proces učení .....	17
3.5.1	Chybová funkce (Loss Function) .....	18
3.5.2	K-násobná křížová validace .....	18
3.5.3	Přeučení sítě .....	18
3.6	Optimalizační techniky .....	19
3.6.1	Gradientní sestup.....	19
3.6.2	Stochastický gradientní sestup .....	19
3.6.3	Mini-batch .....	19
3.6.4	Adam .....	19
3.7	Přínos hlubokého učení pro diagnostiku EKG .....	20
3.8	Jednodimenzionální reziduální neuronová síť .....	20
4	Praktická část .....	22
4.1	Navržení algoritmu pro klasifikaci EKG .....	22
4.2	Použitá data.....	23
4.3	Použité programy .....	24
4.4	Načtení, předzpracování dat a zobrazení signálu.....	25
4.5	Rozdělení dat na trénovací, validační a testovací množinu .....	26
4.6	Architektura modelu .....	26

4.7	Trénování modelu .....	27
4.8	Vyhodnocení úspěšnosti modelu .....	27
5	Diskuze výsledků .....	30
5.1	Srovnání výsledků modelu s výsledky jiných autorů .....	30
6	Závěr .....	32
7	Literatura .....	33
	Seznam zkratk .....	36
	Seznam příloh.....	37
A	Popis realizovaných funkcí .....	38

## Seznam obrázků

Obrázek 1.1: EKG křivka a její složky [4].....	5
Obrázek 1.2 Hrudní svody a jejich umístění [3] .....	6
Obrázek 1.3: Žádná abnormalita, sinusový rytmus. [6] .....	7
Obrázek 1.4: Sinusová bradykardie. [6].....	7
Obrázek 1.5: Sinusová tachykardie. [6] .....	8
Obrázek 1.6: Flutter síní. [3] .....	8
Obrázek 3.1: Ukázka 1D-CNN konfigurace s třemi vrstvami CNN a dvěma plně propojenými vrstvami. [12].....	14
Obrázek 3.2: Ukázka principu 2D konvoluce. [14] .....	15
Obrázek 3.3: Reziduální blok [15] .....	16
Obrázek 3.4: Ukázka neuronové sítě a) bez použití BatchNorm, b) s použitím BatchNorm, kde $\mu$ je střední hodnota mini-batche a $\sigma^2$ je jeho rozptyl. $\gamma$ a $\beta$ jsou nové parametry, které posouvají a škálují normalizované hodnoty. [17].....	17
Obrázek 3.5: Schéma K-násobné křížové validace. [11] .....	18
Obrázek 3.6: Srovnání vyhodnocování EKG klasickými metodami s vyhodnocováním metodami hlubokého učení [22].....	20
Obrázek 3.6: Schéma jednodimenzionální reziduální neuronové sítě [6].....	21
Obrázek 4.1: Blokové schéma navrženého postupu pro klasifikaci EKG. ....	22
Obrázek 4.2: Ukázka záznamu se sinusovým rytmem. Záznam JS00021, svod II. [19] .....	23
Obrázek 4.3: Ukázka záznamu se sinusovou bradykardií. Záznam JS00002, svod II. [19].....	24
Obrázek 4.4: Ukázka záznamu s flutterem síní. Záznam JS00029, svod II. [19] .....	24
Obrázek 4.5: Ukázka záznamu se sinusovou tachykardií. Záznam JS00057, svod II. [19].....	24
Obrázek 4.6: Ukázka záznamu JS00002. Nahoře bez jakékoliv filtrace či podvzorkování, dole filtrovaný a podvzorkovaný na 125 Hz. [19] .....	26
Obrázek 4.7: Blokové schéma navrženého modelu. ....	27
Obrázek 4.8: Blokové schéma reziduálního bloku. ....	27
Obrázek 4.8: Průběh trénovací a validační přesnosti(vlevo) a chyby(vpravo) při učení modelu. ....	28

## Seznam tabulek

Tabulka 4.1: Přehled klasifikovaných tříd [19].....	23
Tabulka 4.2: Matice záměn navrženého klasifikačního modelu. ....	28
Tabulka 4.3: Přesnost (precision), úplnost (recall) a F1 skóre zvlášť pro každou třídu. .....	29
Tabulka 5.1: Ukázka malého množství záznamů s některými abnormalitami.....	30
Tabulka 5.2: Srovnání navrhovaného modelu s modely souvisejících publikací [6], [22].....	31

## Úvod

Onemocnění kardiovaskulárního systému je jednou z hlavních příčin onemocnění po celém světě, a právě elektrokardiogram velmi napomáhá správné diagnostice onemocnění. Dlouhou dobu EKG sledovali zejména experti na problematiku, kteří se roky a roky učili kardiovaskulární choroby správně rozpoznat, diagnostikovat a léčit.

S postupem času a s neustálým rozvojem umělé inteligence se nabízí možnost nechat elektrokardiogramy vyhodnocovat automaticky a tyto metody se pyšní velké úspěšnosti. Když nalezne umělá inteligence využití v rozpoznání obrazu nebo mluvení, má tato technologie doajista potenciál i v řešení problémů medicínských. Mezi různé způsoby automatické klasifikace EKG se řadí i metody klasifikace pomocí hlubokého učení, z nichž některé se pyšní dokonce vyšší úspěšností nežli experti. Třebaže je na tom úroveň automatické diagnostiky EKG velmi dobře, měla by však být pouze doprovodem, podporou, opravdového lékaře, nikoliv něčím, co by mohlo rozhodovat za něj.

Tato práce má za cíl čtenáři představit, jak se EKG diagnostikovalo klasickými metodami, po nichž čtenáři budou představeny přínosy a principy metod s hlubokým učením, než bude představen navržený model v praktické části.

# 1 Elektrokardiografie (EKG) a srdce

## 1.1 Srdce

Srdce je dutý orgán, který má stěny tvořené zejména myokardem, speciální srdeční svalovinou, jejíž vlákna jsou oproti vláknům kosterního svalu kratší, ale i silnější. Srdce má dvě síně a dvě komory. Tyto čtyři srdeční dutiny jsou vystlány endokardem který s myokardem srůstá. Svalovina předsíní a komor je oddělena vazivovým skeletem tvořícím bázi pro čtyři srdeční chlopně. [1]

Rytmičké střídání systoly a diastoly je základem čerpací činnosti srdce. Diastolou se rozumí relaxace svaloviny komor, při níž se komory plní krví. Při systole, tedy kontrakci svaloviny komor, zase srdce krev vypuzuje do plicnice a do aorty. [1]

## 1.2 Fyziologie srdce

### 1.2.1 Převodní systém srdeční

Srdce funguje jako pumpa zejména díky své elektrické aktivitě. Soustava, která vytváří, potažmo vede pravidelné vzruchy po celém srdci, se nazývá převodní systém srdeční. Jeho jednotlivé části mají schopnost tvořit spontánně vzruchy. Sinoatriální (SA) uzel vytváří vzruchy nejrychleji, je tedy přirozeným dodavatelem rytmu, přirozeným pacemakerem. Dojde k depolarizaci síní a vzruchy jsou vedeny síňovými drahami do atrioventrikulárního (AV) uzlu, Hisova svazku, Tawarových ramének a skrze Purkyňova vlákna pak ke komorovému svalu. [2]


## 1.3 Elektrokardiografie

Elektrokardiografie (EKG) je metoda snímání elektrické aktivity srdce, respektive srdečních buněk. Podporuje diagnózu, je používána i při léčbě poruch srdečního rytmu, infarktu myokardu, případně pomáhá odhalit příčinu bolestí na hrudi, někdy i příčiny dušnosti. [3]

V této práci je relevantní hlavně dvanáctisvodové EKG. Při snímání EKG tímto způsobem je třeba deset elektrod, z čehož se šest umísťuje na hrudník a další čtyři ke každé končetině s tím, že na pravou nohu se obvykle umísťuje zemnicí elektroda. [3]

### 1.3.1 EKG křivka

V EKG křivce, která je pro ilustraci zobrazena na obrázku 1.1, se nachází několik důležitých částí, které reprezentují různé děje v určité části srdce. Jedná se především o vlny P a T a QRS komplex. [4]



Obrázek 1.1: EKG křivka a její složky [4]


Vlna P odráží depolarizaci síní. Většinou se vejde do 120 ms a napětím se dostává maximálně na 300  $\mu\text{V}$ . Komplex QRS zde stojí za depolarizaci komor a jeho součástí jsou první negativní kmit Q, pozitivní kmit R, a druhý negativní kmit S. Je nejvýraznější složkou EKG křivky, protože může dosahovat i napětí 3 mV. T nakonec reprezentuje repolarizaci síní. Při vyšší tepové frekvenci se zužuje a doba mezi T vlnou a komplexem QRS se zkracuje. [4]

Bývají měřeny také intervaly PQ, RR a QT. PQ interval vyjadřuje čas potřebný k přechodu impulsu od SA uzlu do srdečních komor. Interval QT znázorňuje dobu od začátku depolarizace komor do konce jejich repolarizace. Interval RR je interval mezi dvěma po sobě jdoucími kmity R, tedy doba trvání jednoho srdečního komorového cyklu. [4]

### 1.3.2 Standardní dvanáctisvodové EKG

Různé svody „pozorují“ srdce odlišně, z jiných úhlů. Svody můžeme dělit na standardní a na hrudní. Zatímco standardní svody hledí na srdce v rovině vertikální, svody hrudní srdce sledují v horizontální rovině a zleva, jak lze vidět na obrázku 1.2. Hrudní unipolární svody představují napětí mezi elektrodami na hrudi a Wilsonovou svorkou, která se vypočítá jako aritmetický průměr potenciálů končetinových elektrod, o nichž pojednává následující odstavec. [3],[5]





