



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

VYUŽITÍ NEURONOVÉ SÍTĚ PŘI DETEKCI PORUCH SRDEČNÍHO RYTMU Z EKG DAT A SIGNÁLU AKCELEROMETRU

USING OF NEURAL NETWORK FOR DETECTION OF HEART RHYTHM DISTURBANCES FROM ECG DATA
AND ACCELEROMETER SIGNAL

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Borys Aleksandrenko

VEDOUCÍ PRÁCE

SUPERVISOR

Mgr. Veronika Bulková, Ph.D., MHA.

BRNO 2024

Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Borys Aleksandrenko

ID: 240481

Ročník: 3

Akademický rok: 2023/24

NÁZEV TÉMATU:

Využití neuronové sítě při detekci poruch srdečního rytmu z EKG dat a signálu akcelerometru

POKYNY PRO VYPRACOVÁNÍ:

1) Provedte analýzu možností detekce symptomů z EKG dat ve vztahu k akcelerometrickým datům. 2) Navrhněte optimální metodiku pro analýzu vztahu EKG signálu a akcelerometru. 3) Vytvořte databázi vzorků pro trénování neuronové sítě. 4) Navrhněte neuronovou síť pro detekci symptomatických stavů ze vstupních EKG dat a akcelerometru. 5) V programovacím jazyce Python vytvořte aplikaci, jejímž vstupem bude EDF soubor a výstupem bude XML soubor obsahující detekované symptomy vč. jejich začátků a konců. 6) Provedte diskusi získaných výsledků a zhodnoťte účinnost a využitelnost řešení.

DOPORUČENÁ LITERATURA:

[1] FALASCETTI, Laura, Michele ALESSANDRINI, Giorgio BIAGETTI, Paolo CRIPPA a Claudio TURCHETTI. ECG-Based Arrhythmia Classification using Recurrent Neural Networks in Embedded Systems. *Procedia Computer Science* [online]. 2022, 207, 3479-3487 [cit. 2023-09-21]. ISSN 18770509. Dostupné z: doi:10.1016/j.procs.2022.09.406

[2] XU, Xuexiang a Hongxing LIU. ECG Heartbeat Classification Using Convolutional Neural Networks. *IEEE Access* [online]. 2020, 8, 8614-8619 [cit. 2023-09-21]. ISSN 2169-3536. Dostupné z: doi:10.1109/ACCESS.2020.2964749

Termín zadání: 5.2.2024

Termín odevzdání: 29.5.2024

Vedoucí práce: Mgr. Veronika Bulková, Ph.D., MHA.

doc. Ing. Jana Kolářová, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské 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 bakalářská práce se věnuje problematice detekce poruch srdečního rytmu ze signálů EKG a akcelerometru s využitím strojového učení. Nejprve byla provedena analýza možností detekce poruch srdečního rytmu z těchto signálů pomocí teoretické rešerše. V další části byla navržena metodika pro detekci dvou poruch rytmu: nepřiměřené sinusové tachykardie a chronotropní inkompetence. Metodika byla dodatečně doplněna adaptivní filtrací EKG signálu pomocí signálu akcelerometru. Ve třetí části práce byla vytvořena databáze vzorků pro trénování modelů strojového učení navržených v metodice. Další část obsahovala popis a realizaci modelů. V páté části práce byla v programovacím jazyce Python vytvořena aplikace pro detekci poruch srdečního rytmu pomocí navržené metodiky. Nakonec byla provedena diskuze a evaluace výsledků.

KLÍČOVÁ SLOVA

Poruchy srdečního rytmu, EKG signál, signál akcelerometru, adaptivní filtrace, skrytý Markovův model, LSTM neuronová síť, strojové učení, srdeční frekvence, Python, holter, Vivalink.

ABSTRACT

This bachelor's thesis addresses the issue of detecting heart rhythm disorders from EKG and accelerometer signals using machine learning. First, an analysis of the possibilities for detecting heart rhythm disorders from these signals was conducted through a theoretical review. In the next part, a methodology was proposed for detecting two rhythm disorders: inappropriate sinus tachycardia and chronotropic incompetence. The methodology was further supplemented with adaptive filtering of EKG signals using signals from the accelerometer. In the third part of the thesis, a database of samples was created for training machine learning models proposed in the methodology. The next section included the description and implementation of the models. In the fifth part of the thesis, an application for detecting heart rhythm disorders using the proposed methodology was developed in the Python programming language. Finally, a discussion and evaluation of the results were conducted.

KEYWORDS

Heart rhythm disorders, ECG signal, accelerometer signal, adaptive filtering, hidden Markov model, LSTM neural network, machine learning, heart rate, Python, holter, Vivalink.

ALEKSANDRENKO, Borys. *Využití neuronové sítě při detekci poruch srdečního rytmu z EKG dat a akcelerometru*. Bakalářská práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2024. Vedoucí práce: Mgr. Veronika Bulková, Ph.D., MHA.

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Borys Aleksandrenko
VUT ID autora: 240481
Typ práce: Bakalářská práce
Akademický rok: 2023/24
Téma závěrečné práce: Využití neuronové sítě při detekci poruch srdečního rytmu z EKG dat a akcelerometru

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/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autora*

*Autor podepisuje pouze v tištěné verzi.

PODĚKOVÁNÍ

Rád bych poděkoval vedoucí bakalářské práce paní Mgr. Veronice Bulkové, Ph.D., MHA. a konzultantovi pánu Ing. Romanovi Kozubíkovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci. Také děkuji Tereze Slípkové za kontrolu pravopisu v textu.

Obsah

Úvod	17
1 Detekce poruch srdečního rytmu z EKG dat ve vztahu k akcelerometrickým datům	19
1.1 Symptomy které je možné detekovat z kombinace EKG a akcelerometrických dat	19
1.1.1 Nepřiměřená sinusová tachykardie	19
1.1.2 Chronotropní inkompetence	20
1.2 Využití akcelerometrických dat pro zlepšení kvality EKG záznamů: Adaptivní filtrace pohybových artefaktů	21
2 Metodika pro analýzu vztahu EKG a akcelerometrického signálu	25
2.1 Korelační analýza mezi šumem v EKG a akcelerometrickými daty . .	25
2.2 Umělé neuronové sítě pro analýzu signálů	27
2.3 Návrh konkrétní metodiky pro analýzu a zpracování signálů EKG a akcelerometru	29
3 Výběr a příprava databáze pro trénování neuronové sítě	31
3.1 Dataset MDT	31
4 Realizace navržené metodiky	33
4.1 Model strojového učení pro určení úrovně aktivity	33
4.1.1 Stochastický proces	33
4.1.2 Markovův proces a Markovův řetězec	34
4.1.3 Skrytý Markovův model	34
4.1.4 Realizace HMM modelu v Pythonu	35
4.2 Určení úrovně aktivity	38
4.3 Rozhodovací strom pro detekci poruch rytmu	39
4.4 LSTM neuronová síť pro predikci hodnot srdeční frekvence	40
4.4.1 Realizace v Pythonu	43
4.5 BLMS filtr	46
4.5.1 Realizace v Pythonu	46
4.5.2 Určení osy akcelerometru pro použití v filtraci	47
4.5.3 Určení optimálních parametrů filtru	47
4.5.4 Výsledky filtrace	48
4.5.5 Korelační analýza pro adaptaci	49
4.5.6 Výpočet směrodatné odchylky pro adaptaci	51

5 Aplikace detekující poruchy srdečního rytmu, včetně jejich začátku a symptomů	55
6 Diskuze a evaluace výsledků	57
6.1 Analýza možností detekce poruch a symptomů srdečního rytmu z EKG a akcelerometrického signálu	57
6.2 Návrh metodiky pro analýzu vztahu EKG signálu a akcelerometru . .	57
6.3 Vytvoření databáze vzorků pro trénování modelů strojového učení . .	57
6.4 Návrh a trénování modelů strojového učení	58
6.4.1 Skrytý Markovův model a jeho evaluace	58
6.4.2 LSTM neuronová síť a její evaluace	60
6.5 Vytvoření adaptivního BLMS filtru	60
6.6 Metodika byla realizována v podobě Python aplikace	61
6.6.1 Evaluace detekce nepřiměřené sinusové tachykardie a chronotropní inkompetence	62
Závěr	65
Literatura	67
Seznam symbolů a zkratk	71
Seznam příloh	73
A Tabulky	75
B Obsah elektronické přílohy	77

Seznam obrázků

1.1	Schema definici nepřiměřené sinusové tachykardie.	20
1.2	Konceptuální struktura adaptivního filtračního systému[19]	22
1.3	blokové schéma struktury filtru založeného na adaptivním algoritmu BLMS[19]	23
2.1	Spektrum pro interpretaci korelačního koeficientu[22]	26
2.2	Korelační analýza EKG signálu a signálu z akcelerometru. S dýcháním.[23]	26
2.3	Korelační analýza EKG signálu a signálu z akcelerometru. Bez dýchání.[23]	26
2.4	Vizualizace plně propojené dopředné umělé neuronové sítě se dvěma skrytými vrstvami[26].	28
2.5	Autoenkodér extrahuje z dat skryté informace, které jsou užitečné pro rekonstrukci surových dat a lze je použít v dalších algoritmech strojového učení pro predikci.[27]	29
2.6	Blokové schéma metodiky pro analýzu a zpracování signálů EKG a akcelerometru.	30
3.1	Specifikované umístění přístroje Vivalink	31
3.2	Vzorová data naměřená přístrojem Vivalink	32
4.1	Průběh trénování HMM modelu	35
4.2	Průběh trénování HMM modelu (A-spánek, B-bdění, C-vysoká fy- zická aktivita; 1-5 jsou nominální kategorie úrovně aktivity)	37
4.3	Průběh trénování HMM modelu	37
4.4	Subjekt se nachází v spánku? 1 - Ano, 0 - Ne. Každý graf pro odlišný subjekt	38
4.5	Určení úrovně aktivity z označeného testovacího datasetu	39
4.6	Závislost tepu na úrovni aktivity při A - vysoké aktivitě, B - nízké aktivitě.	39
4.7	Výsledky detekce chronotropní inkompetence a NST	40
4.8	Zjednodušené blokové schéma programu pro detekci nepřiměřené si- nusové tachykardie a chronotropní inkompetence	41
4.9	Rekurentní jednotka skryté vrstvy v RNN neuronové síti[38]	42
4.10	Komplexní jednotka skryté vrstvy v LSTM neuronové síti[38]	42
4.11	Zjednodušené blokové schéma pro popis zvolené architektury LSTM neuronové sítě	44
4.12	Učící křivka LSTM neuronové sítě	45
4.13	Blokové schéma běhu BLMS filtrování	47
4.14	Výběr ose akcelerometru pro filtrování EKG	48
4.15	Analýza různých hodnot parametrů filtru BLMS	49
4.16	Výsledky filtrace	50

4.17	Srovnání morfologie EKG před a po filtraci	50
4.18	Výsledky korelační analýzy mezi signálem EKG a akcelerometru . . .	51
4.19	Výpočet směrodatné odchylky a rozptylu s oknem 100 vzorků	52
4.20	Demonstrace aktivace BLMS filtrace při dosažení prahové hodnoty směrodatné odchylky	53
5.1	Blokové schéma finálního programu pro určení poruch srdečního rytmu	55
6.1	Srovnání reálné srdeční frekvence (HR) v průběhu dne, srdeční frek- vence predikované LSTM modelem a náhodně generované srdeční frekvence	60
6.2	Výsledky určení R-píků a stanovení srdeční frekvence s filtrací a bez filtrace	61
6.3	Poincarého mapy RR intervalů pro denní záznam EKG s BLMS fil- trací a bez BLMS filtrace	62

Seznam tabulek

3.1	Specifikace EKG Holter zařízení	32
A.1	Algoritmy používané pro odstranění pohybových artefaktů[20]	75

Úvod

V současné době se zvyšující se dostupností nositelných technologií a monitorů biofyzikálních signálů z člověka se nabízí nové možnosti pro monitorování a diagnostiku zdravotních stavů. Tato práce se zabývá průzkumem a analýzou vztahu mezi elektrokardiografickými (EKG) daty a daty získanými z akcelerometrů, se zaměřením na detekci poruch srdečního rytmu.

Hlavním stanoveným cílem této práce je zkoumat, jak lze kombinovat EKG a akcelerometrická data pro identifikaci specifických poruch srdečního rytmu, jako jsou nepřiměřená sinusová tachykardie a chronotropní inkompetence. Kromě toho se práce věnuje využití akcelerometrických dat pro zlepšení kvality EKG záznamů prostřednictvím adaptivní filtrace artefaktů.

Metodologický přístup zahrnuje podrobnou analýzu EKG a akcelerometrických signálů, včetně statistické analýzy, a využívá pokročilé metody strojového učení, zejména neuronových sítí, pro analýzu vztahů mezi oběma typy dat. K dosažení těchto cílů byla navržena inovativní metodika pro analýzu a zpracování těchto signálů, připravena specifická databáze, pomocí které byly následně trénovány navržené modely, realizován a otestován filtr, který filtruje EKG pouze pomocí signálu z akcelerometru. Na základě všech metodologických postupů byl vytvořen program v programovacím jazyce Python. Na konci práce byla provedená evaluace výsledků a diskuze.

1 Detekce poruch srdečního rytmu z EKG dat ve vztahu k akcelerometrickým datům

V oblasti detekce poruch rytmu z EKG dat s využitím akcelerometru lze identifikovat dva hlavní přístupy. První z nich spočívá v analýze kombinace těchto dvou typů signálů, což umožňuje detekovat stavy, jako je například apnoe[1]. Tato práce se zaměřuje na inovativní aplikaci této kombinace v detekci nepřiměřené sinusové tachykardie a chronotropní inkompetence, oblastí, kde dosud chybí dostatečný výzkum integrace těchto signálů. Druhým přístupem je adaptivní filtrace pohybových artefaktů v EKG datech pomocí informací z akcelerometru. Cílem této práce je propojit oba tyto přístupy a prozkoumat jejich synergetický potenciál v kontextu vybraných kardiovaskulárních symptomů.

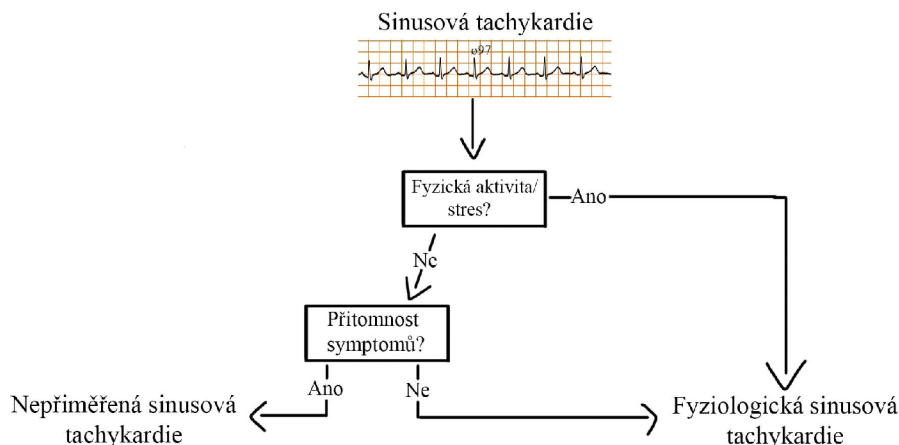
1.1 Symptomy které je možné detekovat z kombinace EKG a akcelerometrických dat

1.1.1 Nepřiměřená sinusová tachykardie

Nepřiměřená sinusová tachykardie je definovaná jako zvýšená srdeční frekvence vyšší než 100 tepů za minutu v klidu nebo při minimální námaze, která je neadekvátní úrovni aktivity nebo stresu, a je detekovaná u těch, kteří má související symptomy[3],[5]. Z definice vyplývá, že detekce tohoto stavu by mohla být možná, pokud by bylo možné extrahovat úroveň aktivity subjektu ze signálu akcelerometru a porovnat ji s frekvencí srdečního rytmu určenou z EKG.

Typické symptomy nepřiměřené sinusové tachykardie zahrnují: dušnost při menší aktivitě, pocit bušení srdce, závratě, bolest na hrudi a únava. Průměrná srdeční frekvence z 24hodinového záznamu je více než 90 za minutu. Klidové srdeční frekvence jsou často v normálních rozmezích. Epidemiologická data jsou velmi omezená. Výskyt v populaci se tak pohybuje mezi 1.16 % ze studií s 604 subjekty[7] a 4.98 % ze studií s 1265 subjekty[8]. Tento stav se převážně projevuje u mladých žen[6].

Existuje široké spektrum sekundárních příčin sinusové tachykardie, které by měly být vyloučené pro správné diagnostikování, mezi které patří: úzkost, anémie, snížený objem tekutin, horečky, plicní embolie, srdeční selhání, sepse či působení léků. Srdeční frekvence při nepřiměřené sinusové tachykardii není nutně trvale zvýšena. Významné zvýšení frekvence nastává při menší aktivitě a změnách polohy, někdy může nastat z neznámých důvodů[3]. Na rozdíl od náhlého začátku u fokální síněvé tachykardie, zvýšení srdeční frekvence při nepřiměřené sinusové tachykardii obvykle



Obr. 1.1: Schema definici nepřiměřené sinusové tachykardie.

probíhá postupně, zvýší se během 30 sekund až několika minut[6]. Kromě výše zmíněných symptomů byly také popsány komorbidity, které výrazně zhoršují kvalitu života. Nejčastější komorbidity jsou deprese (25,6 %) a úzkosti (24,6 %)[4]. Kvůli stejné morfologii EKG s fyziologickou sinusovou tachykardií je detekování nepřiměřené sinusové tachykardie založené na jedné proměnné: srdeční frekvenci[3]. Evaluace syndromu obvykle zahrnuje holterovské monitorování a zátěžový test[3]. Mezi cíle této práce patří pokus o sjednocení holterovského monitorování a zátěžového testu do jednoho měření.

1.1.2 Chronotropní inkompetence

Chronotropní inkompetence, původně označovaná jako "nepřiměřená bradykardie"[9], je symptom a stav, kdy dochází k nedostatečnému zvýšení srdeční frekvence v reakci na zvýšenou fyzickou námahu a metabolické požadavky[10]. Chronotropní inkompetence je typická pro pacienty s vrozenou vadou srdeční a také může být projevem ischemické choroby srdeční[10].

