

Západočeská univerzita v Plzni
Fakulta aplikovaných věd
Katedra kybernetiky

BAKALÁŘSKÁ PRÁCE

PLZEŇ, 2016

ONDŘEJ HAVLÍČEK

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Ondřej HAVLÍČEK**
Osobní číslo: **A13B0609P**
Studijní program: **B3918 Aplikované vědy a informatika**
Studijní obor: **Kybernetika a řídicí technika**
Název tématu: **Rozpoznávání pohybových aktivit osob pomocí senzorů z mobilních telefonů s operačním systémem Android**
Zadávací katedra: **Katedra kybernetiky**

Z á s a d y p r o v y p r a c o v á n í :


1. Seznamte se se současným stavem monitorování pohybových aktivit pomocí inerciálních senzorů.
2. Prozkoumejte možnosti monitorování pohybových aktivit osob pomocí "chytrých" telefonů. Zvláštní důraz věnujte možnosti identifikace nežádoucích pohybů (pád, záchvat, ...).
3. Navrhněte algoritmus pro rozpoznání epileptického záchvatu dětí během spánku a jeho implementaci do mobilního telefonu s operačním systémem Android. Pro rozpoznání záchvatu použijte klasifikační metody založené na frekvenční analýze naměřeného signálu.
4. Vyvinutý algoritmus ověřte na vhodném testovacím zařízení.

Rozsah grafických prací: dle potřeby
Rozsah kvalifikační práce: 30-40 stránek A4
Forma zpracování bakalářské práce: tištěná
Seznam odborné literatury:

BEHAR, Joachim, Aoife ROEBUCK, Mohammed SHAHID, Jonathan DALY, Andre HALLACK, Niclas PALMIUS, John STRADLING a Gari D. CLIFFORD. SleepAp: An Automated Obstructive Sleep Apnoea Screening Application for Smartphones. IEEE Journal of Biomedical and Health Informatics [online]. 2015, 19(1): 325-331 [cit. 2015-10-07]. DOI: 10.1109/jbhi.2014.2307913.
BAYAT, Akram, Marc POMPLUN a Duc A. TRAN. A Study on Human Activity Recognition Using Accelerometer Data from Smartphones. Procedia Computer Science [online]. 2014, 34: 450-457 [cit. 2015-10-07]. DOI: 10.1016/j.procs.2014.07.009.
BUJARI, Armir, Bogdan LICAR a Claudio E. PALAZZI. Movement pattern recognition through smartphone's accelerometer. In: 2012 IEEE Consumer Communications and Networking Conference (CCNC)[online]. 2012 [cit. 2015-10-07]. DOI: 10.1109/ccnc.2012.6181029.
MEDNIEKS, Zigurd R. Programming Android. 2nd ed. Beijing: O'Reilly, c2012, xvii, 542 s. ISBN 9781449316648.
MILETTE, Greg a Adam STROUD. Professional Android sensor programming. Hoboken, N.J.: Wiley, c2012, xxxiii, 517 p. ISBN 978-1-118-26505-5.

Vedoucí bakalářské práce: Prof. Ing. Miloš Schlegel, CSc.
Katedra kybernetiky

Datum zadání bakalářské práce: 1. listopadu 2015
Termín odevzdání bakalářské práce: 13. května 2016


Doc. RNDr. Miroslav Lávička, Ph.D.
děkan




Prof. Ing. Josef Psutka, CSc.
vedoucí katedry

V Plzni dne 30. října 2015

Prohlášení

Předkládám tímto k posouzení a obhajobě bakalářskou práci zpracovanou na závěr studia na Fakultě aplikovaných věd Západočeské univerzity v Plzni.

Prohlašuji, že jsem bakalářskou práci vypracoval samostatně a výhradně s použitím odborné literatury a pramenů, jejichž úplný seznam je její součástí.

V Plzni dne

.....

vlastnoruční podpis

Poděkování

Tímto bych rád poděkoval vedoucímu mé bakalářské práce, panu prof. Ing. Miloši Schlegelovi, CSc., za jeho odborné vedení, za podnětné návrhy k práci, za čas, který mi byl ochoten věnovat, a za jeho schopnost mě vždy motivovat dalšímu zkoumání daného problému. Dále bych také rád poděkoval mé rodině za to, že mi poskytla výborné zázemí pro studium na vysoké škole a psaní této bakalářské práce.

Abstrakt

Tato práce se zabývá vlastnostmi měření na systému Android. Rozebírá několik možností, jak lze využít inerciálních senzorů v mobilních telefonech k rozpoznávání pohybových aktivit člověka.