Obrázek 1.2 Hrudní svody a jejich umístění [3]

Co se týče bipolárních svodů, jejich napětí lze vypočítat snadno. Končetinové elektrody budeme označovat následovně: R pro elektrodu na pravém zápěstí, L pro elektrodu na zápěstí levém, F pro elektrodu na levé noze. Elektroda umístěná na pravé noze je referenční a značí se písmenem N, ale ve výpočtech unipolárních svodů ji používat nebudeme. Jak vypočítat napětí na Einthovenových svodech I, II a III je patrné z rovnic 1.1, 1.2 a 1.3: [5]

$$U_I = V_L - V_R \quad (1.1)$$

$$U_{II} = V_F - V_R \quad (1.2)$$

$$U_{III} = V_F - V_L \quad (1.3)$$

Kde  $U$  je napětí  $V$  je potenciál na elektrodě, jejíž umístění poznáme podle označení v dolním indexu. Zbývající tři bipolární svody jsou augmentované a přezdívá se jim Goldbergerovy. Jejich výpočet probíhá dle rovnic 1.4 až 1.6: [5]

$$U_{aVR} = V_R - \frac{V_L + V_F}{2} \quad (1.4)$$

$$U_{aVL} = V_L - \frac{V_R + V_F}{2} \quad (1.5)$$

$$U_{aVF} = V_F - \frac{V_L + V_R}{2} \quad (1.6)$$

## 1.4 Vybrané abnormality na EKG křivce

Cílem této kapitoly je seznámit čtenáře s klasifikovanými abnormalitami, které algoritmus rozeznává. Jedná se o sinusovou bradykardii, sinusovou tachykardii a fibrilaci síní. Obrázek 1.3 zobrazuje sinusový rytmus na EKG svodu II, který sice patologický není, ale v rámci této práce bude jednou z klasifikovaných tříd. [6]



Obrázek 1.3: Žádná abnormalita, sinusový rytmus. [6]

### 1.4.1 Sinusová bradykardie

Sinusová bradykardie je označení pro pomalý sinusový rytmus. Neexistuje však hranice, pod kterou by všechny rytmy byly jednoznačně považovány za bradykardii. Lze ji zaznamenat mimo jiné při akutním infarktu myokardu. Vyskytuje se ale také při mdlobách nebo u trénovaných sportovců. [3] Na obrázku 1.4 níže je ukázka EKG záznamu sinusové bradykardie ze svodu II.



Obrázek 1.4: Sinusová bradykardie. [6]

### 1.4.2 Sinusová tachykardie


Rychlý sinusový rytmus nazýváme sinusovou tachykardií. Vyskytuje se zejména při fyzické zátěži, dále pak i při bolesti, strachu, ale i krvácení. Třebaže tachykardie označují rychlou tepovou frekvenci, neexistuje hraniční frekvence, jejíž převýšení by nutně znamenalo tachykardii. Záznam EKG se sinusovou tachykardií je na obrázku 1.5. [3]



Obrázek 1.5: Sinusová tachykardie. [6]

#### 1.4.3 Flutter síní

Flutter síní je stav, kdy frekvence síní přesáhne 250 tepů/min a mizí izoelektrická linie mezi vlnami P. Při flutteru jsou v záznamu EKG patrné P vlny pilovitého charakteru o vysoké frekvenci. Na obrázku 1.6 níže je zobrazen záznam EKG s flutterem síní. [3]



Obrázek 1.6: Flutter síní. [3]

## 2 Standardní metody diagnostiky EKG

### 2.1 Metody předzpracování signálů

Standardní metody vyžadují určitou pozornost už při předzpracovávání signálů. Ty mohou být předzpracovávány například pomocí diskretní vlnkové transformace, která je pro analýzu nestacionárních signálů vhodná. Signál je rozdělen do devíti frekvenčních pásem, Inverzní vlnková transformace může pak být vypočtena z pásem 3 až 8, aby byl signál zbaven šumu a kolísání nulové izolínie. [9]

V odšuměných signálech mohou být detekovány komplexy QRS například pomocí Pan-Tompkinsova algoritmu. Následně byl z každého okolí QRS komplexu vytvořen úsek o délce několik set vzorků, ze kterých mohou být následně extrahovány lineární i nelineární příznaky. [9]

Pro snížení výpočetní náročnosti je také vhodné snížit vzorkovací frekvenci, nemá-li to přílišný vliv na ztrátu kvality signálu. Snížení vzorkovací frekvence se říká decimace a určuje se při ní decimační faktor  $D$ , kdy platí, že vzorkovací frekvence decimovaného signálu je  $D$ -krát nižší než vzorkovací frekvence signálu původního. Probíhá to tak, že je ponechán každý  $D$ -tý vzorek původního signálu. Aby však nedošlo k aliasingu, je pak aplikován filtr typu dolní propust o velikosti rovné jedné polovině nové vzorkovací frekvence. Nový signál zabírá zpravidla  $D$ -krát méně výpočetního místa. [23]

### 2.2 Metody extrakce a volby příznaků

Krok, který odlišuje klasické metody od metod hlubokého učení, je hlavně extrakce a volba příznaků. Níže bude popsána extrakce lineárních a nelineárních příznaků. Sady příznaků z EKG dat jsou tvořeny kombinací lineárních a nelineárních (ICA). [9] Vektor příznaků byl složen z lineárních příznaků  $L_t$  a nelineárních příznaků  $N_t$ :

$$Z_t = L_t + N_t \quad (2.14)$$

#### 2.2.1 Extrakce lineárních příznaků pomocí PCA

Pro extrakci lineárních příznaků může být použita diskretní vlnková transformace. Na určitá pásma jejího výstupu je následně použita analýza hlavních komponent (PCA – Principal Component Analysis). [9]

PCA je jedna z neznámějších metod pro redukci dimenzionality a extrakci příznaků. První hlavní komponenta představuje vektor největšího rozptylu (nejméně korelovaný), druhá hlavní komponenta představuje další vektor ve směru kolmém na předchozí, a tak dále. [9] Hlavní komponenty jsou vypočteny následujícími kroky:

Zprvé – výpočet kovarianční matice:

$$C = (x - \mu)(x - \mu)^T \quad (2.1)$$

kde  $x$  je matice dat a  $\mu$  je vektor středních hodnot  $x$ . [9] Druhým krokem bude výpočet vlastních vektorů  $V$  a diagonální matice vlastních hodnot  $D$ :

$$V^{-1}CV = D \quad (2.2)$$

Třetí krok spočívá v seřazení vlastních vektorů  $V$  sestupně podle pořadí vlastních hodnot v  $D$ , a promítnout data do směrů těchto vlastních vektorů tím, že jako podkladové mapování je brán vnitřní součin mezi maticí dat a seřazenou maticí vlastních vektorů:

$$p = [V^T(x - \mu)^T]^T \quad (2.3)$$

Celkem dvanáct (šest z každého pásma) příznaků bylo v rámci studie [9] použito pro další identifikaci vzoru klasifikátorem. [9]

### 2.2.2 Extrakce nelineárních příznaků pomocí ICA

Analýza nezávislých komponent (ICA – Independent Component Analysis), nelineární metoda k redukci dimenzionality, je statistická technika, která je účinná v odhalování skrytých faktorů mezi smíšenými vzorky měření náhodných veličin. [9] Zahrnuje vícevariantní analýzu, která redukuje vícezdrojový signál na aditivní dílčí komponenty. Může být reprezentována matematicky jako:

$$X = A \cdot S \quad (2.7)$$

kde  $X$  je matice  $n$  pozorovaných signálů ( $X = [x_1, x_2, \dots, x_n]^T$ ),  $S$  je matice  $m$  podkladových signálů ( $S = [s_1, s_2, \dots, s_m]^T$ ) a  $A$  je směšovací matice  $n \times m$ . [9] Počet nezávislých komponent lze vypočítat nalezením „odsměšovací“ matice  $w$ , pro kterou platí:

$$S = w \cdot X \quad (2.8)$$

Pro výpočet  $w$  musí být data centrována a bělena, což se nejběžněji dělá rozkladem vlastních hodnot kovarianční matice:

$$EXX^T = EDE^T \quad (2.9)$$

kde  $E$  je ortogonální matice vlastních vektorů  $EXX^T$  s  $D$  je diagonální matice vlastních hodnot  $D$ . [9] Bělená matice  $X'$  je vypočtena následovně:

$$X' = ED^{1/2}E^T X \quad (2.10)$$

Bělení transformuje „odsměšovací“ matici, pro kterou platí:

$$S' = w \cdot X' = wED^{1/2}E^T X = wX \quad (2.11)$$

Počet odhadovaných parametrů se minimalizuje, protože  $w$  je ortogonální. [9] Odsměšovací matice je tedy:

$$w = wED^{-1/2}E^T \quad (2.12)$$

Nakonec se matice  $A$  získá z rovnice:

$$A = (w^T w)^{-1} w^T \quad (2.13)$$

### 2.2.3 Kombinace lineárních a nelineárních příznaků

## 2.3 Metody klasifikace

Extrahované příznaky poslouží jako vstup do klasifikátorů, které mohou být na různé bázi. Např. v rámci publikace [9] byl vyvinut klasifikátor pro rozdělení EKG záznamů do 5 tříd arytmiických tepů: neektopické, supraventrikulární ektopické, ventrikulární ektopické, fúzované, a nakonec nezařaditelné nebo stimulované tepe. Pro každou z pěti tříd bylo pro testování extrahováno celkem 28 příznaků z kombinovaného příznakového vektoru. Vyhodnocení příznakového vektoru bylo provedeno klasifikátorem na bázi neuronové sítě a metodou podpůrných vektorů. [9]