Kvalita života je významně ovlivněna schopností vykonávat fyzickou práci[11], která je umožněna zvýšením příjmu kyslíku[12]. U zdravých osob se během intenzivního aerobního cvičení příjem kyslíku zvyšuje přibližně čtyřnásobně[12]. Tento nárůst je výsledkem 2,2-násobného zvýšení srdeční frekvence, 1,3-násobného navýšení objemu srdečního výdeje a 1,5-násobného zvýšení rozdílu v obsahu kyslíku mezi arteriální a žilní krví[12]. Z toho vyplývá, že nejvýznamnějším faktorem pro dlouhodobou aerobní výkonnost je zvýšení srdeční frekvence[13]. Proto není překvapující, že chronotropní inkompetence může být primární příčinou nebo významným fak-

torem v případě vážné intolerance k fyzické práci[14]. Kvůli absenci konzistentní metodologie pro stanovení chronotropní inkompetence různé zdroje uvádí různou prevalenci tohoto stavu mezi subjekty. V hodnocení více než 1500 pacientů s chronotropní inkompetencí, kteří byli odkázáni na implantaci kardiostimulátoru, vedlo použití pěti různých definic chronotropní inkompetence k prevalenci od 34 % do 87 % [17]. Chronotropní inkompetence byla nejčastěji diagnostikována, když srdeční frekvence nesplnila náhodně stanovené procento (buď 85 %, 80 % nebo méně často 70 %) z APMHR (Věkem předpovězená maximální tepová frekvence) získané během postupného dynamického cvičebního testu[14]. V rámci této práce a zkoumaných signálů by bylo možné detekovat chronotropní inkompetenci z hodnot srdeční frekvence, určených ze signálu EKG, a úrovně zátěže subjektu, určené ze signálu akcelerometru.

Nejsložitější rovnice pro stanovení chronotropní inkompetence byla navržena Wilkkofem a kol.[15]

$$AMPHR = \frac{(220 - věk - HR_{klidové}) \times (METS_{klidové} - 1)}{(METS_{pikové} - 1)} + HR_{klidové} \quad (1.1)$$

Protože v rovnici od Wilkkofa a kol. je použita hodnota spotřeby kyslíku (METS), pro účely této práce bude lepší použít rovnici navrhnoutou Gulati a kol.,[16]

$$AMPHR = 206 - 0.88 \times věk \quad (1.2)$$

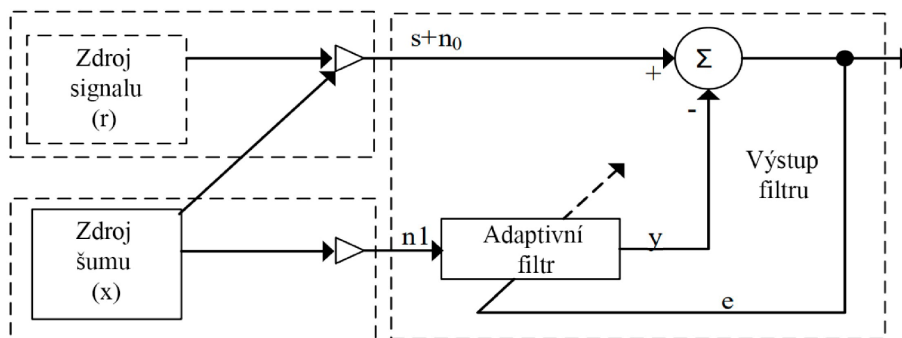
a rovnici navrhnoutou Brawnerem a kol. [18], pro pacienty s koronárními srdečními nemocemi, kteří užívají terapii s β -adrenergními blokátory.

$$AMPHR = 164 - 0.7 \times věk \quad (1.3)$$

Pro účely této práce bude jako práh pro stanovení chronotropní inkompetence stanoven 80 % AMPHR.

1.2 Využití akcelerometrických dat pro zlepšení kvality EKG záznamů: Adaptivní filtrace pohybových artefaktů

Pohybový artefakt představuje typ interferenčního šumu, který je začleněn do elektrokardiogramu (EKG) v důsledku pohybu elektrody EKG. Konkrétně jde o situaci kdy pohyb elektrody indukuje deformace v oblasti kůže v místě umístění elektrody, což sekundárně vyvolává změny v elektrických charakteristikách této oblasti kůže. Tyto změny se následně projevují v záznamu EKG jako pohybový artefakt. Tento




Obr. 1.2: Konceptuální struktura adaptivního filtračního systému[19]

artefakt může v EKG vytvářet signály s velkou amplitudou, které mohou připomínat P, QRS a T vlny. Je běžný zejména při ambulantním monitorování a zátěžovém testu. Z klinického hlediska může pohybový artefakt vést k chybné diagnóze a následně i ke zpožděným nebo nevhodným rozhodnutím o léčbě.[19]

Existuje řada metod používaných pro odstranění pohybových artefaktů v EKG, nejběžnější z nich jsou popsány v tabulce A.1 (viz přílohu k práci). Každá metoda má svoje nevýhody. V posledních letech se adaptivní filtrace stala klíčovou metodou pro zpracování a analýzu EKG signálů[20]. Adaptivní filtr představuje sofistikovaný typ filtru, vyznačující se použitím adaptivního algoritmu pro přizpůsobení svých parametrů a struktury, který reaguje na proměnlivost okolního prostředí. Ačkoli jeho základní struktura zůstává stabilní, klíčem k jeho účinnosti jsou časově proměnlivé koeficienty. Ty jsou průběžně upravovány adaptivním algoritmem tak, aby se automaticky a plynule přizpůsobovaly aktuálním charakteristikám signálu, čímž zajišťují optimální odezvu. Největším přínosem adaptivního filtru je schopnost efektivně operovat v neznámém prostředí a přizpůsobovat se proměnlivým vlastnostem vstupních signálů. Díky adaptivním filtrům lze efektivně minimalizovat pohybové artefakty a z šumu vyčlenit užitečné informace. Klíčovým principem adaptivního filtru je využití adaptivního algoritmu spolu s transversálním filtrem pro iterativní upravování parametrů filtru a provádění dynamického filtrování proměnlivých signálů.[19] Obrázek 1.2 znázorňuje strukturu systému s adaptivním filtrem. Tento systém zahrnuje dva vstupní signály. Prvním je původní vstup r , který obsahuje efektivní EKG signál s a šumový signál n_0 . Druhým je referenční vstup x , který není korelovan s signálem s . Referenční signál x je veden do filtru, kde dochází k úpravě jeho vah, aby byl získán výstupní signál y . Chybový signál e adaptivního filtračního systému lze pak formulovat pomocí efektivního EKG signálu s , šumového signálu n_0 a výstupního signálu filtru y následujícím způsobem:

$$e = s + n_0 - y \quad (1.4)$$



Obr. 1.3: blokové schéma struktury filtru založeného na adaptivním algoritmu BLMS[19]

Výkon nebo energie tohoto signálu je vypočítána umocněním rovnice 1.4

$$e^2 = (s + n_0 - y)^2 = (s + n_0)^2 - 2y(s + n_0) + y^2 = (n_0 - y)^2 + s^2 + 2sn_0 - 2ys \quad (1.5)$$

Vzhledem k tomu, že signál s a šum n_0 nejsou korelované, střední kvadratická chyba (MSE) se rovná:

$$E[e^2] = E[(n_0 - y)^2] + E[s^2] \quad (1.6)$$

Adaptivní filtr typu LMS (Least mean squares) extrahuje signál nebo eliminuje šum iterativní minimalizací střední kvadratické chyby (MSE) mezi původním a referenčním vstupem. Je třeba maximálně potlačit šum v původním signálu, aby hodnota $E[e^2]$ dosáhla minima, zároveň musí být zachována co nejvyšší energie účinného signálu EKG. V této práci bude využito modifikace adaptivního filtru LMS. Filtr typu BLMS (Block Least Mean Square), neboli Blokovaný algoritmus nejmenších čtverců, prokázal vyšší účinnost než LMS [19].

Na obrázku 1.3 je znázorněno blokové schéma struktury filtru založeného na adaptivním algoritmu BLMS. Jako původní vstup je použit elektrokardiografický signál r , který obsahuje pohybové artefakty n_0 a účinný EKG signál s . Jako referenční signál x bude použit signál získaný z tříosého akcelerometru. Koeficient filtrace je w a výstup adaptivního filtru je $y(n) = xw^T$. Na rozdíl od koeficientů filtru tradičního algoritmu LMS, kde jsou koeficienty přepočítány a aktualizovány pro každý vzorek signálu, algoritmus BLMS aktualizuje váhové koeficienty po blocích. Implementace adaptivního algoritmu filtrace EKG signálu na základě BLMS obnáší následující kroky:

- Nastavování parametrů: L je délka bloku, μ je velikost kroku.
- Inicializace: vektor vah je inicializován, $w(0) = 0$.
- Výpočet: Na rozdíl od klasického LMS algoritmu, kde se úpravy provádějí po každém jednotlivém vzorku, v algoritmu BLMS se úpravy váhových koeficientů filtrů aplikují po blocích dat. Po zpracování každého bloku se tak váhové

koeficienty aktualizují hromadně, což znamená, že se adaptace neodehrává pro každý vzorek zvlášť, ale pro skupinu vzorků v bloku. Tímto způsobem se váhové koeficienty filtrů postupně upravují od jednoho bloku k dalšímu. Vektor váhových koeficientů se aktualizuje z bloku na blok následujícím způsobem:

$$w(k+1) = w(k) + \mu \sum_{i=0}^{L-1} x(kL+i)e(kL+i) \quad (1.7)$$

Významným rysem blokového algoritmu BLMS je kombinace následujících odhadů gradientního vektoru ve svém návrhu.

$$\nabla(k) = -\frac{1}{L} \sum_{i=0}^{L-1} x(kL+i)e(kL+i) \quad (1.8)$$

Algoritmus BLMS lze zapsat jako následující rovnici podle rovnice (1.8)

$$w(k+1) = w(k) - \mu_B \cdot \nabla(k) \quad (1.9)$$

$$\mu_B = L \cdot \mu \quad (1.10)$$

μ_b lze považovat za efektivní velikost kroku algoritmu BLMS. Aktuální chybový signál e lze vypočítat podle vstupu,

$$e(kL+i) = r(kL+i) - y(kL+i) \quad (1.11)$$

kde $r(kL+i)$ je původní EKG signál zarušený pohybovými artefakty a $y(kL+i)$ je filtrovaný výstupní signál v $n = kL+i$, daný jako

$$y(kL+i) = w^T(k)x(kL+i) \quad (1.12)$$

Výše uvedené kroky se mají opakovat pro každou iteraci. V práci D. Berwal a kol. byl počet iterací stanovený jako délka vstupního signálu[19].

2 Metodika pro analýzu vztahu EKG a akcelerometrického signálu

2.1 Korelační analýza mezi šumem v EKG a akcelerometrickými daty

Korelace slouží k určení míry závislosti mezi dvěma proměnnými. Korelační koeficient je měřítkem pro kvantifikaci této míry závislosti proměnných. Obvykle se v aplikacích používají dva typy korelačních koeficientů, a to Pearsonův a Spearmanův korelační koeficient.[21] Hodnoty korelačního koeficientu se pohybují v rozmezí od -1 do +1. Korelační koeficient +1 naznačuje, že dvě proměnné jsou dokonale závislé kladným (lineárním) způsobem, zatímco korelační koeficient -1 ukazuje, že dvě proměnné jsou dokonale spojeny negativním (lineárním) způsobem. Korelační koeficient nula naopak naznačuje, že mezi zkoumanými proměnnými neexistuje lineární vztah. Příklady těchto závislostí jsou znázorněny na obrázku 2.1.[22] Korelační analýza obvykle začíná vytvořením bodového grafu, kde jedna proměnná je reprezentována na ose X a druhá na ose Y, aby bylo možné vizuálně posoudit povahu jejich vztahu[22]. Výhodou bodového grafu je, že je jednoduchý na vytvoření, nemá matematický charakter a není ovlivněn případnými extrémními hodnotami v datech. Také nám okamžitě ukáže, zda jsou v datech odlehlé hodnoty, nebo zda je vztah mezi proměnnými skutečně nelineární nebo ne zcela lineární. Obvykle se skrz body na bodovém grafu vede čára, aby se určila linearita vztahu. Tato čára se nazývá regresní čára nebo čára nejmenších čtverců, protože je určena tak, aby součet čtverců vzdáleností všech datových bodů od čáry byl co nejnižší[22]. Nevýhodou bodového grafu je, že nám neposkytne jednu konkrétní hodnotu, která by nám pomohla pochopit, zda mezi zkoumanými proměnnými existuje korelace, a proto je nutné přejít k dalšímu kroku a vypočítat korelační koeficient. Pro výpočet Pearsonova korelačního koeficientu musí být splněny tři předpoklady:


- Vztah mezi proměnnými je lineární.
- Proměnné jsou nezávislé jedna na druhé.
- Proměnné mají normální rozdělení.

Pro výpočet Pearsonova korelačního koeficientu se dá použít následující vzorec:

$$R = \frac{n(\sum XY) - (\sum X)(\sum Y)}{\sqrt{[n \sum X^2 - (\sum X)^2][n \sum Y^2 - (\sum Y)^2]}} \quad (2.1)$$

Kde n je počet vzorků, x je hodnota první proměnné a y je hodnota druhé proměnné.

Výzkumný tým vedený D.K. Hanem provedl korelační analýzu mezi pohybovým šumem v EKG signálu a signálem z akcelerometru[23]. Analýza zahrnovala 13 typů




Obr. 2.1: Spektrum pro interpretaci korelačního koeficientu[22]


pohybů, včetně běhu, chůze, sezení, ležení a dalších. Metodologie analýzy využívala výpočet velikosti signálového vektoru (SVM), který se počítá jako euklidovská norma podle následujícího vzorce[24],

$$SVM = \sqrt{x^2 + y^2 + z^2} \quad (2.2)$$

kde x , y a z jsou komponenty signálu akcelerometru odpovídající jednotlivým osám. Transformace původního trojrozměrného signálu z akcelerometru na SVM umožňuje minimalizovat rotační složku signálu[24]. Výsledky této analýzy jsou znázorněny na obrázcích 2.2 a 2.3. Hodnoty korelačních koeficientů byly 0,7168 při dýchání a 0,9213 bez dýchání. Bylo zjištěno, že vyšší úroveň tělesné aktivity vedla k zesílení akcelerace a větší variabilitě základní linie EKG signálu. Přerušování dýchání mělo za následek zvýšení hodnoty korelačního koeficientu. Bylo to způsobeno tím, že vrchol R ve sig-



Obr. 2.2: Korelační analýza EKG signálu a signálu z akcelerometru. S dýcháním.[23]



Obr. 2.3: Korelační analýza EKG signálu a signálu z akcelerometru. Bez dýchání.[23]


nálu EKG nebyl ovlivněn dýcháním, na rozdíl od fluktuace základní linie způsobené pohybem subjektu[23]. V této práci by mohla být korelační analýza využita pro určení okamžitých hodnot úrovně rušení EKG signálu, které je způsobeno pohybem pacienta, a nikoli jinými zdroji rušení.

2.2 Umělé neuronové sítě pro analýzu signálů

Stručně řečeno, umělé neuronové sítě jsou inspirovány spojením neuronů a strukturami, které se nacházejí v lidském mozku. Umělé neuronové sítě se skládají z vstupní vrstvy, několika skrytých vrstev a výstupní vrstvy (viz obr. 2.4). Každá vrstva obsahuje několik umělých neuronů, které jsou typicky propojeny s neurony v další vrstvě (toto se obvykle označuje jako dopředná síť) prostřednictvím tzv. vah, které napodobují axony a dendrity spojující mozkové buňky. Počet neuronů ve vstupní vrstvě je obvykle stejný jako počet vstupních atributů, zatímco počet neuronů ve výstupní vrstvě je obvykle roven počtu tříd v případě problému klasifikace, například zdravých a nemocných pacientů. Zvýšením počtu skrytých vrstev a neuronů v každé skryté vrstvě síť získává větší schopnost řešit složitější nelineární problémy. Nicméně síť se stává složitější na optimalizaci a trénink[25]. Umělé neuronové sítě s mnoha skrytými vrstvami se obvykle označují jako hluboké neuronové sítě. Různé specializované architektury neuronových sítí již byly pro aplikaci v medicíně vyvinuty. V poslední době začaly modely založené na hlubokém učení překonávat tradiční metody strojového učení v široké škále úloh a někdy dokonce převyšují i výkony člověka. Mezi příklady patří rekurentní neuronové sítě, včetně neuronových sítí s dlouhou krátkodobou pamětí (LSTM), které jsou ideální pro zpracování sekvenčních časových dat. Naopak konvoluční neuronové sítě se osvědčily jako výkonný nástroj pro složité úlohy zpracování signálů a obrazů, jako je například automatické stanovení stadia nádoru na základě obrazových dat.[26]

Umělé neuronové sítě lze kategorizovat do tří základních typů. Prvním je učení s učitelem (supervised learning), které vyžaduje přípravu dvou souborů dat – vstupních dat, která projdou neurony, a jejich požadované výstupní ohodnocení (labels), jež popisují kategorii nebo hodnotu výstupních dat (například rozdíl mezi normálním stavem a rakovinou nebo mezi přežitím a smrtí). Učení s učitelem se snaží na základě těchto požadovaných výstupů nalézt vzorec, kde výstupem je buď kategorie (klasifikační problém) nebo konkrétní hodnota (regresní problém). Oproti tomu učení bez učitele (unsupervised learning) je algoritmus, který bez použití označených dat odhaluje skryté vzory přímo v datech. Příkladem mohou být shlukovací algoritmy, jako jsou k-means nebo hierarchické shlukování, které rozdělují data do skupin (počet skupin je obvykle definován výzkumníkem) na základě jejich rozložení. Posledním typem je posilovací učení (reinforcement learning), které se zaměřuje na vytváření optimální strategie pro řešení specifických problémů v rámci výpočetně vytvořeného prostoru, a to metodou "pokus, omyl".[27]

Strojové učení, obzvláště v oblasti umělých neuronových sítí, přináší řadu výhod pro analýzu dat v medicíně. Jedním z klíčových přínosů většiny modelů strojového učení je jejich schopnost pracovat s daty bez předpokladů o jejich rozložení, jako je

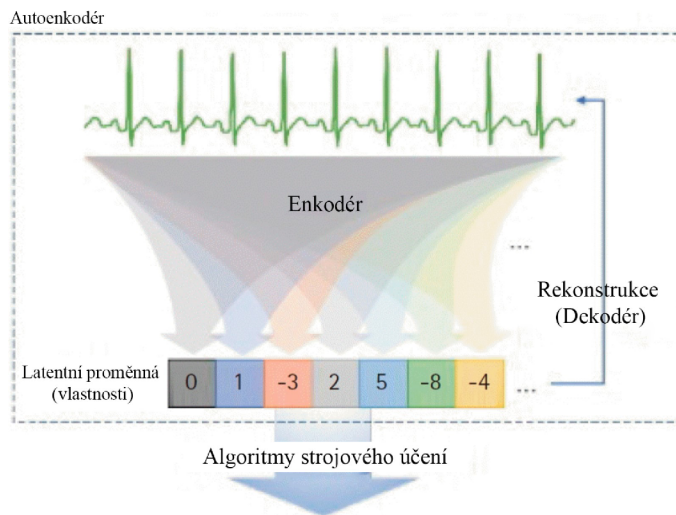


Obr. 2.4: Vizualizace plně propojené dopředné umělé neuronové sítě se dvěma skrytými vrstvami[26].

například normální distribuce. Díky použití regularizace v mnoha přístupech strojového učení jsou tyto modely schopny dobře zvládat data s vysokým šumem a velkými rozptyly, přestože menší šum je vždy lepší[26]. Složitější modely strojového učení jsou schopny identifikovat složité, mnohorozměrné a nelineární vzory, které nemusí být na první pohled zřejmé ani pro lidské experty, ani pro jednoduché lineární modely.