Je zde popsáno několik vědeckých prací, které demonstrují možnosti využití inerciálních senzorů v mobilních telefonech. Například aplikace detekující spánkové cykly, aplikace detekující obstrukční spánkovou apnoe nebo náramek, který detekuje epileptické záchvaty uživatele.

Dále jsou zde rozebrány možnosti a skutečné vlastnosti senzorů, které nabízí systém Android.

Potom je diskutován návrh algoritmu pro detekci epileptických záchvatů. Jsou zde uvedeny grafy s naměřenými hodnotami od skutečných pacientů s epileptickými záchvaty a jejich analýza.

Na závěr jsou testovány schopnosti mobilního telefonu detekovat různé frekvence ze signálu získaného z akcelerometru. Mobilní akcelerometr je porovnáván s průmyslovým akcelerometrem od firmy Kistler.

Klíčová slova: android, inerciální senzory, epilepsie, záchvat, spánek

Abstract

The thesis deals with characteristics of measuring on the Android system. It analyses a few options of using inertial sensors in mobile phones to detect human physical activity.

It describes several scientific works which demonstrates some ways of using inertial sensors in mobile phones. For example applications detecting sleep cycles, obstructive sleeping apnea or a bracelet detecting epileptic fit of the user.

Furthermore there are examined capabilities and real characteristics of the sensors which are offered by Android system.

Then there is discussed a project of algorithm for detecting epileptic fit including charts with measured values of real patients suffering from epileptic fits and their analysis.

Finally capabilities of a mobile phone have been tested to detect various frequency rates received from accelerometer signal. Mobile accelerometer is compared with industrial accelerometer made by Kistler company.

Keywords: android, inercial sensors, epilepsi, seizure, sleep

Obsah

1	Úvod	1
1.1	Struktura bakalářské práce	1
1.2	Použité matematické aparáty	2
1.2.1	Diskrétní Fourierova transformace	2
1.2.2	Lineární interpolace	2
1.2.3	Dominantní frekvence signálu	3
1.2.4	Energie a efektivní hodnota signálu	3
2	Současný stav monitorování pohybových aktivit	4
2.1	Aplikace rozpoznávající typ činnosti uživatele	4
2.2	Aplikace detekující spánkové cykly	6
2.2.1	Spánkový cyklus	6
2.2.2	Algoritmus	6
2.2.3	Výsledky	7
2.3	Aplikace pro detekci obstrukční spánkové apnoe	7
2.3.1	Obstrukční spánková apnoe	7
2.3.2	Současný stav	7
2.3.3	Detekce OSA vyvinutá Behar et al.	8
2.3.4	Detekce OSA vyvinutá Al-Mardini et al.	9
2.4	Aplikace detekující epileptické záchvaty pomocí akcelerometru a elektrodermální aktivity	10
2.4.1	Způsob měření	11
2.4.2	Redukce dat	11
2.4.3	Extrakce vlastností po redukci dat	12
2.4.4	Shrnutí	12
3	Vlastnosti měření na systému Android	13
3.1	Senzory	13
3.2	Deklarované vlastnosti akcelerometru	14
3.3	Deklarované vlastnosti lineárního akcelerometru	15
3.4	Reálné naměřené vzorkovací frekvence	16

3.4.1	Chyba vzorkovací frekvence v čase	16
3.4.2	Akcelerometr	17
3.4.3	Lineární akcelerometr	17
3.5	Schopnost detekovat frekvence o různé amplitudě	17
4	Epilepsie	19
4.1	Praktická definice epilepsie	19
4.2	Epileptický záchvat	19
4.2.1	Dělení epileptických záchvatů	20
4.2.2	Popis častých druhů epileptických záchvatů	20
4.3	Shrnutí	21
5	Analýza naměřených dat	22
5.1	Naměřená data v klidu	22
5.2	Naměřená data při převalování na posteli	23
5.3	Naměřená data při simulovaném epileptickém záchvatu	26
5.4	Naměřená data skutečného epileptického záchvatu	26
5.4.1	Způsob měření	26
5.4.2	Naměřená data	28
5.5	Analýza umístění telefonu	36
6	Algoritmus a programování aplikace	38
6.1	Navrhnutý algoritmus	38
6.1.1	Redukce dat	38
6.1.2	Algoritmus - Zpracování dat	38
6.1.3	Princip klasifikace	39
6.2	Programování aplikace	39
7	Testování aplikace	40
7.1	Měření	40
7.2	Záznamy v signálu	40
7.3	Výsledky měření	43
7.3.1	1. Měření - 1 Hz	43
7.3.2	2. Měření - 5 Hz	43
7.3.3	3. Měření - 10 Hz	47
7.3.4	4. Měření - 1 Hz, 5 Hz a 10 Hz	47
7.3.5	5. Měření - 1 Hz, 2 Hz a 3 Hz	47
7.4	Nedetekování nízkých frekvencí	50
7.5	Shrnutí	50
8	Závěr	52

Kapitola 1

Úvod

V dnešní době používá chytré telefony kolem 60 % obyvatel České republiky [5] a díky zabudovaným sensorům mají chytré telefony téměř neomezené možnosti využití. Tato práce pojednává o několika možných využití sensorů v chytrých telefonech a také vyhodnocuje schopnosti měření pomocí těchto sensorů.