### 2.3.1 Umělá neuronová síť

V umělé neuronové síti každý neuron počítá váhovaný součet svých vstupů a dosazuje jej do takzvané aktivační funkce. Vstupní vrstva obvykle obsahuje tolik neuronů, kolik příznaků je používáno, a ve vrstvě výstupní je tolik neuronů, kolik je klasifikovaných tříd. Příkladem je studie [9], v níž sestávala vstupní vrstva síť z 28 neuronů, protože síť pracovala právě s 28 příznaky. Skrytá vrstva pak obsahovala 40 neuronů a výstupní vrstva měla neuronů 5, jedna za každou z pěti tříd EKG. Zlepšení procesu učení bylo provedeno zpětným šířením chyby – na základě výpočtu střední kvadratické odchylky (MSE) mezi požadovaným výstupem a skutečným výstupem neuronové sítě jsou upravovány váhy, dokud chyba neklesne pod stanovený práh. Na takto nastavené síti jsou potom klasifikována testovací data. [9]

### 2.3.2 Support Vector Machine

Předností metody Support Vector Machine (SVM) je její generalizační schopnost díky maximálnímu rozpětí hyperroviny k oddělení tříd. SVM převádí vstupní vektorové vzory na příznakový prostor vyšších dimenzí pomocí nelineárního mapování, načež získává optimální oddělovací hyperrovinu pro oddělení dvou tříd vzorků. Na základě vzdáleností hyperroviny, která rozděluje třídy, je proveden optimalizační proces. [9]

K mapování dat do vyšších dimenzí jsou použity různé kernelovské funkce, např.: kvadratická, polynomiální nebo radiální bazová funkce (RBF). Výkon SVM je ovlivnitelný hyperparametry, které určují počet podpůrných vektorů a maximální rozpětí SVM. [9]

Metoda SVM byla původně navržena na řešení binárních problémů (klasifikace do dvou tříd, např. zdravý a nemocný). Při klasifikování do více tříd je nutné zvolit jinou metodu. [8]

### 2.3.3 Náhodný les

Náhodný les, známý spíše pod anglickým názvem Random Forest, je klasifikační metoda, která vytváří několik klasifikačních stromů. Každý klasifikační strom je generován z podmnožiny dat. Trénovací data pro tuto metodu jsou generována technikou zvanou bagging. To znamená, že je dostupný dataset rozdělený do tolika kombinací, kolik je stromů. Na těchto kombinacích jsou jednotlivé stromy trénovány. Každý strom má svou vlastní kombinaci dat, na které je trénován a validován. Při testování náhodného lesa dohromady pak každý strom klasifikuje podle toho, jak je naučený. Náhodný les nakonec zvolí tu třídu, kterou zvolilo nejvíce stromů. [7], [8]

## 2.4 Limitace klasických metod diagnostiky EKG

Automatická diagnostika EKG se těší v posledních dekáдах velké oblibě, díky čemuž vzniklo mnoho modelů pro klasifikaci abnormalit. Hlavní limitací klasických metod, z nichž některé byly zmiňovány v této kapitole, je krok extrakce příznaků. Tento krok vyžaduje experty k extrakci užitečných příznaků, které budou využity ke klasifikaci. Tento problém mizí příchodem metod založených na hlubokém učení, o kterých pojednává následující kapitola. [22]

## 3 Hluboké učení

### 3.1 Hluboké neuronové sítě

Hluboké neuronové sítě jsou modely sestávající z více vrstev neuronů, přičemž každá vrstva je schopna učit se stále abstraktnější a abstraktnější reprezentace vstupních dat pro provádění konkrétních úkolů. [10]

Schopnost hlubokých neuronových sítí rozpoznávat vzory a učit se užitečné funkce z nezpracovaných vstupních dat bez nutnosti rozsáhlého předběžného zpracování dat nebo ručně vytvořených pravidel je to, co je činí zvláště vhodnými pro interpretaci dat EKG.

Výkon hlubokých neuronových sítí má tendence se zvyšovat společně s rostoucím množstvím trénovacích dat, a proto má tento přístup dobrou pozici pro využití rozšířené digitalizace dat EKG. [10]

Metody hlubokých neuronových sítí zaznamenaly významný úspěch v rozpoznávání řeči, klasifikacích obrazů, a podobných úlohách. Dá se tedy očekávat, že tyto metody mohou přinést pokrok i do oblasti zdravotnické péče. [6]

Nevýhoda hlubokých neuronových sítí je, že pro co správný chod požadují velká množství označených dat, jejichž získání v případě medicínských aplikací představuje různé problémy, týkající se kupříkladu zabezpečení a důvěrnosti osobních údajů. [6]


### 3.2 Konvoluční neuronové sítě

CNN (z anglického Convolutional Neural Network) jsou vhodné pro zpracování dat, která mají mřížkovitou strukturu. Příkladem mohou být obrazy které jsou uvažovány jako 2D mřížka pixelů, nebo i 1D signály, které jsou sbírány v pravidelných intervalech a poskládány do mřížky (pod sebe). [11]

#### 3.2.1 1D konvoluční neuronové sítě

Jednodimenzionální konvoluční neuronové sítě (1D-CNN) jsou uzpůsobeny pro práci s 1D signály. Ve srovnání s 2D konvoluční neuronovou sítí je zde výhodou zejména nižší výpočetní náročnost a nižší požadovaná hloubka sítě, tedy menší množství skrytých neuronových vrstev. V případě dvanáctisvodového EKG sít' nevnímá záznam jako jeden obrázek, ale jako dvanáct řádků. Takové sítě jsou mnohem jednodušší na implementaci a trénování, což znamená i nižší hardwarové nároky. Mohou tedy být vyvíjeny pro levné aplikace, například pro mobily či jiná příruční zařízení, kterých pracují v reálném čase. Architektura 1D-CNN je znázorněna na obrázku 3.1. [12]






Obrázek 3.1: Ukázka 1D-CNN konfigurace s třemi vrstvami CNN a dvěma propojenými vrstvami. [12]

### 3.3 Základní bloky konvolučních neuronových sítí

#### 3.3.1 Konvoluční vrstva

Konvoluční vrstva slouží k přeměně vstupu (např. obrázku nebo matice signálů) na výstupní příznakovou mapu. Je to provedeno pomocí filtru o menší velikosti než vstup, který má určité váhy. Pomocí tohoto filtru je následně provedena 2D konvoluce tak, jak je vidno na obrázku 3.2, tedy součet součinů více hodnot vstupu a filtru dává právě jednu hodnotu výstupu. Tento výstup je nakonec dosazen do aktivační funkce (běžně se používá např. ReLU) a vznikne příznaková mapa. [13], [14]



Obrázek 3.2: Ukázka principu 2D konvoluce. [14]

Výhodou oproti standardní umělé neuronové síti je výrazně nižší počet vah. Bude-li uvažován vstupní RGB obrázek o rozměrech  $64 \times 64 \times 3$  a filtrem  $6 \times 6$ , konvoluční vrstva bude mít pouze 108 vah, zatímco u standardní, plně propojené neuronové sítě, by bylo 12 288 vah. [13]

### 3.3.2 Pooling

Poolingová vrstva má podvzorkovací funkci, sníží tedy rozměr vstupu, čímž sníží i jeho množství parametrů a samozřejmě i výpočetní náročnost modelu. Nejčastěji se používá max-pooling, při kterém vstupem prochází maska o velikosti  $2 \times 2$  s krokem 2 a na výstup uloží maximum ze čtyř zaměřených hodnot. Vzhledem ke ztrátové povaze poolingové vrstvy není vhodné volit velikost masky větší než  $2 \times 2$ . [13] Další známá poolingová funkce ukládá na výstup průměrnou hodnotu ze zaměřených hodnot. [14]

### 3.3.3 Plně propojená vrstva

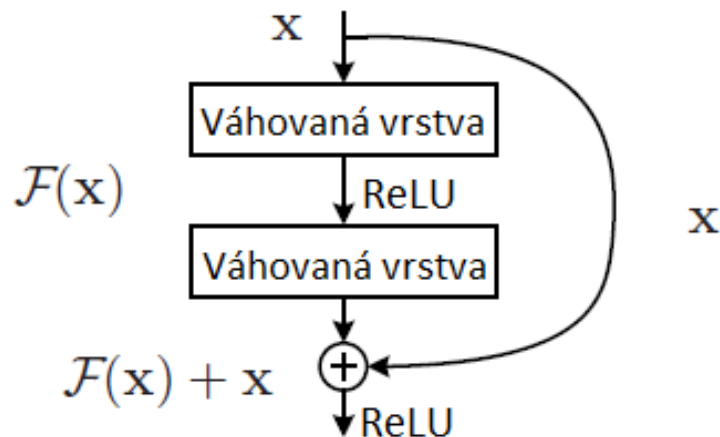
Plně propojená vrstva obsahuje neurony přímo spojené se sousedními vrstvami. Nejsou však propojeny mezi sebou. Tento způsob je shodný s tím, jak jsou propojeny neurony u běžných umělých neuronových sítí. [13]

### 3.4 Pokročilé bloky konvolučních neuronových sítí

#### 3.4.1 Reziduální blok

U hlubokých sítí je občas vidět takzvaný degradační problém – se zvyšující hloubkou sítě se zvyšuje přesnost, dokud se neustálí, ale potom obrovsky degraduje. Přidávání dalších vrstev tedy nemá význam, vedlo by to k ještě větší chybě. A právě zde se nabízí reziduální blok jako řešení. [15]