Nicméně strojové učení má také svá omezení. Schopnost rozpoznávat komplexní nelineární vzory může vést k obtížnější interpretaci oproti jednoduchým lineárním modelům, což často vede k označení těchto modelů jako "black box". Taky je důležité se vyvarovat přeučení modelů na trénovacích datech, což by snížilo jejich schopnost generalizace. Obecně, čím je model složitější, tím vyšší je riziko přeučení, což je zvláště pravdivé pro hluboké neuronové sítě s velkým počtem parametrů. Kromě toho mohou modely také trpět nedostatečným učením, což se projevuje sníženou přesností jak v trénovacích, tak v testovacích datech [28].

Ve studii Dukyong Yoon a kol. byly popsány [27] různé metodiky pro extrakci skrytých informací z biosignálů s použitím hlubokých neuronových sítí. Na rozdíl od standardních neuronových sítí hluboké neuronové sítě nevyžadují tak intenzivní předběžnou analýzu a extrakci charakteristik ze signálů. Hluboké neuronové sítě přijímají surová data jako vstup, samy extrahují relevantní vlastnosti z těchto dat a učí se rozpoznávat vzory bez potřeby zásahu či předzpracování dat člověkem. Jedna z architektur schopná extrakce vlastností se nazývá autoenkodér. Autoenkodér je typem architektury umělé neuronové sítě, který se skládá z enkodéru, který komprimuje původní surová data na menší velikost, a dekodéru, který obnovuje komprimované informace do původních dat (Obr. 2.5). Je klasifikován jako model s učením bez učitele, protože jsou potřeba pouze původní data bez informací o výstupu. Jde o model schopný reprezentací ve smyslu identifikace vnitřní struktury dat a extrakce



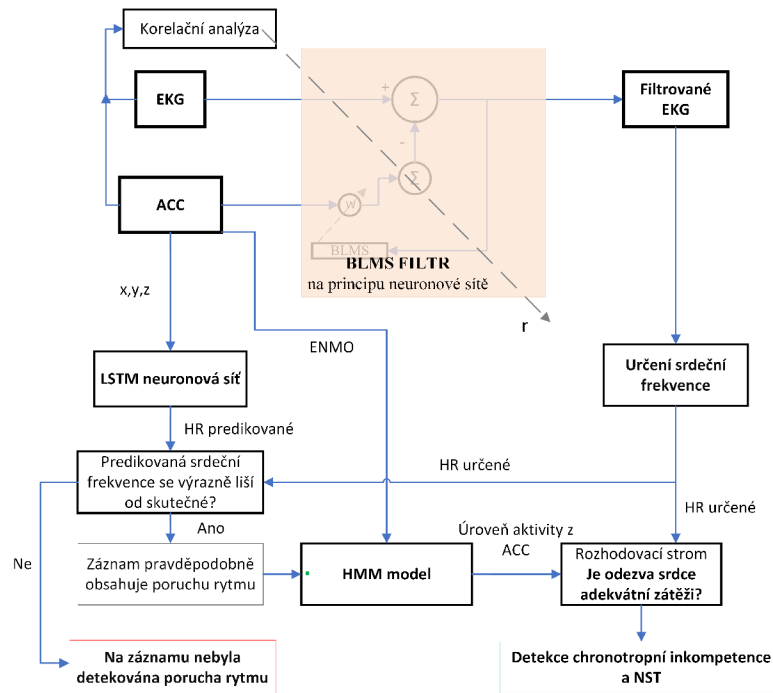
Obr. 2.5: Autoenkodér extrahuje z dat skryté informace, které jsou užitečné pro rekonstrukci surových dat a lze je použít v dalších algoritmech strojového učení pro predikci.[27]

vlastností z nich. Identifikace klíčových informací a jejich komprese do menších rozměrů je podobná tradičním metodám snižování dimenzí, jako je analýza hlavních komponent, nicméně autoenkodér má výhodu v reprezentaci komplexnějších datových prostorů prostřednictvím nelineárních funkcí. Autoenkodér se snaží naučit se minimalizovat chybu rekonstrukce, která představuje rozdíl mezi původními daty X a rekonstruovanými daty X' , což je výstup z dekodéru. Informace komprimované enkodérem jsou latentní proměnnou (h). Pokud jsou původní data obnovena s pomocí latentní proměnné menší velikosti, než mají původní data, znamená to, že enkodér identifikoval vzor nebo vnitřní strukturu dat a extrahoval hlavní vlastnosti. V takovém případě lze latentní proměnnou extrahovanou enkodérem použít jako vstupní data pro další modely strojového učení, jako je shlukování nebo klasifikace[27].

Konkrétní typy a architektury neuronových jsou navržena v dalších kapitolách.

2.3 Návrh konkrétní metodiky pro analýzu a zpracování signálů EKG a akcelerometru

Na obrázku 2.6 je zobrazeno navržené blokové schéma metodiky pro analýzu a zpracování signálů EKG a akcelerometru. Tato metodika představuje kombinaci metod popsaných v předchozích kapitolách. Vstup tvoří dva signály: EKG, získaný z EKG holteru, a ACC, pocházející z akcelerometru. EKG a ACC signály vstupují do BLMS filtru, který adaptivně filtruje EKG signál na základě informací z ACC



Obr. 2.6: Blokové schéma metodiky pro analýzu a zpracování signálů EKG a akcelerometru.


signálu. BLMS filtr je řízen výstupem korelační analýzy v podobě korelačního koeficientu r . Tento filtr filtruje signál na základě stanoveného prahu hodnoty korelačního koeficientu. Pokud je korelační koeficient mezi šumem v EKG signálu a ACC signálem nízký, znamená to, že šum není způsoben pohybem pacienta a aplikace BLMS filtru pro odstranění pohybových artefaktů není nutná. Naopak vysoká hodnota r naznačuje, že šum je pohybový, a filtrace je požadována. Výstupem z BLMS filtru je filtrovaný EKG signál, který postupuje do bloku pro určení srdeční frekvence. Signál z akcelerometru (ACC) je nejprve zpracován neuronovou sítí LSTM, jejímž cílem je predikovat srdeční frekvenci na základě tohoto signálu. Predikovaná srdeční frekvence je následně porovnávána se srdeční frekvencí určenou. Pokud se tyto dvě hodnoty liší více, než je stanovená mez, naznačuje to možný výskyt poruchy srdečního rytmu. Pro určení, o jakou poruchu rytmu se jedná, se aktivují další bloky zpracování signálu. Jedním z těchto bloků je HMM model, který přijímá signál z akcelerometru transformovaný do 1D podoby (kap. 4.1.4) a určuje úroveň aktivity subjektu. Tato úroveň aktivity spolu s hodnotou srdeční frekvence vstupuje do rozhodovacího stromu. Cílem rozhodovacího stromu je určit, zda je srdeční odezva adekvátní zátěži a detekovat stavy, jako jsou chronotropní inkompetence a nepřiměřená sinusová tachykardie (NST).

3 Výběr a příprava databáze pro trénování neuronové sítě

Pro účely trénování modelů strojového učení zaměřených na detekci chronotropní inkompetence a nepřiměřené sinusové tachykardie (NST) byl vytvořen dataset. Data byla sbírána od pacientů, kteří nosili EKG holtery nabízené firmou MDT. Mezinárodní centrum pro telemedicínu, nestátní zdravotnické zařízení, nabízí tyto přístroje, provádí hodnocení EKG a poskytuje podporu pacientům po celou dobu monitorování.

3.1 Dataset MDT

Pro účely detekce chronotropní inkompetence a nepřiměřené sinusové tachykardie byl vytvořen dataset s kombinacemi EKG a akcelerometrického signálu. Data byla pořízena pomocí přístrojů Vivalink vv330 a vv350. Jedná se o jednosvodový EKG záznamník holterovského typu. Tabulka 3.1 uvádí technické specifikace přístroje. Umístění přístroje na těle bylo specifikováno a každý subjekt byl poučen formou textového a video návodu (Obr.3.1). K vytvoření daného datasetu byl napsán pro-




Obr. 3.1: Specifikované umístění přístroje Vivalink

gramový skript v jazyce PHP. Programový skript lze najít v přílohách práce. Vzhledem k tomu, že data získaná z přístroje Vivalink jsou archivována ve formátu JSON

EKG Holter	Vivalink VV330/VV350
Maximální f_{vz} EKG	128 Hz
Maximální f_{vz} ACC	5 Hz
Maximální počet svodů	1
Interface pro přenos dat	Bluetooth
Datový formát	JSON

Tab. 3.1: Specifikace EKG Holter zařízení

na serverech společnosti MDT, bylo nezbytné implementovat skript pro syntaktickou analýzu (parsing) těchto dat s cílem vytvořit příslušný dataset. Dataset obsahuje 7 atributů: x, y, z osy akcelerometru (v jednotkách $g \cdot 1000$), časové značky, EKG signál (v milivoltech) a stanovená srdeční frekvence. Zahrnuje 80 dní záznamů z 10 různých přístrojů, přičemž každý den obsahuje 86 000 řádků (jeden řádek = jedna sekunda). Celková velikost datasetu je 5.54 GB a je uložen ve formátu CSV. Vzhledem k tomu, že se jedná o soukromý dataset společnosti MDT s citlivými anonymizovanými údaji budou představeny jenom vzorová data naměřená na přístroji Vivalink, která nespádají do datasetu. Vzorová data jsou prezentována v podobě grafů (Obr.3.2).



Obr. 3.2: Vzorová data naměřená přístrojem Vivalink

4 Realizace navržené metodiky

4.1 Model strojového učení pro určení úrovně aktivity

Úkolem první neuronové sítě je stanovit úroveň aktivity subjektu z neanotovaného signálu akcelerometru. Pro tenhle účel bylo rozhodnuto použít Skrytý Markovův model (angl. HMM). Jedná se o model, u kterého se předpokládá, že modelovaný systém je Markovovým procesem s neznámými parametry. Úlohou modelu je určit skryté parametry z pozorovaných dat. Řada technik strojového učení založených na skrytých Markovových modelech byla úspěšně aplikována na různé úkoly včetně rozpoznávání řeči, optického rozpoznávání znaků, výpočetní biologie, a stala se základním nástrojem v bioinformatice. Díky jejich robustnímu statistickému základu, konceptuální jednoduchosti a adaptabilitě jsou přizpůsobitelné pro různorodé klasifikační problémy[29]. Hlavní důvod pro výběr tohoto modelu je jeho schopnost k učení bez učitele[30]. Byl tak nejlepší volbou pro výše popsaná neanotovaná data z akcelerometru.

4.1.1 Stochastický proces

Základní myšlenka modelování procesu spočívá ve vytvoření modelu procesu založeného na souboru sekvencí událostí, které jsou typicky generovány samotným procesem. Následně lze tento model použít také k odhalení vlastností procesu nebo k předpovídání budoucích událostí na základě minulé historie. Z obecného hlediska lze model použít k třem hlavním účelům: popisu detailů procesu, predikci jeho výsledků nebo pro účely klasifikace, tj. predikci jedné proměnné k , která nabývá hodnot v konečné neseřazené množině na základě vstupních dat x (x_1, \dots, x_n). Na rozdíl od deterministického modelu, který s jistotou předpovídá výsledky pomocí sady rovnic přesně popisujících vstupy a výstupy systému, stochastický model zobrazuje situaci, kde je přítomna nejistota. Jinými slovy, jedná se o model pro proces, který zahrnuje určitý druh náhodnosti. Při modelování stochastických procesů hraje klíčovou roli čas; stochastický model je nástrojem pro předpovídání pravděpodobnostních rozdělení potenciálních výsledků tím, že umožňuje náhodné variace ve svých vstupech v průběhu času. Stochastický proces je definován jako soubor náhodných proměnných $X = \{X_t : t \in T\}$, definovaných na společném pravděpodobnostním prostoru, které nabývají hodnot ve společné množině S (stavový prostor) a jsou indexovány množinou T , často buď \mathbb{N} nebo $[0, \infty)$, která je považována za čas (diskrétní nebo spojitý).[29]

4.1.2 Markovův proces a Markovův řetězec

Důležitým typem stochastických procesů jsou Markovův proces a Markovův řetězec. Markovův proces je proces splňující Markovovy vlastnosti (je bez paměti), což znamená, že nemá žádnou paměť a rozdělení pravděpodobnosti následujícího stavu závisí výhradně na současném stavu. Formálně je stochastický proces $X(t)$ Markovovým procesem, pokud splňuje následující vlastnosti:

1. Počet možných výsledků nebo stavů je konečný.
2. Pravděpodobnosti jsou konstantní v čase.
3. Splňuje Markovovu vlastnost (je bez paměti).

Matematické vyjádření Markovova procesu vypadá následovně:

$$P(X^{(n+1)} = i | X^{(n)} = j, X^{(n-1)} = i_{n-1}, \dots, X^{(0)} = i_0) = P_{ij} \quad n \geq 0 \quad (4.1)$$

kde $i, j, i_0, i_1, \dots, i_{n-1} \in$ konečné nebo spočetné množině \mathcal{M} [31]. Výše uvedenou pravděpodobnost lze interpretovat takto: podmíněné rozdělení jakéhokoliv budoucího stavu $X^{(n+1)}$ za předpokladu minulých stavů $X^{(0)}, X^{(2)}, \dots, X^{(n-1)}$ a současný stav $X^{(n)}$ je nezávislé na minulých stavech a závisí pouze na současném stavu. Pravděpodobnost P_{ij} představuje pravděpodobnost, že proces přejde do stavu i , pokud je v současné době ve stavu j . Zřejmě platí:

$$P_{ij} \geq 0, \quad \sum_{i=0}^{\infty} P_{ij} = 1, \quad \text{pro } j = 0, 1, \dots$$

Matice obsahující P_{ij} , pravděpodobnosti přechodu

$$P = \begin{pmatrix} P_{00} & P_{01} & \cdots \\ P_{10} & P_{11} & \cdots \\ \vdots & \vdots & \vdots \end{pmatrix}$$

se nazývá jedнокroková matice pravděpodobnosti přechodu procesu.

4.1.3 Skrytý Markovův model

HMM je generativní pravděpodobnostní model, ve kterém je sekvence pozorovatelných proměnných \mathbf{X} generována sekvencí vnitřních skrytých stavů \mathbf{Z} . Skryté stavy nejsou přímo pozorovány. Přechody mezi skrytými stavy se předpokládají ve formě (prvního řádu) Markovova řetězce. Ty mohou být specifikovány pomocí počátečního pravděpodobnostního vektoru π a přechodové pravděpodobnostní matice \mathbf{A} . Emisní pravděpodobnost pozorovatelné proměnné může být jakékoliv rozdělení s parametry θ podmíněnými aktuálním skrytým stavem. HMM je kompletně určen π , \mathbf{A} a θ . Existují tři základní problémy pro HMM:

- Dané parametry modelu a pozorovaná data, odhaduje se optimální sekvence skrytých stavů.
- Dané parametry modelu a pozorovaná data, vypočítává se věrohodnost modelu.
- Daná pouze pozorovaná data, odhadují se parametry modelu.

