

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2021

Bc. Michal Vencel



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

HODNOCENÍ KVALITY SIGNÁLŮ EKG

EKG QUALITY EVALUATION

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Michal Vencel

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Lukáš Smital, Ph.D.

BRNO 2021



Diplomová práce

magisterský navazující studijní obor **Biomedicínské a ekologické inženýrství**

Ústav biomedicínského inženýrství

Student: Bc. Michal Vencel

ID: 221425

Ročník: 2

Akademický rok: 2020/21

NÁZEV TÉMATU:

Hodnocení kvality signálů EKG

POKYNY PRO VYPRACOVÁNÍ:

1) Prostudujte problematiku hodnocení kvality signálů EKG. Proveďte literární rešerši nejčastěji používaných metod v krátkodobých i dlouhodobých záznamech EKG. 2) Vybranou metodu/metody realizujte a implementujte ve vhodném programovém prostředí. 3) Funkčnost realizovaných metod ověřte na umělých datech nebo na vhodné volně dostupné databázi. Dosažené výsledky diskutujte. 4) Na základě předchozích poznatků navrhnete vlastní metodu odhadu kvality signálů EKG nebo optimalizujte některou z již navržených metod. 5) Ověřte robustnost vlastní metody na kompletní vhodné databázi s reálnými záznamy EKG a porovnejte ji s metodami jiných autorů. 7) Proveďte diskusi dosažených výsledků, formulujte použitelnost jednotlivých metod.

DOPORUČENÁ LITERATURA:

[1] SILVA, Ikaro; MOODY, George B.; CELI, Leo. Improving the quality of ECGs collected using mobile phones: The Physionet/Computing in Cardiology Challenge 2011. In: Computing in Cardiology, 2011. IEEE, 2011. p. 273-276.

[2] ORPHANIDOU, Christina, et al. Signal-quality indices for the electrocardiogram and photoplethysmogram: derivation and applications to wireless monitoring. IEEE journal of biomedical and health informatics, 2015, 19.3: 832-838.

Termín zadání: 8.2.2021

Termín odevzdání: 21.5.2021

Vedoucí práce: Ing. Lukáš Smital, Ph.D.

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

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 se zabývá tématem hodnocení kvality EKG signálů. V úvodních kapitolách jsou vysvětleny základní charakteristiky EKG signálů – měření, průběh naměřeného signálu, způsoby analýzy. Uvedena je fyziologie srdeční činnosti a patologie. Zmíněny jsou také nejčastější typy šumu, které se u EKG signálů vyskytují. Čtenář je dále seznámen s významem problematiky hodnocení kvality EKG signálů.

V praktické části práce jsou představeny dvě vlastní metody pro hodnocení kvality EKG. Nejdříve je podán stručný teoretický úvod k použitým technikám při tvorbě metod, následuje popis principu algoritmu. Za účelem srovnání funkčnosti navržených metod jsou uvedeny ještě další tři metody od jiných autorů. Je stručně popsán jejich princip.

V závěrečné kapitole jsou všechny metody podrobeny testování funkčnosti. Výsledky jsou zhodnoceny a jednotlivé metody mezi sebou srovnány.

Klíčová slova

Elektrokardiografie, EKG, hodnocení kvality EKG, FSST, neuronové sítě, Odstup signálu od šumu

Abstract

This seminar work deals with the topic of evaluating the quality of ECG signals. The introductory chapters explain the basic characteristics of ECG signals - measurement, the form of the measured signal, methods of analysis. The cardiac physiology and pathology is presented. The most common types of noise that occur in ECG signals are also mentioned. Further, the reader is acquainted with the importance of the issue of evaluating the quality of ECG signals.

In the practical part of the work, two own methods for ECG quality evaluation are presented. First, a brief theoretical introduction to the techniques used in the creation of methods is given, followed by a description of the principle of algorithms. In order to compare the functionality of the proposed methods, three more methods from other authors are presented. Their principle is briefly described.

In the final chapter, all methods are subjected to functionality testing. The results are examined and all methods are compared with each other.

Keywords

Electrocardiography, ECG, ECG quality evaluation, FSST, neural networks, Signal to noise ratio

Bibliografická citace

VENCEL, M. *Hodnocení kvality signálů EKG*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2021. Diplomová práce. Vedoucí práce: Ing. Lukáš Smital, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení studenta: *Michal Vencel*

VUT ID studenta: *221425*

Typ práce: *Diplomová práce*

Akademický rok: *2020/21*

Téma závěrečné práce: *Hodnocení kvality signálů EKG*

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

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

V Blansku dne: 17. května 2021

podpis autora

Poděkování

Na tomto místě bych chtěl poděkovat vedoucímu diplomové práce Ing. Lukáši Smitalovi, Ph.D. za cenné rady a pomoc při vypracovávání práce. Dále bych chtěl poděkovat Ing. Tomáši Vičarovi za pomoc s problematikou neuronových sítí.

V Blansku dne: 17. května 2021

podpis autora

Obsah

1	EKG	1
1.1	HISTORIE.....	1
1.2	FYZIOLOGIE SRDEČNÍ ČINNOSTI.....	2
1.3	EKG SIGNÁL.....	4
1.4	PATOLOGICKÉ PRŮBĚHY EKG.....	6
1.5	TYPY ŠUMU.....	9
1.6	VÝZNAM HODNOCENÍ KVALITY EKG.....	11
2	POUŽITÉ NÁSTROJE	12
2.1	FOURIEROVA „SYNCHROSQUEEZED“ TRANSFORMACE (FSST).....	12
2.2	NEURONOVÉ SÍŤE.....	14
3	REALIZACE METOD PRO HODNOCENÍ EKG	18
3.1	NEPŘÍMÁ METODA.....	18
3.2	PŘÍMÁ METODA.....	28
3.3	SNR METODA.....	31
3.4	MSQI.....	33
4	VÝSLEDKY	37
4.1	TESTY SPRÁVNOSTI HODNOCENÍ NA DELŠÍCH EKG DATECH.....	37
4.2	TEST UNIVERZÁLNOSTI.....	41
4.3	TEST CITLIVOSTI NA PATOLOGIE.....	45
4.4	ČASOVÁ NÁROČNOST.....	46
4.5	ZHODNOCENÍ METOD.....	47
5	ZÁVĚR	49
6	ZDROJE	51

1 EKG

Elektrokardiografie (EKG) je jednou z nejpoužívanějších aktivních elektrodiagnostických metod v lékařství. Výstupem měření je tzv. elektrokardiogram. V principu jde o zobrazení elektrické aktivity srdce v čase. EKG signál reprezentuje rozdíly potenciálů, které vznikají při činnosti srdce – systola a diastola síní a komor.

Tyto elektrické potenciály se snímají z povrchu těla sadou elektrod. Rozdíl mezi dvojicí elektrod označujeme jako svod. V praxi se používá několik svodových systémů. Mezi nejčastější patří standardní dvanácti svodový systém, kdy je dohromady deset elektrod rozmístěno na hrudníku a na končetinách. Deset, protože některé elektrody jsou součástí párů a představují tak dva svody.

Analýzou takto nasnímaného signálu jsme schopni velmi účinně odhalit a diagnostikovat různá onemocnění srdečního svalu pacienta. Diagnostika se provádí zejména na základě analýzy průběhu nasnímaného EKG signálu. Srovnáním nasnímaného signálu se signálem zdravého člověka lze odhalit některá onemocnění srdce. Záznam aktivity srdce však není jediný ukazatel stavu srdce. EKG nám dává informaci také o tepové frekvenci a její variabilitě (Heart Rate Variability). Diagnostiku z naměřeného signálu může provádět lékař nebo signál vyhodnotí speciálně navržené algoritmy. [1] [2] [3]

1.1 Historie

Počátky snímání elektrických potenciálů z těla se datují do konce 18. století. Italský fyzik Luigi Galvani v roce 1786 poprvé zjistil, že může být z kosterních svalů snímán elektrický proud. Později v roce 1842 další italský fyzik Carlo Matteucci při pokusech s žabím srdcem objevil, že každý srdeční stah je doprovázen změnou elektrického potenciálu. První záznam srdeční aktivity člověka pořídil až o třicet pět let později britský fyziolog Augustus Waller. K snímání použil elektrody umístěné na hrudníku a zádech pacienta.


Za průkopníka v oblasti elektrokardiografie je považován nizozemský fyziolog Willem Einthoven, který v roce 1901 vyvinul za použití strunového galvanometru první elektrokardiograf. Einthoven vycházel při tvorbě EKG z práce svého předchůdce Wallera. Aplikací matematických korekcí na naměřené křivky v EKG dostal jejich podobu, kterou známe dnes. Zavedl také pojmenování jednotlivých vln v záznamu, které se používá dodnes. Einthovenovi se také podařilo zredukovat počet snímacích elektrod na tři z původních deseti. Elektrody byly nově umístěny pouze na pažích a nohách. Pro tento tří-svodový koncept se vžilo označení bipolární snímání. Za svoje objevy byla Einthovenovi udělena v roce 1924 Nobelova cena.

V dobách svého objevu bylo bipolární snímání nejpoužívanější technikou. Časem se však zjistilo, že tento přístup nemusí přinášet zcela přesné výsledky (některé patologie nemusí být odhaleny). Jako orientační měření se bipolární techniky však používají i dnes.

Řešení přinesl v roce 1934 Frank Norman Wilson, který zavedl koncept unipolárních svodů. Vytvořil referenční bod (známý jako Wilsonova svorka) kombinací tří končetinových svodů a zprůměrováním jejich potenciálů. Elektroda umístěna na hrudníku pacienta je připojena k tomuto referenčnímu bodu a měřena změna potenciálu. Unipolární svody jsou tedy protikladem k bipolárním, u kterých se měří změna potenciálů mezi dvěma místy na těle. Nejdříve se používal šesti-svodový systém a následně 1954 začalo přecházet na dvanácti svodový, který je dodnes nejpoužívanějším a nejpřesnější metodou snímání EKG. [4]

1.2 Fyziologie srdeční činnosti

Srdce je orgán zajišťující cirkulaci krve v těle člověka, chová se tedy jako pumpa. Cirkulace krve slouží jako spojení buněk s okolním prostředím i navzájem. Mezi hlavní úkoly kladené na krev patří doprava kyslíku a oxidu uhličitého, živin a metabolitů, rozvod látkových signálů a tepla. Srdce člověka se skládá ze dvou funkčně a anatomicky spojených čerpadel – pravá a levá polovina. V každé polovině se nachází síň a komora. Proud krve v lidském srdci můžeme demonstrovat na obr. 1.1. Z levé komory (LK) proudí krev aortou do hlavy a těla. Vrací se horní a dolní dutou žílou do pravé předsíně (PP). Z pravé komory (PK) je vedena plicními tepnami do plic, ze kterých se vrací plicními žilami do levé předsíně (LP). Chlopně brání zpětnému toku.




Obr. 1.1: Proudění krve v srdci [5]

Čerpání krve je zajištěno pravidelným střídáním ochabnutí (diastola) a stažením (systola) svaloviny síní a komor. Srdce je také opatřeno chlopněmi, které fungují jako polopropustná membrána, a zabraňují tak zpětnému toku krve. Síně fungují jako pomocná čerpadla, která napomáhají plnění komor. Krev se do srdce vrací jednak z plic plicní žílou do levé předsíně a z těla dolní a horní dutou žílou do pravé předsíně.

Časově a prostorově koordinovaný cyklus srdečních svalů je zajišťován tzv. srdeční převodní soustavou. Jedná se o elektrické propojení buněk srdeční svaloviny (myokardu) plazmatickými můstky. Díky specializovaným srdečním vláknům, která mají schopnost samovolně generovat a vést akční potenciály, se vzruchy šíří z místa podráždění na celé srdce. Srdeční svalovina nemá na rozdíl od kosterní svaloviny motorické jednotky, není proto možné regulovat síla stahu. Myokard reaguje na podráždění buď úplným stahem, nebo vůbec.

Srdeční svalovina není ovládána vůlí, podněty pro stažení se tedy vytváří sama díky tzv. pacemakerům. Vzruchy vznikají ve stěně pravé předsíně při ústí horní duté žíly v tzv. sinoatriálním (SA) uzlu, odkud se šíří přes předsíně. SA uzel je za normálních okolností dominantním pacemakerem, řídícím frekvenci srdečního stahu. Na svalovinu komor se vzruch dostane přes atrioventrikulární (AV) uzel a Hisův svazek, který slouží jako vodivé spojení mezi síní a komorou. Hisův svazek se ještě rozdělí na dvě Tawarova raménka, která na svém konci přechází v Purkyňova vlákna. Vedení vzruchu srdeční svalovinou je patrné z obr. 1.2. Tyto elektrické potenciály jsme schopni snímat při EKG. [5]



Obr. 1.2: Převodní soustava srdeční [5]


1.3 EKG signál

Na obr. 1.3 je zobrazena ukázka EKG signálu. Vidíme, že signál se skládá z vln P, T, případně U a komplexu QRS. Význam jednotlivých vln je následující [6]:

- P vlna – depolarizace síní
- QRS komplex – depolarizace komor
- T vlna – repolarizace komor
- U vlna – zbytková aktivita papilárního svalu v komoře, ne vždy patrná


Mimo tvary jednotlivých vln jsou důležitým ukazatelem také vyznačené segmenty a intervaly. Například RR intervaly slouží například k výpočtu variability srdečního rytmu (HRV).

Záznamy EKG můžeme z hlediska délky snímání rozdělit na krátkodobé a dlouhodobé. Krátkodobé snímání se provádí běžně v ordinacích lékařů a netrvá déle než 10 minut. Jedná se buď o klidové EKG, případně se měří při zátěži pacienta. V tomto případě se jedná o tzv. ergometrii. V některých případech však krátkodobé vyšetření nemusí odhalit skutečný problém. Například pokud se abnormalita na EKG záznamu objeví pouze několikrát za den. V případě podezření na nějaké onemocnění se proto často přistupuje k dlouhodobému snímání, které může trvat i více než 24 hodin. Pro dlouhodobé snímání se používají EKG holtery. Jedná se o zařízení, která jsou umístěná na těle pacienta a zaznamenávají EKG, případně také krevní tlak atd., po delší časový interval. [7]




Obr. 1.3: Ukázka EKG zdravého člověka [6]

Při pohledu na EKG signál z frekvenčního hlediska zjistíme, že většina energie užitečného signálu leží v rozsahu frekvencí 0,5 – 50 Hz (obr. 1.4). Nejnižší složky odpovídají tepové frekvenci a pomalejším vlnám P a T, nejvyšší složky poté nejrychleji měnící se části QRS komplexu (10 – 50 Hz). Méně výrazné složky QRS komplexu dosahují však až do hodnot 125 Hz. Složky obsažené v EKG signálu s frekvencemi mimo toto rozmezí lze považovat za nežádoucí a rušivé (šum). Typy šumu se zabývá kapitola 3. [8]



Obr. 1.4: Frekvenční složky v EKG [9]

V dnešní době se pro snímání používá nejčastěji již zmíněný dvanácti svodový systém končetinových a hrudních elektrod. Končetinové elektrody se umísťují na zápěstí pravé horní končetiny, levé horní končetiny, ke kotníku levé dolní končetiny a pravé dolní končetiny. Hrudní elektrody se umísťují do 4. mezižebří těsně napravo od sternu (V1), do 4. mezižebří těsně vlevo od sternu (V2), do 5. mezižebří v medioklavikulární čáře (V4), doprostřed mezi V2 a V4 (V3), do 5. mezižebří v horizontálním pokračování V4 v přední axilární čáře (V5) a ve střední axilární čáře (V6). Rozložení elektrod na hrudníku je znázorněno na obr. 1.5. [10]




Obr. 1.5: Umístění elektrod na hrudníku [10]

1.4 Patologické průběhy EKG

Jak již bylo řečeno, stanovení diagnózy ze záznamu EKG se provádí na základě analýzy průběhu nasnímané křivky. Průběh EKG křivky může být u každého člověka do jisté míry individuální, různé záznamy srdeční činnosti se proto můžou od ideálního průběhu (viz obr. 1.4) do určité míry lišit. Existují však velké množství tvarů, jejichž výskyt v EKG signálu téměř vždy značí přítomnost patologie na srdci. Detekce takových patologických průběhu proto může posloužit ke stanovení diagnózy pacienta. Existují však také onemocnění, které se na průběhu EKG křivky neprojeví (např. nadměrně zvýšená tepová frekvence). V této kapitole si probereme vybrané patologie diagnostikovatelné z EKG.