Uvažujme požadované mapování jako  $H(x)$ . Pak necháme naskládané váhované vrstvy přizpůsobit dalšímu mapování  $F(x) = H(x) - x$ . Původní mapování je tedy  $H(x) = F(x) + x$ . Tato formulace může být realizována dopřednou neuronovou sítí se zkratkovými spoji, jak vidno na obrázku 3.3. Zkratkové spoje jsou ty, které přeskakují jednu nebo více vrstev. V případě níže je jejich výstup přičten k výstupu váhovaných vrstev. [15]



Obrázek 3.3: Reziduální blok [15]

#### 3.4.2 DropOut

Hluboké neuronové sítě jsou schopné naučit se velmi komplikované vztahy mezi svými vstupy a výstupy. S omezeným množstvím trénovacích dat však tyto vztahy nebude vždy možné rozklíčovat a trénování spíše povede k přeučení nežli ke zdokonalení modelu. [16]


Metoda DropOut (z anglického drop out – vypustit) adresuje tento problém tím, že z jednoho velkého modelu utvoří několik menších modelů tak, že vypustí některé náhodně zvolené neurony ze sítě. Vypuštěním jednotky ji dočasně odstraníme ze sítě spolu s jejími vstupními a výstupními spoji. [16], [17]

Zjednodušeně řečeno, každý neuron je vypnut s fixní pravděpodobností  $p$ . Aby byl vykompenzován úbytek, zbylé neurony ve vrstvě jsou touto pravděpodobností vyděleny.

U neuronů vstupní vrstvy však tato pravděpodobnost bývá bližší hodnotě 1, než 0,5, ve skrytých vrstvách pak bývá obvykle 0,5. Neurony výstupní vrstvy se nevypínají vůbec. Při trénování modelu pak vznikne velké množství prořídilých sítí a upravují se vždy váhy pouze těm neuronům, které nebyly vypuštěny. V testovací fázi jsou zapnuty všechny neurony. [16], [17]

### 3.4.3 BatchNorm

Batch Normalizace je metoda, která byla vytvořena za účelem urychlení učení sítě. Normalizuje hodnoty každé vrstvy v síti, nikoli jen vstupní. Normalizace je vypočtena zvlášť pro každý mini-batch (dávku trénovacích dat). Srovnání standardní sítě se sítí po aplikaci BatchNorm je vidět na obrázku 3.4. [17]



Obrázek 3.4: Ukázka neuronové sítě a) bez použití BatchNorm, b) s použitím BatchNorm, kde  $\mu$  je střední hodnota mini-batche a  $\sigma^2$  je jeho rozptyl.  $\gamma$  a  $\beta$  jsou nové parametry, které posouvají a škálují normalizované hodnoty. [17]

BatchNorm pracuje tak, že upraví hodnoty každého mini-batche. Ty jsou během trénování tvořeny náhodně, což má za výsledek šum, který napomáhá regularizovat, tedy předejít přeučení (overfittingu). [17]

Tento blok je možné umístit za každým konvolučním blokem. Bývá umisťován před aktivační blok (např. ReLU). [11]

### 3.5 Proces učení

Model, který by klasifikoval data, je nutné nejprve na nějakých datech naučit, natrénovat. Data jsou obvykle rozdělena do tří podmnožin, a sice do trénovací, validační a testovací sady. Trénovací data slouží k naučení modelu a optimalizaci jeho parametrů. Validací data se používají ke sledování výkonu modelu během učení a k nalezení nejlepšího modelu. Testovací data se používají k vyhodnocení konečného výkonu vyvinutého modelu. [20]

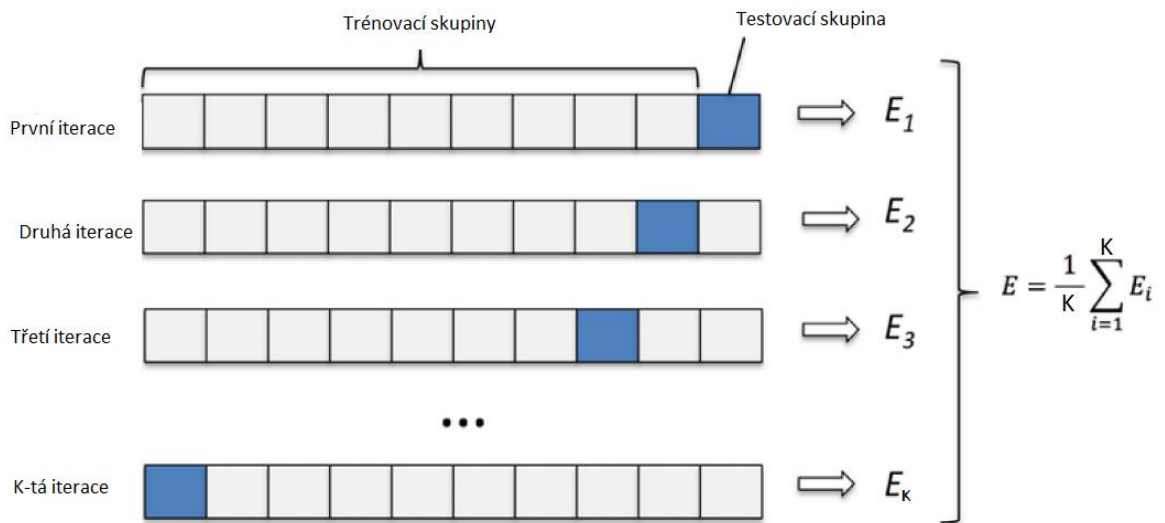
Při rozdělení dat do těchto podmnožin je důležité, aby se zabránilo překrývání mezi trénovací, validační a testovací datovou sadou, což zajistí rozvoj zobecňovací schopnosti vyvinutých modelů. Velikost datového souboru potřebného pro trénování modelů závisí na povaze a složitosti daného úkolu. Správné rozdělení dat do těchto podmnožin je zásadní pro zajištění robustního vývoje modelu a přesného vyhodnocení výkonu. [20]

### 3.5.1 Chybová funkce (Loss Function)

Chyba je rozdílem mezi skutečnými hodnotami a hodnotami, které určil model. Výběr vhodné chybové funkce záleží na účelu modelu. Pro klasifikační úlohy se běžně používá křížová entropie, pro regresní je vhodnější střední kvadratická odchylka. [20]

### 3.5.2 K-násobná křížová validace

Validace je část učení, při které jsou trénovací data rozdělena na K stejných skupin. K-1 z těchto skupin je použito pro trénování modelu, a poslední, K-tá skupina je použita k validaci. Toto je opakováno K-krát, na konci je tedy natrénováno K modelů. Přesnost klasifikátoru je pak rovna jedné K-tině součtu všech K iterací. Na obrázku 3.5 je znázorněno schéma křížové validace, kde K=10. [11]



Obrázek 3.5: Schéma K-násobné křížové validace. [11]

### 3.5.3 Přeučení sítě

Jev přeučení sítě, známý hlavně pod anglickým označením overfitting, nastal, pokud je trénovací přesnost vysoká a testovací přesnost výrazně nižší. Taková síť pak není schopna generalizovat a je naučená fungovat dobře pouze na trénovací data. [13]

Tento problém je možné řešit buď snížením komplexnosti, složitosti modelu, nebo přidáním trénovacích dat, případně použitím regularizačních technik jako Dropout nebo BatchNorm. [14], [17]

Jelikož množství dat je omezené, často je z důvodu nedostatku množství nutné počet dat navyšovat uměle. Těmto metodám se říká augmentační metody. Spočívají v tvorbě nových objektů z těch originálních pomocí různých druhů transformace, jako například přidání šumu, posun nebo rotace. Díky tomu je možné natrénovat model kvalitnější, než kdyby byla použita pouze data originální. [25]

### 3.6 Optimalizační techniky

Trénování modelu je zejména optimalizačním procesem, který se snaží minimalizovat chybu (jinými slovy rozdíl mezi skutečnou a predikovanou hodnotou). Metody, kterými je toho docíleno, jsou gradientní sestup, stochastický gradientní sestup, a mini-batch. Gradientem se rozumí směr nejstrmějšího růstu chyby, jde se tedy proti směru gradientu. Je derivací chybové funkce v určité hodnotě parametru. Pokročilou technikou je pak Adam, při kterém je upravován krok učení. Krok učení je hyperparametr, který určuje, jak moc jsou parametry modelu upravovány. [20]

#### 3.6.1 Gradientní sestup

Gradientní sestup (též Batch nebo Vanilla gradientní sestup) nebo je optimalizační algoritmus, který se používá k úpravě parametrů sítě za účelem minimalizace chyby. V případě této metody jsou upravovány váhy při každé epoše, tedy po každém zpracování celého trénovacího datasetu. [20]

#### 3.6.2 Stochastický gradientní sestup

Tato metoda je malým vylepšením Vanilla gradientnímu sestupu, o kterém je pojednáno výše. Liší se od něj právě tím, že upravuje váhy ne po každé epoše, ale dokonce při každé iteraci, čili po zpracování každého jednoho objektu trénovacího datasetu. [20]

#### 3.6.3 Mini-batch

Mini-batch je metoda, která je kompromisem metod předchozích. Váhy jsou totiž aktualizovány po zpracování každých N objektů, kde N je velikost batche, zvaná batch size. [20]