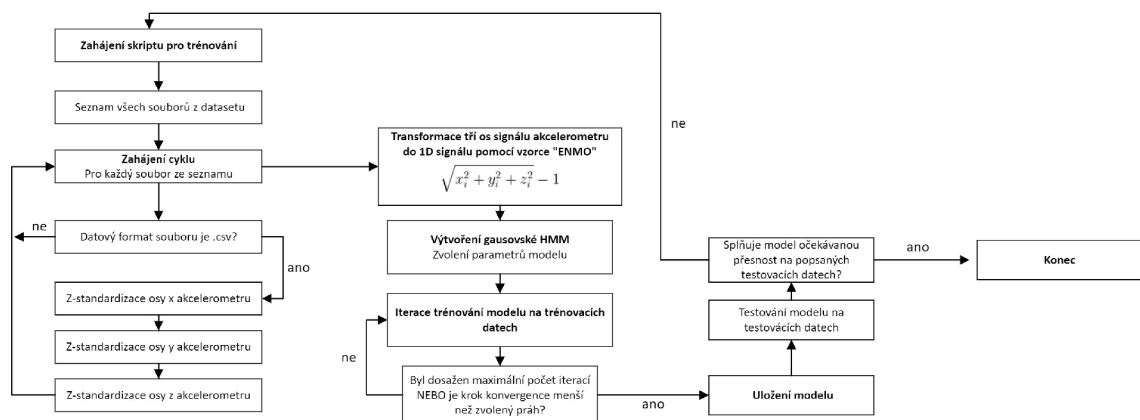
První a druhý problém mohou být řešeny dynamickými programovacími algoritmy známými jako Viterbiho algoritmus a Forward-Backward algoritmus. Poslední problém může být řešen iterativním algoritmem Expectation-Maximization (EM), známým jako Baum-Welchův algoritmus.[32, 33, 34]

4.1.4 Realizace HMM modelu v Pythonu

Pro předzpracování dat a trénování neuronové sítě byl použit programovací jazyk Python v.3.10. Použity byly následující knihovny:

- `numpy` v.1.26.4: Pro numerické výpočty a manipulaci s daty.
- `pandas` v.2.2.1: Pro manipulaci s datovými rámci a analýzu dat.
- `matplotlib` v.3.8.3, `seaborn` v.0.13.2: Pro vizualizaci dat a výsledků.
- `scikit-learn` v.1.4.1: Pro předzpracování dat.
- `hmmlearn` v.0.3.2: Pro výběr a trénování modelu.
- `os`: Pro interakci s operačním systémem a správu souborů.
- `pickle`: Pro serializaci a deserializaci objektů.
- `time`: Pro měření a správu času.

Hmmlearn je open-source sada algoritmů pro učení bez učitele Skrytých Markovových Modelů. Průběh trénování a testování je zobrazen pomocí blokového schématu (Obr. 4.1). Prvním krokem je parsování dat. Jednotlivé .csv soubory z MDT datasetu pro trénování neuronové sítě se načítají jako pandas dataframe. Pro účely trénování byly použity jenom první tři atributy, a to jsou: x, y a z osy akcelerometru.



Obr. 4.1: Průběh trénování HMM modelu

Pro zobrazení byl použit ještě atribut timestamp, označující z jaké doby byla snímána data. Funkci StandardScaler x, y a z ose akcelerometru prošly Z-standardizací, podle vzorce

$$Z = \frac{x_i - \mu}{\sigma} \quad (4.2)$$

kde x_i je aktuální vzorek, μ je průměr ze všech vzorků jednoho dne a σ směrodatná odchylka. Po standardizaci všech vzorků byl tříosový signál akcelerometru transformován do 1D signálu pomocí vzorce ENMO (angl. Euclidean Norm Minus One). ENMO je rozšířením vzorce pro výpočet velikosti signálového vektoru, od kterého se odečítá 1 pro korigování gravitace[35]

$$ENMO = \sqrt{x^2 + y^2 + z^2} - 1 \quad (4.3)$$

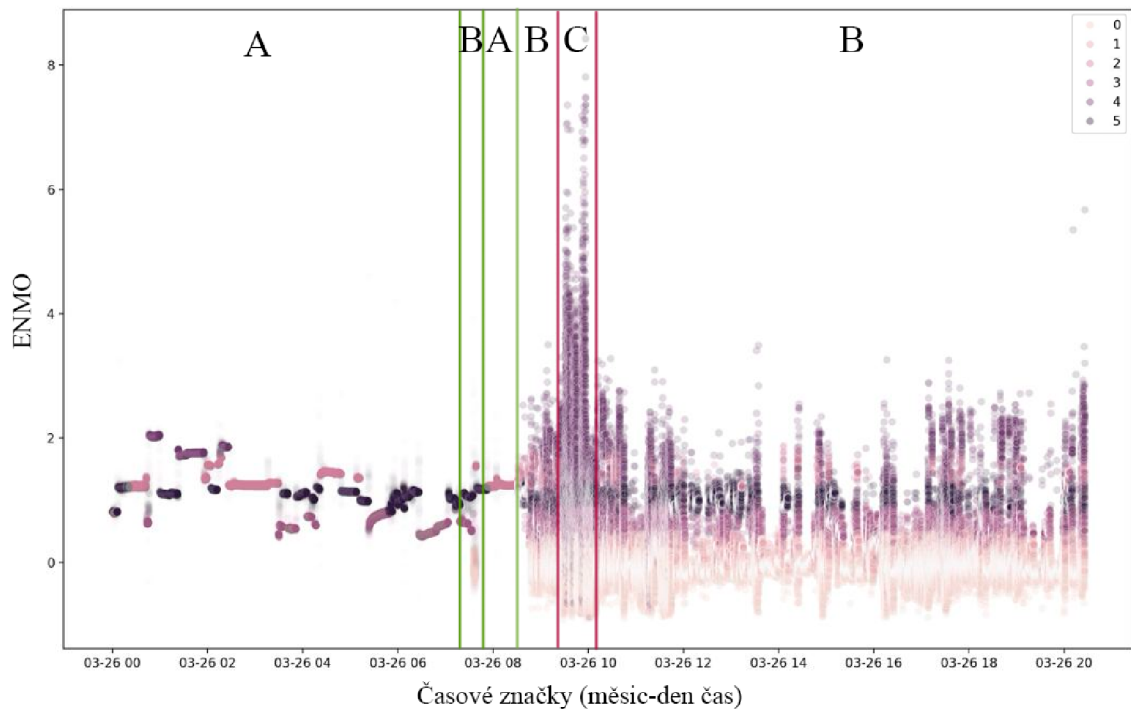
Dalším krokem bylo vytvoření modelu pomocí knihovny *hmmlearn*. Byl vybrán Skrytý Markovův Model s Gaussovými emisemi. Tenhle typ emise se ukázal jako neoptimálnější k použití pro reálná data z akcelerometru [36]. Zvolené parametry pro konečný model a jeho trénování byly následující:

- Maximální počet iterací: 500
- Prahová hodnota změny logaritmu pravděpodobnosti: 0.01
- Typ kovariance: plný ("full")
- Počet komponent: 6


Podmínky ukončení trénování v podobě maximálního počtu iterací a prahové hodnoty změny skóre (logaritmu pravděpodobnosti) byly zvolené s ohledem na výpočetní schopnosti počítače a doby trénování. Typ kovariance a počet komponent byly zvoleny empiricky, při porovnání výsledků s jinými možnostmi. Po ukončení trénování byl model uložen a jeho schopnost určení úrovně aktivity byla ověřena na označených testovacích datech (Obr. 4.2). Jestliže výsledky a přesnost určení aktivity splnila očekávání, parametry modelů byly uloženy. Kvůli tendenci modelu se zasekávat v lokálním optimu, bylo nutné trénování spustit pro zvolené parametry vícekrát. Nejlepší model byl vybrán podle dosažené hodnoty logaritmu pravděpodobnosti (Obr. 4.3). Logaritmus pravděpodobnosti (log-likelihood) musí dosáhnout nejvyšší hodnoty pro konkrétně zvolené parametry.

Na první pohled se může zdát, že logaritmus pravděpodobnosti nemůže být větší než 0, protože logaritmus čísla mezi 0 a 1 je záporný. Toto tvrzení však platí pouze pro diskrétní pravděpodobnost. V případě spojité pravděpodobnosti mohou hustoty pravděpodobnosti nabývat hodnot větších než 1, což může způsobit, že logaritmus těchto hustot bude kladný. Pro diskrétní pravděpodobnost je log-likelihood definován jako součet logaritmů jednotlivých pravděpodobností:

$$\log \mathcal{L}(\theta) = \sum_{i=1}^n \log P(x_i; \theta),$$



Obr. 4.2: Průběh trénování HMM modelu (A-spánek, B-bdění, C-vysoká fyzická aktivita; 1-5 jsou nominální kategorie úrovně aktivity)



Obr. 4.3: Průběh trénování HMM modelu

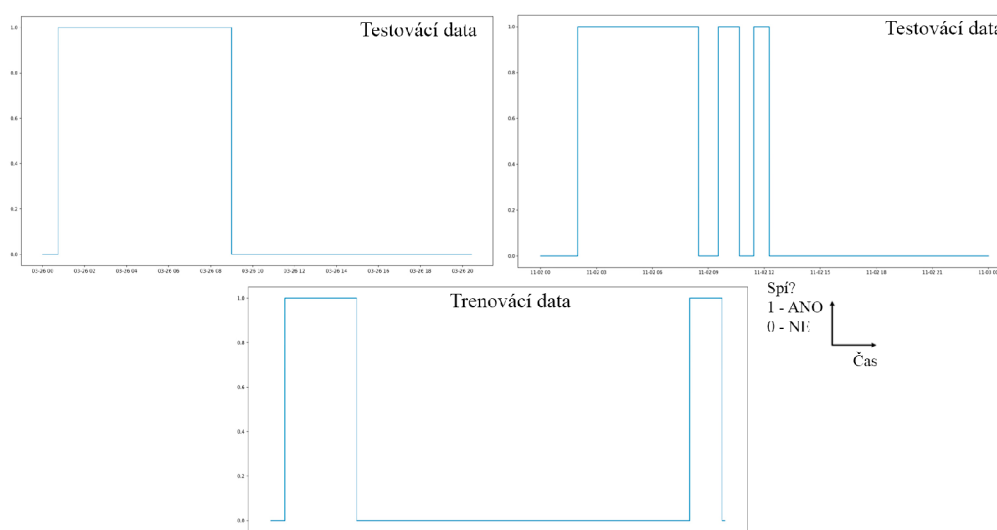
kde $P(x_i; \theta)$ je pravděpodobnost výskytu x_i daná parametrem θ . Pro spojitou pravděpodobnost je log-likelihood definován jako součet logaritmu hustot pravděpodobnosti:

$$\log \mathcal{L}(\theta) = \sum_{i=1}^n \log f(x_i; \theta),$$

kde $f(x_i; \theta)$ je hustota pravděpodobnosti pro x_i daná parametrem θ . Výše popsáný model pracuje se spojitými hustotami pravděpodobnosti. Hodnoty log-likelihood (Obr. 4.3) mohou být kladné, protože jsou vypočítávány z těchto hustot, nikoliv z diskrétních pravděpodobností.


4.2 Určení úrovně aktivity

Nejdříve bylo pomocí označeného testovacího datasetu (Obr. 4.2) určeno, které nominální kategorie nalezené HMM modelem jsou převážně přítomné během spánku subjektu a které nejsou nebo se vyskytují jen ojediněle. Pomocí této informace bylo



Obr. 4.4: Subjekt se nachází v spánku? 1 - Ano, 0 - Ne. Každý graf pro odlišný subjekt

možné určit, zda se subjekt nachází ve spánku (Obr. 4.4). Dalším krokem bylo opět pomocí označeného testovacího datasetu přiřadit každé nominální kategorii odpovídající úroveň aktivity. Minimální fyzická aktivita měla číselnou hodnotu 1 a nejvyšší aktivita hodnotu 10. Pro nejvyšší fyzickou aktivitu (a pouze pro ni) byl stanoven vhodný práh (metoda cut-point). Přiřazené úrovně aktivity ke každé kategorii jsou zobrazené na grafu (Obr. 4.5). Dvě kategorie ze sedmi měly přiřazené variabilní hodnoty úrovně aktivity na základě toho, jestli se vyskytovaly během spánku nebo během toho, když subjekt byl vzhůru. Na základě přiřazených úrovní aktivity byly nominální kategorie přeložené do číselných hodnot úrovně aktivit. Převodění se provádělo v průměrovacích oknech o délce 90 vzorků (18 vteřin). Podrobnější informace o převodění jsou zobrazené na blokovém schématu celkového kódu (Obr. 4.8).



Obr. 4.5: Určení úrovně aktivity z označeného testovacího datasetu

4.3 Rozhodovací strom pro detekci poruch rytmu

Pomocí informací o momentální úrovni aktivity a tepu subjektu bylo možné vytvořit rozhodovací strom, který určuje, zda je srdeční odezva adekvátní fyzické zátěži. Nejprve bylo ověřeno, že vytvořený model určuje úroveň fyzické aktivity s dostatečnou přesností na to, aby byla viditelná závislost tepu na fyzické aktivitě (Obr. 4.6).

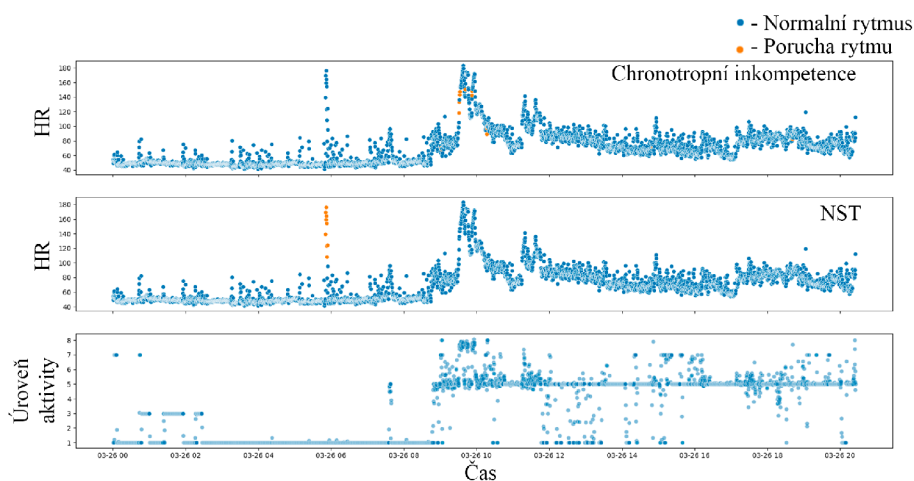


Obr. 4.6: Závislost tepu na úrovni aktivity při A - vysoké aktivitě, B - nízké aktivitě.

Je patrné, že vyšší přesnost a závislost jsou přítomny v záznamech při vyšší fyzické aktivitě než při nízké (Obr. 4.6A, Obr.4.6B). Pro určení hraničních hodnot

tepové frekvence byla použita informace z kapitoly 1.1, a to:

- Nepřiměřená sinusová tachykardie:
 - *Tepová frekvence* - Nad 100 úderů za minutu
 - *Úroveň aktivity* - Pod 3 (Nízká)
- Chronotropní inkompetence:
 - *Tepová frekvence* - Pod $0.8 * AMPHR$ vypočtené vzorcem č. 1.2
 - *Úroveň aktivity* - Nad 7.5 (Vysoká)



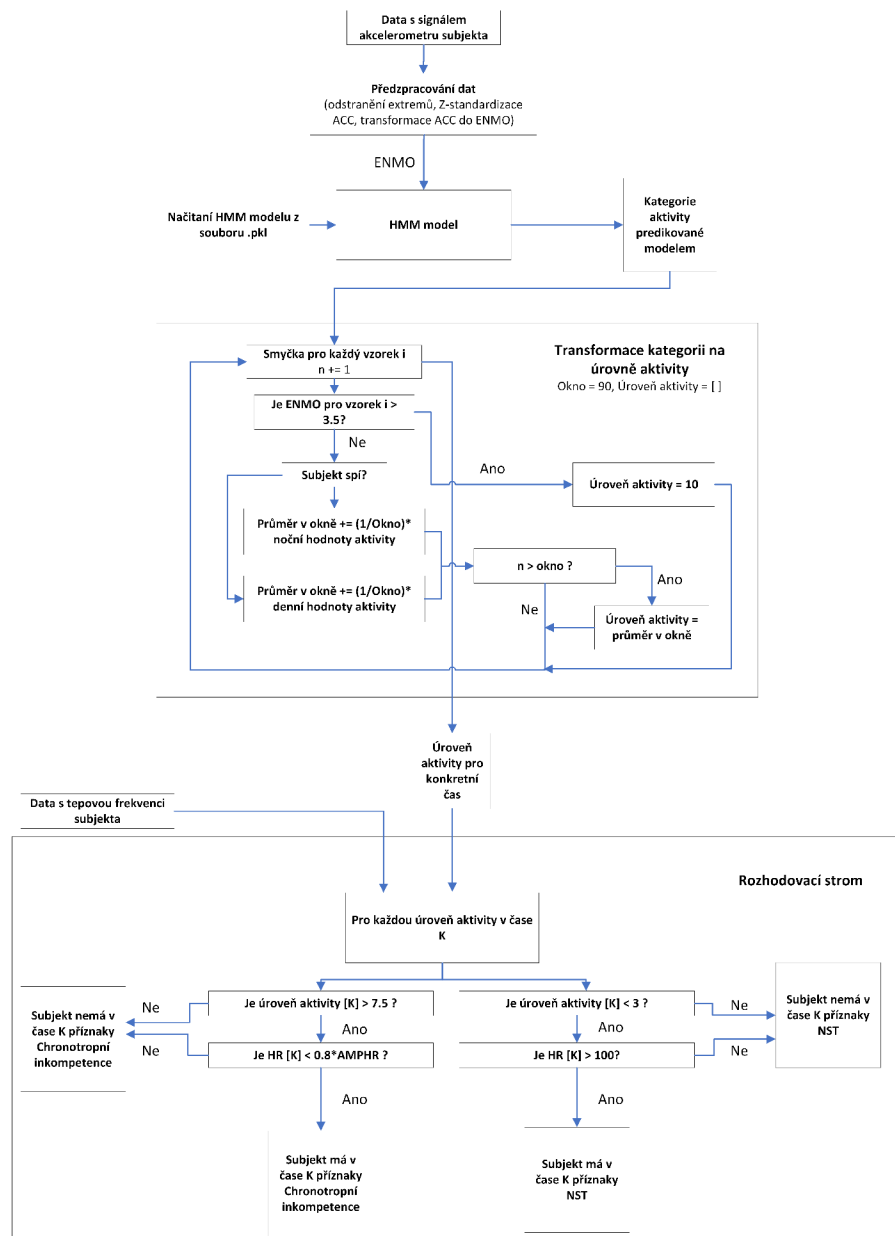
Obr. 4.7: Výsledky detekce chronotropní inkompetence a NST

Na blokovém schématu (Obr. 4.8) je představen zjednodušený běh programu a struktura rozhodovacího stromu pro určení a detekci výše popsaných symptomů v rámci HMM modelu. Výsledky detekce na testovacích datech jsou zobrazeny v grafu (Obr. 4.7).