1.4.1 Extrasystola

Jedná se o poruchy rytmu vyvolané vzruchy, které vznikají v jiných místech než v sinusovém uzlu (ektopické). Tento stav se projevuje předčasnými stahy. Extrasystoly dělíme na síňové a komorové. Síňová extrasystola se nejvíce projeví na tvaru vlny P, protože ektopický stah se v síni šíří jinou cestou než je obvyklé. Počátek síňové extrasystoly často splývá s vlnou T předchozího stahu (obr. 1.5). Ektopický vzruch se obvykle převede i na sinusový uzel a vybijí vzruch, který se na něm tvoří. Po extrasystole proto následuje kompenzační pauza. Při síňové extrasystole není ovlivněn tvar QRS komplexu, naopak v případě komorové je změna výrazná. Komorová extrasystola je obecně závažnější stav. [11]



Obr. 1.5: Ukázka extrasystoly – vlevo síňová, vpravo komorová [11]

1.4.2 Raménkové blokády


Blokáda Tawarova raménka je porucha vedení vzruchu myokardem vznikající v důsledku postižení převodního systému srdečního a mající za následek opožděnou depolarizaci (a tudíž činnost) pravé nebo levé komory. Celá postižená komora je v tom případě depolarizována z raménka, které přísluší druhé komoře, což vede k rozšíření a morfologické změně QRS komplexu. Na obr. 1.6 je znázorněn příklad blokády levého raménka. [12]



Obr. 1.6: Raménková blokáda – QRS komplex rozšířen [12]

1.4.3 Patologie P vlny


Fyziologicky trvá vlna P do 80 ms, její amplituda je do 0,25 mV. Patologicky je vlna P změněna tehdy, pokud impuls sice vychází z SA uzlu, ovšem je přítomna hypertrofie či dilatace síní. To má za následek prodloužení doby vedení mezi síněmi. Patologická je vlna P taktéž v případě, že nevychází z SA uzlu ale z jiného místa v síni. Při hypertrofii pravé síně je P vlna vysoká a hrotnatá a označuje se jako P-pulmonale (obr. 1.7 – vlevo). Při hypertrofii levé síně je vlna P prodloužena a má zvlněný tvar (obr. 1.7 – vpravo). Patologie P vln jsou nejčastěji přítomny u pacientů s plicním onemocněním a vadou trojčpé chlopně. [13]



Obr. 1.7: Hypertrofie síní [13]

1.4.4 Wolff – Parkinson – White syndrom

Fyziologicky zajišťuje spojení mezi síněmi a komorami pouze atrioventrikulární uzel. V případě WPW syndromu jsou však přítomny další vodivé spojení. AV uzel má přirozeně pro vedení vzruchu jistou zpomalovací funkci. Tyto patologické spojení ovšem tuto vlastnost postrádají. V důsledku přítomnosti akcesorní spojky probíhá začátek aktivace myokardu komor jinak než fyziologicky. Impuls je ze síní veden na komory spojkou rychleji než AV uzlem a aktivita komor začíná od místa úponu spojky do komory. Zároveň je často impuls veden i fyziologicky AV uzlem. Aktivace srdeční svaloviny komor tak probíhá buď jen od místa úponu spojky, nebo kombinovaně s AV uzlem. Na EKG se to projeví jednak zkrácením PQ (vedení spojkou je rychlejší než AV uzlem) a dále přítomností vlny delta (obr. 1.8). [10]



Obr. 1.8: Vlna delta u WPW syndromu [10]


1.4.5 Patologie úseku ST a vlny T

Úsek ST a vlna T jsou projevem repolarizace myokardu komor. Patologické změny průběhu v této části záznamu nejčastěji značí přítomnost akutního infarktu myokardu nebo zánětu osrdečníku (perikarditida), sledování ST úseku má proto medicínsky velký význam. V případě probíhajícího infarktu dochází k elevaci ST úseku. Pokud dojde pouze k neúplně ischemii, projeví se tento stav naopak depresí ST úseku. Elevace ST úseku vznikají poškozením membránového napětí kardiomyocytů ischemií a rozdílným načasováním repolarizace myokardu. Zvýšení ST úseků se někdy nazývají Pardeeho vlny podle lékaře Harolda Pardeeho, který tento jev 1920 poprvé popsal. [10]

Zvýšení ST úseku není při infarktu myokardu stále stejné, ale mění se v čase. Po určité době od prodělání ischemie dokonce vymizí úplně. Vývoj průběhu EKG po výskytu ischemie je na obr. 1.9:

- Stav před ischemií, fyziologický průběh
- Hyperakutní stav – vlna T je abnormálně vysoká a štíhlá
- Za několik minut dochází k elevaci ST úseku. Je způsobeno nedokrvením určité části myokardu, svalovina však ještě neodumřela

- d) Za několik hodin dochází k nekróze. Objevuje se patologická vlna Q, ST úsek klesá a vlna T se invertuje
- e) Po odumření celé ischemizované oblasti zůstane patologické Q a zprvu navíc invertované vlny T
- f) Po několika letech se průběh normalizuje a zůstane již pouze patologické Q (zjizvený myokard)




Obr. 1.9: Vývoj průběhu EKG po prodělání ischemie [10]

1.5 Typy šumu

Při snímání EKG signálu měříme poměrně nízká napětí. EKG signál je proto citlivý na různé typy šumu, které mohou jeho výslednou kvalitu značně ovlivnit. Šumy a artefakty v signálu vznikají z fyziologických i nefyziologických příčin a obzvláště při dlouhodobějších měřeních není možné se jim zcela vyhnout. Nyní si stručně představíme nejčastější typy šumu, které se u EKG signálů vyskytují.

1.5.1 Kolísání izolinie


Kolísáním izolinie neboli driftem (obr. 1.10), rozumíme modulaci signálu nízkofrekvenčním rušením. Můžeme pozorovat táhlé zvlnění celého signálu. Za kolísáním izolinie může stát například pohyb pacienta při měření (kašláni, chůze) nebo změna impedance mezi pokožkou a elektrodou (pocení, odlepování elektrod). Frekvence toho rušení zpravidla nedosahuje frekvencí vyšších než 1 Hz. Většina energie tohoto rušení leží mimo rozmezí užitečného signálu, je proto snadné zvlnění odfiltrovat například lineárním filtrem typu horní propust. [3] [8]



Obr. 1.10: Ukázka kolísání izolinie [14]

1.5.2 Síťové rušení (brum)


Jedná se o rušení pocházející z elektrovedné sítě, má proto frekvenci 50 nebo 60 Hz (obr. 1.11). Tento typ rušení vzniká nejčastěji špatným odstíněním elektrod od síťových kabelů, případně elektrickými spotřebiči, které se nacházejí v blízkosti. Ve výkonovém spektru se přítomnost tohoto typu šumu projeví jako impuls na frekvenci 50/60 Hz. K odstranění brumu je vhodné použít filtr typu úzkopásmová zadrž. [3] [8]



Obr. 1.11: Ukázka brumu [14]

1.5.3 Elektromyografické rušení

EMG rušením (obr. 1.12) rozumíme nežádoucí snímání elektrické aktivity kosterních svalů z míst, kde jsou umístěny elektrody pro EKG. Ke vzniku EMG rušení dochází při pohybu pacienta. Velice náchylné jsou proto zátěžová měření (např. ergometrie). Myopotenciály se řadí k nejproblematictějšímu druhu šumu z hlediska jeho odstraňování. Charakteristikou myopotenciálů je jejich frekvenční širokopásmovost (10 – 500 Hz), značnou měrou proto zasahují do užitečných frekvencí EKG signálu. Nejúčinnější metodou pro odstranění tohoto typu šumu je vlnková filtrace. [3] [8]



Obr. 1.12: Ukázka EMG rušení [14]

1.6 Význam hodnocení kvality EKG


Pro stanovení kvalitní diagnózy je nutné, aby se vycházelo pouze ze signálů, ve kterých je zřetelně patrný užitečný signál. Záměna některé složky EKG signálu například se šumem by mohla vést k nesprávné diagnóze, a tím pádem k závažným důsledkům. Přistupuje se proto k vytváření algoritmů, které ohodnotí části EKG na úseky vhodné a nevhodné pro analýzu. Hodnocení kvality nabývá na důležitosti zejména v případě dlouhodobých signálů, kde není z důvodu časové náročnosti možné hledat a manuálně vyřazovat nevhodné úseky.

Návrh algoritmů pro stanovování kvality je stále se vyvíjející téma, existuje proto mnoho různých postupů. Snaha je však o dosažení stejného cíle, kterým je přiřazení třídy kvality signálu nebo jeho částem.

Třídy kvality nejsou zatím nijak přesně definované, mezi autory však panuje určitá shoda. V publikovaných pracích se setkáváme nejčastěji s těmito třídami v různých podobách [3] [15]:

- 2 třídy – signál je vhodný k analýze nebo není
- 3 třídy – signál je vhodný k podrobné analýze, pouze částečné (např. jen tepová frekvence), není vhodný
- Více tříd – kvalita signálu je odstupňována podrobněji (perfektní, dobrá, vyhovující, atd.)

Příklady průběhů reálných signálů zařazených do tří tříd kvality jsou na obr. 1.13. Tohoto dělení se budeme držet po zbytku práce.



Obr. 1.13: Ukázka 3 tříd kvality

2 Použité nástroje

Pro realizaci jednotlivých metod pro hodnocení EKG, které budou představeny v této práci, bylo použito několika nástrojů. V této kapitole si postupně rozebereme jejich principy.

2.1 Fourierova „Synchrosqueezed“ transformace (FSST)


Signály můžeme obecně rozdělit na stacionární a nestacionární. Stacionární signály jsou takové, u kterých jsou frekvenční složky v čase neměnné. Může jít například o součet několika harmonických funkcí. Nestacionární signály jsou naopak takové, u kterých se frekvenční složky v čase mění. Mezi nestacionární signály tedy můžeme zařadit i EKG.

Pro převod signálů do frekvenční oblasti se používají různé druhy transformací. Pro stacionární signály se používá například rychlá Fourierova transformace (FFT). Spektrum signálu získané pomocí FFT nám dává informace o jeho frekvenčních složkách. Nejsme schopni určit, ve kterém čase došlo k výskytu vybrané frekvence, což však v případě stacionárních signálů není omezení. [16]


EKG ovšem patří mezi nestacionární signály, využití FFT pro frekvenční analýzu proto není vhodné. Pro nestacionární signály se používá krátkodobá Fourierova transformace (short-time Fourier transform – STFT) nebo vlnková transformace (wavelet transform – WT). Zjednodušeně řečeno, signál je v případě STFT a WT konvolován určitým oknem (vlnkou), a výsledné spektrum nám díky tomu dává i časovou informaci o frekvenčních složkách. V případě STFT se jedná o okno vhodného tvaru, v případě WT o speciální vlnku s proměnnou šířkou a frekvencí. Velikost okna významně ovlivňuje přesnost transformace. Obecně platí, že čím větší okno, tím lepší frekvenční rozlišení na úkor časového a naopak. [16]

Tento problém řeší Fourierova „Synchrosqueezed“ transformace (FSST). Jedná se o rozšíření, které lze použít pro STFT i WT. FSST potlačuje „rozmazání“ frekvence ve spektru, které je způsobené nenulovou šířkou okna v případě STFT nebo WT. Dostáváme tak přesnější informaci o frekvenci a času zároveň. Efekt „stlačení“ je zřejmý z příkladu na obr. 2.1 a 2.2, kde je zobrazeno spektrum funkce složené z dvou harmonických složek podle (1) získané pomocí STFT a FSST [16] [17] [18]:

$$f(n) = e^{j\frac{2\pi n}{10}} + 3e^{j3\frac{2\pi n}{10}}, \quad (1)$$



Obr. 2.1: Spektrum funkcí sinus – STFT [18]



Obr. 2.2: Spektrum funkcí sinus – FSST [18]

2.2 Neuronové sítě


Stavebním kamenem celého algoritmu je využití neuronové sítě, konkrétně rekurentní sítě typu LSTM. V následujícím odstavci si proto vysvětlíme základní principy neuronových sítí a poté se zaměříme na rekurentní sítě.

Umělé neuronové sítě jsou adaptivní systémy, které se skládají z vrstev vzájemně propojených uzlů (neuronů) připomínající lidský mozek. Umělé sítě se stejně jako lidský mozek učí na základě příkladů. Podobnost s lidským mozkem můžeme pozorovat i na projevech učení na úrovni neuronů. Dochází k úpravám propojení mezi jednotlivými neurony.


Neuronová síť může být trénována mnoha příklady k rozpoznání určitých tvarů v 1D i 2D signálech (obrázcích), stejně jako lidský mozek. Chování sítě se odvíjí od síly, popřípadě váhování jednotlivých spojení neuronů. Tyto váhy jsou v průběhu učícího procesu upravovány do té doby, než dá síť na výstupu správné řešení. Cílem učení je minimalizace ztrátové funkce, která odpovídá chybě predikce.

Matematický model neuronu vychází ze stavby skutečného neuronu (obr. 2.3). Každý neuron pomocí svých dendritů získává vstupní signál od jiného neuronu v předcházející vrstvě. Následně pomocí axonu posílá informaci do neuronu v další vrstvě. Základní princip fungování modelu neuronu je znázorněn na obr. 2.3. Signály přicházející z axonu jiného neuronu (x_0) jsou v místě synapse násobeny synaptickou energií (vahou) přidělenou napojenému dendritu (w_0). Váha w je právě již zmíněná veličina, které se mění při procesu učení sítě. Po vynásobení postupuje vstupní signále dále do těla neuronu, kde se všechny hodnoty signálu sečtou. Pokud výsledek přesáhne určitou hranici (b), je informace axon na výstupu vyslána dál (aktivační funkce).

Běžné neuronové sítě jsou nejčastěji uspořádány do topologie s plně propojenými vrstvami (obr. 2.4). V tomto případě jsou neurony sousedních vrstev propojeny každý s každým, avšak neurony ve stejné vrstvě propojeny nejsou. Vrstvy nacházející se mezi vstupní a výstupní vrstvou se nazývají skryté vrstvy. [19] [20] [21]



Obr. 2.3: Srovnání biologického a matematického modelu neuronu [19]



Obr. 2.4: Topologie s plně propojenými vrstvami [20]

2.2.1 Rekurentní neuronové síť

Rekurentní neuronové síť (RNN) se používají zejména pro zpracování sekvenčních dat (např. EKG). Pojmem rekurentní rozumíme, že neuronová síť využívá pro predikci každého prvku posloupnosti již provedených predikcí. Jednotlivé výstupy jsou tedy ovlivňovány předcházejícími hodnotami. Rekurentní síť mají určitou formu paměti, které zachycují informace, které byly prozatím vypočteny.