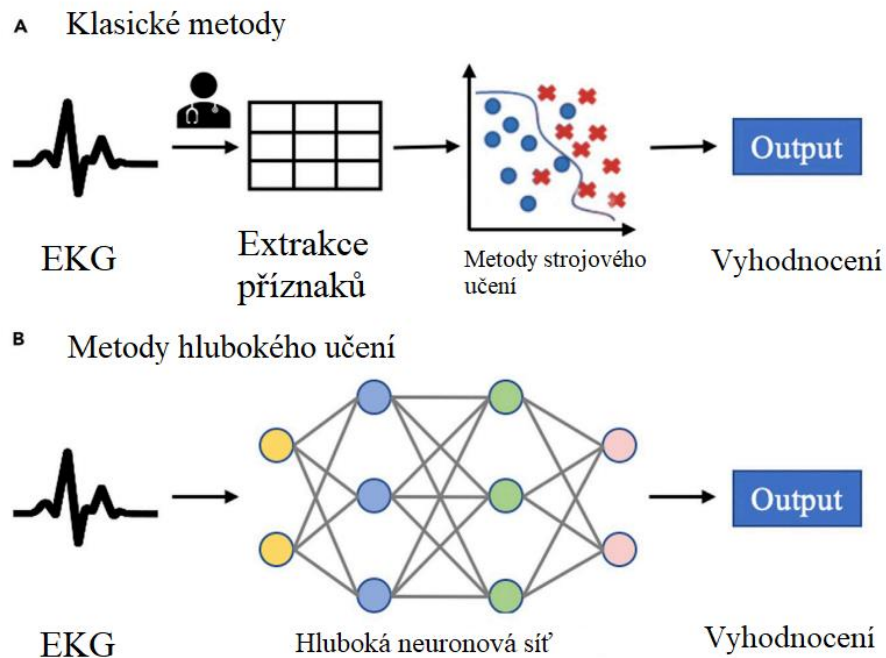
#### 3.6.4 Adam

Optimalizační techniky vycházející z gradientního sestupu mají jednu společnou nevýhodu – krok učení je stanoven na začátku a dále se již nemění. Proto byly vyvinuta

metoda ADAM (zkrácené Adaptive Moment estimation), která je schopná i úpravy kroku učení. Právě díky tomu se pyšní velké popularitě v odvětví hlubokého učení. [20] [21]

### 3.7 Přínos hlubokého učení pro diagnostiku EKG

Třebaže klasické klasifikační metody (např.: umělá neuronová síť, SVM, Random Forest) dosahují dobrých výsledků, procesy získávání příznaků ze signálů EKG a následné tvorby vektoru příznaků jsou komplikované a náročné časově. Navíc je s těmito metodami náročné v praxi dosáhnout očekávané přesnosti či účinnosti. Je zde riziko overfittingu neboli přeučení, jelikož klasifikace je velmi závislá na výběru příznaků, které jsou snadno ovlivnitelné subjektivními faktory. Na obrázku 3.5 je znázorněno srovnání klasických metod s metodami hlubokého učení. [18]



Obrázek 3.6: Srovnání vyhodnocování EKG klasickými metodami s vyhodnocováním metodami hlubokého učení [22]

Metody hlubokého učení mohou minimalizovat proces zpracování signálu a extrakce příznaků, a stejně dosáhnout lepší klasifikační a generalizační schopnosti. Velkou výhodou hlubokého učení je, že tyto neuronové sítě umí extrahovat příznaky a zároveň klasifikovat, namísto aby tyto dvě činnosti byly dělány samostatně. [11], [18]

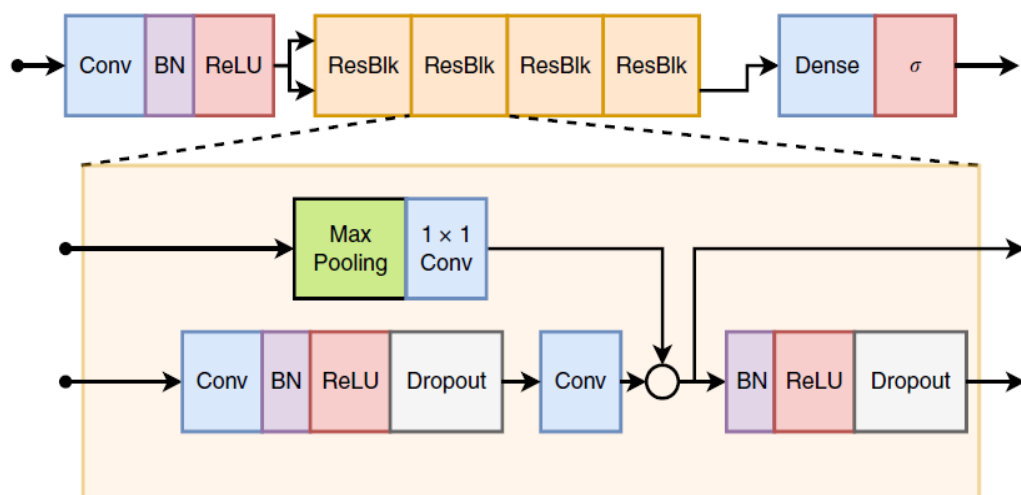
### 3.8 Jednodimenzionální reziduální neuronová síť

Takovou sítí se rozumí konvoluční neuronová síť adaptovaná na 1D signály, do které jsou navíc zařazeny reziduální bloky. Příkladem může být síť uvedená v publikaci [6].

Nejdříve byly pro tuto síť všechny EKG záznamy převzorkovány na vzorkovací frekvenci 400 Hz. Tento signál je vstupem pro neuronovou síť. [6]

Tato síť se skládá z konvoluční vrstvy (Conv) následované čtyřmi reziduálními bloky se dvěma konvolučními vrstvami v každém bloku. Výstup posledního bloku je pak přiveden do plně propojené vrstvy (Dense) se sigmoidní aktivační funkcí  $\sigma$ , která byla použita, protože třídy se vzájemně nevylučují a ve stejném záznamu se mohou vyskytovat i dvě nebo více abnormalit. Výstup každé konvoluční vrstvy je přeškálován pomocí batch normalizace (BN) a přiváděn do usměrněné lineární aktivační jednotky (ReLU), po níž se aplikuje DropOut. Schéma sítě je znázorněno obrázkem 3.6. [6]

Konvoluční vrstvy mají délku filtru 16. 64 filtrů je v první vrstvě a reziduálním bloku, počet filtrů se zvyšuje o 64 v každém druhém reziduálním bloku, podvzorkovává se faktorem 4 na každém reziduálním bloku. Do zkratkových spojů jsou zahrnuty vrstvy Max Pooling a konvoluční vrstvy s délkou filtru 1 (1x1 Conv), aby rozměry byly přizpůsobeny rozměrům signálů v hlavní větvi. [6]



Obrázek 3.6: Schéma jednodimenzionální reziduální neuronové sítě [6]

Podobná reziduální konvoluční neuronová síť byla navržena i v publikaci [22], lišila se hlavně zkratkovým spojem, který v jejich případě neobsahoval žádné bloky.

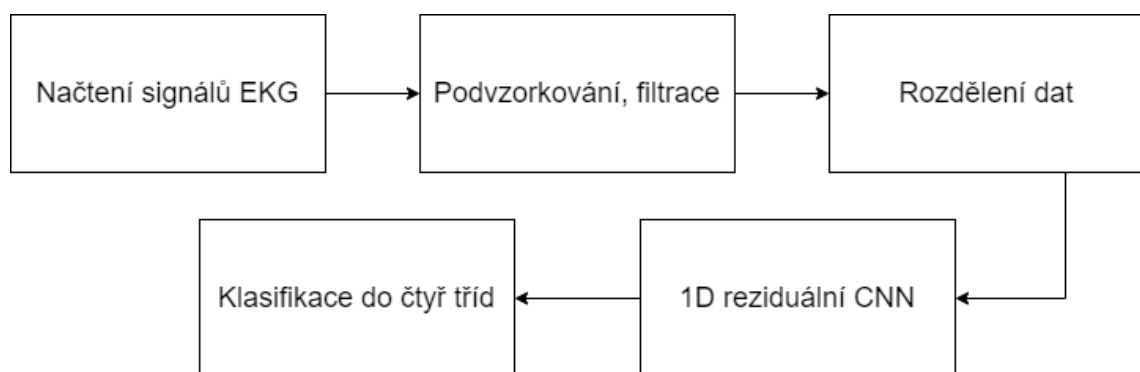


## 4 Praktická část

V této kapitole bude představen navržený model hluboké neuronové sítě, který bude klasifikovat záznamy EKG. Tato kapitola také obsahuje části, v nichž bude model vyhodnocován a upravován.

### 4.1 Navržení algoritmu pro klasifikaci EKG

Na obrázku 4.1 se nachází obecnější blokové schéma postupu. Na začátku jsou EKG data tak, jak se nacházejí v datasetu. Předzpracování bude spočívat ve snížení vzorkovací frekvence z důvodu snížení výpočetní náročnosti. Takto předzpracované signály pak jsou vstupem do konvoluční neuronové sítě, která je podrobněji popsána v kapitole 3.8.



Obrázek 4.1: Blokové schéma navrženého postupu pro klasifikaci EKG.