4.4 LSTM neuronová síť pro predikci hodnot srdeční frekvence

LSTM neuronová síť je typem rekurentní neuronové sítě (RNN). Vlastností RNN je, že nedochází k okamžitému toku informací mezi neurony, ale spíše pomocí smyček. To umožňuje udržet vliv informace o proměnné v určitém období až do dokončení sekvenční časové řady.[37]


RNN neuronová síť, podobně jak typická dopředná neuronová síť (Obr. 2.4), se skládá ze vstupní, skryté a výstupní vrstvy. RNN neuronová síť navíc ale obsahuje rekurentní jednotku ve skryté vrstvě, která jí dovoluje zpracovávat sekvenční data. Dělá to tím, že opakovaně předává skrytý stav z předchozího časového kroku a kombinuje ho se vstupem aktuálního časového kroku.[38] Na blokovém schématu (Obr. 4.9) je představena typická rekurentní jednotka skryté vrstvy,



Obr. 4.8: Zjednodušené blokové schéma programu pro detekci nepřiměřené sinusové tachykardie a chronotropní inkompetence

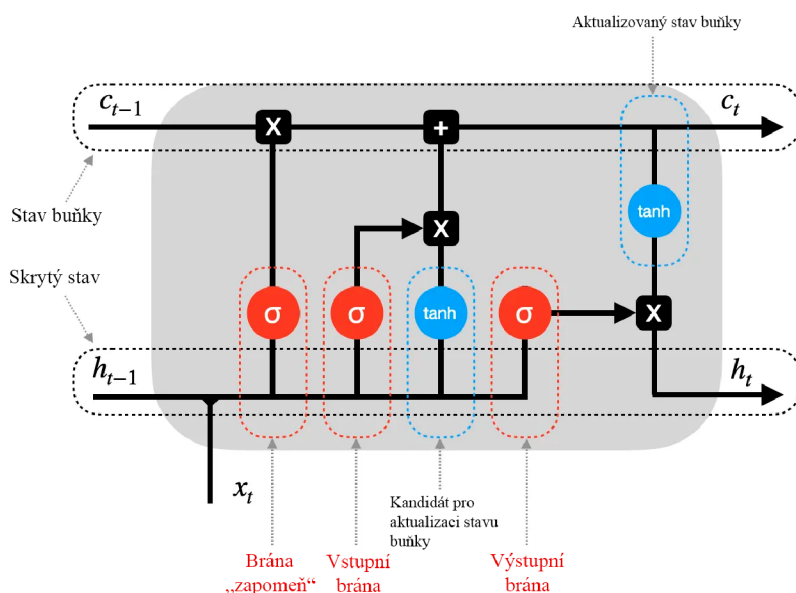
kde h_{t-1} je skrytý stav v předchozím časovém kroku $t - 1$ (paměť), x_t je vstupní vektor v aktuálním časovém kroku t , h_t je skrytý stav v aktuálním časovém kroku t a \tanh je aktivační funkce. Po vypočítání skrytého stavu v časovém kroku t je tento stav předán zpět do rekurentní jednotky a zkombinován se vstupem v časovém kroku $t+1$, aby se vypočítal nový skrytý stav v časovém kroku $t+1$. Tento proces se opakuje pro $t+2, t+3, \dots, t+n$, dokud není dosaženo předdefinovaného počtu (n) časových kroků.

Na rozdíl od RNN, struktura LSTM jednotky je mnohem komplexnější, používá



Obr. 4.9: Rekurentní jednotka skryté vrstvy v RNN neuronové síti[38]

různé brány pro rozhodnutí, jaké informace zachovat nebo vyřadit. Také přidává stav buňky, který funguje jako dlouhodobá paměť LSTM[38]. Blokové schéma LSTM jednotky je představeno na blokovém schématu (Obr.4.10), kde h_{t-1} je skrytý stav v



Obr. 4.10: Komplexní jednotka skryté vrstvy v LSTM neuronové síti[38]

předchozím časovém kroku $t - 1$ (krátkodobá paměť), c_{t-1} je stav buňky v předchozím časovém kroku $t - 1$ (dlouhodobá paměť), x_t je vstupní vektor v aktuálním časovém kroku t , h_t je skrytý stav v aktuálním časovém kroku t a c_t je stav buňky v aktuálním časovém kroku t . Tanh a σ jsou aktivační funkce. Zjednodušený postup při zpracování vzorku LSTM jednotkou je pak následující:

1. Skrytý stav a nové vstupy

Skrytý stav z předchozího časového kroku (h_{t-1}) a vstup v aktuálním časovém kroku (x_t) jsou kombinovány.

2. Zapomínací brána

Tato brána určuje, jaké informace by měly být zapomenuty. Protože sigmoidní funkce nabývá hodnot mezi 0 a 1, nastavuje, které hodnoty v buňkovém stavu by měly být vyřazeny (vynásobené 0), zapamatovány (vynásobené 1) nebo částečně zapamatovány (vynásobené hodnotou mezi 0 a 1).

3. Vstupní brána

Vstupní brána pomáhá identifikovat důležité prvky, které je třeba přidat do buňkového stavu. Výsledky vstupní brány se vynásobí s kandidátem buňkového stavu, takže do buňkového stavu se přidá pouze informace, kterou vstupní brána považuje za důležitou.

4. Aktualizace stavu buňky

Nejprve se předchozí stav buňky (c_{t-1}) vynásobí výsledkem brány "zapomeň". Poté přidáním nové informace z [vstupní brána \times kandidát pro aktualizaci stavu buňky] bude získán aktuální stav buňky (c_t).

5. Aktualizace skrytého stavu

Poslední krok spočívá v aktualizaci skrytého stavu. Aktuální buňkový stav (c_t) projde aktivační funkcí \tanh a vynásobí se výsledky výstupní brány.[38]

4.4.1 Realizace v Pythonu

Neuronová síť byla naučena na datech z MDT datasetu v programovacím jazyce Python. Použity byly následující knihovny:

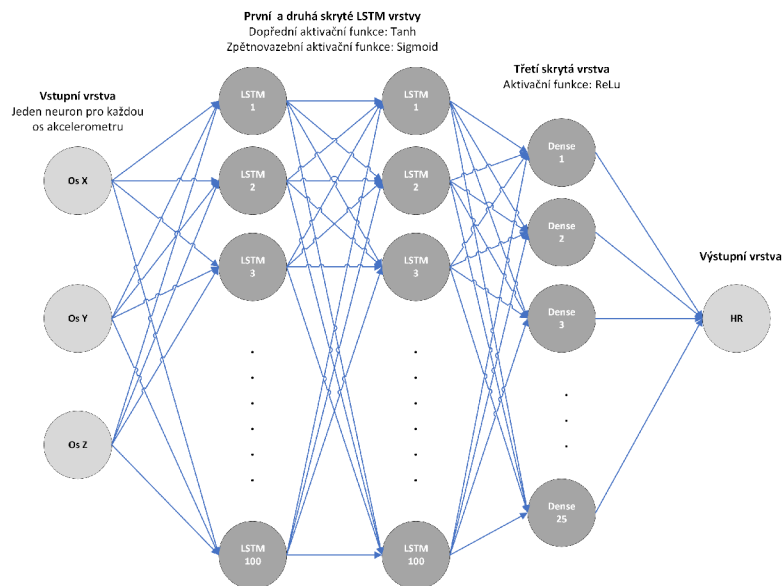
- `numpy v.1.26.4`: Pro numerické výpočty a manipulaci s daty.
- `pandas v.2.2.1`: Pro manipulaci s datovými rámci a analýzu dat.
- `matplotlib v.3.8.3`, `seaborn v.0.13.2`: Pro vizualizaci dat a výsledků.
- `scikit-learn v.1.4.1`: Pro předzpracování dat.
- `tensorflow.keras v.2.15.0`: Pro vytvoření a trénování modelu.
- `os`: Pro interakci s operačním systémem a správu souborů.
- `pickle`: Pro serializaci a deserializaci objektů.
- `time`: Pro měření a správu času.

Data z datasetu byla načtena do jednoho velkého datového rámce `pandas DataFrame`. Pro účely trénování neuronové sítě byly použity čtyři atributy: osy akcelerometru x , y , z jako vstupní proměnné a hodnota HR jako výstupní. Po extrakci těchto atributů z datového rámce prošly krokem předzpracování. Z atributu HR byly odstraněny odlehlé hodnoty a nahrazeny sousedními. Atributy x , y , z prošly Z-standardizací (vzorec 4.2) pomocí funkce `StandardScaler`. Hodnoty funkce `StandardScaler` byly uloženy pro standardizaci nových dat pro budoucí predikci.

Dalším krokem bylo rozdělení os akcelerometru do oken po 150 vzorcích (30 sekund) s překrytím 20 %. Překrytí bylo zavedeno pro zaručení schopnosti neuro-

nové síti pamatovat si informace z předchozích oken. Všechny osy akcelerometru byly následně sjednoceny do jedné množiny X, zatímco hodnoty srdeční frekvence HR byly zprůměrovány v okně 150 vzorků (30 sekund), aby na výstupu byla vždy jedna hodnota srdeční frekvence. Hodnoty srdeční frekvence byly následně také standardizovány a uloženy do množiny Y. Množiny byly pak rozděleny na testovací data (10%), trénovací data (74%) a validační data (16%).

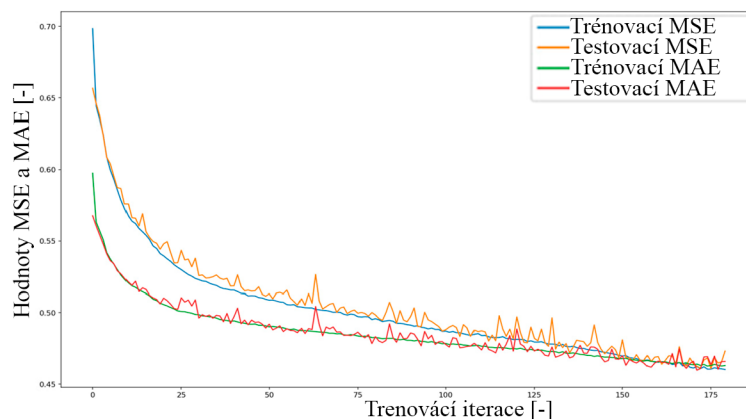
Zvolená architektura neuronové síti je zobrazena v zjednodušené podobě na blokovém schématu (Obr. 4.11). Vstupní vrstva obsahuje tři neurony, jeden pro každou osu akcelerometru jako vstupní atribut. První a druhá skrytá vrstva obsahují každá 100 LSTM neuronů. Aktivační funkce těchto neuronů v dopředném směru je Tanh a Sigmoid v zpětnovazebním. Třetí skrytá vrstva obsahuje 25 klasických "Dense" neuronů s aktivační funkcí ReLU. Tato vrstva byla přidána do modelu pro zvýšení jeho nelinearity a schopnosti rozpoznávat složitější nelineární vlastnosti. Výstupní vrstva pak obsahuje jeden neuron a udává hodnotu srdeční frekvence.



Obr. 4.11: Zjednodušené blokové schéma pro popis zvolené architektury LSTM neuronové síti

Parametry trénování byly zvoleny následovně:

- Maximální počet iterací: 180
- Učící krok (learning rate): 10^{-4}
- Velikost dávky (batch size): 64
- Optimalizační technika: Adam (Adaptive Moment Estimation) pro gradientní sestup
- Ztrátová funkce: Střední kvadratická chyba (MSE)
- Dodatečná metrika: Průměrná absolutní chyba (MAE)



Obr. 4.12: Učící křivka LSTM neuronové sítě

Bylo také nastaveno brzké ukončení trénování s podmínkou neklesající ztrátové funkce pro validační data a ukládání hodnot vah pro nejnižší MSE. Výsledná učící křivka je zobrazena na grafu (Obr. 4.12). V posledním kroku byla neuronová síť otestována na testovacích datech. Výsledky testování po destandardizaci jsou následující:

- Střední kvadratická chyba (MSE) : 130
- Průměrná absolutní chyba (MAE): 7.98
- Koeficient determinace (R^2): 0.58

Střední kvadratická chyba (MSE) měří průměr čtverců rozdílů mezi skutečnými a předpovězenými hodnotami. Je to běžně používaná metrika pro hodnocení regrese.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

kde:

- n je počet vzorků.
- y_i je skutečná hodnota.
- \hat{y}_i je předpovězená hodnota.

Průměrná absolutní chyba (MAE) měří průměr absolutních rozdílů mezi skutečnými a předpovězenými hodnotami. MAE poskytuje jasnou interpretaci chyby v jednotkách cílové proměnné.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

kde:

- n je počet vzorků.
- y_i je skutečná hodnota.
- \hat{y}_i je předpovězená hodnota.

V kontextu této problematiky hodnota MAE 7.98 znamená, že průměrná absolutní chyba mezi předpovězenými a skutečnými hodnotami srdečního tepu je přibližně 8 úderů za minutu. Koeficient determinace (R^2) měří, jak dobře model vysvětluje variabilitu cílové proměnné. Hodnoty R^2 se pohybují od 0 do 1, kde hodnota blízká se 1 znamená, že model vysvětluje většinu variability v datech.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

kde:

- y_i je skutečná hodnota.
- \hat{y}_i je předpovězená hodnota.
- \bar{y} je průměrná hodnota skutečných hodnot.

V kontextu této problematiky hodnota R^2 0,58 znamená, že model vysvětluje 58% variability v hodnotách srdečního tepu, což naznačuje, že model není schopen přesně predikovat hodnoty srdeční frekvence v tomto vzorku.

Nicméně pro účely této práce jsou dosažené výsledky dostatečně uspokojivé. Je důležité zmínit, že původní dataset obsahoval jak zdravé, tak nezdravé subjekty. Vyšší hodnoty metrik by mohly naznačovat přeučení modelu, protože v této aplikaci není cílem, aby predikované hodnoty tepu byly patologické, i když jsou z hlediska trénovaného modelu správné. Klíčovým krokem je tedy nastavit hranici pro rozdíl mezi predikovanou hodnotou tepu během pohybu a skutečnou hodnotou. Překročení této hranice by pak mohlo indikovat možnou poruchu rytmu u subjektu.

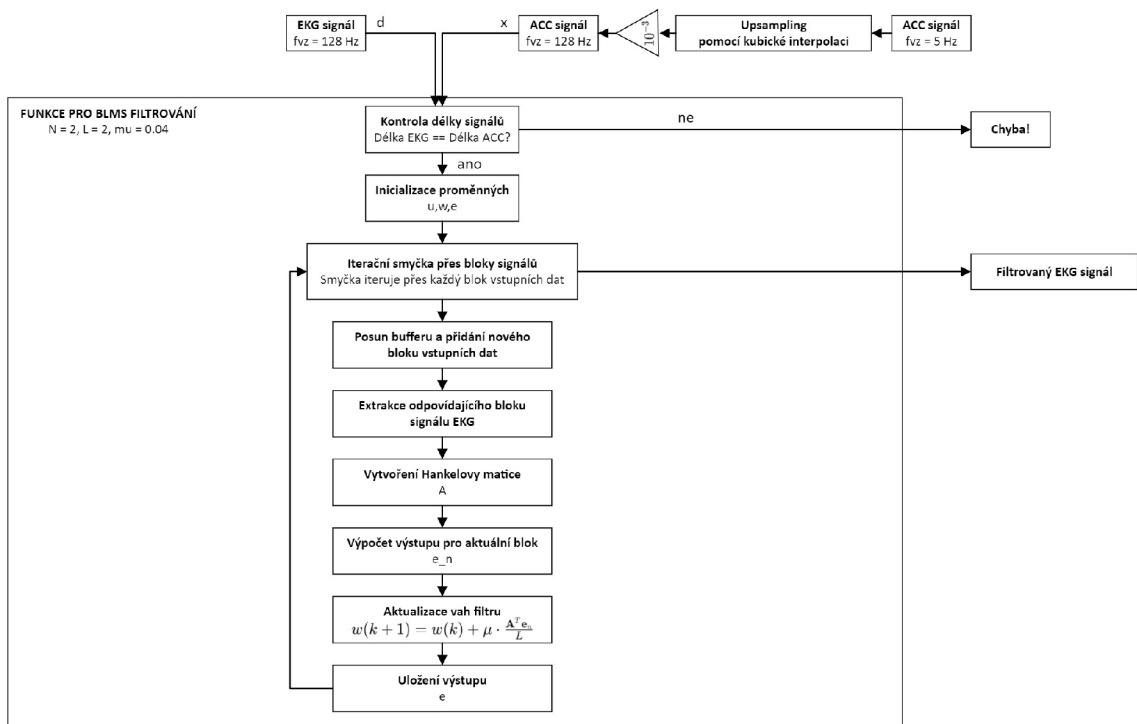
4.5 BLMS filtr

4.5.1 Realizace v Pythonu

Filtr byl vytvořen jako funkce v programovacím jazyce Python. Použité byly následující knihovny:

- **numpy v.1.26.4**: Pro numerické výpočty a manipulaci s daty.
- **pandas v.2.2.1**: Pro manipulaci s datovými rámci a analýzu dat.
- **matplotlib v.3.8.3**: Pro vizualizaci dat a výsledků.
- **scipy v.1.13.0**: Pro upsampling dat.

Hlavní kroky pro filtrování a běh funkce jsou popsány v blokovém schématu (Obr. 4.13). Pro signály z přístroje Vivalink, se vzorkovací frekvencí EKG 128 Hz a vzorkovací frekvencí signálu akcelerometru 5 Hz, je nutné zvýšit vzorkovací frekvenci signálu akcelerometru. Pro správný běh filtrování se vzorkovací frekvence a délka obou signálů musí rovnat. Zvýšení vzorků bylo provedeno pomocí kubické interpolace z knihovny SciPy. Převzorkovaný signál akcelerometru je dále dělený 1000,



Obr. 4.13: Blokové schéma běhu BLMS filtrování

aby jeho amplituda odpovídala amplitudě EKG a filtrování proběhlo správně. Takto upravený signál akcelerometru a signál EKG vstupují do funkce BLMS pro samotné filtrování. Vnitřní běh funkce je popsán v blokovém schématu (Obr. 4.13).