Rekurentní síť se od běžných liší architekturou spojení jednotlivých neuronů. Běžné síť jsou, jak již bylo zmíněno, tvořeny navazujícími vrstvami neuronů a informace prochází od vstupu do výstupu bez možnosti vzniku cyklů, jsou tedy dopředné. Rekurentní síť naopak cyklů využívají, což umožňuje informaci setrvat po delší dobu a ovlivnit tak následující výpočet. [22]

2.2.1.1 LSTM síť

LSTM (Long short-term memory) síť vynikají schopností pamatovat si informace po dlouhé časové úseky, a umí se tak naučit dlouhodobé závislosti. Proto jsou tyto síť vhodné mimo jiné pro klasifikaci EKG dat. LSTM síť se vyznačují vlastností, že dokáží selektivně vybírat, které informace budou při procesu učení zachovány a které zapomenuty, což je výhodou oproti níže zmíněným temporálním konvolučním sítím. [22] [23]

2.2.2 Konvoluční neuronové síť

Konvoluční neuronové síť byly vytvořeny zejména pro klasifikaci obrazových dat. Jako trénovací data se proto nejčastěji používají dvourozměrné vstupy. Konvoluční síť je však možné použít i na sekvenční 1D data. Může jít například o rozpoznání typu lidské aktivity (stání, běh), která byla naměřena gyroskopem, řeči nebo v našem případě jednotlivých kvalit EKG záznamu. Výhodou využití konvolučních sítí pro klasifikaci sekvenčních dat


je, že se síť dokáže naučit přímo na surových vstupních datech. [19]

2.2.2.1 Temporální konvoluční síť

Pro klasifikaci sekvenčních dat se v současnosti často používají tzv. temporální konvoluční síť (Temporal Convolutional Networks, TCN). Architektura TCN představují alternativu k již zmíněným rekurentním neuronovým sítím.

Základním znakem architektury TCN jsou kauzální konvoluce, což znamená, že výpočet probíhá v reálném čase. Jinými slovy, výstup je konvolován pouze s prvky v aktuálním čase a dřívějšími z předchozí vrstvy. Hodnota aktivační funkce vypočtená pro aktuální krok tak nemůže záviset na hodnotě z následujících kroků. K získání informací z předchozích kroků se používá uspořádání z obr. 2.5. Jde o naskládání několika konvolučních vrstev na sebe, přičemž pro každou z nich je definován tzv. dilatační faktor (dilation). Jeho hodnota určuje, kolik informací z minulosti ovlivňuje aktuální krok.

Obdobně jako RNN dokáže TCN na vstup přijmout libovolně dlouhou sekvenci a na výstupu poté získat klasifikovanou sekvenci stejné délky. K dosažení shodné délky je nutné, aby všechny skryté vrstvy měly stejnou délku jako vstup. Výhodou TCN je, že je možné jednoduše ovlivňovat velikost oblasti trénovacích dat, které má síť k dispozici v jednom kroku (např. použitím více konvolučních vrstev). [24] [25]



Obr. 2.5: Propojení vrstev u TCN architektury [26]

2.2.3 Návrh neuronové sítě

Myšlenka algoritmů pro stanovení kvality signálu navržených v této práci stála na vytvoření neuronové sítě, která by dokázala provést segmentaci (rozpoznat jednotlivé vlny v EKG) případně rovnou ohodnotit celý EKG signál dle kvality.

Obecný postup pro vytvoření neuronové sítě je následující:

1. Rozdělení vstupních dat do množiny trénovacích a testovacích dat
2. Učení sítě na trénovací množině
3. Ověření funkčnosti nově vzniklé sítě na testovacích datech

Zároveň musí platit, že trénovací a testovací množina neobsahuje stejná data. V trénovací množině nachází algoritmus určité vztahy a tím se učí. Testovací množinu učící algoritmus nemá k dispozici a slouží proto k ověření funkčnosti sítě. Cílem je, aby natrénovaná síť vytvářela predikce na testovacích datech se stejnou úspěšností jako na trénovací množině. V případě, že na trénovacích datech dosahuje systém mnohem větší úspěšnosti, je síť přeučená. [21]

3 Realizace metod pro hodnocení EKG

V následující kapitole budou popsány návrhy vlastních metod pro hodnocení kvality EKG signálů. Bude představena tzv. přímá a nepřímá metoda. Nepřímá metoda využívá neuronovou síť pouze pro segmentaci EKG signálu, hodnocení kvality provádí následný algoritmus. V případě přímé metody je vstupní EKG signál přímo ohodnocen neuronovou sítí. Pro srovnání budou uvedeny i metody prezentované v [3], [29] a [30], které nevyužívají neuronové sítě. Hodnocení se v tomto případě provádí na základě detekce přítomnosti rušení v signálu. Budou vysvětleny principy jednotlivých algoritmů a příprava dat pro trénování neuronových sítí. Vytvoření neuronové sítě i samotná realizace algoritmů proběhla v prostředí MATLAB.

3.1 Nepřímá metoda

Nepřímá metoda využívá pro hodnocení signálů EKG dvou kroků. Nejdříve jsou v signálu pomocí naučené neuronové sítě segmentovány jednotlivé vlny (P, QRS, T) a poté je použit hodnotící algoritmus, který přiřadí jednotlivým úsekům známku kvality.

3.1.1 Učení sítě

Zvolil jsem doporučený typ sítě pro segmentaci EKG signálů, tzn., rekurentní neuronovou síť typu LSTM. Jako trénovací data byly použity EKG záznamy z veřejně dostupné databáze [31]. Jde o přibližně 15 min dlouhé záznamy EKG 105 pacientů se vzorkovací frekvencí 250 Hz. V těchto záznamech byly následně vyznačeny podle [32] jednotlivé regiony v EKG signálu. Z původní databáze bylo vytvořeno 210 segmentovaných EKG signálů. Do trénovací množiny bylo umístěno 70% náhodně vybraných signálů, zbylých 30 % bylo uloženo do množiny testovací.

Cílem bude, aby na vstupu neuronové sítě byl vstupní EKG signál a na výstupu klasifikační vektor o stejném počtu vzorků jako vstupní signál. Klasifikační vektor bude rozlišovat 4 kategorie:

- **QRS** – vzorek vstupního signálu leží v komplexu QRS
- **P** – vzorek vstupního signálu leží ve vlně P
- **T** – vzorek vstupního signálu leží ve vlně T
- **n/a** – vzorek vstupního signálu leží v klidové oblasti nebo oblast nelze spolehlivě přiřadit k žádné z předchozích

Dle [28] dosahuje neuronová síť při segmentaci nejlepších výsledků, pokud do ní vstupuje vstupní signál ve formě frekvenčního spektra. Je proto nutné přetransformovat trénovací množinu do frekvenčního spektra. Z předchozí teorie víme, že EKG je nestacionární signál, a pro transformaci se tak nejlépe hodí FSST.

Zvolili jsme následující architekturu sítě (vrstvy – layers) a pro její trénování jsme specifikovali nastavení z tab. 3.1.

```

layers = [ ...
    sequenceInputLayer(40)
    lstmLayer(200, 'OutputMode', 'sequence')
    fullyConnectedLayer(4)
    softmaxLayer
    classificationLayer];

```

Tab. 3.1: Nastavení pro trénování sítě

Název parametru	Nastavení
Solver Name	Adam
Max Epochs	10
Mini Batch Size	50
Initial Learn Rate	0,01
Learn Rate Drop Period	3
Learn Rate Schedule	piecewise
Gradient Threshold	1
Shuffle	every-epoch

Vrstvy

sequenceInputLayer – Nastavíme vstupní vrstvu, aby dokázala přijmout jako vstup vybraný počet složek ze spektra.

lstmLayer – Pro skryté vrstvy volíme typ sítě LSTM. Pro optimální výkonnost zvolíme počet skrytých uzlů (neuronů) na 200. Jako požadovaný výstup nastavíme sekvenci. To znamená, že na výstupu dostaneme klasifikační vektor o stejném počtu vzorků jako vstupní signál.

fullyConnectedLayer – Použijeme topologii s plně propojenými vrstvami o výstupní velikosti 4 (pro každou kategorii – QRS, T, P, n/a).

softmaxLayer, classificationLayer – vrstvy řídící výstup

Nastavení parametrů

Solver Name – Volba algoritmu pro výpočet ztrátové funkce.

Max Epochs – Maximální počet epoch použitých při trénování. Epochou se rozumí celý průchod trénovacího algoritmu přes množinu trénovacích dat.

Mini Batch Size – Velikost dávky použité pro jednu trénovací iteraci. Dávkou rozumíme podmnožinu dat z trénovací množiny, na které spočítáme gradient ztrátové funkce a upravíme váhy.

Initial Learn Rate – Rychlost učení. Ovlivňuje přesnost a dobu trénování. Pokud by byl

parametr příliš nízký, bude trénování trvat dlouhou dobu. Pokud příliš vysoký, výsledek nebude dostatečně přesný.


Learn Rate Drop Period – Nastavené číslo udává, po kolika uplynutých epochách dojde k snížení rychlosti učení. Slouží k zpřesňování výsledku ke konci učení.

Learn Rate Schedule – Nastavení „piecewise“ slouží k povolení snižování rychlosti učení (viz Learn Rate Drop Period).

Gradient Threshold – Slouží pro stabilizaci trénovacího algoritmu při vyšších rychlostech učení.

Shuffle – Při nastavení „every-epoch“ promíchá trénovací data před každou epochou a testovací data před každou validací.

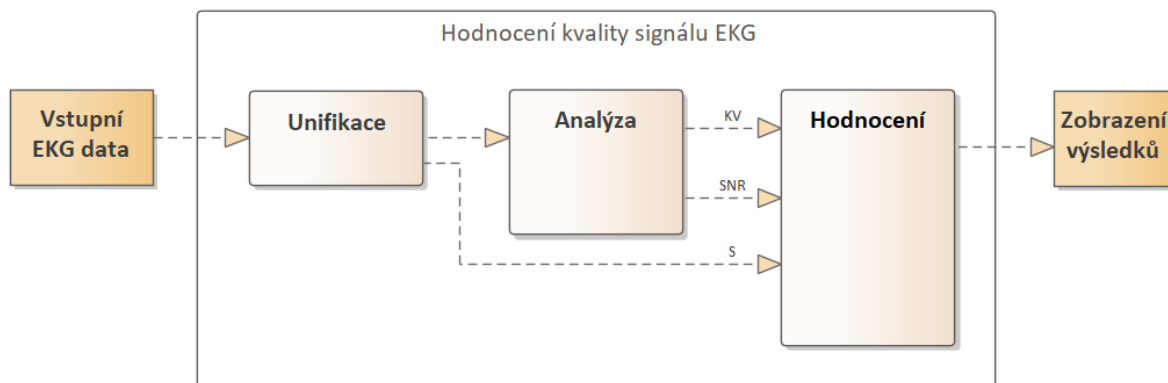
S takto nastavenou architekturou sítě, možnostmi trénovacího algoritmu, vybranou trénovací a testovací množinou je zahájeno učení sítě. Průběh učení sítě je zobrazen na obr. 3.1. Na trénovací množině bylo dosaženo přesnosti predikce přes 90 %, u testovací poté okolo 85 %.



Obr. 3.1: Průběh trénování sítě – začátek a konec

3.1.2 Princip algoritmu

V této části bude popsán princip činnosti algoritmu pro hodnocení kvality EKG signálů pomocí Nepřímé metody. Algoritmus vychází ze třech tříd hodnocení kvality (viz kap. 1.6). Základní princip se dá shrnout do blokového schématu na obr. 3.2. Vstupní data jsou klasifikována podle kvality a na výstupu jsou zobrazeny výsledky. Jednotlivé bloky si nyní rozebereme podrobněji.



Obr. 3.2: Blokové schéma algoritmu Nepřímé metody

3.1.2.1 Vstupní EKG data

Vstupními daty pro hodnocení může být jakýkoliv EKG signál. Může jít o reálný případně i uměle generovaný signál. Teoreticky je možno poslat na vstup i jiný signál než EKG, na výstupu ale bude vyhodnocen jako nekvalitní EKG signál (známka 3). Jediným požadavkem na vstupní data tedy zůstává vzorkovací frekvence 250 Hz, případně její celočíselné násobky. Na vstup je možno vložit i případnou anotaci analyzovaného signálu, pro srovnání s ohodnoceným signálem na výstupu.

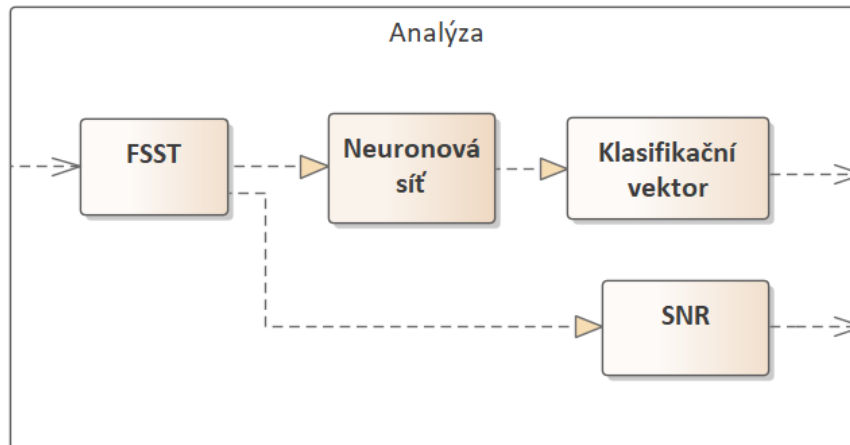
3.1.2.2 Unifikace

V tomto bloku dochází nejprve, je-li to třeba, k podvzorkování signálu na vzorkovací frekvenci 250 Hz. Následně je vstupní signál rozdělen do částí o délce zvoleného okna. Okno se volí o délce přibližně 15 period EKG signálu, při uvažování běžné tepové frekvence. Rozdělení se provádí z důvodu zlepšení výkonu neuronové sítě a snížení časové náročnosti. Do sítě by neměly vstupovat příliš dlouhé úseky signálu. Druhým důvodem je příprava pro výpočet SNR (Signal to noise ratio, viz blok *Analýza*).

Výstupem z bloku *Unifikace* je podvzorkovaný, rozdělený signál, který vstupuje do bloku *Analýza* a bloku *Hodnocení* (viz obr. 3.2).

3.1.2.3 Analýza

Činnost bloku *Analýza* je možno podrobněji demonstrovat na podrobnějším schématu na obr. 3.3.



Obr. 3.3: Podrobné schéma bloku Analýza

V bloku *Analýza* se provádí segmentace unifikovaného signálu pomocí natrénované neuronové sítě. Signál vstupuje do sítě po jednotlivých částech o velikosti okna definovaného v bloku *Unifikace*. Síť očekává vstupní data v podobě transformovaného signálu pomocí FSST. Ze spektra signálu se vybere pouze nejvýznačnější pásmo frekvencí užitečného signálu v rozmezí 0,5 – 40 Hz (viz obr. 1.4). Takto upravený transformovaný signál vstupuje do neuronové sítě.