Model klasifikuje EKG záznamy do čtyř tříd – záznam zdravého pacienta, a tři zvolené abnormality, které si nejsou příliš podobné, ale zároveň jsou v hojném množství zastoupené v datasetu. První třídou budou záznamy pacientů zdravých, tedy se sinusovým rytmem. Do druhé třídy spadají pacienti se sinusovými bradykardiemi. Třetí třída bude pro záznamy pacientů, kteří trpí flutterem síní. Jako třída čtvrtá byla zvolena sinusová tachykardie. Tyto abnormality byly popsány v kapitole 1.4, jejich ukázky budou v kapitole 4.2. Všechny ostatní záznamy, které nejsou zdravé, avšak je nelze zařadit ani do jedné ze tří abnormalit výše, nebudou použity. V tabulce 5.1 níže je k nalezení přehled klasifikovaných tříd, které byly stručně představeny v kapitole 1.4.

Třída	Název	Zkratka	SNOMED kód	Počet zástupců
1	Sinusový rytmus	SR	426783006	8114
2	Sinusová bradykardie	SB	426177001	16559
3	Flutter síní	AF	164890007	8039
4	Sinusová tachykardie	ST	427084000	7251
5	Jiné abnormality			11440


Tabulka 4.1: Přehled klasifikovaných tříd [19]

## 4.2 Použitá data

Byl použit dataset z databáze PhysioNet, který obsahuje 45 152 záznamů standardního dvanáctisvodového EKG o délce deset sekund, měřeného v klidu. Data byla z databáze PhysioNet převzata ve formátu WFDB (Wave Form Database), ve kterém každý EKG záznam je reprezentován dvojicí souborů – soubor obsahující surová data s příponou .mat, a související hlavičkový soubor s příponou .hea. Hlavičkový soubor obsahuje další informace, například údaje o věku a pohlaví pacienta. Obsahuje i údaj o třídě záznamu. Každý záznam obsahuje 5000 vzorků signálu. Vzorkovací frekvence každého záznamu je 500 Hz, délka každého signálu je tedy deset sekund. [6], [19]


Označení každého záznamu EKG, respektive jeho rytmu či případných dalších srdečních stavů bylo provedeno licencovaným lékařem. Tato označení byla posléze validována jiným licencovaným lékařem. Pokud došlo k neshodě, zasáhl vrchní lékař a učinil konečné rozhodnutí. Tato označení jsou k nalezení v .hea souboru každého záznamu pod položkou Dx, a to podle SNOMED kódu. Tyto kódy jsou rozklíčovány v souboru ConditionNames\_SNOMED-CT.csv. [6], [19]

Na obrázcích 4.2 až 4.5 níže jsou zobrazeny ukázky signálů z datasetu, a to z každé ze čtyř tříd.




Obrázek 4.2: Ukázka záznamu se sinusovým rytmem. Záznam JS00021, svod II. [19]

Na obrázku 4.3 je ukázka záznamu sinusové bradykardie, typické hlavně svojí nízkou tepovou frekvencí.




Obrázek 4.3: Ukázka záznamu se sinusovou bradykardií. Záznam JS00002, svod II. [19]

Záznam flutteru síní na obrázku 4.4 je typický P vlnami pilovitého charakteru o vysoké frekvenci.



Obrázek 4.4: Ukázka záznamu s flutterem síní. Záznam JS00029, svod II. [19]

Záznam EKG se sinusovou tachykardií je zobrazen na obrázku 4.5 a je charakteristický výrazně vysokou frekvencí.



Obrázek 4.5: Ukázka záznamu se sinusovou tachykardií. Záznam JS00057, svod II. [19]

### 4.3 Použité programy

Tato práce byla realizována v jazyce Python v prostředí Spyder. Při psaní kódu byly využity známé knihovny funkce, zejména Numpy pro usnadnění práce s vícerozměrnými poli (takzvané arrays), dále knihovna Tensorflow pro návrh modelu nebo knihovna Os

pro práci se složkami uloženými v počítači. Za zmínku též stojí knihovna SciPy pro práci se signály a Seaborn nebo Pyplot pro zobrazování výsledků.


#### 4.4 Načtení, předzpracování dat a zobrazení signálu

Data jsou rozmístěna ve 46 složkách, kde každá složka má deset podsložek a v každé podsložce je 100 záznamů v souboru .mat a 100 hlavičkových souborů ve formátu .hea. Funkce *folderloader* tato data načte složku po složce. Pro snížení výpočetní náročnosti tato funkce ukládá signály rovnou předzpracované, navíc ve formátu float16. Labely, tedy informace o příslušné třídě, byly uloženy formou One Hot Encodingu, což znamená, že každá třída byla uložena v binárním vektoru plném nul, kde se vyskytovala jednička na takové pozici, které přísluší třída záznamu.

Dále byla vytvořena funkce *predzpracovani*, jejíž vstupem je surový signál, jeho vzorkovací frekvence a decimální faktor. Funkce disponuje dvěma filtry typu FIR pro odstranění rušení. První filtr je horní propust, která má za úkol odstranit nízkofrekvenční rušení, tedy kolísání nulové izolínie způsobené např. pohybem pacienta nebo jeho dýcháním. Jeho mezní frekvence je nastavena na 0,8 Hz. Druhým filtrem je dolní propust k odstranění vysokofrekvenčního rušení. Jeho mezní frekvence je 100 Hz. Po filtraci navíc funkce sníží vzorkovací frekvenci na 125 Hz (při decimálním faktoru 4). Nižší vzorkovací frekvence je již pro účely práce s EKG příliš nízká, avšak s frekvencí 250 Hz (při decimálním faktoru 2) je také možné pracovat. Pro snížení výpočetní náročnosti byly také signály ponechány v datovém typu float16.

Jiné abnormality, které nebyly zařazeny ani do jedné ze zkoumaných tříd, byly z datasetu odstraněny. K tomu slouží vytvořená funkce *remover*, která zjistí, kde se v množině dat nacházejí signály jiných abnormalit. Jakmile zjistí pozice těchto signálů, odstraní je a proměnnou s labely učiní o sloupec kratší. Výstupem z funkce *remover* je tedy množina signálů, které spadají do zvolených tříd, a množina přidělených tříd jakožto binární pole se čtyřmi sloupci.

Dále byla vytvořena funkce *zobraz*, která zobrazí signál před filtrací a po filtraci. Vstupem je surový signál a jeho vzorkovací frekvence. Funkce *zobraz* zavolá funkci *predzpracovani* pro úpravu signálu a jako výstup pomocí knihovny Pyplot vytvoří zobrazení signálu. Na obrázku 4.6 je ukázka záznamu JS00002 v jeho surové a filtrované formě.



Obrázek 4.6: Ukázka záznamu JS00002. Nahoře bez jakékoliv filtrace či podvzorkování, dole filtrovaný a podvzorkovaný na 125 Hz. [19]

#### 4.5 Rozdělení dat na trénovací, validační a testovací množinu

Pro tyto účely byla vytvořena funkce *rozdeleni*, která množinu signálů rozdělenou do čtyř tříd zamíchá a rozdělí v následujícím poměru: 70 % objektů na trénování sítě, 15 % pro průběžnou validaci a 15 % pro konečné testování dat.

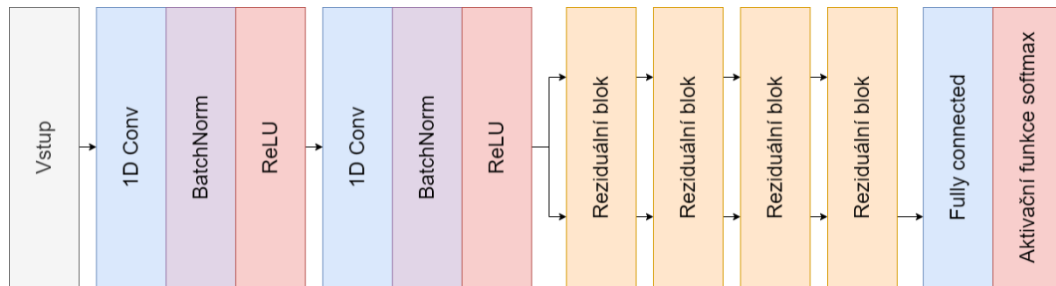
Problém nevyváženého datasetu byl adresován funkcí *weighting*, která přiřazuje váhy jednotlivým třídám. Sinusová bradykardie má kupříkladu nejvíce zástupců v datasetu, je jí tedy přiřazena nejnižší váha, zatímco sinusová tachykardie má zástupců nejméně, je jí tedy přiřazena váha nejvyšší.

Trénovací množina dat byla navíc rozšířena – pomocí funkce *generator\_dat* byly v každém batchi utvořeny nové vzorky signálu, které vycházely z originálních dat, ale totožné s nimi nebyly. Toto umožnilo zvýšit množství dat, které bylo modelu předloženo k učení. Originální záznamy byly posunuty o malý počet vzorků, což mělo za následek vznik nových záznamů, které přispěly k rozmanitosti dat, a tedy k natrénování kvalitnějšího modelu.


#### 4.6 Architektura modelu

Architektura modelu vychází z modelů, které byly představeny v teoretické části v kapitole 3, zejména pak z modelu z publikace [6]. Jedná se tedy o 1D reziduální model. Model sestává ze dvou konvolučních bloků následovaných batch normalizací a aktivační funkcí ReLU a čtyř bloků reziduálních. Konvoluční bloky sestávají z 64 filtrů o délce 16.

Na konci je již plně propojená vrstva s čtyřmi neurony s aktivační funkcí softmax, které provedou klasifikaci do čtyř tříd. Na obrázku 4.7 je znázorněno podrobnější blokové schéma navrženého modelu, obrázek 4.8 pak poskytuje náhled do reziduálního bloku.



Obrázek 4.7: Blokové schéma navrženého modelu.