4.5.2 Určení osy akcelerometru pro použití v filtraci


Filtrace byla provedená na všech osách akcelerometru a na vektoru jejich velikostí (Vzorec 2.2). Výsledky filtrace jsou zobrazené na grafu (Obr. 4.14). Z grafu je patrné, že nejúčinnější osou pro filtraci konkrétního signálu je osa X. Nicméně vektor SVM dosáhl ještě lepších výsledků při filtraci, což odpovídá teoretickým předpokladům. Proto bylo rozhodnuto používat vektor velikosti signálů jako vstup d do funkce BLMS pro filtrování EKG signálu.

4.5.3 Určení optimálních parametrů filtru

Filtr obsahuje 3 hlavní parametry, a to jsou:

- N : Řád filtru, určuje počet vah.
- L : Délka bloku, určuje, po kolika vzorcích se mění hodnota vah.
- μ : Krok filtrování, určuje míru změny hodnoty vah v každé iteraci.

Jejich určení probíhalo v několika krocích. Nejdříve byly zvoleny výchozí hodnoty empiricky: $N = 2, L = 10, \mu = 0.05$. Každý parametr se pak měnil při konstantních

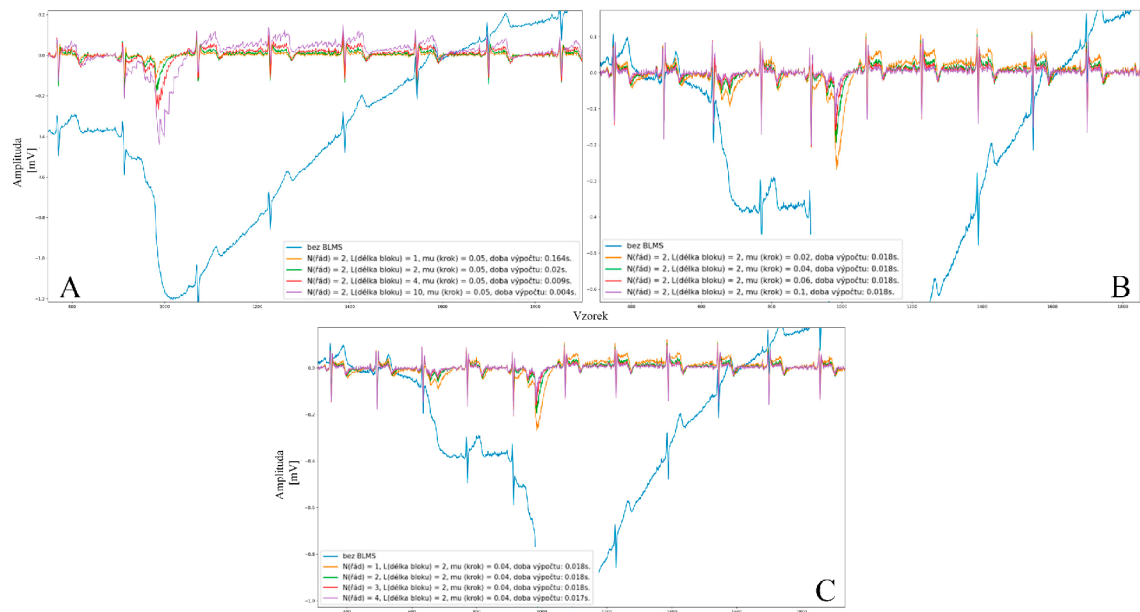


Obr. 4.14: Výběr ose akcelerometru pro filtrování EKG

dvou ostatních parametrech. Výsledky této analýzy jsou zobrazeny na grafech (Obr. 4.15). Nejdříve byly vykresleny výsledky pro různý parametr délky bloku. Zvolené hodnoty délky bloků byly: $L = 1$, $L = 2$, $L = 4$, $L = 10$. Je patrné (Obr. 4.15A), že účinnost filtrování se zvyšuje s klesající délkou bloků. Také při vyšších délkách bloků se zavádí patrné vysokofrekvenční rušení, které by mohlo vést k falešným nálezům na EKG. Bylo rozhodnuto použít délku bloku $L = 2$ vzhledem k účinnosti filtrování a výpočetní době pro filtrování. Filtrování pro $L = 1$ trvalo 0.164 sekundy, což bylo 8.2krát déle než pro $L = 2$, kde filtrování trvalo 0.02 sekundy. Dalším krokem bylo určeno nastavení parametru pro krok filtrace. Zvolené hodnoty byly: $\mu = 0.02$, $\mu = 0.04$, $\mu = 0.06$, $\mu = 0.1$. Je patrné (Obr. 4.15B), že účinnost filtrování se zvyšuje se zvyšujícím se krokem filtrace. Se zvyšováním filtrace pohybových artefaktů se ale potlačovaly i nízkofrekvenční složky užitečného signálu, což se projevovalo snížováním amplitudy vlny T na EKG. S ohledem na potlačení užitečných složek EKG bylo rozhodnuto použít krok filtrace $\mu = 0.04$. Čas nutný pro běh filtrace se neměnil s krokem filtrace. Posledním krokem bylo určeno nastavení řádu filtru. Zvolené hodnoty byly: $N = 1$, $N = 2$, $N = 3$, $N = 4$. Z grafu je patrné (Obr. 4.15C), že účinnost filtrování se zvyšuje s řádem filtru. Nicméně při vyšších řádech jsou výrazně potlačeny užitečné složky EKG. Proto byla jako optimální hodnota řádu filtru zvolena $N = 2$. Doba potřebná pro filtrování se s řádem filtru výrazně neměnila.

4.5.4 Výsledky filtrace

Z celého denního EKG záznamu byl vybrán první úsek s výrazným pohybovým rušením a na něm byl použit BLMS filtr bez další filtrace. Výsledek filtrace s dříve stanovenými parametry je vidět na grafu (Obr. 4.16). Je vidět, že filtr je schopen




Obr. 4.15: Analýza různých hodnot parametrů filtru BLMS


vyfiltrovat poměrně zarušené úseky (Obr. 4.16A) s klesající základní linií EKG na hodnotu -1.2 mV (Obr. 4.16C). Na vyfiltrovaném EKG zůstal artefakt s amplitudou -0.2 mV. Filtr je také schopen obnovit deformované EKG vlny způsobené rušením (Obr. 4.16B), které nejsou rozeznatelné na původním signálu EKG. Nicméně je také patrné mírné potlačení užitečných nízkofrekvenčních složek EKG, projevující se hlavně zmenšením amplitudy T vlny a ST elevace na EKG zdravého jedince. Tento jev se projevuje i na úsecích EKG záznamu, které nebyly zasaženy rušením (Obr. 4.7A). Řešením tohoto problému by mohlo být rozšíření adaptačních vlastností filtru, popsané ve dvou dalších kapitolách.

4.5.5 Korelační analýza pro adaptaci

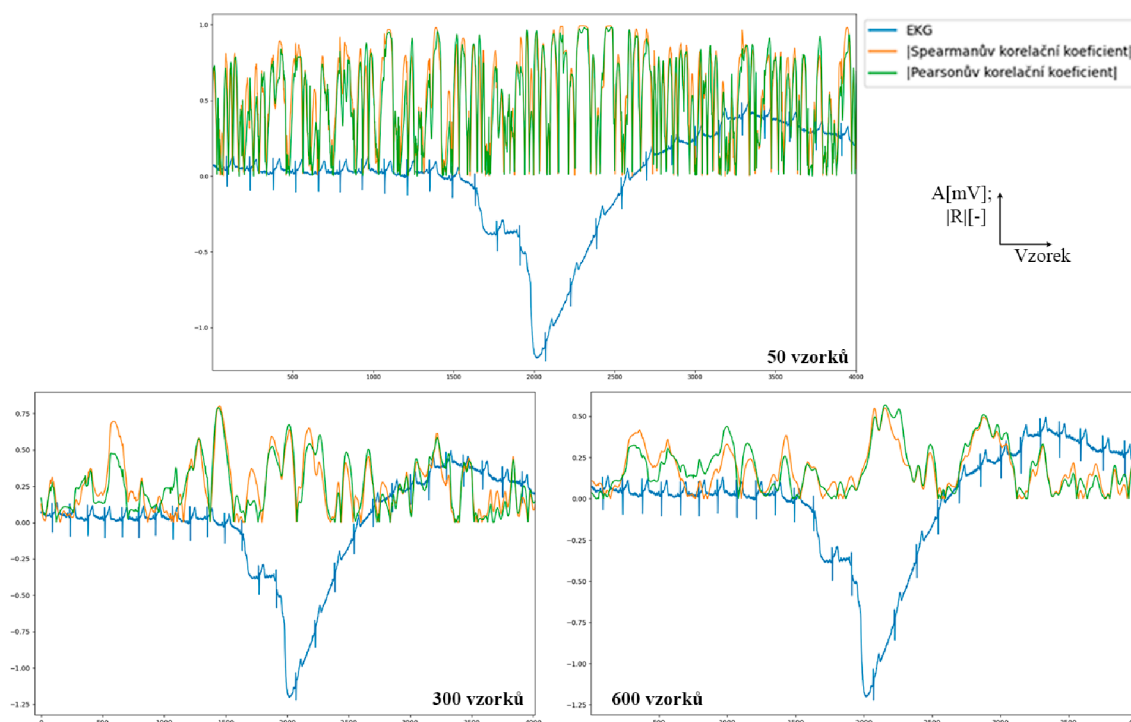
BLMS filtr potlačuje některé užitečné složky EKG, hlavně nízké frekvence, což se projevuje především vizuálním snížením T vlny (Obr. 4.17). Tahle změna morfologie EKG by mohla vést ke zkreslení jeho evaluace a proto bylo rozhodnuto přidat další adaptivní prvek do filtrace, aby se prováděla jenom v okamžik, kdy je EKG výrazně zarušené pohybovými artefakty. Původní vize řešení tohoto problému spočívala v použití korelačního koeficientu mezi signálem EKG a signálem akcelerometru k zjištění, zda jsou v EKG přítomny pohybové artefakty. Výsledky korelační analýzy jsou zobrazeny na grafu (Obr. 4.18). Pro srovnání byly vypočteny jak Pearsonův, tak Spearmanův korelační koeficient. Korelační koeficienty byly vždy počítány v okně, které zahrnovalo aktuální vzorek EKG a N dalších vzorků a aktuální vzorek SVM s N dalšími vzorky. Z Obr. 4.18 je zřejmé, že ani jeden z koeficientů, bez ohledu



Obr. 4.16: Výsledky filtrace



Obr. 4.17: Srovnání morfologie EKG před a po filtraci



Obr. 4.18: Výsledky korelační analýzy mezi signálem EKG a akcelerometru

na nastavení okna, neposkytuje užitečné informace o přítomnosti pohybových artefaktů. Proto bylo toto řešení vyhodnoceno jako nevhodné a nahrazeno analýzou směrodatné odchylky v EKG signálu, o čemž se pojedná v následující kapitole.

4.5.6 Výpočet směrodatné odchylky pro adaptaci

Rozptyl měří průměrnou kvadratickou odchylku jednotlivých hodnot od jejich průměru. Pro soubor dat s hodnotami x_1, x_2, \dots, x_n a průměrem \bar{x} je rozptyl definován jako:

$$\sigma^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (4.4)$$

kde:

- σ^2 je rozptyl,
- n je počet hodnot v datovém souboru,
- x_i jsou jednotlivé hodnoty v datovém souboru,
- \bar{x} je průměr hodnot v datovém souboru.


Směrodatná odchylka je odmocnina z rozptylu a poskytuje míru variability ve stejných jednotkách jako původní data. Je definována jako:

$$\sigma = \sqrt{\sigma^2} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (4.5)$$

kde:

- σ je směrodatná odchylka,
- σ^2 je rozptyl.

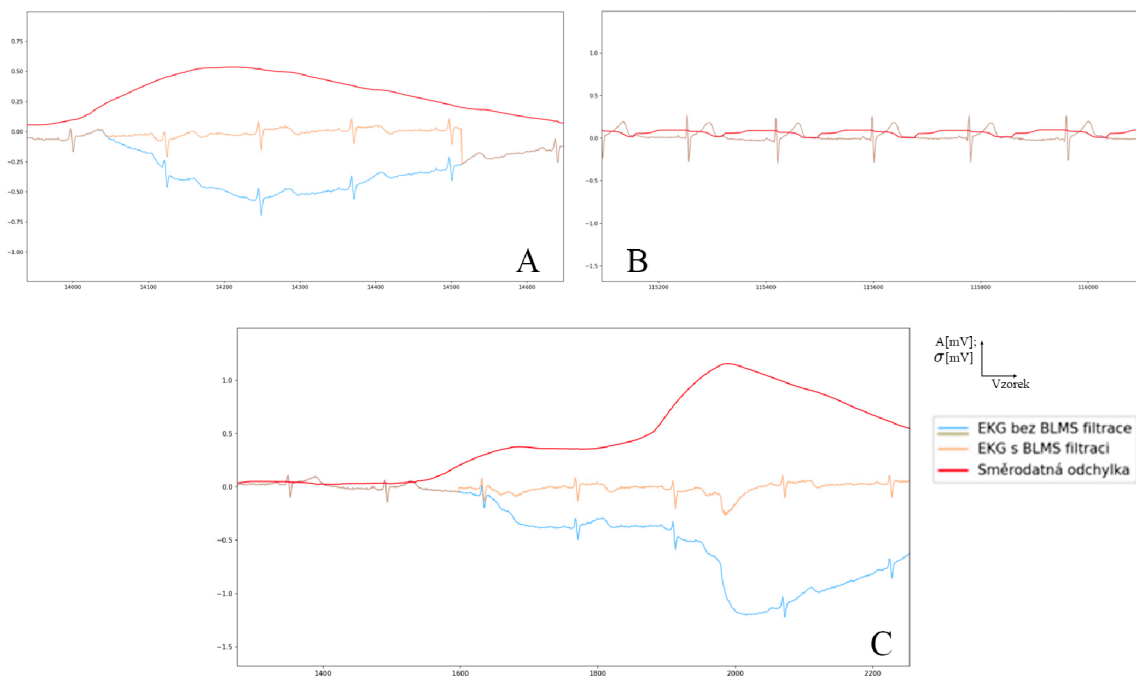
Mezi rozptylem a směrodatnou odchylkou byla pro účely této práce vybrána směrodatná odchylka kvůli její jednodušší interpretovatelnosti a vyšší citlivosti na odchylky, což je patrné na grafu (Obr. 4.19). Stejně jako u korelační analýzy se směro-



Obr. 4.19: Výpočet směrodatné odchylky a rozptylu s oknem 100 vzorků

datná odchylka počítala pro aktuální vzorek v okně s N dalšími vzorky. Ve vzorci pro výpočet (Vzorec 4.5) byla jako průměr vždy brána hodnota 0. Směrodatná odchylka tak zobrazovala odchylku EKG od své základní linie (0), což úspěšně indikovalo místa s výskytem pohybových artefaktů a driftem základní linie (Obr. 4.19). Výsledek použití směrodatné odchylky jako dalšího prvku adaptace je zobrazen na grafech (Obr. 4.20).

Filtr se úspěšně aktivoval pouze po překročení nastaveného prahu směrodatné odchylky ve výši 0,2 mV (Obr. 4.20C) a přestal zasahovat do signálu při návratu hodnoty směrodatné odchylky pod tento práh (Obr. 4.20A). Tím bylo dosaženo toho, že nežádoucí změny EKG se neprojevovaly v okamžicích, kdy nedocházelo k pohybovému rušení a driftu základní linie (Obr. 4.20B).

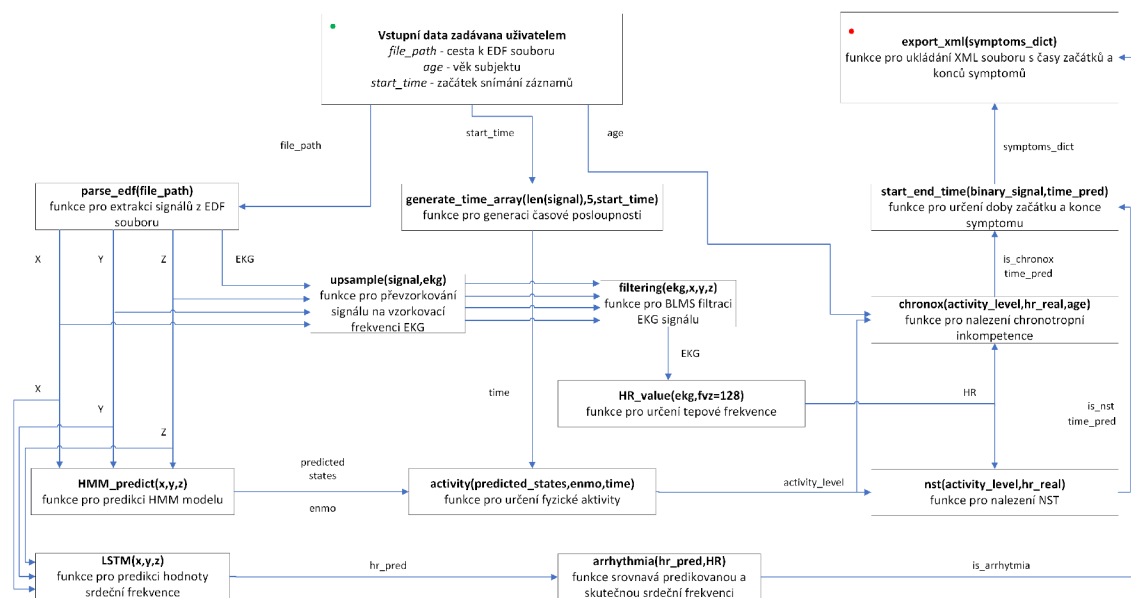


Obr. 4.20: Demonstrace aktivace BLMS filtrace při dosažení prahové hodnoty směrodatné odchylky

5 Aplikace detekující poruchy srdečního rytmu, včetně jejich začátku a symptomů

S využitím kódů popsaných v předchozích kapitolách byl vytvořen program pro detekci chronotropní inkompetence a nepřiměřené sinusové tachykardie. Program byl napsán v programovacím jazyce Python v.3.10. Použity byly následující knihovny:

- `numpy` v.1.26.4: Pro numerické výpočty a manipulaci s daty.
- `pandas` v.2.2.1: Pro manipulaci s datovými rámci a analýzu dat.
- `scikit-learn` v.1.4.1: Pro předzpracování dat.
- `hmmlearn` v.0.3.2: Pro načtení a práci HMM modelu.
- `pyedflib` v. 0.1.37: Pro načtení a zpracování EDF souboru.
- `tensorflow` v. 12.6.1: Pro načtení a práci LSTM modelu.
- `keras` v. 3.3.3: Pro načtení a práci LSTM modelu.
- `heartpy` v. 1.2.7: Pro určení reálné hodnoty srdeční frekvence z EKG signálu.
- `pyinstaller` v. 6.7.0: Pro uložení programu jako jeden `.exe` soubor.
- `os`: Pro interakci s operačním systémem a správu souborů.
- `pickle`: Pro serializaci a deserializaci objektů.
- `time`: Pro měření a správu času.