FSST je také využito pro výpočet SNR vstupního signálu. SNR můžeme vyjádřit česky jako odstup signálu od šumu. Většinou se udává v decibelech a platí, že čím má větší hodnotu, tím více je v signálu patrná užitečná složka na úkor šumu. Obecný vztah pro výpočet SNR je definován jako:

$$SNR_{dB} = 10 \cdot \log_{10} \left(\frac{P_{signal}}{P_{noise}} \right), \quad (2)$$

kde P_{signal} je výkon užitečné složky (signál bez šumu) a P_{noise} výkon šumu. V našem případě postupujeme při výpočtu SNR následujícím způsobem:


1. FSST části vstupního signálu o délce okna
2. Označení frekvenčních složek v rozmezí 0,5 – 40 Hz za signál bez šumu
3. Označení frekvenčních složek mimo rozmezí 0,5 – 40 Hz za šum
4. Zpětná FSST obou částí
5. Výpočet SNR z výkonů obou částí podle vzorce (2)

Je tedy zřejmé, že výsledná hodnota přesně neodpovídá skutečné hodnotě SNR, jde pouze o přiblížení. V případě zašumění signálu širokopásmovým šumem (EMG) se nachází šumové frekvence i v rozmezí frekvencí užitečného signálu. Vychází se však

z úvahy, že pokud je vstupní signál zašuměný více, vzroste i výkon šumu mimo rozmezí užitečného signálu.

Výstupem ze sítě je klasifikační (kategorický) vektor o stejném počtu vzorků jako vstupní signál. Každému vzorku ze vstupního signálu bude v klasifikačním vektoru odpovídat některá z kategorií (QRS, P, T, n/a). Pomocí klasifikačního vektoru je nyní možné zobrazit segmentovaný signál (obr. 3.4).

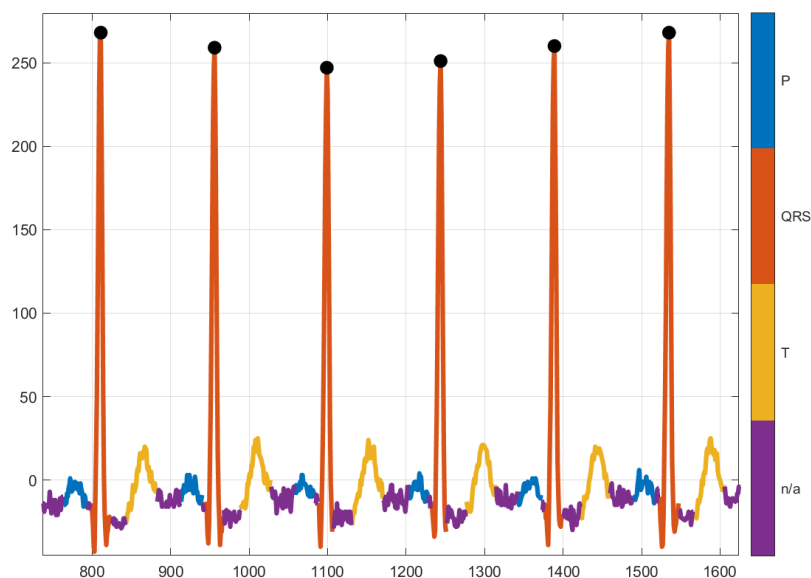
Výstupem z bloku *Analýza* je klasifikační vektor a vypočtená hodnota SNR pro části signálu. Společně z unifikovaným signálem S (viz obr. 3.2) vstupují data do bloku *Hodnocení*.



Obr. 3.4: Ukázka segmentovaného signálu

3.1.2.4 Hodnocení

V bloku *Hodnocení* se provádí samotné přiřazení tříd kvality odpovídajícím částem signálu. Nejprve však dojde k detekci pozic R vln ve vstupním EKG signálu. K detekci pozic R vln (obr. 3.5) je potřeba klasifikační vektor, který jsme získali jako výstup z neuronové sítě. Z klasifikačního vektoru jsou separovány vzorky, které náležejí QRS komplexům. V extrahovaných komplexech jsou detekovány maxima a minima. Jestliže je kladný kmit výraznější, je za vrchol R vlny označeno maximum, v opačném případě minimum. Detekce pozic R vln je nezbytná ke stanovení variability srdečního tepu (Heart Rate Variability – HRV), což je jedno z kritérií pro stanovení kvality.



Obr. 3.5: Ukázka detekovaných R vln

Před samotným hodnocením kvality je segmentovaný signál EKG rozdělen do oken. Nyní však již známe pozice vrcholů R vln, můžeme proto okno nastavit přesně na délku 20 detekovaných period (rozumná délka pro výpočet HRV). Jedná se tedy o okno s proměnlivou délkou (ne každá perioda má stejnou délku). Všem periodám v daném okně je poté přidělena známka na základě následujících kritérií:

- Kritéria pro celé okno
 - A. HRV pro vybrané periody (20 period)
 - B. SNR v dané části
- Upřesňující kritéria pro jednotlivé periody v okně
 - C. Perioda v rozsahu fyziologické tepové frekvence
 - D. Přítomnost falešných QRS komplexů mezi sousedními komplexy
 - E. Výskyt vln P a T v okolí QRS komplexu

Limitní hodnoty pro všechna kritéria jsou shrnuty v tab. 3.2 a 3.3. Princip přidělování známek na základě uvedených kritérií je znázorněn na obr. 3.7. Podmínka maximální povolené variability tepu (A) a minimální povolené hodnoty SNR (B) jsou kritéria, která se testují v rámci celého okna, čili pro více period najednou. Naopak podmínky C, D a E se testují pro jednotlivé periody.

Nejprve se otestuje, zda vybrané periody splňují maximální povolenou hodnotu HRV. Pokud ne, je všem vzorkům přidělena známka 3 (A). Hodnota HRV se vypočítává jako stonásobek podílu směrodatné odchylky period a průměrné periody v daném okně podle vzorce:

$$HRV = \frac{\sqrt{\frac{1}{N-1} \sum_{i=1}^N (T_i - \bar{T})^2}}{\bar{T}} \cdot 100, \quad (3)$$

kde N je počet period v okně, T_i hodnoty jednotlivých period, \bar{T} průměrná hodnota period v daném okně. Hodnota HRV je tedy vyjádřena jako směrodatná odchylka v procentech vztažená k průměrné délce period. Jedná se o úpravu standardního vzorce pro směrodatnou odchylku. Úpravu jsem zavedl proto, abych potlačil vliv délky period na hodnotu směrodatné odchylky.

V částech, kde je HRV v povolených mezích, se dle vztahu (2) určí, zda SNR překročilo nejnižší povolenou hodnotu. Pokud ne, všem vzorkům v této části je přiřazena známka 2 (B). Všechny vzorky, kterým nebyla přiřazena známka 3, poté postupují k hodnocení po jednotlivých periodách.

V této sekci se nejprve otestuje, zda je délka periody v rozsahu fyziologické tepové frekvence. Minimální tepová frekvence je stanovena na 30 tepů/min, maximální na 250 tepů/min. Délka periody odpovídající frekvenci mimo toto rozmezí se vyhodnocuje jako příznak chybných dat. Vzorkům v periodě je proto přiřazena známka 3 (C).

Dále se zjišťuje, zda se ve vybrané periodě nachází falešné QRS vzorky. Jedná se o vzorky, které nepřísluší skutečnému QRS komplexu. Přítomnost těchto vzorků může značit, že v periodě se nachází útvary podobné skutečným QRS komplexům. V takovém případě není perioda vhodná k analýze a je ohodnocena známkou 3 (D).

Periody, které doposud nebyly nijak ohodnoceny, postoupí k závěrečné podmínce. Zjišťuje se, zda jsou v okolí vymezeném fyziologickými hodnotami dostatečně zřetelně patrné vlny P a T. Pokud ne, je perioda ohodnocena známkou 2. Pokud ano, je periodě uděleno hodnocení 1. Perioda v tom případě prošla všemi podmínkami, a je tak součástí signálu vysoké kvality.

Po dokončení hodnocení se vzorkům nacházejících se před první a za poslední R vlnou přiřadí známka 3. Tyto úseky obsahují necelou periodu, k analýze se proto nehodí. Výstupem z bloku Hodnocení je tedy vektor stanovené kvality, který má stejný počet vzorků jako vstupní signál. Pomocí něj můžeme zobrazit ohodnocený signál (obr. 3.6).

V tab. 3.2 a 3.3 jsou shrnuty limitní hodnoty pro všechna kritéria.

Tab. 3.2: Limitní hodnoty


Rozsah platnosti	Označení	Požadavek	Limit
Okno	A	HRV nižší než limit	30 %
	B	SNR vyšší než limit	26,5 dB*
Perioda	C	Perioda ve fyz. rozsahu	30 – 250 tepů/min
	D	Žádné falešné QRS vzorky	0 vzorků

*Pouze orientační hodnota SNR

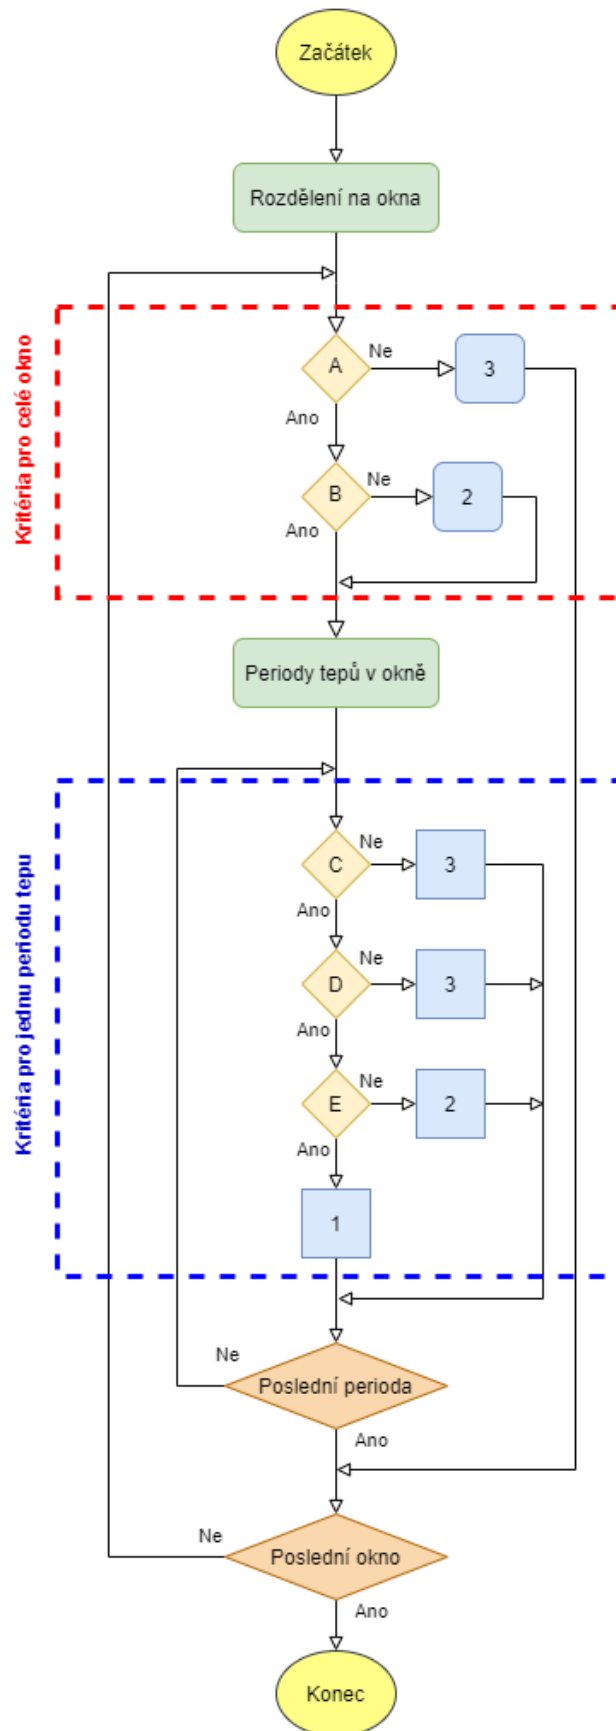
Tab. 3.3: Limitní hodnoty pro kritérium E

Kritérium E			
Vlna	Interval	Délka intervalu [ms]	Min. délka vlny v intervalu [ms]
P	PR	300	60
T	ST	400	100

Pozn.: Pro udělení známky 1 musí vlny v odpovídajících intervalech dosáhnout minimální délky.



Obr. 3.6: Ukázka části ohodnoceného signálu



Obr. 3.7: Rozhodovací schéma pro přidělování známek

3.2 Přímá metoda


Pro zopakování ještě uvedeme, že přímá metoda spočívá v hodnocení kvality EKG signálů rovnou neuronovou sítí.

3.2.1 Učení sítě

K realizaci přímé metody byla použita konvoluční neuronová síť, konkrétně architektura typu TCN [27]. Cílem bude, abychom přímo ze sítě dokázali na výstupu získat vektor kvality, který bude o stejné délce jako vstupní signál, a bude mu tak odpovídat. Pro dosažení uspokojivé úspěšnosti sítě je v případě přímé metody zapotřebí velké množství anotovaných dat, ve kterém se vyskytují ideálně rovnoměrně zastoupené všechny třídy kvality. Za tímto účelem byla použita databáze [33], která obsahuje anotované záznamy o délce přibližně sto hodin. Obsažená anotace je vytvořena ručně třemi hodnotiteli. Z důvodu snahy využít co největší množství dat pro trénování bylo do trénovací množiny umístěno 90 % z celkového počtu záznamů, do testovací zbylých 10 %.

Důležitou vlastností každého algoritmu pro hodnocení kvality EKG je jeho schopnost akceptovat patologické signály. Nemělo by docházet k tomu, že kvalitní patologický signál je vyřazen (označen známkou 3) z důvodu odlišného průběhu z případné další analýzy. Síť je proto naučená i na vybrané patologické průběhy, které svoji kvalitou odpovídají známce 1. Zahrnovat do trénovací množiny patologické signály nižší kvality (2 nebo 3) nemá smysl, protože tyto signály se od EKG zdravého člověka liší mnohdy jen velmi málo (viz kap. 1.4), v případě zašuměnosti signálu tak mohou tyto odchylky splýnout s rušením.

Pro učení sítě byly použity patologické průběhy z volně dostupné databáze MIT-BIH Arrhythmia Database [34]. Jedná se o reálné signály o délce 30 minut, ve kterých se vyskytují různé druhy patologií, zejména některé typy raménkových blokád, komorové i síňové extrasystoly a také patologie ST úseků (viz kap. 1.4). Do trénovací množiny byly zařazeny úseky s nejvyšším výskytem patologií. Dostupné signály jsou však vzorkovány frekvencí 360 Hz, bylo tedy nutné je převzorkovat na požadovanou frekvenci 250 Hz. Příklad použitého patologického průběhu je na obr. 3.8, kde můžeme kromě standardního QRS komplexu vidět komorovou extrasystolu (označeno písmenem V).



Obr. 3.8: Komorová extrasystola

Na rozdíl od učení sítě pro nepřímou metodu nyní používáme k trénování netransformovaná originální data. Použití 2D spekter není v tomto případě možné, protože síť využívá 1D konvoluce. Zvolená architektura se skládá z tzv. bloků, které se skládají z několika vrstev (layers). Pro trénování byly zvoleny parametry uvedené v tab. 3.4.

Tab. 3.4: Nastavení pro trénování sítě

Název parametru	Nastavení
Solver Name	Adam
Max Epochs	20
Mini Batch Size	7
Initial Learn Rate	0,001
Learn Rate Drop Period	3
Gradient Threshold	1
Number of Blocks	15
Number of Filters	100

Vrstvy

Jeden blok se skládá ze dvou konvolučních vrstev se stejným dilatačním faktorem (DCC), po nich následují normalizační (N), ReLU a spatial dropout (SD) vrstvy dle schématu na obr. 3.9.