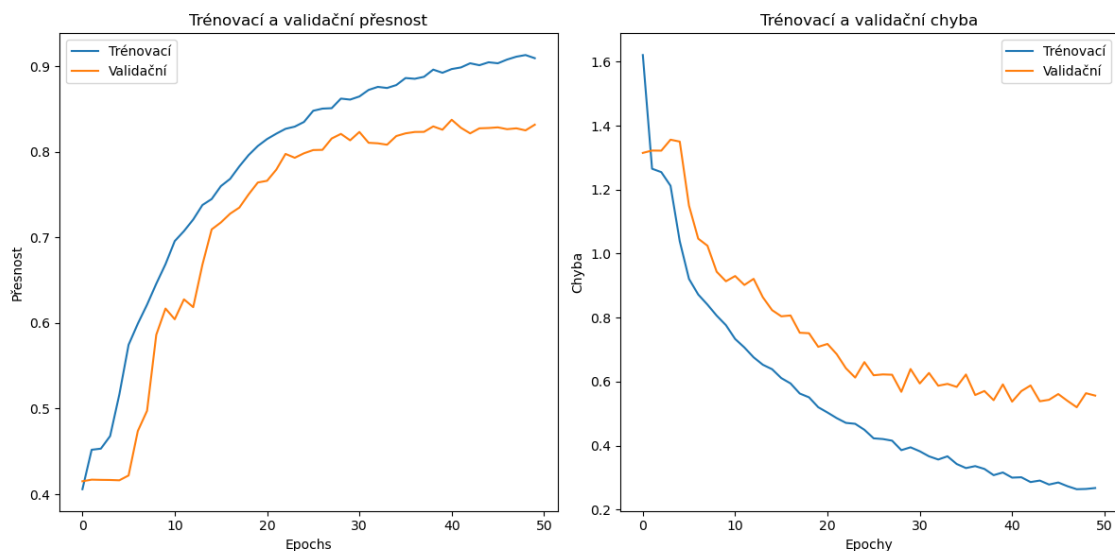
Obrázek 4.8: Blokové schéma reziduálního bloku.

## 4.7 Trénování modelu

Jako optimalizační technika byla použita technika ADAM, zejména pro svoji schopnost upravovat krok učení dle potřeby. Dále byla zvolena velikost dávky (batch size), a to sto objektů. Bylo rozhodnuto, že model bude trénován padesáti epochami. Po každé z epoch byla stanovena validační přesnost pro lepší sledování úspěšnosti modelu. Jako chybová funkce byla zvolena křížová entropie.

## 4.8 Vyhodnocení úspěšnosti modelu

Model po padesáti epochách trénování skončil s trénovací přesností 90,94 % a testovací přesností 82,85 %. Na obrázku 4.8. je zobrazen průběh trénovací a validační úspěšnosti po celou dobu učení. Tabulka 4.2. pak znázorňuje matici záměn, která již poskytuje lepší náhled na úspěšnost modelu.



Obrázek 4.8: Průběh trénovací a validační přesnosti(vlevo) a chyby(vpravo) při učení modelu.

Matice záměn		Predikované třídy			
		SR	SB	FLUT	ST
Skutečné třídy	SR	1192	37	405	27
	SB	16	3113	189	4
	FLUT	85	78	1360	45
	ST	73	13	399	957

Tabulka 4.2: Matice záměn navrženého klasifikačního modelu.

Tyto výsledky budou nyní vyhodnoceny pomocí přesnosti (precision), úplnosti (recall) a F1 skóre. Přesnost (precision) vyjadřuje, kolik objektů, kterým byla přiřazena třída, do této třídy skutečně patří. [24] Je vyjádřena rovnicí 4.1:

$$precision = \frac{TP}{TP + FP} \quad (4.1)$$

kde TP je počet skutečně pozitivních vzorků, v tomto případě tedy EKG záznam, jehož predikovaná třída shodná s třídou skutečnou. FP je pak počet falešně pozitivních vzorků, v tomto případě tedy počet EKG záznamů, jejichž predikovaný třída byla jiná, než je skutečná (v tabulce 4.2 je příkladem FP 16 záznamů bradykardie, které byly nesprávně označeny za sinusový rytmus). [24]

Úplnost (recall) vyjadřuje, kolik z objektů skutečně patřících do určité třídy bylo modelem správně označeno. V tomto případě by to byl poměr správně označených záznamů EKG ku počtu všech záznamů skutečně spadajících do této třídy. [24] Úplnost lze vyjádřit rovnicí 4.2:

$$recall = \frac{TP}{TP + FN} \quad (4.2)$$

kde FN je počet falešně negativních vzorků, tedy počet vzorků, které patří do určité třídy, ale nebyly do ní modelem zařazeny. V tomto případě je v tabulce 4.2 příkladem FN 45 záznamů flutteru síní, které byly mylně označeny za tachykardii. [24]

F1 skóre je pak harmonickým průměrem mezi přesností (precision) a úplností a lze jej vyjádřit rovnicí 4.3:

$$F1 = 2 \times \frac{P \times R}{P + R} \quad (4.3)$$

kde P je přesnost (precision) a R je úplnost. [24]

Třída	Přesnost (precision)	Úplnost (recall)	F1 skóre	Počet záznamů
SR	0,873	0,718	0,788	1661
SB	0,961	0,937	0,948	3322
FLUT	0,578	0,867	0,693	1568
ST	0,926	0,664	0,773	1442
Průměr	0,835	0,797	0,801	

Tabulka 4.3: Přesnost (precision), úplnost (recall) a F1 skóre zvlášť pro každou třídu.

Z výsledků je patrné, že nejlépe si model vedl při vyhodnocování sinusové bradykardie. Z hlediska přesnosti si pak nejhůře vedl při detekci flutteru síní a z hlediska úplnosti při detekci sinusových tachykardií. Tyto chyby jsou dány mírnou podobností těchto abnormalit.



## 5 Diskuze výsledků

V této diplomové práci byl navržen klasifikační model, který vycházel z dostupných publikací na téma automatické klasifikace EKG. Model měl po padesáti trénovacích epochách trénovací přesnost 90,94 % a testovací přesnost 82,55 %. Takové výsledky jsou sice uspokojivé, avšak výsledky publikací, ze kterých model vychází, jsou stále patrně vyšší. Výsledky navrženého modelu mohly být ovlivněny následujícími jevy:

První je, že mnohým záznamům z datasetu byla originálně přidělena více než jedna třída. To mohlo vést k tomu, že se v některých záznamech mohl projevit rys jiné abnormality, než byla softwarově přidělena, a toto mohlo vést ke zkreslení výsledků.

Druhá možnost, která modelu bránila v dosažení lepších výsledků, mohla být v nevelkém výběru dostatečně zastoupených tříd. Dataset sice nabízel přes padesát různých nalezených abnormalit, jejichž množství však bylo malé. V tabulce 5.1 jsou uvedeny některé třídy, jejichž množství je pro jejich využití v práci nedostatečné:

Název abnormality	Počet objektů v datasetu
Blokáda levého Tawarova raménka	240
Předčasný ventrikulární tep	294
Blokáda pravého Tawarova raménka	649

Tabulka 5.1: Ukázka malého množství záznamů s některými abnormalitami

Třetí důvod, který model drží při nízké úspěšnosti, je mírná podobnost mezi hodnocenými třídami, dost záznamů flutteru síní bylo například nesprávně označeno za záznam se sinusovou tachykardií.

### 5.1 Srovnání výsledků modelu s výsledky jiných autorů

V tabulce 5.2 jsou zobrazeny výsledky modelů z jiných publikací, které řešily podobnou problematiku.

Jméno autora	Průměrná přesnost (precision)	Průměrná úplnost (recall)	Průměrné F1 skóre	Průměrná přesnost (accuracy)
Antonio Ribeiro	0,924	0,934	0,9255	neuveдено
Ondřej Blaude	0,835	0,797	0,801	82,85 %
Dongdong Zhang	0,821	0,812	0,813	96,6 %

Tabulka 5.2: Srovnání navrhovaného modelu s modely souvisejících publikací [6], [22]

Model publikace [22] (autor Dongdong Zhang) klasifikoval 9 tříd, z nichž žádná třída kromě sinusového rytmu nebyla s naším modelem společná. Model Antonia Ribeira zase vyhodnocoval 6 tříd, z toho dvě abnormality byly společné s naším datasetem, a to sinusová bradykardie a tachykardie. Tento model navíc nedetekoval sinusový rytmus a byl zaměřen pouze na abnormality.

Co se týče používaných datasetů, v publikaci [6] (autor Antonio Ribeiro) byl trénovací dataset mnohokrát větší než dataset použitý v této práci, a to přes 2,3 milionu záznamů, testovací dataset byl ale zase mnohem menší, a to pouhých 827 záznamů. [6] V publikaci [22] byl dataset poněkud menší, ale stále větší než v našem případě. V rámci trénování v publikaci uvádí dataset o velikosti přes 91 tisíc záznamů. [22] Používání jiných datasetů, které navíc nabývají jiných velikostí, může též mít za následek odlišné výsledky.

## 6 Závěr

Tato diplomová práce se zabývala problematikou automatické klasifikace dvanáctisvodového EKG metodami hlubokého učení. Práce měla za cíl prozkoumat porovnat klasické metody klasifikace s metodami hlubokého učení, navrhnout klasifikační model a ověřit jeho funkčnost pomocí doporučeného datasetu z databáze PhysioNet.

První kapitola tedy obsahuje krátké pojednání o EKG i o srdci. Je zde popsána funkce srdce, stejně tak jsou zde uvedeny i vybrané abnormality, které byly v pozdějších kapitolách klasifikovány, včetně jejich ukázek na EKG.