Obr. 5.1: Blokové schéma finálního programu pro určení poruch srdečního rytmu

Program načítá EDF soubor, extrahuje z něj signály, provádí filtraci EKG signálu pomocí vytvořeného BLMS filtru a signálů z tří os akcelerometru (kap. 4.4). Dále

určuje tepovou frekvenci z filtrovaného EKG signálu a posuzuje, zda je tepová frekvence adekvátní momentální fyzické aktivitě (kap. 4.3), kterou určuje HMM model (kap. 4.1.4). LSTM neuronová síť predikuje srdeční frekvenci z třech os akcelerometru a tato predikovaná hodnota se porovnává se skutečnou, určenou z filtrovaného signálu. Finálním krokem programu je export určených symptomů, včetně jejich začátku a konce, ve formátu XML. Celý proces programu je popsán na blokovém schématu (Obr. 5.1). Všechny zobrazené funkce byly vytvořeny specificky pro potřeby této práce.

Aplikace je dostupná ke stažení z internetu prostřednictvím odkazu v přílohách této práce. Zdrojové kódy a všechny funkce jsou rovněž přiloženy.

6 Diskuze a evaluace výsledků

6.1 Analýza možností detekce poruch a symptomů srdečního rytmu z EKG a akcelerometrického signálu

Provedenou analýzou byly nalezeny dva přístupy využití synergického potenciálu EKG a akcelerometrického signálu. Prvním přístupem je použití adaptivní filtrace v EKG datech pomocí informací z akcelerometru. Tato možnost byla analyzována a teoreticky popsána v kapitole 1.2. Druhým přístupem bylo přímé zpracování těchto dvou signálů. Byla analyzována a teoreticky popsána možnost detekce dvou poruch srdečního rytmu, konkrétně chronotropní inkompetence a nepřiměřené sinusové tachykardie.

6.2 Návrh metodiky pro analýzu vztahu EKG signálu a akcelerometru

Pro účely detekce chronotropní inkompetence a nepřiměřené sinusové tachykardie byla navržena konkrétní inovativní metodika, zahrnující oba analyzované přístupy. Metodika kombinuje adaptivní filtraci EKG signálu akcelerometrickým signálem, statistickou analýzu signálů, zpracování modely strojového učení a analýzu výstupních hodnot těchto modelů, filtrů a extrahovaných atributů z pozměněných signálů. Každý prvek metodiky přispívá ke zpřesnění a umožnění detekce stavů, jako je chronotropní inkompetence a nepřiměřená sinusová tachykardie. Jediným prvkem metodiky, který nebyl použit v praktické aplikaci, je korelační analýza. Tento blok byl nahrazen analýzou směrodatné odchylky mezi okamžitými hodnotami EKG signálu a jeho základní linií (0).

6.3 Vytvoření databáze vzorků pro trénování modelů strojového učení

Vytvořená databáze obsahovala 80 dní záznamů z přístroje Vivalink od 10 různých subjektů. Databáze zahrnovala jak záznamy signálů EKG a akcelerometru, tak i přiřazené hodnoty srdeční frekvence a časové značky. Očividným omezením této práce je vzorkovací frekvence signálu akcelerometru z přístroje Vivalink. Lze předpokládat, že s vyšší vzorkovací frekvencí, ideálně shodnou se vzorkovací frekvencí signálu

EKG, by bylo možné dosáhnout lepších a přesnějších výsledků při stanovení úrovně aktivity pacientů, filtrování signálů a predikci hodnot srdeční frekvence. Toto představuje vhodnou příležitost pro další výzkum v této oblasti.

6.4 Návrh a trénování modelů strojového učení

V této práci byly realizovány dva modely. Skrytý Markovův model pro stanovení úrovně aktivity subjektu a LSTM neuronová síť pro predikci hodnoty srdeční frekvence. Skrytý Markovův model byl naučen na neanotovaných datech. Využitím učení bez učitele byl model natrénován určovat úroveň aktivity pouze ze signálu akcelerometru. LSTM neuronová síť využívala učení s učitelem. Tímto způsobem se neuronová síť naučila predikovat očekávanou hodnotu srdeční frekvence.

6.4.1 Skrytý Markovův model a jeho evaluace

- **Nulová hypotéza (H_0):** Trénovaný model nevysvětluje testovací data lépe než simulovaná data.
- **Alternativní hypotéza (H_1):** Trénovaný model vysvětluje testovací data lépe než simulovaná data.

Pro potvrzení nebo zamítnutí nulové hypotézy byla použita technika bootstrap. Celkem v 10 000 iteracích byla generována simulovaná data se stejným rozdělením jako testovací data. Následně byly vypočítány hodnoty log-likelihood pro každý vzorek simulovaných dat a pro testovací data. Výsledná p-hodnota byla stanovena jako podíl simulovaných vzorků, kde hodnota log-likelihood byla větší než u testovacích dat.

- **Hladina významnosti (α):** 0.001
- **p-hodnota:** $<10^{-4}$

Zamítáme H_0 na hladině významnosti 0.001 a přijímáme H_1 .

- **Nulová hypotéza (H_0):** Trénovaný model nevysvětluje testovací data lépe než simulovaná data.
- **Alternativní hypotéza (H_1):** Trénovaný model vysvětluje testovací data lépe než simulovaná data.

Pro potvrzení nebo zamítnutí nulové hypotézy byla použita technika bootstrap. Celkem v 10 000 iteracích byla generována simulovaná data se stejným rozdělením jako testovací data. Následně byly vypočítány hodnoty log-likelihood pro každý vzorek simulovaných dat a pro testovací data. Výsledná p-hodnota byla stanovena jako podíl simulovaných vzorků, kde hodnota log-likelihood byla větší než u testovacích dat.

- **Hladina významnosti (α):** 0.01

- **p-hodnota:** $<10^{-4}$

Zamítáme H_0 na hladině významnosti 0.01 a přijímáme H_1 .

- **Nulová hypotéza (H_0):** Trénovaný model nevysvětluje testovací data lépe než náhodný model se stejným rozdělením jako testovací data.
- **Alternativní hypotéza (H_1):** Trénovaný model vysvětluje testovací data lépe než náhodný model se stejným rozdělením jako testovací data.

Pro potvrzení nebo zamítnutí nulové hypotézy byla opět použita technika bootstrap. Celkem v 1000 iteracích byly generovány simulované vzorky a na nich byly trénovány modely se stejnými parametry jako skutečný model. Následně byly vypočítány hodnoty log-likelihood pro každý náhodný model a skutečný model na testovacích datech. Výsledná p-hodnota byla stanovena jako podíl náhodných modelů s vyšší hodnotou log-likelihood než skutečný model.


- **Hladina významnosti (α):** 0.01
- **p-hodnota:** $<10^{-3}$
- **log-likelihood skutečného modelu:** 73301
- **průměrné log-likelihood náhodných modelů:** -380317

Zamítáme H_0 na hladině významnosti 0.01 a přijímáme H_1 .

Z provedených evaluačních testů a srovnáním s testovacími daty (kap. 4.2) lze stanovit, že přesnost modelu není náhodná a model rozpoznal nelineární závislosti v trénovacích a testovacích datech. Nicméně model měl i své nedostatky. Model měl tendenci vytvářet ostřejší hranice kolem nejčtetnějších úrovní signálu. Z toho vyplývá, že model nemohl rozeznat nejvyšší úroveň aktivity od vysoké. To naznačuje, že v datasetu bylo málo vzorků se subjekty vykonávajícími těžkou fyzickou aktivitu. Pro budoucí aplikaci by bylo vhodné zvážit větší dataset, ve kterém budou vyvážené všechny úrovně aktivity. Také lze zvážit jinou transformaci tříosového signálu místo techniky ENMO.

Po převodu úrovně aktivity do číselných hodnot bylo možné vidět (Obr. 4.6) pozitivní závislost mezi hodnotou srdeční frekvence a úrovní aktivity. Tato informace svědčila o neideální, ale dostačující přesnosti vytvořeného systému pro určení úrovně aktivity subjektu.

Realizace HMM modelu pro určení úrovně aktivity byla logickým pokračováním práce profesora Witowského a kol.[36]. Ve své práci profesor aplikoval podobné principy pro určení fyzické aktivity na simulovaných datech. Jednou z nezodpovězených otázek v závěru práce [36] bylo, jak přesně HMM model provede určení úrovně aktivity na reálných datech. Tato práce odpovídá na tuto otázku a rozšiřuje metodiku práce profesora Witowského o učení bez učitele místo učení na označených a simulovaných datech.



Obr. 6.1: Srovnání reálné srdeční frekvence (HR) v průběhu dne, srdeční frekvence predikované LSTM modelem a náhodně generované srdeční frekvence

6.4.2 LSTM neuronová síť a její evaluace

Evaluační metriky již byly popsány v kapitole 4.4.1. Nejzřetelnější interpretace přesnosti modelu byla určena pomocí hodnoty průměrné absolutní chyby (MAE). MAE se rovnala 7.98, což naznačuje, že průměrná absolutní chyba, do obou směrů od hodnoty, činila přibližně 8 úderů za minutu. Koeficient determinace modelu byl roven 0.58 a střední kvadratická chyba se rovnala 138. To naznačuje, že model se více chyboval pro vyšší hodnoty srdeční frekvence.

Přesnost modelu však byla považována za dostačující s ohledem na to, že původní dataset s velkou pravděpodobností obsahoval jak zdravé, tak i nemocné pacienty. Lepší hodnoty metrik by s velkou pravděpodobností naznačovaly přeučení modelu, protože v této aplikaci model musel predikovat pouze přibližnou očekávanou hodnotu, nikoliv patologickou, i když přesnou.

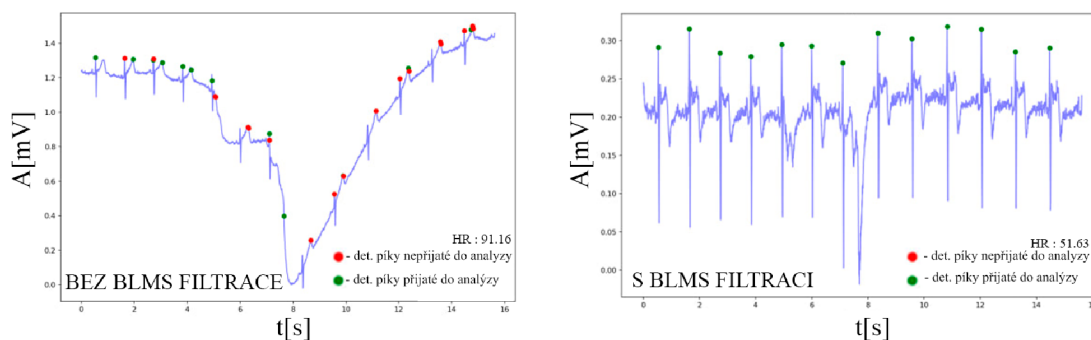
Dodatečně, evaluace proběhla na dalších testovacích datech. Testovací data od tohoto subjektu se nevyužívala pro trénování sítě. Na grafu (Obr.6.1) je zobrazeno srovnání reálných hodnot srdeční frekvence, hodnot predikovaných LSTM neuronovou sítí a hodnot generovaných náhodným modelem.

6.5 Vytvoření adaptivního BLMS filtru

Poměrně velkou částí práce bylo také vytvoření adaptivního BLMS filtru pro filtrování EKG signálu akcelerometrickým signálem. Tato filtrace byla nutná pro budoucí

určení hodnoty srdeční frekvence ze signálu EKG.

Filtrovací schopnosti BLMS filtru byly ověřeny na reálných záznamech EKG a akcelerometru. Výsledky filtrace byly popsány a ukázány v kapitole 4.5. Zda filtrování zpřesňuje určení R-píků a tím i stanovení srdeční frekvence, bylo ověřeno. Výsledky jsou představeny na grafech (Obr.6.1).



Obr. 6.2: Výsledky určení R-píků a stanovení srdeční frekvence s filtrací a bez filtrace

Evaluační metriky pro nefiltrovaný úsek EKG jsou následující:

- **True Positives (TP):** 4
- **False Positives (FP):** 6
- **False Negatives (FN):** 9
- **Senzitivita (Se):** 0.307
- **Pozitivní Prediktivní Hodnota (PPV):** 0.4

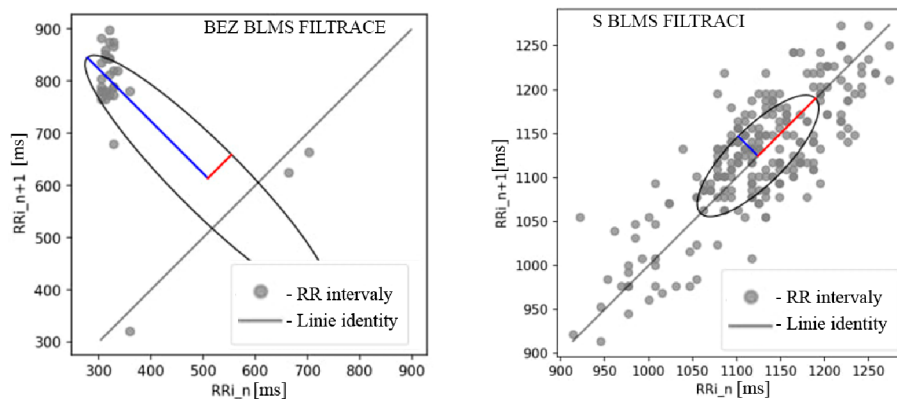
Pro úsek EKG po filtraci pak:

- **True Positives (TP):** 13
- **False Positives (FP):** 0
- **False Negatives (FN):** 0
- **Senzitivita (Se):** 1
- **Pozitivní Prediktivní Hodnota (PPV):** 1

Pro záznam EKG z celého dne evaluace a srovnání proběhlo pomocí Poincarého mapy (Obr. 6.2), kde rozptýl bodů kolem diagonály může indikovat chyby nebo nekonzistence v detekci R vrcholů. Pokud je detekce přesná, body na mapě tvoří úzký elipsovité útvar podél diagonály.

6.6 Metodika byla realizována v podobě Python aplikace

Vytvořená metodika a všechny modely byly použity v Python aplikaci. Aplikace přijímá na vstupu EDF soubor, extrahuje z něj signály a vytváří XML soubor s detekovanými symptomy, včetně jejich začátků a konců. Pro aplikaci byly vytvořeny



Obr. 6.3: Poincarého mapy RR intervalů pro denní záznam EKG s BLMS filtrací a bez BLMS filtrace

specifické funkce, z nichž každá realizuje určitou část této práce. Celý běh aplikace na procesoru *Intel Core i7 9700K 3.6 GHz 12MB* trvá přibližně 25 vteřin pro 13minutový záznam.

6.6.1 Evaluace detekce nepřiměřené sinusové tachykardie a chronotropní inkompetence

Pro nepřiměřenou sinusovou tachykardii jsou hypotézy následující:

- **Nulová hypotéza (H0):** Podíl nemocných v testovacím vzorku odpovídá referenčnímu podílu v populaci (5 %).
- **Alternativní hypotéza (H1):** Podíl nemocných v testovacím vzorku neodpovídá referenčnímu podílu v populaci (5 %).

Vzhledem k malé velikosti testovacího vzorku byla evaluace provedena pomocí binomického testu. Počet subjektů s detekovanou nepřiměřenou sinusovou tachykardií v testovacím vzorku byl 5 lidí z 11. Výsledná p-hodnota činila 0.0001. Zamítáme H_0 na hladině významnosti 0.05.

Je patrné, že pro datasetový vzorek a referenční hodnotu popsanou v kapitole 1.1 vytvořené řešení neprodukuje statisticky významné výsledky. Důležité je si uvědomit, že v datasetovém vzorku subjekty byli pacienti, kteří již měli podezření na nějakou poruchu srdečního rytmu. Nelze pak hodnotit navržené řešení jako neúspěšné. Pro přesnou evaluaci by bylo třeba vytvořit větší vzorek lidí ze standardní populace a zopakovat test.

Pro chronotropní inkompetenci jsou hypotézy následující:

- **Nulová hypotéza (H0):** Podíl nemocných v testovacím vzorku odpovídá referenčnímu podílu v nemocné populaci (60 %)[17].

- **Alternativní hypotéza (H1):** Podíl nemocných v testovacím vzorku neodpovídá referenčnímu podílu v nemocné populaci (60 %)[17].

Pro potvrzení nebo zamítnutí nulových hypotéz byl použit binomický test. Počet subjektů s detekovanou chronotropní inkompetencí v testovacím vzorku byl 6 lidí z 11. Výsledná p-hodnota činila 0.7635. Nezamítáme H_0 na hladině významnosti 0.05. To znamená, že výsledky pro detekci chronotropní inkompetence v datasetovém vzorku odpovídají referenčním hodnotám. Pro potvrzení výsledků a přesnější evaluaci by testování mělo být provedeno na větším vzorku.

Závěr

Tato práce byla zaměřená na analýzu a detekci poruch srdečního rytmu, konkrétně chronotropní inkompetence a nepřiměřené sinusové tachykardie, pomocí kombinace EKG a akcelerometrického signálu. Byly identifikovány dva hlavní přístupy: adaptivní filtrace EKG signálu za použití informací z akcelerometru a přímé zpracování obou signálů. Na základě těchto přístupů byla vyvinuta komplexní a inovativní metodika, která zahrnovala adaptivní filtraci, statistickou analýzu, využití modelů strojového učení a analýzu výstupních hodnot.