Obr. 3.9: Řazení vrstev v bloku

Dilated causal convolution layers – konvoluční vrstvy se stejným dilatačním faktorem

Normalizační vrstva – normalizuje výstup z předchozí vrstvy, zefektivňuje proces učení a zabraňuje přeučení sítě [35]

ReLU - rectified linear activation function. Pokud je hodnota funkce kladná, je vstup přenesen nezměněn na výstup, v opačném případě je na výstupu nula.

Spatial dropout vrstva – zabraňuje přeučení sítě, výstupy z této vrstvy jsou náhodně podvzorkovány [36]

Nastavení parametrů

Většina parametrů je již vysvětlena v kap. 3.1.1, zde proto uvedme je nové parametry.

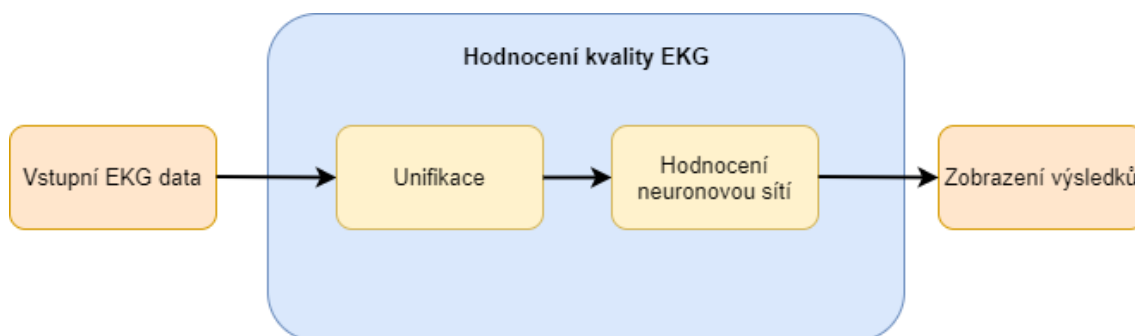
Number of Blocks – udává počet jednotlivých bloků, představuje velikost sítě

Number of Filters – taktéž představuje velikost sítě. Čím více filtrů, tím lépe dokáže síť extrahovat informace z trénovacích dat.

S takto zvoleným nastavením bylo zahájeno trénování sítě. Naučená síť poté dosáhla úspěšnosti predikce na trénovacích datech 92 %. Úspěšnost na testovacích datech je rozebrána v kap. 4.1.

3.2.2 Princip algoritmu

Popis principu algoritmu pro hodnocení EKG pomocí přímé metody je ve srovnání s nepřímou metodou stručnější, protože se zde nevyskytuje žádný druhotný hodnotící algoritmus. Základní myšlenka je však stejná, tzn., že algoritmus vychází z hodnocení signálu to třech tříd kvality (kap. 1.6). Princip hodnotícího algoritmu je možné shrnout do blokového schématu na obr. 3.10.



Obr. 3.10: Blokové schéma algoritmu Přímé metody

3.2.2.1 Vstupní EKG data

Na vstupní data je opět kladen pouze jeden požadavek a to, že vzorkovací frekvence musí mít hodnotu 250 Hz, případně její celočíselné násobky. Na vstup tak může být přiveden jakýkoliv EKG signál (i jiný než EKG), žádná jeho amplituda ani délka není omezující. Na vstup se vkládá i případná anotace signálu pro ověření funkčnosti algoritmu.

3.2.2.2 Unifikace

V tomto bloku je nejdříve upravena vzorkovací frekvence signálu na požadovanou frekvenci 250 Hz. Poté se provede rozdělení signálu na části, velikost jednoho okna se volí na délku přibližně odpovídající 20 periodám. Rozdělení se provádí z důvodu vylepšení výkonosti algoritmu.

3.2.2.3 Hodnocení neuronovou sítí

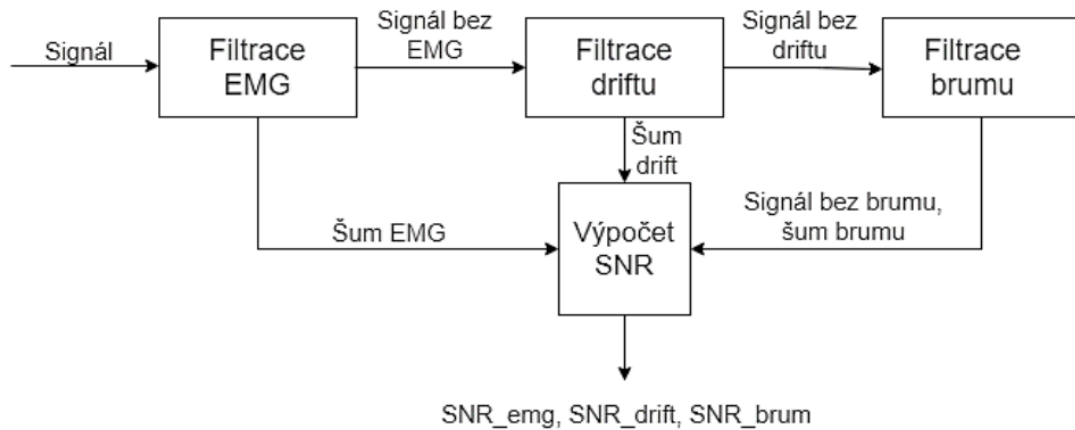
Unifikovaná data vstoupí do tohoto bloku, kde se pomocí natrénované neuronové sítě provede po jednotlivých oknech hodnocení vstupního signálu na škále 1 až 3. Síť je naučená i na vybrané patologické průběhy, nemělo by tedy dojít k jejich nežádoucímu vyřazení. V tomto bloku se neprovádí detekce maxim R vln. Tato funkce algoritmu přímé metody chybí, pro účely hodnocení kvality signálu však není nutná.

Výstupní vektor kvalit, který má stejnou délku jako vstup, může místy obsahovat drobné nespojivosti. Například v úseku signálu určité kvality se může nesprávně vyskytnout několik vzorků jiné kvality. V rámci bloku hodnocení se proto ještě provádí

průchod signálu oknem, které má za úkol učinit oznamování signálu více spojitě. Ze vzorků, které se nacházejí v daném okně, se vybere nejvíce zastoupená známka a udělí se všem ostatním. Volí se okno o malé délce (cca. 2 periody).

3.3 SNR metoda

Metoda SNR využívá k hodnocení kvality signálu vypočtený koeficient Signal to noise ratio (SNR) neboli česky odstup signálu od šumu. Hodnota SNR nám tedy udává, jak moc je užitečný signál zarušen. Ze vzorce (2) pro výpočet parametru SNR je patrné, že pro jeho stanovení potřebujeme od sebe oddělit šum a užitečný signál. Za tímto účelem se zpravidla používají různé druhy filtrací. Algoritmy prezentované v [3] a [29] se snaží od užitečného signálu odfiltrovat všechny tři nečastější druhy rušení, které se vyskytují u EKG signálů (viz kap. 1.5). Příspěvky všech tří druhů šumu se poté s vhodným váhováním sečtou a výsledek se použije k výpočtu SNR. Tento princip je možno znázornit v následujícím schématu (obr. 3.11).



Obr. 3.11: Výpočet SNR z jednotlivých šumových složek [3]

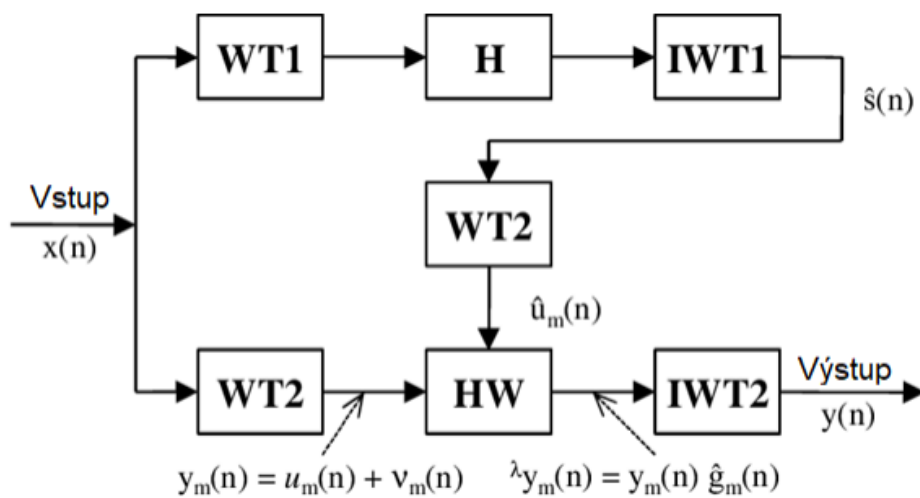
3.3.1 Princip algoritmu

Pro filtraci jednotlivých druhů rušení se používají odlišné druhy filtrací. Z důvodu, že SNR metoda je uvedena v této práci pouze za účelem srovnání jejích výsledků s algoritmy využívající neuronové sítě, nebude zde použito jednotlivých filtračních technik popsáno podrobně. Všechny filtrační postupy jsou již detailně popsány v práci Michaely Brackové [3] případně také v práci Lukáše Smitala [29]. Zde je proto zmíníme pouze stručně a zaměříme se spíše na srovnání funkčnosti algoritmů.

K filtraci nežádoucího rušení způsobeného svalovou aktivitou (EMG) je v algoritmu použito wienerovského vlnkového filtru. Jeho princip zjednodušeně řečeno spočívá v použití vlnkové transformace a následné úpravě vlnkových koeficientů prahováním a násobením korekčními faktory. Tímto způsobem jsme schopni určit míru svalového rušení. Postup je možno pro ilustraci shrnout do schématu na obr. 3.12. Schéma je možno ještě rozdělit na dvě části: bloky WT1, H a IWT1, kde probíhá prostá vlnková filtrace

a bloky WT2, HW a IWT2, kde probíhá wienerovská filtrace. Nyní uveďme, co jednotlivé bloky představují.

- Část 1 – signál je podroben vlnkové transformaci (WT1), pomocí prahování jsou v bloku H upraveny vlnkové koeficienty a po provedení zpětné vlnkové transformace IWT1 dostáváme odhad užitečné složky signálu $\hat{s}(n)$
- Část 2 – jsou aplikovány dvě vlnkové transformace (WT2), jedna na odhad užitečného signálu $\hat{s}(n)$ a druhá na vstup $x(n)$. Výstupy jsou potom spojeny v bloku HW, kde dojde k vynásobení vlnkových koeficientů vypočteným korekčním faktorem. Po provedení zpětné vlnkové transformace (IWT2) dostáváme vyfiltrovaný signál.

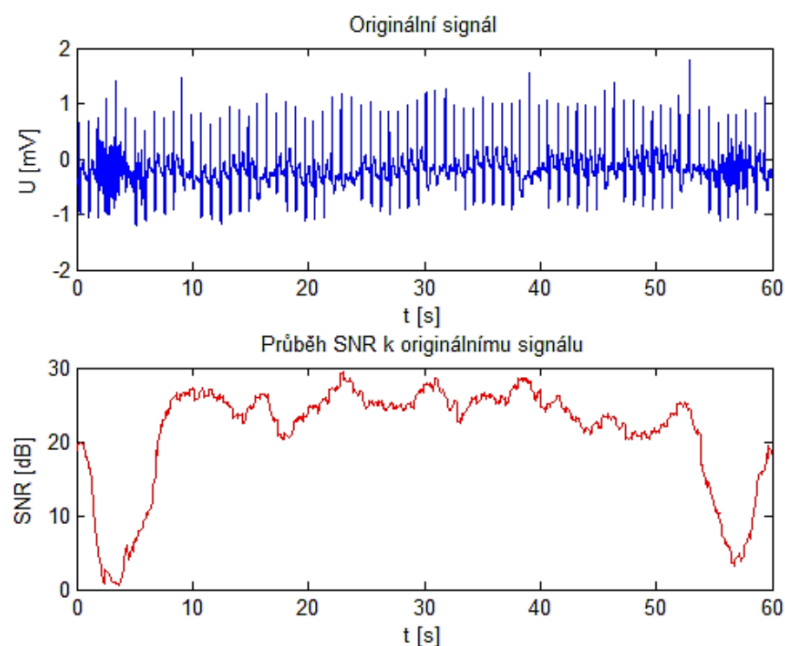


Obr. 3.12: Schéma wienerovské filtrace [3]

K odfiltrování nízkofrekvenčního rušení (driftu) je použito filtru FIR (filtr s konečnou impulsní charakteristikou) typu horní propust. Mezní frekvence filtru se nastavuje na 0,67 Hz. Tato frekvence odpovídá srdeční frekvenci 40 tepů za minutu, kterou lze považovat za nejnižší fyziologickou. Všechny frekvence nižší než tato hodnota tedy pravděpodobně představují nízkofrekvenční rušení a je možné je odfiltrovat.

Pro filtraci posledního druhu rušení brumu bylo využito filtru IIR (filtr s nekonečnou impulsní charakteristikou) typu pásmová zadrž. Brum je aditivní druh rušení, který vzniká přítomnosti síťového napětí, zadržované frekvence byly proto zvoleny v rozsahu 49 až 51 Hz.

Po zjištění příspěvků všech tří nejběžnějších druhů rušení je možné spočítat hodnotu SNR. Výhodou těchto algoritmů pro hodnocení kvality EKG je, že analyzují signál spojitě. To znamená, že na výstupu dostaneme vektor hodnot SNR o stejné délce jako je vstupní signál, bez předchozího dělení na okna (viz obr. 3.13).



Obr. 3.13: Změny SNR v závislosti na kvalitě signálu

Platí, že čím je hodnota SNR vyšší, tím je odstup signálu od šumu větší, tím pádem je i kvalita signálu lepší a naopak. Pro využití hodnoty SNR k hodnocení signálu do třech tříd kvality je nutné zvolit prahové hodnoty p_1 a p_2 , kde $p_1 < p_2$, které reprezentují přípustnou respektive nepřípustnou míru zašumění:

$$\begin{aligned}
 SNR < p_1; Q &= 3 \\
 p_1 \leq SNR \leq p_2; Q &= 2 \\
 SNR > p_2; Q &= 1,
 \end{aligned} \tag{4}$$


Z principu metody je zřejmé, že dokáže bez problému správně ohodnotit i patologické průběhy. Jelikož metoda zkoumá pouze zarušenost signálu, lze očekávat, že jakýkoliv kvalitní patologický signál nebude chybně vyřazen (známka 3). Je však pravděpodobné, že algoritmus se bude takto chovat k libovolnému nezašuměnému signálu.

3.4 MSQI

Tato metoda byla prezentována v článku od Diany Tobónové [30] a dále testována v práci od Michaely Brackové [3], zde ji uvádíme z důvodu, že bude využita ke srovnání s metodami využívající neuronové sítě. Algoritmus využívá pro hodnocení rychlou Fourierovu transformaci (FFT) a na základě jejího výsledku je vypočítán index kvality modulačního spektra (Modulation Spectrum Quality Index) na jehož základě jsme schopni učit kvalitu signálu EKG.