Ve druhé kapitole jsou představeny klasické metody vyhodnocování EKG, jako například SVM nebo náhodný les. Je zde popsán základní princip extrakce příznaků např. metodou PCA. U každé metody je krátce popsán její princip a přednosti. Je zde též popsána limitace těchto metod.

Třetí kapitola slouží k seznámení s metodami hlubokého učení. Byly zde popsány základní a pokročilé bloky konvolučních neuronových sítí, byly vysvětleny i přínosy metod hlubokého učení oproti metodám klasickým. Byla také představena struktura reziduální sítě.

Čtvrtá kapitola již sestává z popisu navrženého modelu, jeho trénování a testování. Testovací přesnost modelu byla 82,55 %, průměrné F1 skóre bylo 0,801. Výsledky jsou pak v páté, poslední kapitole diskutovány a srovnány s dostupnými publikacemi.

## 7 Literatura

- [1] LANGMEIER, Miloš. *Základy lékařské fyziologie*. Praha: Grada, 2009. ISBN 978-80-247-2526-0.
- [2] GANONG, William F. *Přehled lékařské fyziologie*. Jinočany, 1995. ISBN 80-857-8736-9.
- [3] HAMPTON, John R. *EKG stručně, jasně, přehledně*. Vyd. 2., rozš. Praha: Grada, 2005, c1996. ISBN 80-247-0960-0.
- [4] VÍTEK, M. *Automatické rozměření signálů EKG*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2010. 129 s. Vedoucí dizertační práce doc. Ing. Jiří Kozumplík, CSc.
- [5] ROZMAN, Jiří. *Elektronické přístroje v lékařství*. Praha: Academia, 2006. Česká matice technická (Academia). ISBN 80-200-1308-3.
- [6] RIBEIRO, Antônio H., Manoel Horta RIBEIRO, Gabriela M. M. PAIXÃO, et al. Automatic diagnosis of the 12-lead ECG using a deep neural network. *Nature Communications* [online]. 2020, **11**(1). ISSN 2041-1723. Dostupné z: doi:10.1038/s41467-020-15432-4
- [7] KENNEDY, Alan, Dewar D. FINLAY, Daniel GULDENRING, Raymond R. BOND, Kieran MORAN a James MCLAUGHLIN. Automated detection of atrial fibrillation using R-R intervals and multivariate-based classification. *Journal of Electrocardiology* [online]. 2016, **49**(6), 871-876. ISSN 00220736. Dostupné z: doi:10.1016/j.jelectrocard.2016.07.033
- [8] PAL, M. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing* [online]. 2007, **26**(1), 217-222. ISSN 0143-1161. Dostupné z: doi:10.1080/01431160412331269698
- [9] 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, **127**, 52-63. ISSN 01692607. Dostupné z: doi:10.1016/j.cmpb.2015.12.024
- [10] HANNUN, Awni Y., Pranav RAJPURKAR, Masoumeh HAGHPANAHI, Geoffrey H. TISON, Codie BOURN, Mintu P. TURAKHIA a Andrew Y. NG. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine* [online]. 2019, **25**(1), 65-69. ISSN 1078-8956. Dostupné z: doi:10.1038/s41591-018-0268-3

- [11] AVANZATO, Roberta a Francesco BERITELLI. Automatic ECG Diagnosis Using Convolutional Neural Network. *Electronics* [online]. 2020, 9(6). ISSN 2079-9292. Dostupné z: doi:10.3390/electronics9060951
- [12] 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. Dostupné z: <https://arxiv.org/abs/1905.03554>
- [13] O'SHEA, Keiron a Nash RYAN. *An Introduction to Convolutional Neural Networks* [online]. arXiv, 2015. Dostupné z: doi:10.48550/ARXIV.1511.08458
- [14] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. *Deep Learning* [online]. MIT Press, 2016. Dostupné z: [www.deeplearningbook.org](http://www.deeplearningbook.org)
- [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. ISBN 978-1-4673-8851-1. Dostupné z: doi:10.1109/CVPR.2016.90
- [16] Srivastava, Nitish & Hinton, Geoffrey & Krizhevsky, Alex & Sutskever, Ilya & Salakhutdinov, Ruslan. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*. 15. 1929-1958. Dostupné z: [jmlr.org/papers/volume15/srivastava14a/srivastava14a.pdf](http://jmlr.org/papers/volume15/srivastava14a/srivastava14a.pdf)
- [17] GARBIN, Christian, Xingquan ZHU a Oge MARQUES. Dropout vs. batch normalization: an empirical study of their impact to deep learning. *Multimedia Tools and Applications* [online]. 2020, **79**(19-20), 12777-12815. ISSN 1380-7501. Dostupné z: doi:10.1007/s11042-019-08453-9
- [18] NIU, Lisha, Chao CHEN, Hui LIU, Shuwang ZHOU a Minglei SHU. A Deep-Learning Approach to ECG Classification Based on Adversarial Domain Adaptation. *Healthcare* [online]. 2020, 8(4). ISSN 2227-9032. Dostupné z: doi:10.3390/healthcare8040437
- [19] Zheng, J., Guo, H., & Chu, H. (2022). *A large scale 12-lead electrocardiogram database for arrhythmia study (version 1.0.0)*. PhysioNet. Dostupné z: [doi.org/10.13026/wgex-er52](https://doi.org/10.13026/wgex-er52).

- [20] 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). ISSN 1229-6929. Dostupné z: doi:10.3348/kjr.2019.0312
- [21] KINGMA, Diederik P. a Jimmy BA. Adam: A Method for Stochastic Optimization [online]. 2017. Dostupné z: doi:arxiv.org/abs/1412.6980
- [22] ZHANG, Dongdong, Samuel YANG, Xiaohui YUAN a Ping ZHANG. Interpretable deep learning for automatic diagnosis of 12-lead electrocardiogram. *IScience* [online]. 2021, 24(4). ISSN 25890042. Dostupné z: doi:10.1016/j.isci.2021.102373
- [23] OPPENHEIM, Alan V. a Ronald W. SCHAFER. Discrete time signal processing [online]. Second edition. Prentice-Hall. ISBN 0-13-754920-2. Dostupné také z: [https://research.iaun.ac.ir/pd/naghsh/pdfs/UploadFile\\_2230.pdf](https://research.iaun.ac.ir/pd/naghsh/pdfs/UploadFile_2230.pdf)
- [24] DALIANIS, Hercules. Evaluation Metrics and Evaluation. *Clinical Text Mining* [online]. Cham: Springer International Publishing, 2018, 2018-05-15, 45-53. ISBN 978-3-319-78502-8. Dostupné z: doi:10.1007/978-3-319-78503-5\_6
- [25] 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](https://www.vutbr.cz/studenti/zav-prace/detail/113381?zp_id=113381). Dizertační práce. VUT. Vedoucí práce Radim Burget.

## Seznam zkratek

SA uzel	Sinoatriální uzel
AV uzel	Atrioventrikulární uzel
EKG	Elektrokardiogram
DWT	Diskrétní vlnková transformace (angl. Discrete Wavelet Transform)
PCA	Analýza hlavních komponent (angl. Principal Component Analysis)
ICA	Analýza nezávislých komponent (angl. Independent Component Analysis)
SVM	Metoda podpůrných vektorů (angl. Support Vector Machine)
RBF	Radiální bazová funkce (angl. Radial Basis Function)
CNN	Konvoluční neuronová síť Convolutional Neural Network
WFDB	Wave Form Database
SNOMED CT	Systematized Nomenclature of Medicine Clinical Terms
SR	Sinusový rytmus
SB	Sinusová bradykardie
FLUT	Flutter síní
ST	Sinusová tachykardie

## Seznam příloh

A Popis realizovaných funkcí

38



## A Popis realizovaných funkcí

V této práci jsou celkem čtyři .py soubory, díky kterým je realizována klasifikace EKG:

- *main.py* – spouštěcí skript, volá funkce dle potřeby. Nejprve načte a předzpracuje data, potom odstraní „jiné abnormality“, rozdělí data na trénovací, validační a testovací množinu, vytvoří a natrénuje model, a nakonec model vyhodnotí.
- *folderloader.py* – Soubor, který slouží k načtení dat. Obsahuje čtyři funkce:
  - *folderloader* – Načte veškeré složky a rovnou předzpracované signály ukládá do polí, s kterými se následně pracuje. Volá funkci *predzpracovani* ze souboru *predzprac.py*.
  - *remover* – odstraní všechny objekty, které patří do kategorie „jiné abnormality“.
  - *weighting* – přidělí každé klasifikované třídě váhu podle zastoupení třídy v datasetu (čím větší zastoupení, tím menší váha)
  - *rozdeleni* – rozdělí dataset na trénovací, validační a testovací množinu.
- *predzprac.py* – obsahuje dvě funkce – jednu k předzpracování signálů a jednu k jejich zobrazení.
  - *predzpracovani* – odstraní nízkofrekvenční i vysokofrekvenční rušení a podvzorkuje signál dle zadaného stupně decimace.
  - *zobraz* - *zobrazí* signál před a po předzpracování. Volá funkci *predzpracovani*.
- *my\_net.py* – obsahuje čtyři funkce, které mají na starost chod, konstrukci a vyhodnocení navrženého modelu.
  - *generator\_dat* – funkce augmentující data přidáním posunu.
  - *resBlk* – funkce konstruuující reziduální blok.
  - *resNet* – funkce konstruuující reziduální síť.
  - *skore* – funkce, která vypočítá z matice záměn přesnost (precision), úplnost (recall) a F1 skóre pro každou klasifikovanou třídu.