Pro realizaci metodiky byl vytvořen dataset vzorků obsahující záznamy z přístroje Vivalink. Tento dataset byl následně využit pro trénink a evaluaci dvou modelů strojového učení: Skrytého Markovova modelu pro stanovení úrovně aktivity a LSTM neuronové sítě pro predikci srdeční frekvence. Výsledky ukázaly, že oba modely byly schopny dosáhnout určité míry přesnosti, přičemž model HMM prokázal schopnost rozpoznat nelineární závislosti v datech a model LSTM predikoval hodnoty srdeční frekvence s přijatelnou průměrnou absolutní chybou.

Kromě toho byl vyvinut adaptivní BLMS filtr pro filtrování EKG signálu, jehož účinnost byla ověřena na reálných datech. Filtrování vedlo ke zvýšení přesnosti detekce R-píků a následného určení srdeční frekvence, což je klíčové pro spolehlivou analýzu srdečního rytmu.

Aplikace vyvinutá v rámci této práce umožňuje automatizovanou detekci symptomů srdečních poruch a poskytuje uživateli výsledky ve formě XML souboru. Výsledky detekce nepřiměřené sinusové tachykardie a chronotropní inkompetence byly statisticky evaluovány a ukázaly, že i přes některé limity v datasetu má metodika potenciál pro praktické využití. Pro budoucí výzkum by bylo vhodné zvýšit vzorkovací frekvenci akcelerometru a provést trénování s následujícím testováním na větším a diverzifikovanějším vzorku populace.

Závěrem lze konstatovat, že vyvinutá metodika a její implementace má potenciál přinést posun v možnostech detekce poruch srdečního rytmu pomocí kombinace EKG a akcelerometrických signálů. Tento přístup otevírá nové možnosti pro neinvazivní monitorování a diagnostiku srdečních poruch v reálném čase.

Literatura

- [1] SWEENEY Kevin T.; MITCHELL Edmond; GAU Jennifer; KANE Thomas; COSTELLO Richard et al. *Identification of sleep apnea events using discrete wavelet transform of respiration, ECG and accelerometer signals*. IEEE International Conference on Body Sensor Networks. 2013. s. 1-6. DOI: 10.1109/BSN.2013.6575488.
- [2] ZWEERINK Alwin; VAN DER LINGEN Anne-Lotte C.J.; HANDOKO M. Louis; VAN ROSSUM Albert C.; ALLAART Cornelis P. *Chronotropic Incompetence in Chronic Heart Failure*. Europace. 2018. s. 11. DOI: 10.1161/CIRCHEARTFAILURE.118.004969.
- [3] OLSHANSKY B.; SULLIVAN RM. *Inappropriate sinus tachycardia*. Circulation: Heart Failure. 2019. s. 21, 194–207. DOI: 10.1016/j.jacc.2012.07.074.
- [4] OLSHANSKY B.; SULLIVAN RM. *Natural history and clinical outcomes of inappropriate sinus tachycardia*. Journal of Cardiovascular Electrophysiology. 2019. s. 137-143. DOI: 10.1111/jce.14288.
- [5] SHELDON RS.; GRUBB 2nd BP.; OLSHANSKY B.; et al. *Heart Rhythm Society expert consensus statement on the diagnosis and treatment of postural tachycardia syndrome, inappropriate sinus tachycardia, and vasovagal syncope*. Heart Rhythm. 2015. s. 12, e41–63. DOI: 10.1016/j.hrthm.2015.03.029
- [6] BRAUNWALD E.; LIBBY P. *Supraventricular Tachycardias*. In Braunwald's heart disease: a textbook of Cardiovascular Medicine (12th ed., pp. 1251–1252). Elsevier. 2022. ISBN 9780323722193.
- [7] STILL Aino-Maija; RAATIKAINEN Pekka; YLITALO Antti; KAUMA Heikki; IKÄHEIMO Markku; KESÄNIEMI Y. Antero; HUIKURI Heikki V. *Prevalence, characteristics and natural course of inappropriate sinus tachycardia*. EP Europace. 2005. Volume 7, Issue 2, Pages 104–112. DOI: 10.1016/j.eupc.2004.12.007.
- [8] BRADY PA.; LOW PA.; SHEN WK. *Inappropriate sinus tachycardia, postural orthostatic tachycardia syndrome, and overlapping syndromes*. Pacing and Clinical Electrophysiology. 2005. s. 28, 1112–1121.
- [9] ELLESTAD Myrvin H. *Chronotropic Incompetence*. 1996. DOI: 10.1161/01.CIR.93.8.1485.
- [10] DIMOPOULOS Konstantinos; ALONSO-GONZALEZ Rafael; D'ALTO Michele. *Heart Failure, Exercise Intolerance, and Physical Training*. In: Gatzoulis,

- M. A., Webb, G. D., Daubeney, P. E. F., editors. *Diagnosis and Management of Adult Congenital Heart Disease (Third Edition)*. Elsevier. 2018. s. 77-87. ISBN 9780702069291. DOI: 10.1016/B978-0-7020-6929-1.00007-1.
- [11] KITZMAN DW. *Exercise intolerance*. Prog Cardiovasc Dis. 2005. s. 47, 367–379. DOI: 10.1016/j.pcad.2005.02.002.
- [12] HIGGINBOTHAM MB.; MORRIS KG.; MCHALE PA.; COLEMAN RD.; COBB FR.; WILLIAMS RS. *Regulation of stroke volume during submaximal and maximal upright exercise in normal man*. Circ Res. 1986. s. 58, 281–291. DOI: 10.1161/01.RES.58.2.281.
- [13] HIGGINBOTHAM MB.; MORRIS KG.; WILLIAMS RS. *Physiologic basis for the age-related decline in aerobic work capacity*. Am J Cardiol. 1986. s. 57, 1374–1379. DOI: 10.1016/0002-9149(86)90221-3.
- [14] BRUBAKER Peter H.; KITZMAN Dalane W. *Chronotropic Incompetence: Causes, Consequences, and Management*. Circulation. 2011. s. 123, 1010–1020. DOI: 10.1161/CIRCULATIONAHA.110.940577.
- [15] WILKOFF Bruce L.; MILLER Raymond E. *Exercise Testing for Chronotropic Assessment*. Cardiology Clinics. 1992. Volume 10, Issue 4, Pages 705-717. ISSN 0733-8651. DOI: 10.1016/S0733-8651(18)30211-X.
- [16] GULATI Martha.; et al. *Heart rate response to exercise stress testing in asymptomatic women: the St. James women take heart project*. Circulation. 2010. s. 122, 130-137.
- [17] COMAN JAMES M.D.; FREEDMAN ROGER M.D.; KOPLAN BRUCE A. M.D.; et al. *A Blended Sensor Restores Chronotropic Response More Favorably than an Accelerometer Alone in Pacemaker Patients: The LIFE Study Results*. Pacing Clin Electrophysiol. 2008. s. 11, 1442. DOI: 10.1111/j.1540-8159.2008.01207.x.
- [18] BRAWNER Clinton A.; EHRMAN Jonathan K.; SCHAIRER John R.; CAO Jie J.; KETEYIAN Steven J. *Predicting maximum heart rate among patients with coronary heart disease receiving -adrenergic blockade therapy*. American Heart Journal. 2004. s. 910-914. DOI: 10.1016/j.ahj.2004.04.035.
- [19] HUANG Miao.; CHEN Dongyi.; XIONG Fan. *An Effective Adaptive Filter to Reduce Motion Artifacts from ECG Signals Using Accelerometer*. Association for Computing Machinery. 2019. s. 83–88. DOI: 10.1145/3326172.3326214.

- [20] BERWAL D.; C.R. V.; DEWAN S.; C.V. J.; BAGHINI M. S. *Motion Artifact Removal in Ambulatory ECG Signal for Heart Rate Variability Analysis*. IEEE Sensors Journal. 2019. s. 12432-12442. DOI: 10.1109/JSEN.2019.2939391.
- [21] SENTHILNATHAN Samithamby. *Usefulness of Correlation Analysis*. Social Science Research Network. 2019. DOI: 10.2139/ssrn.3416918.
- [22] GOGTAY NJ.; THATTE UM. *Principles of Correlation Analysis*. Journal of The Association of Physicians of India. 2017. s. 78-81.
- [23] HAN D. K.; HONG J. H.; SHIN J. Y.; LEE T. S. *Accelerometer based motion noise analysis of ECG signal*. World Congress on Medical Physics and Biomedical Engineering. 2009. s. 198–201. DOI: 10.1007/978-3-642-03904-1_56.
- [24] LEE Song-Mi; YOON Sang Min; CHO Heeryon. *Human activity recognition from accelerometer data using Convolutional Neural Network*. International conference on big data and smart computing (bigcomp). 2017. s. 131-134. DOI: 10.1109/BIGCOMP.2017.7881728.
- [25] HUSI Holger. *Computational biology*. Codon Publications. 2019. ISBN-13: 978-0-9944381-9-5.
- [26] MACEACHERN Sarah J.; FORKERT Nils D. *Machine learning for precision medicine*. Genome. 2021. s. 64(4), 416-425. DOI: 10.1139/gen-2020-0131.
- [27] YOON Dukyong.; et al. *Discovering hidden information in biosignals from patients using artificial intelligence*. Korean journal of anesthesiology. 2020. s. 73(4), 275-284. DOI: 10.4097/kja.19475.
- [28] ZOU James.; et al. *A primer on deep learning in genomics*. Nature genetics. 2019. s. 51(1), 12-18. DOI: 10.1038/s41588-018-0295-5.
- [29] FRANZESE Monica; IULIANO Antonella. *Hidden Markov Models*. Academic Press. 2019. s. 753-762. DOI: 10.1016/B978-0-12-809633-8.20488-3.
- [30] TRAN Ke; BISK Yonatan; VASWANI Ashish; MARCU Daniel; KNIGHT Kevin. *Unsupervised Neural Hidden Markov Models*. arXiv preprint. 2016. DOI: arXiv:1609.09007.
- [31] CHING Wai-Ki; HUANG Ximin; NG Michael K.; SIU Tak-Kuen. *Markov Chains: Models, Algorithms and Applications*. Springer New York, NY. 2013. DOI: 10.1007/978-1-4614-6312-2.
- [32] RABINER Lawrence R. *A tutorial on hidden Markov models and selected applications in speech recognition*. Proceedings of the IEEE. 1989. s. 77(2), 257-286.

- [33] BILMES Jeff A. *A gentle tutorial of the EM algorithm and its application to parameter estimation for Gaussian mixture and hidden Markov models*. 1998.
- [34] STAMP Mark. *A revealing introduction to hidden Markov models*. Tech. rep. Department of Computer Science, San Jose State University. 2018. Za odkazem: <https://www.cs.sjsu.edu/stamp/RUA/HMM.pdf>
- [35] BAKRANIA Kishan; YATES Thomas; ROWLANDS Alex V.; ESLIGER Dale W.; BUNNEWELL Sarah; SANDERS James; DAVIES Melanie; KHUNTI Kamlesh; EDWARDSON Charlotte L. *Intensity Thresholds on Raw Acceleration Data: Euclidean Norm Minus One (ENMO) and Mean Amplitude Deviation (MAD) Approaches*. PLOS ONE. 2016. 11(10). DOI: 10.1371/journal.pone.0164045
- [36] WITOWSKI V.; FORAITA R.; PITSILADIS Y.; PIGEOT I.; WIRSIK N. *Using Hidden Markov Models to Improve Quantifying Physical Activity in Accelerometer Data – A Simulation Study*. PLOS ONE. 2014. 9(12). DOI: 10.1371/journal.pone.0114089
- [37] SAHOO Bibhuti Bhusan; JHA Ramakar; SINGH Anshuman; KUMAR Deepak. *Long short-term memory (LSTM) recurrent neural network for low-flow hydrological time series forecasting*. Research Article - Hydrology. 2019. s. 1471–1481. DOI: 10.1007/s11600-019-00330-1
- [38] DOBILAS Saul. *LSTM Recurrent Neural Networks — How to Teach a Network to Remember the Past*. Towards Data Science - Medium. 2022.

Seznam symbolů a zkratek

ACC	Signál z akcelerometru
EKG	Elektrokardiografie
BLMS	Blokový algoritmus nejmenších čtverců
SVM	Velikost signálového vektoru
LMS	Algoritmus nejmenších čtverců
NST	Nepřiměřená sinusová tachykardie
AMPHR	Age-Predicted Maximum Heart Rate (věkem předpovídaná maximální srdeční frekvence)
LSTM	Long Short-Term Memory (Dlouhá krátkodobá paměť)
TP	True Positives
FP	False Positives
FN	False Negative
Se	Senzitivita
PPV	Pozitivní Prediktivní Hodnota

Seznam příloh

A Tabulky	75
B Obsah elektronické přílohy	77

A Tabulky

Tab. A.1: Algoritmy používané pro odstranění pohybových artefaktů[20]

Základní algoritmus	Operace	Omezení
Adaptivní Rekurentní Filtr	Tento způsob upravuje filtrační koeficienty při každém výskytu signálového komplexu, aby získal požadovanou impulzovou odezvu minimalizací střední kvadratické chyby mezi hlavním a referenčním signálem. Odstraňuje rušení elektrické sítě a základní šumy spolu s pohybovými artefakty.	Referenční impuls musí být přesně shodný se signálovým komplexem, jinak může zkreslit tvar signálu.
Least Mean Square	Dvoustupňová adaptivní filtrace je schopna měnit krok velikosti podle úrovně šumu pro přesnou eliminaci šumu bez zkreslení EKG komponenty.	Některé složky nízké frekvence nebyly úplně odstraněny.
Normalizovaný Least Mean Square	Tato fúzní metoda používá výstupy senzorů akcelerometru a gyroskopu k adaptivnímu odstranění pohybového artefaktu ze signálu EKG.	Některé náhodné pohyby nebyly touto metodou odstraněny a vyžaduje další senzory pro odstranění pohybového artefaktu.
Diskrétní Vlnková Transformace (Meyerova)	Použití DWT pro potlačení EMG a MA pomocí měkkých a tvrdých prahů a nulování desáté dekomponované aproximace koeficientů.	Šum/pohybový artefakt nebyl úplně odstraněn.
Diskrétní Vlnková Transformace (Daubechies)	Aplikuje DWT s různými prahy pro lepší poměr Signál-k-Šum pro odstranění pohybového artefaktu.	Metoda selhala při odstranění artefaktů, které měly spektrální překryv s EKG signálem.
Stacionární Vlnková Transformace (Haa-rova)	Odhad pohybového artefaktu je získán odstraněním QRS komplexů a aplikací prahování na různých úrovních SWT dekompozice a poté odečtením od původního EKG.	Tato metoda nefunguje, když je EKG signál ovlivněn nízkofrekvenčním i vysokofrekvenčním pohybovým artefaktem.
Stacionární Vlnková Transformace (Haa-rova)	Odstraňuje QRS komplex, P a T vlny z EKG signálu ovlivněného pohybem pomocí prahování založeného na energii QRS komplexu a mediánových hodnotách lokálních maxim a minim. Poté je pohybový artefakt odečten od původního signálu.	Někdy nedetekuje QRS vrchol EKG signálu, takže korelace faktoru je menší.
Nezávislá Komponentní Analýza	Tato metoda je používána pro oddělení nezávislých komponent z více EKG signálů a nalezení nejvyšší kurtózy v původním signálu pro odstranění artefaktů a šumu.	Vyžaduje více dat pro zpracování a není zaručeno, že čistý EKG signál je jeden z nezávislých komponentů.
Detekce vrcholů a metoda posuvného průměru	Metoda detekce vrcholů QRS založená na pohybovém artefaktu nejdříve zjišťuje vrcholy QRS, pak tyto artefakty odstraňuje pomocí průměrů, které detekují nízkofrekvenční pohybové artefakty pomocí mediánových hodnot místních maxim a minim. Poté je pohybový artefakt odečten od původního signálu.	Mění morfologii EKG signálu a nezahrnuje nezávislou komponentní analýzu pro odstranění pohybového artefaktu.

B Obsah elektronické přílohy

Níže je uveden obsah elektronické přílohy se zdrojovými kódy. Před spuštěním je důležité, aby všechny knihovny odpovídaly požadavkům popsaným v souboru *requirements.txt*. Program byl napsán a otestován v programovacím jazyce *Python 3.10*. Doporučuje se spouštět program prostřednictvím spustitelného souboru *.exe* dostupného ke stažení přes odkaz: https://github.com/Borysi/arrhythmia_detector.git. Tento soubor nebyl přiložen k práci práce z důvodu své velikosti.

```
/.....kořenový adresář přiloženého archivu
├── main_program_source.....zdrojové skripty finálního programu
│   ├── LSTM.....Soubory pro běh LSTM neuronové sítě
│   │   ├── LSTM_NN.keras
│   │   ├── scaler_X.sav
│   │   ├── scaler_Y.sav
│   │   ├── scaler_ymean.sav
│   │   └── scaler_Z.sav
│   ├── viva_healthy.edf ..... Vzorový EDF záznam
│   ├── viva_NST_with_Chrono.edf ..... Vzorový EDF záznam
│   ├── activity_recoq.py
│   ├── blms_filtering.py
│   ├── create_xml.py
│   ├── des_tree.py
│   ├── HMM_prediction.py
│   ├── HR_detection.py
│   ├── LSTM_predict.py
│   ├── main.py ..... Hlavní soubor pro běh programu
│   ├── openedf.py
│   ├── resample.py
│   ├── start_end_symptoms.py
│   ├── hmm_model_full_enmo_e3_1000iter_non0.pkl
│   ├── README.txt
│   ├── requirements.txt
│   ├── symptoms_viva_healthy.xml.....Detekované symptomy pro vzorový záznam
│   └── symptoms_viva_NST_with_Chrono.xml ... Detekované symptomy pro vzorový
│       záznam
├── making_dataset ..... PHP skript pro vytvoření datasetu
│   └── Parse_acc_data_Vivalink_V01.php
└── LSTM_HMM_training..... Skripty používané pro trénování modelů
    ├── HMM_train.py
    └── LSTM_train.py
```