3.4.1 Princip algoritmu

Vstupní signál je na počátku nejprve rozdělen pomocí 32-bodového sinusového okna do několika v řadě za sebou překrývajících se segmentů. Na získané úseky je poté aplikována 512-bodová rychlá Fourierova transformace, a dostaneme tak jejich transformaci do frekvenční oblasti. Transformované segmenty lze využít k tvorbě spektrogramu. Jednotlivé segmenty jsou poté dále rozdělovány do překrývajících se částí, tentokrát ovšem přes časovou osu. Za tímto účelem je využito 128-bodové modulační okno se 75% překrytím. Na rozdělené úseky je použita opět 512-bodová FFT. Výsledkem procesu je konečná reprezentace frekvence nazývaná modulační spektrogram $X(f, f_m, k)$, kde f je konvenční frekvence, f_m frekvence modulace a k představuje index okna pro druhou transformaci. Popsaný princip algoritmu je znázorněn na obr. 3.14.



Obr. 3.14: Princip vytvoření modulačního spektrogramu [30]

Ze získaného modulačního spektra je možné vypočítat index kvality, který vychází z vlastností EKG komponent a artefaktů v modulových spektrech EKG signálů. Užitečný EKG signál a šumové složky se totiž v modulačním spektru projevují odlišně. Přítomnost užitečných částí EKG způsobí výskyt viditelných kmitočtových laloků ve spektru, s modulovou frekvencí v rozsahu 0 – 40 Hz. Naopak šumové složky typické vzory ve spektru nevytvářejí a lze je proto identifikovat. Typická hodnota modulační frekvence pro šumovou složku se stacionárním zdrojem rušení je 0 Hz. Algoritmus proto nejdříve určí parametry laloků ve spektru. Vypočítává se energie pro modulační frekvenci v rozmezí $0,8 \leq f_m \leq 3$ Hz a poté se průměruje v rozmezí konvenční frekvence $0 \leq f \leq 40$ Hz.

Jako hlavní lalok je označen ten s nejvyšší energií modulační frekvence. Index kvality modulačního spektra se vypočítá jako:


$$MS - QI(k) = \frac{EME(k)}{RME(k)}, \quad (5)$$

kde $EME(k)$ je celková modulová energie, která se počítá jako suma všech modulačních energií obsažených v hlavním laloku a jeho dalších harmonických. Experimentálně bylo zjištěno, že pro nejlepší výsledky je vhodné pro výpočet EME zahrnout hlavní lalok a další 3 harmonické. Předpokladem je, že EME parametr představuje informace dostupné z užitečných složek EKG. Vše ostatní nacházející se mimo vybrané čtyři laloky odpovídá šumu. Celková modulační energie se potom vypočítá jako:


$$EME(k) = \sum_{j=1}^4 X(f|_0^{40}, jf_m^* - B \leq jf_m^* \leq jf_m^* + B, k), \quad (6)$$

kde $f|_0^{40} = 0 \leq f \leq 40$ a $B = 0,3125$ Hz. Parametr RME představuje rozdíl mezi celkovou energií modulačního spektragramu a EME . Výsledný index kvality $MS - QI(k)$ je dán jako průměr přes všechny kroky okna v nasnímaném EKG signálu. Experimentálně bylo zjištěno, že hodnoty $MS - QI$ se pohybují v rozmezí 0 a 1,5. Platí, že čím je index vyšší, tím lepší je kvalita signálu.

Funkčnost algoritmu je pro lepší pochopení znázorněna na obr. 3.15. Na vstup je přiveden uměle vygenerovaný signál, který je rozdělen na dvě poloviny. První část obsahuje zašuměný signál a druhá čistý. Ze vstupu vytvoříme spektragram a následně je vypočítán podle (5) index kvality $MS - QI$ (obr. 3.16). Je vidět, že s rostoucí kvalitou se zvýšil i koeficient $MS - QI$.



Obr. 3.15: Ukázka modulačního spektragramu [3]



Obr. 3.16: Změna koeficientu $MS - QI$ s odlišnou kvalitou signálu [3]

Výpočet koeficientu $MS - QI$ probíhá na vstupním signálu po oknech. Pro zvolený časový úsek (délku okna) je proto jeho hodnota pro všechny vzorky v okně stejná. Nejkratší okno, které je pro výpočet možno použít, má délku 5 s. [3] Aby bylo možné využít vypočtené hodnoty $MS - QI$ pro zařazení jednotlivých částí signálu do třech tříd kvality, je nutné zavést dvě prahové hodnoty p_1 a p_2 , kde $p_1 < p_2$. Potom platí:

$$\begin{aligned}
 MS - QI < p_1; Q &= 3 \\
 p_1 \leq MS - QI \leq p_2; Q &= 2 \\
 MS - QI > p_2; Q &= 1,
 \end{aligned}
 \tag{7}$$

kde Q je známka kvality přiřazená všem vzorkům v okně.

Nevýhodou algoritmu je, že v sobě nemá zahrnutou detekci patologických signálů. V případě, že se na vstupu vyskytne signál s patologií, která ho silně odlišuje od průběhu zdravého EKG (např. akutní infarkt myokardu nebo komorová extrasystola, viz kap. 1.4), může dojít k nežádoucímu poklesu koeficientu $MS - QI$ a tím pádem i známky kvality. Algoritmus tedy v některých případech nemusí být schopen rozlišit zarušený signál od výrazné patologie.

4 Výsledky

Zkoumání správnosti hodnocení kvality EKG bylo provedeno u celkově pěti algoritmů:

1. Nepřímá metoda
2. Přímá metoda
3. SNR algoritmus – autor Lukáš Smital a tým [29] (SNR LS)
4. SNR algoritmus – autor Michaela Bracková [3] (SNR MB)
5. MSQI algoritmus – autor Diana Tobónová [30] (MSQI)

Na uvedených algoritmech byly provedeny celkově čtyři testy. Na každý z testů byla použita různá testovací sada dat. Šlo o:

- Test úspěšnosti hodnocení na delších EKG datech
- Test univerzálnosti
- Test citlivosti na patologie
- Časovou náročnost

Výstupem všech prezentovaných algoritmů je vždy vektor kvalit, který má stejnou délku jako vstupní signál. U každého z testů s výjimkou *Časové náročnosti* se proto bude v různých podobách porovnávat tento vektor s vektorem anotací.

4.1 Testy správnosti hodnocení na delších EKG datech

Test správnosti hodnocení jsme provedli na dvou EKG signálech. Jako první signál byla vybrána spojená data nacházející se v testovací množině (viz učení sítě pro *Přímou metodu*, kap. 3.2.1). Jde o 10 % z celkového objemu anotovaných dat získaných z veřejně dostupné databáze na portálu PhysioNet [33]. Záznam je ručně anotován třemi hodnotiteli. Celková délka tohoto testovacího záznamu je přibližně 11 hodin.

Druhým použitým signálem je moje vlastní EKG o délce necelé 3 hodiny naměřené přístrojem Faros. Tento signál jsem ručně anotoval, přičemž jsem vycházel ze znalosti rozdělení signálu do třech tříd kvality.

Analýza funkčnosti všech algoritmů probíhala formou vyhodnocení procentuální shody stanoveného vektoru kvalit z obou vstupních signálů s vektorem anotací. Shoda vektoru kvalit s anotací *zeleně* je vyjádřena pomocí matice záměn, kde Q_A je anotovaná a Q_H hodnocená kvalita (tab. 4.1 a 4.2).

Procentuální chyba *modře* odpovídá místům, kde byl signál ohodnocen horší známkou, než jakou byl anotován, avšak nejedná se o hrubou chybu. Tyto případy není nutné považovat za chybu. Svědčí to spíše o jiné úrovni přísnosti hodnotícího algoritmu ve srovnání s anotací. Tyto nepřesnosti proto zahrneme do úspěšnosti.

Procentuální chyba nad hlavní diagonálou *červeně* odpovídá místům, kde byl signál ohodnocen lepší známkou, než jakou byl anotován. Znamená to, že úseky s nekvalitním signálem by mohly být nesprávně označeny jako vhodné pro následnou analýzu. Tento

údaj proto již můžeme považovat za chybu algoritmu. Shrňme si tedy, jak se vypočítají jednotlivé veličiny popisující funkčnost algoritmu:

$$shoda = Q_{1A} \cap Q_{1H} + Q_{2A} \cap Q_{2H} + Q_{3A} \cap Q_{3H} \quad (8)$$

$$úspěšnost = shoda + Q_{1A} \cap Q_{2H} + Q_{1A} \cap Q_{3H} + Q_{2A} \cap Q_{3H} \quad (9)$$

$$chyba = Q_{2A} \cap Q_{1H} + Q_{3A} \cap Q_{1H} + Q_{3A} \cap Q_{2H} \quad (10)$$

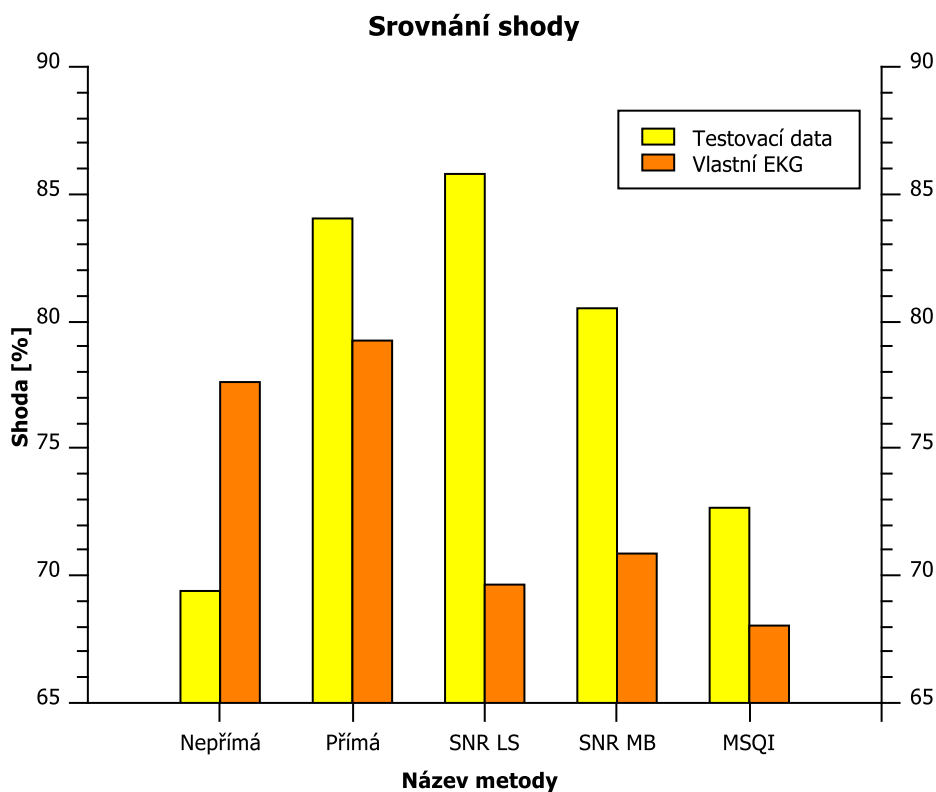
Na obr. 4.1 a 4.2 je zobrazeno srovnání shody a úspěšnosti všech metod pro obě testovací data. Celkové výsledky jsou shrnuty v tab. 4.3, přičemž je vyznačena nejlepší hodnota u každého z parametrů (shoda, úspěšnost, chyba).

Tab. 4.1: Výsledky pro Testovací data

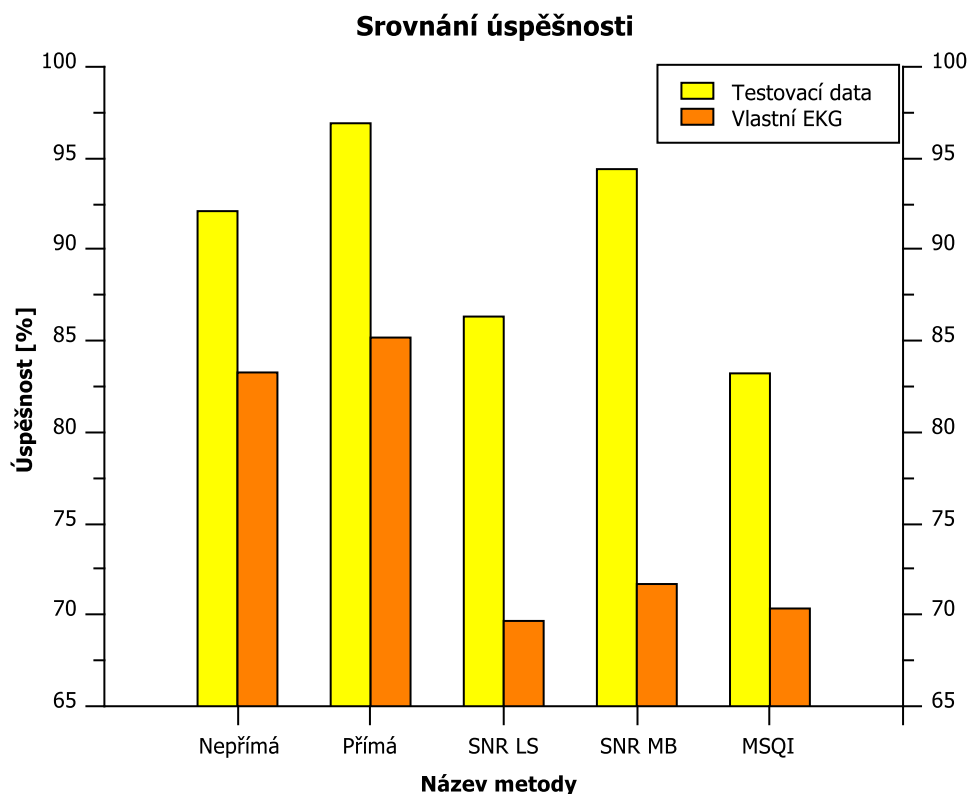
Testovací data – délka 10,7 h									
Nepřímá metoda [%]				SNR LS [%]			MSQI [%]		
	Q_{1A}	Q_{2A}	Q_{3A}	Q_{1A}	Q_{2A}	Q_{3A}	Q_{1A}	Q_{2A}	Q_{3A}
Q_{1H}	50,21	7,53	0,16	70,45	12,44	1,07	58,42	14,65	1,41
Q_{2H}	20,27	13,06	0,21	0,48	10,07	0,16	9,62	6,44	0,72
Q_{3H}	0,45	1,98	6,13	0,00	0,06	5,27	0,10	0,83	7,81
	$shoda = 69,40$ $úspěšnost = 92,10$ $chyba = 7,90$			$shoda = 85,79$ $úspěšnost = 86,33$ $chyba = 13,67$			$shoda = 72,67$ $úspěšnost = 83,22$ $chyba = 16,78$		
Přímá metoda [%]				SNR MB [%]					
	Q_{1A}	Q_{2A}	Q_{3A}	Q_{1A}	Q_{2A}	Q_{3A}			
Q_{1H}	58,07	1,11	0,08	57,30	4,39	0,68			
Q_{2H}	12,86	21,45	1,90	13,83	18,05	0,52			
Q_{3H}	0,00	0,02	4,51	0,01	0,05	5,16			
	$shoda = 84,04$ $úspěšnost = 96,91$ $chyba = 3,09$			$shoda = 80,51$ $úspěšnost = 94,40$ $chyba = 5,60$					

Tab. 4.2: Výsledky pro záznam Vlastní EKG

Vlastní EKG – délka 2,7 h											
Nepřímá metoda [%]				SNR LS [%]			MSQI [%]				
	Q_{1A}	Q_{2A}	Q_{3A}	Q_{1A}	Q_{2A}	Q_{3A}	Q_{1A}	Q_{2A}	Q_{3A}		
Q_{1H}	64,75	16,21	0,34	67,63	20,38	9,29	65,34	19,80	8,48		
Q_{2H}	2,55	2,07	0,19	0,02	0,66	0,67	2,16	1,19	1,37		
Q_{3H}	0,35	2,76	10,79	0,00	0,00	1,36	0,08	0,07	1,51		
			shoda = 77,61 úspěšnost = 83,27 chyba = 16,73			shoda = 69,65 úspěšnost = 69,67 chyba = 30,34			shoda = 68,04 úspěšnost = 70,35 chyba = 29,65		
Přímá metoda [%]				SNR MB [%]							
	Q_{1A}	Q_{2A}	Q_{3A}	Q_{1A}	Q_{2A}	Q_{3A}					
Q_{1H}	61,56	3,46	0,01	66,69	18,66	8,86					
Q_{2H}	5,94	17,67	11,35	0,82	2,47	0,79					
Q_{3H}	0,00	0,00	0,01	0,00	0,00	1,71					
			shoda = 79,24 úspěšnost = 85,18 chyba = 14,82			shoda = 70,87 úspěšnost = 71,69 chyba = 28,31					



Obr. 4.1: Srovnání shody pro oba záznamy



Obr. 4.2: Srovnání úspěšnosti pro oba záznamy

Tab. 4.3: Celkové výsledky

	Nepřímá	Přímá	SNR LS	SNR MB	MSQI
Prům. shoda [%]	73,51	81,64	77,72	75,69	70,34
Prům. úspěšnost [%]	87,69	91,05	78,00	83,05	76,79
Prům. chyba [%]	12,31	9,55	22	16,95	23,21

4.1.1 Diskuze výsledků

Provedli jsme test na dvou delších EKG záznamech – Testovací data (11 h) a Vlastní EKG (3 h). Z testu vyšla nejlépe Přímá metoda, která se umístila na prvním místě z hlediska *shody* i důležitého parametru *úspěšnosti* (druhá Nepřímá, poslední MSQI, viz obr. 4.1 s 4.2). Hodnota *úspěšnosti* nám říká, jakému procentu vzorků byla udělena správná známka, a zároveň nedošlo k chybnému přidělení lepší známky, než na jakou je úsek anotován (vztah (9)). Chybné přidělování je důležitým parametrem, který hodnota *úspěšnosti* zohledňuje, můžeme ji proto považovat za důležitější ukazatel než hodnotu *shody*.

Nepřímá metoda skončila s hodnotou *úspěšnosti* těsně za Přímou metodou (tab. 4.3). Z výsledků vyplynulo, že Nepřímá metoda má oproti Přímé lepší schopnost detekce nekvalitních signálů o kvalitě 3, avšak zaostává v rozeznání kvalit 1 a 2.

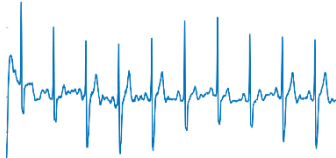
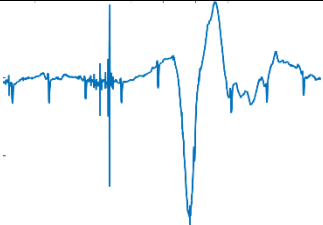
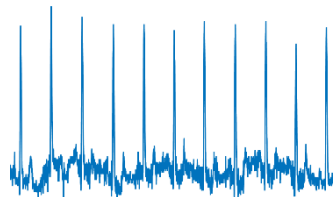

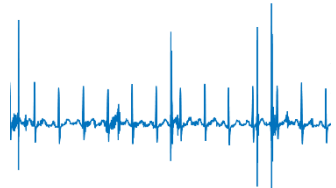

Z výsledků je dále zřejmé, že všechny algoritmy dosáhly nižší úspěšnosti na Vlastním EKG v porovnání s Testovacími daty. Vlastní EKG data pravděpodobně obsahují jiné typy průběhů než Testovací data a metody je neumí správně identifikovat. Je také možné, že výsledek byl způsoben neodbornou tvorbou anotace (vytvořena autorem diplomové práce).

4.2 Test univerzálnosti


Test univerzálnosti by měl odhalit, jak vybrané hodnotící metody reagují na různorodě vypadající akceptovatelné a neakceptovatelné EKG signály. Pro účely tohoto testu byla vybrána databáze [37], která obsahuje 1000 záznamů – 773 akceptovatelné a 225 neakceptovatelné kvality. Využívá teda pouze řazení do dvou tříd kvality. EKG záznamy jsou dvanácti svodové.

Z databáze jsme následně vybrali 20 akceptovatelných a 20 neakceptovatelných signálů o délce 10 s. Z dvanácti svodového EKG byly pro test vybrány vždy signály z jednoho svodu, které bylo možné jednoznačně přiřadit k jedné ze dvou kategorií. Pro obě skupiny byla snaha vybrat odlišné průběhy signálů tak, aby se ukázala funkčnost na různých podobách záznamů. Pro testování bylo použito také několik průběhů nevzniklých při EKG (např. funkce sinus, bílý šum). Ukázky několika využitých signálů jsou v tab. 4.4a a 4.4b.

Tab. 4.4a: Ukázky signálů použitých pro test

Anotováno jako akceptovatelný	Anotováno jako neakceptovatelný
	
	
	

Tab. 4.4b: Ukázky signálů použitých pro test

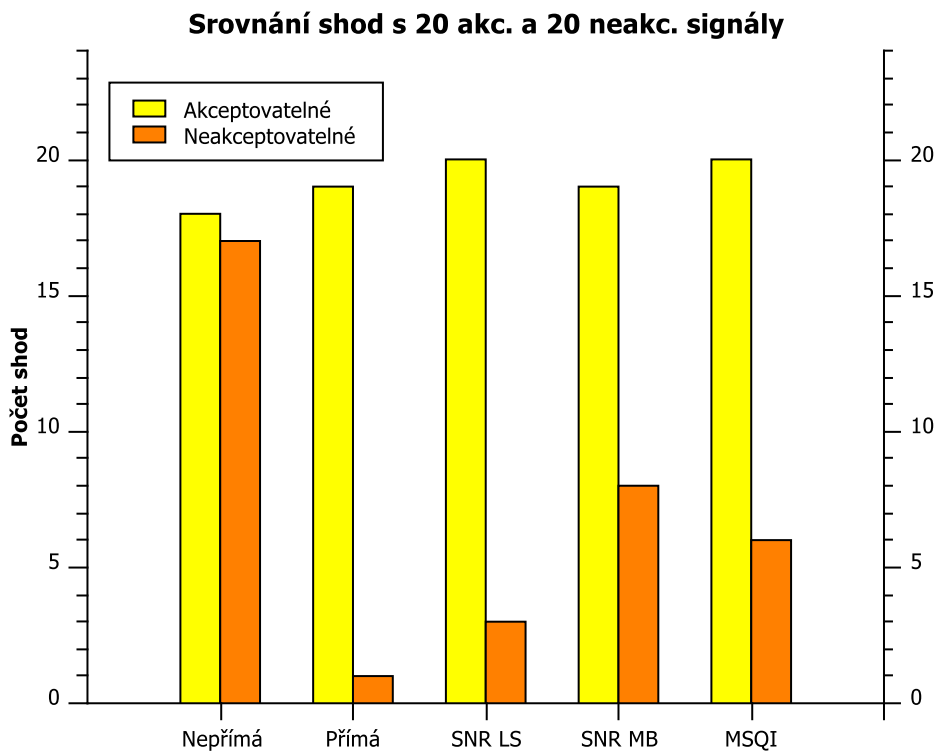


Pokud algoritmus ohodnotil záznamy známkou 1 nebo 2, byly považovány za akceptovatelné. Pokud se v signálu objevila známka 3 pro více jak 25 % vzorků, byl celý signál považován za neakceptovatelný. Výsledky v podobě matice záměn (počty shod) jsou shrnuty v tab. 4.5, kde Q_A (Q_{AA} , Q_{NA}) je anotovaná a Q_H (Q_{AH} , Q_{NH}) hodnocená kvalita.

Tab. 4.5: Výsledky pro druhou databázi

Nepřímá metoda [počet]		SNR LS [počet]		MSQI [počet]	
	Q_{AA}	Q_{NA}		Q_{AA}	Q_{NA}
Q_{AH}	18	3	Q_{AH}	20	17
Q_{NH}	2	17	Q_{NH}	0	3
	<i>shoda</i> = 35 <i>chyba</i> = 5			<i>shoda</i> = 23 <i>chyba</i> = 17	
				<i>shoda</i> = 26 <i>chyba</i> = 14	
Přímá metoda [počet]		SNR MB [počet]			
	Q_{AA}	Q_{NA}		Q_{AA}	Q_{NA}
Q_{AH}	19	19	Q_{AH}	19	12
Q_{NH}	1	1	Q_{NH}	1	8
	<i>shoda</i> = 20 <i>chyba</i> = 20			<i>shoda</i> = 27 <i>chyba</i> = 13	

Na obr. 4.3 je zobrazeno srovnání počtu shod s 20 akceptovatelnými a 20 neakceptovatelnými signály. Obrázek vypovídá o funkčnosti metod na obou skupinách.



Obr. 4.3: Počet správně zařazených záznamů - shody

4.2.1 Diskuze výsledků


Výsledky Testu univerzálnosti potvrdily podezření z předchozího testu na delších EKG datech. Jak vyplývá z tab. 4.5 a obr. 4.3, Nepřímá metoda dokáže za daných podmínek nejlépe odhalit různě vypadající nekvalitní signál (kvalita 3). Výhodou nepřímé metody je, že zohledňuje tvar průběhu EKG signálu. V případě, kdy je na vstup přiveden nezašuměný, ale nekvalitní EKG signál, případně se o EKG signál vůbec nejedná, je ostatními algoritmy označen často za akceptovatelný. Po přivedení signálu o konstantním napětí 0 V na vstup dokonce metoda SNR MB zhavaruje. Situace je demonstrována na obr. 4.4 a 4.5.

Tvar průběhu EKG signálu zohledňují rovněž metody Přímá a MSQI. Nepřímá metoda v tomto testu však nedopadla dobře. Neúspěšnost Přímé metody je zapříčiněna zejména tím, že použitá neuronová síť nebyla natrénována na dostatečném množství dat. V trénovacích datech se vyskytovalo pouze omezené množství nekvalitních signálů, a proto metoda v tomto stavu na širším spektru nevyhovujících signálů selhává.


Metoda MSQI by z jejího principu měla odhalit signály, které jsou nevyhovující pouze průběhem nikoli zašuměním, avšak selhává zde i ona. Důvody nejsem schopen

přesvědčivě diskutovat, neboť nejsem autorem algoritmu MSQI metody. Pravděpodobně však MSQI metoda nezohledňuje tvar průběhu EKG signálu dostatečně.

Akceptovatelné signály dokázaly všechny metody správně zařadit s přibližně stejnou úspěšností. Tento výsledek se dal očekávat na základě výsledků předchozího testu na delších EKG datech.



Obr. 4.4: Výpadek, Nepřímá m. – známka 3, ostatní – známka 1



Obr. 4.5: Nekvalitní signál, Nepřímá m. – známka 3, ostatní – známka 1


4.3 Test citlivosti na patologie

Provedení tohoto testu by mělo objasnit, jak jednotlivé metody reagují na patologické EKG. K testu bylo vybráno 14 desetisekundových signálů, u kterých se vyskytovaly různé druhy patologií (viz kap. 1.4). Šlo například o raménkové blokády, komorové extrasystoly, patologie ST úseku a další. Signály byly vybrány z veřejně dostupné databáze MIT-BIH Arrhythmia Database [34]. Výsledky jsou shrnuty v tab. 4.6. Pro test byly vybrány pouze signály odpovídající kvalitě 1, ideálně by tedy měly toto hodnocení obdržet i od testovaných metod (v tab. 4.6 *zeleně*). Důležité je, aby nedocházelo k ohodnocení kvalitního patologického signálu známkou 3 (*červeně*). Mohlo by tak dojít k jeho vyřazení z následné analýzy pro stanovení diagnózy, což by mohlo mít závažné zdravotní důsledky pro pacienta.

Tab. 4.6: Výsledky testu na patologie

	Nepřímá	Přímá	SNR LS	SNR MB	MSQI
Známka 1	4	14	14	8	14
Známka 2	9	0	0	6	0
Známka 3	1	0	0	0	0

Výsledky jsou shrnuty pro přehlednost ještě v obr. 4.6.



Obr. 4.6: Srovnání výsledků testu na patologie

4.3.1 Diskuze výsledků


Z testu citlivosti metod na patologické signály kvality 1 vyšly nejlépe metody Přímá, SNR od Lukáše Smitala a týmu a metoda MSQI (tab. 4.6 a obr. 4.6). Všechny tři metody měly shodně úspěšnost 100 % a ohodnotili všech 14 signálů známkou 1.

Výsledek u Přímé metody potvrdil správnost naučení neuronové sítě, kterou metoda používá, na vybrané patologické signály. Dobrý výsledek se dal ale očekávat, protože pro test byly zvoleny v převážné míře ty druhy patologických průběhů, na které byla síť natrénovaná. Je možné, že v případě, že by se použili jiné a méně obvyklé patologie, nebyla by úspěšnost hodnocení 100 %.

Nulová chybovost u metod SNR a MSQI je očekávatelná, protože jejich algoritmy se nezaměřují v dostatečné míře na samotný průběh EKG signálu, pouze na jeho zarušenost. Drobným překvapením proto je výsledek u metody SNR od Michaely Brackové, kde přibližně u poloviny záznamů došlo k udělení známky 2. Žádný záznam však nebyl vyřazen (udělení známky 3). Je možné, že algoritmus vyhodnotil některé typy patologií jako druh například nízkofrekvenčního rušení a došlo tak ke zhoršení známky.

Nejhůře si v tomto srovnání vedla Nepřímá metoda. Důvodem je, že do jejího algoritmu není přímo implementována schopnost detekovat patologické signály, z jejich přítomností tedy nepočítá. I přes to však došlo k vyřazení pouze jediného záznamu. Ostatní byly zařazeny buď správně, nebo jim byla udělena známka 2, což však nemusí znamenat jejich vyřazení z případné další analýzy pro stanovení diagnózy pacienta.

4.4 Časová náročnost



Obr. 4.7: Srovnání časové náročnosti výpočtu u jednotlivých metod

Na závěr byly všechny hodnotící metody podrobeny testu časové náročnosti výpočtu. Pro každou metodu byla vybrána stejná data – záznam EKG o délce přibližně 30 hodin. Na obr. 4.7 je zobrazena závislost výpočetní doby na délce vstupních dat.

4.4.1 Diskuze výsledků

Ze srovnání výpočetních dob vyšla nejlépe Přímá a SNR metoda od Michaely Brackové. Pro obě metody nepřesáhla výpočetní doba 5 minut i při 25 hodin dlouhém signálu. U Přímé metody se pohybovala dokonce jen kolem 1 minuty. Výpočetní čas se navíc zvyšoval s rostoucí délkou záznamu lineárně.

Při srovnání zbylých třech metod na to byly lépe metody SNR od Lukáše Smitala a MSQI než Nepřímá metoda, v případě kratších vstupních signálů. U Nepřímé metody se však na rozdíl od zmíněných dvou metod navyšoval výpočetní čas lineárně. Oba algoritmy (SNR LS a MSQI) vykazovaly ve zkoumaném rozsahu jistou míru exponenciálního růstu výpočetní doby. Pokud by se na vstupu objevily data delší než 25 hodin, došlo by proto pravděpodobně k mnohem rychlejšímu nárůstu času výpočtu než u Nepřímé metody.

4.5 Zhodnocení metod

Z výsledků provedených testů je možné shrnout vlastnosti jednotlivých metod do tab. 4.7. Symboly ✓ značí, že metoda dosáhla dobrých, ■ akceptovatelných a ✗ nedostatečných výsledků.

Tab. 4.7: Vlastnosti metod

	Nepřímá	Přímá	SNR LS	SNR MB	MSQI
Citlivost na kvality 1 a 2	■	✓	■	■	■
Citlivost na kvalitu 3	✓	✗	✗	✗	✗
Citlivost na patologie	■	✓	✓	■	✓
Doba výpočtu pro signál > 24 h	■	✓	✗	✓	✗

Při detekci signálů odpovídajících kvalitám 1 a 2 pracovali všechny metody přijatelně až na Přímou metodu, která dosáhla výrazněji lepších výsledků. U ostatních metod docházelo k občasným záměnám kvalit 2 a 1, Přímá metoda tento typ chybovosti vykazovala minimálně. Hranice mezi prvními dvěma stupni kvalit není často jasně vymezena a ani u jednoho z nich zpravidla nedojde k vyřazení signálu z případné další analýzy. Parametr samotný proto zcela jednoznačně nevypovídá o funkčnosti algoritmu.

K opačné situaci, tedy hodnocení signálů o kvalitě 3 známkou 1 nebo 2, již však docházelo v různé míře u všech algoritmů kromě Nepřímé metody. Jedná se o důležitý ukazatel funkčnosti, protože k analýze se můžou dostávat signály nízké kvality. Nejhůře na tom byly v tomto ohledu metody Přímá a SNR od Lukáše Smitala. Důvod nefunkčnosti Přímé metody v odhalování nekvalitních signálů je zejména ten, že pro trénování použité neuronové sítě nebylo k dispozici dostatečné množství dat (zejména o kvalitě 3). V zbylých ohledech (schopnost správně hodnotit patologický signál a výpočetní náročnost) totiž Přímá metoda funguje dobře. Lze tedy očekávat, že při správném naučení sítě by v celkovém měření předčila všechny zmíněné metody.

5 Závěr

Hlavním úkolem diplomové práce bylo seznámit se s problematikou hodnocení kvality EKG signálů, vytvořit vlastní metodu pro klasifikaci dlouhodobých signálů (více než 24 hodin) a srovnat její výkonnost s již existujícími metodami. V rámci práce byly vytvořeny dvě metody pro hodnocení kvality – Nepřímá a Přímá metoda. Oba postupy využívají neuronové sítě. Nepřímá metoda využívá neuronovou síť pouze k segmentaci EKG, následný algoritmus výstup zpracuje a vyhodnotí kvalitu signálu. Naproti tomu Přímá metoda aplikuje neuronovou síť rovnou na hodnocení kvality signálu. Pro srovnání funkčnosti byly vybrány tři metody jiných autorů. Šlo o metody využívající pro hodnocení kvality výpočtu koeficientu SNR (Signal to noise ratio) od Lukáše Smitala a týmu (SNR LS) [29] a Michaely Brackové (SNR MB) [3]. Testována byla i metoda od Diany Tobónové [30], která na základě výpočtu koeficientu kvality $MS - QI$ z modulačních spekter signálu určuje kvalitu. Hlavní cíl práce proto můžeme považovat za splněný.

Po vysvětlení principu byly metody podrobeny testování funkčnosti. Všechny pět metod bylo navrženo tak, aby řadily signál do třech tříd kvality: signál je vhodný ke kompletní analýze (1), pouze částečné (2), není vhodný (3). Výhodou Nepřímé i Přímé metody v porovnání s ostatními je, že zohledňují samotný průběh křivky EKG. V případě Nepřímé metody se tak děje aplikací pěti kritérií na předem segmentovaný signál neuronovou sítí: HRV, SNR, délka periody, přítomnost falešných vzorků QRS, správný průběh signálu uvnitř periody. Nepřímá metoda navíc dosáhla dobré citlivosti na signály špatné kvality 3, tzn., že je nezaměňuje se signály vyšších kvalit, což je jeden z nejdůležitějších parametrů. Přímá metoda využívá neuronovou síť rovnou pro hodnocení signálů. Přímý algoritmus měl dobré výsledky při detekci signálů vyšších kvalit 1 a 2, ale selhával v identifikaci nevyhovujících signálů. Důvodem bylo nedostatečné množství dostupných dat pro trénování sítě (zejména o kvalitě 3). Zbylé metody od jiných autorů taktéž vykazovaly nižší schopnost detekce kvalit 3 oproti Nepřímé metodě.

Je nutno zmínit, že Nepřímá metoda měla ve srovnání s Přímou určité problémy se zpracováním patologických signálů. Při testu na 14 patologických signálech vysoké kvality došlo u udělení horší známky a v jednom případě dokonce k vyřazení signálu. Nepřímá metoda též vyžaduje násobně vyšší výpočetní čas (až 15x). S přihlédnutím na podmínky, za jakých byla práce vypracována (nepříliš velké množství anotovaných dat, práce jednotlivce) je možné i přes tyto nedostatky považovat Nepřímou metodu za nejlepší z testovaných.

V případě, že by bylo k dispozici větší množství anotovaných dat k trénování sítě, zlepšila by se u Přímé metody schopnost detekovat správně signály o kvalitě 3, a v konečném měření by tak předčila všechny uvedené metody nevyužívající neuronové sítě i Nepřímou metodu. Velké množství trénovacích dat by bylo možné získat například

z databází firem, které se zabývají telemedicínským monitoringem EKG. Tyto firmy uskladňují mnoho záznamů svých pacientů a svoje diagnostické algoritmy na nich trénují. V rámci této práce se však nebylo možné k těmto materiálům dostat, protože se jedná o citlivé materiály.

Prezentované metody by mohly nalézt uplatnění například ve zmíněných telemedicínských firmách, kde se používají diagnostické algoritmy pro nalezení patologií v patientských záznamech. Diagnostické algoritmy však často falešně pozitivně detekují patologie v nekvalitních a zašuměných úsecích signálu, které je poté nutno ručně vyřadit [38]. Hodnotící algoritmus by proto mohl předem tyto místa vyřadit a ulehčit tak práci.

Závěrem lze říci, že hodnotící metody využívající neuronové sítě dokážou předčít konvenční metody. Avšak nutno zdůraznit, že architektury neuronových sítí prezentované v této práci nelze brát jako vzorové a nejlepší. V praxi by k jejich tvorbě přistoupil tým na místo jednotlivce a výsledek by tak byl pravděpodobně mnohem více optimalizovaný. Poznatky z výsledků vytvořených algoritmů lze proto pojmout jako naznačení směru dalšího vývoje a zdokonalování.

6 Zdroje

- [1] BĚLOHLÁVEK, J. *EKG v akutní kardiologii: průvodce pro intenzivní péči i rutinní klinickou praxi*. 2. české vyd. Editor Pavel Klener. Překlad Eliška Potluková. Praha: Grada, 2012, 414 s. Scripta. ISBN 978-807-3452-872
- [2] STRAŠIL, Ivo. *EKG záznamník-holter*. Praktická elektronika Amatérské radio. 2014, 19(3), 13-17. ISSN 1804- 7173.
- [3] BRACKOVÁ, Michaela. *Hodnocení kvality signálů EKG* [online]. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2019. Dostupné z: https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=190908
- [4] ALGHATRIF, Majd a LINDSAY, Joseph. *A brief review: history to understand fundamentals of electrocardiography* [online], 2012. Dostupné z: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3714093/>
- [5] VÁCHA, Martin. *Srovnávací fyziologie živočichů*. Brno: Masarykova univerzita v Brně, Přírodovědecká fakulta, 2014.
- [6] Time of Care, Online Medicine Notebook. *Segments vs. Intervals in an ECG* [online]. Dostupné z: <https://www.timeofcare.com/segments-vs-intervals-in-an-ecg/>
- [7] Stránky firmy Kardio Interna s.r.o. *Vyšetření* [online]. Dostupné z: <http://www.kardio-litovel.cz/vysetreni.html>
- [8] SMITAL, Lukáš. *Vlnková filtrace elektrokardiogramů* [online]. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2013. Dostupné z: https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=69902
- [9] SÖRNMO, L a LAGUNA, P. *Bioelectrical signal processing in cardiac and neurological applications*. Boston: Elsevier Academic Press, 2005, 668 s. ISBN 01-243-7552-9.
- [10] Učebnice EKG. *Teorie EKG* [online]. Dostupné z: http://www.ucebnice-ekg.cz/index.php?option=com_content&view=article&id=36&Itemid=117
- [11] HAMAN, Petr. *Poruchy tvorby vzruchu* [online]. Výukový web EKG, Plzeň. Dostupné z: <http://www.ekg.kvalitne.cz/tvorba.htm#Supraventrikul%C3%A1rn%C3%AD%20extra%20systoly>
- [12] Wikiskripta. *Raménkové blokády* [online]. Dostupné z: https://www.wikiskripta.eu/w/Ram%C3%A9nkov%C3%A9_blok%C3%A1dy

- [13] CADOGAN, Mike. *P Wave* [online], 2021. Dostupné z: <https://litfl.com/p-wave-ecg-library/>
- [14] LACIAR, Eric. *Quantification of Ventricular Repolarization Dispersion Using Digital Processing of the Surface ECG* [online]. San Juan: National University of San Juan, 2012. Dostupné z: https://www.researchgate.net/figure/Common-types-of-noise-in-ECG-recordings-a-Baseline-wander-b-50-Hz-power-line_fig2_221923119
- [15] ZHIDONG, Zhao a YEFEI, Zhang. *SQI Quality Evaluation Mechanism of Single-Lead ECG Signal Based on Simple Heuristic Fusion and Fuzzy Comprehensive Evaluation* [online]. Hangzhou: Hangzhou Dianzi University, 2018. Dostupné z: <https://doi.org/10.3389/fphys.2018.00727>
- [16] POLIKAR, Robi. *The Wavelet Tutorial* [online]. Glassboro: Rowan University, Dostupné z: <https://web.iitd.ac.in/~sumeet/WaveletTutorial.pdf>
- [17] OBERLIN Thomas, MEIGNEN Sylvain, PERRIER Valérie. *The Fourier-based Synchrosqueezing Transform* [online], 2013. Dostupné z: <https://hal.archives-ouvertes.fr/hal-00916088/document>
- [18] Stránky MathWorks. *Detect Closely Spaced Sinusoids* [online]. Dostupné z: <https://www.mathworks.com/help/signal/ug/detect-closely-spaced-sinusoids.html>
- [19] *Convolutional Neural Networks for Visual Recognition* [online]. Dostupné z: <https://cs231n.github.io/>
- [20] Stránky MathWorks. *What Is a Neural Network* [online]. Dostupné z: <https://www.mathworks.com/discovery/neural-network.html>
- [21] BÍL, Tomáš. *Hluboké neuronové sítě pro analýzu medicínských obrazových dat* [online]. Brno: Vysoké učení technické v Brně, Fakulta informačních technologií, 2019. Dostupné z: https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=198072
- [22] *Understanding LSTM Networks* [online]. Dostupné z: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [23] Stránky MathWorks. *Long Short-Term Memory (LSTM)* [online]. Dostupné z: <https://www.mathworks.com/discovery/lstm.html>
- [24] BAI, Shaojie, KOLTER, Zico, KOLTUN, Vladlen. *An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling* [online], 2018. Dostupné z: <https://arxiv.org/pdf/1803.01271.pdf>

- [25] ZACHA, Jiří. *Konvoluční neuronové sítě pro klasifikaci objektů z LiDARových dat* [online]. Praha: České vysoké učení technické v Praze, Fakulta elektrotechnická, 2019. Dostupné z: <https://dspace.cvut.cz/bitstream/handle/10467/82351/F3-BP-2019-Zacha-Jiri-Konvolucni-neuronove-site-pro-klasifikaci-objektu-z-LiDARovych-dat.pdf>
- [26] BAI, Chenjia. *Tensorflow-TCN* [online]. Harbin: Harbin Institute of Technology, 2019. Dostupné z: https://github.com/Baichenjia/Tensorflow-TCN/blob/master/misc/Dilated_Conv.png
- [27] Stránky MathWorks. *Sequence-to-Sequence Classification Using 1-D Convolutions* [online]. Dostupné z: <https://www.mathworks.com/help/deeplearning/ug/sequence-to-sequence-classification-using-1-d-convolutions.html>
- [28] Stránky MathWorks. *Waveform Segmentation Using Deep Learning* [online]. Dostupné z: <https://www.mathworks.com/help/signal/ug/waveform-segmentation-using-deep-learning.html>
- [29] SMITAL, Lukáš, HAIDER R. Clifton, VÍTEK, Martin, LEINVEBER, Pavel, JURÁK, Pavel, NĚMCOVÁ, Andrea, SMÍŠEK, Radovan, a MARŠÁNOVÁ, Lucie, PROVAZNÍK, Ivo, FELTON, L. Christopher, GILBERT, K. Barry, HOLMES III, R. David. *Real-Time Quality Assessment of Long-Term ECG Signals Recorded by Wearables in Free-Living Conditions* [online]. Vysoké učení technické v Brně, 2020. Dostupné z: <https://ieeexplore.ieee.org/document/8970507>
- [30] TOBON, Diana; FALK, Tiago H., et al. *MS-QI: A modulation spectrum-based ECG quality index for telehealth applications*. *IEEE Transactions on Biomedical Engineering*, 2016, 63.8: 1613-1622.
- [31] LAGUNA, Pablo, ROGER G. Mark, GOLDBERGER Ary L., a MOODY George B. *A Database for Evaluation of Algorithms for Measurement of QT and Other Waveform Intervals in the ECG* [online]. *Computers in Cardiology*. Vol.24, 1997, pp. 673–676. Dostupné z: <https://physionet.org/content/qtdb/1.0.0/>
- [32] LAGUNA, Pablo, RAIMON Jané, and PERE Caminal. "Automatic detection of wave boundaries in multilead ECG signals: Validation with the CSE database." *Computers and Biomedical Research*. Vol. 27, No. 1, 1994, pp. 45–60.
- [33] NĚMCOVÁ, Andrea, SMÍŠEK, Radovan, OPRAVILOVÁ, Kamila, VÍTEK, Martin, SMITAL, Lukáš a MARŠÁNOVÁ, Lucie. *Brno University of Technology ECG Quality Database (BUT QDB)* [online]. Brno: Vysoké učení technické v Brně, 2020. Dostupné z: <https://doi.org/10.13026/kah4-0w24>
- [34] MOODY, George, MARK, Roger. *MIT-BIH Arrhythmia Database* [online], 2005. Dostupné z: <https://www.physionet.org/content/mitdb/1.0.0/>

- [35] SCHILLING, Fabian. *The Effect of Batch Normalization on Deep Convolutional Neural Networks* [online]. Stockholm: KTH Royal Institute of Technology, 2018. Dostupné z: <https://www.diva-portal.org/smash/get/diva2:955562/FULLTEXT01.pdf>
- [36] BROWNLEE, Jason. *A Gentle Introduction to Dropout for Regularizing Deep Neural Networks* [online], 2018. Dostupné z: <https://machinelearningmastery.com/dropout-for-regularizing-deep-neural-networks/>
- [37] Databáze na portálu PhysioNet. *Improving the Quality of ECGs Collected using Mobile Phones - The PhysioNet Computing in Cardiology Challenge 2011* [online]. Dostupné z: <https://physionet.org/content/challenge-2011/1.0.0/>
- [38] Zkušenosti autora diplomové práce z praxe ve firmě MDT-Medical Data Transfer, s.r.o.