1.1 Struktura bakalářské práce

V první kapitole jsou sepsány poznámky k použitým pojmům a značením, které byly v rámci této bakalářské práce použity.

V druhé kapitole je popsáno několik prací, které demonstrují možnosti využití inerciálních sensorů. První práce se zabývá aplikací pro mobilní telefony, která detekuje spánkové cykly a umožňuje tak uživatelům lépe vstávat. Další práce se zabývají detekcí obstrukční spánkové apnoe (OSA), což je porucha dýchání vázaná na spánek [13]. A nakonec je popsána dizertační práce, která se zabývá návrhem algoritmu pro detekci epileptických záchvatů uživatele a návrhem náramku se senzory pro záznam elektrodermální aktivity a aktigrafie (záznam z akcelerometru), na který by byl tento algoritmus implementován.

Ve třetí kapitole jsou popsány možnosti, které nabízí systém Android pro měření pomocí zabudovaných sensorů. Dále jsou zde popsány skutečné vzorkovací frekvence telefonu oproti deklarovaným, potom také je zde diskutována spolehlivost vzorkování na systému Android a na závěr je zde popsána závislost schopnosti detekovat různé frekvence o různé amplitudě na různých senzorech.

Ve čtvrté kapitole je stručně popsána nemoc epilepsie a s ní související epileptické záchvaty. Cílem bylo učinit tento odstavec co nejstručnější a popsat jen skutečně informace, které jsou potřeba vědět k problému detekce epileptických záchvatů.

V páté kapitole je provedena analýza naměřených dat, která byla naměřena na pacientech trpícími epileptickými záchvaty. Jsou zde popsány různé způsoby měření, jejich výhody a nevýhody.

V šesté kapitole je stručně naznačen algoritmus, jak byla aplikace naprogramována. Autor zveřejňuje zdrojové kódy pod licencí Apache license, verze 2.0, takže si čtenář může kódy projít a popřípadě využít. Zdrojové kódy jsou přiloženy na CD, které je součástí této práce.

V sedmé kapitole jsou prezentovány výsledky testování akcelerometru v mobilním telefonu. Akcelerometr v mobilním telefonu byl porovnán s průmyslovým akcelerometrem od firmy Kistler model 8640A50. Jsou zde analyzovány schopnosti telefonu rozpoznat určité pohybové frekvence a porovnány se schopnostmi speciálního průmyslového akcelerometru.

1.2 Použité matematické aparáty

1.2.1 Diskrétní Fourierova transformace

Definice použité DFT diskrétního signálu $x[k] \in \mathbb{R}$ s N prvky:

$$y[n] = \sum_{k=0}^{N-1} x[k] e^{-i \frac{2\pi}{N} nk} \quad (1.1)$$

A inverzní Fourierova transformace:

$$x[k] = \frac{1}{N} \sum_{n=0}^{N-1} y[n] e^{i \frac{2\pi}{N} nk} \quad (1.2)$$

1.2.2 Lineární interpolace

Lineární interpolace byla použita pro stejnoměrné navzorkování signálu, jelikož systém Android negarantuje, aby vzorkovací perioda byla konstantní.

Lineární interpolace signálu probíhala následovně. Byla zjištěna perioda vzorkování T_s vydělením celkové doby měření T počtem naměřených hodnot o 1 zmenšenou, protože mezi N naměřenými hodnotami je $N - 1$ period viz rovnice (1.3).

$$T_s = \frac{T}{N - 1} \quad (1.3)$$

Následně byl vygenerován časový vektor s N prvky vzdálených od sebe dle vzorkovací periody T_s . Pro každý prvek t_i časového vektoru byla pak následně spočtena funkční hodnota f_i dle vzorce (1.4).

$$f_i = y_n + (y_{n+1} - y_n) \frac{t_i - x_n}{x_{n+1} - x_n}, \quad (1.4)$$

kde t je hodnota časového vektoru, y_n je funkční hodnota naměřeného signálu v čase x_n a y_{n+1} je funkční hodnota naměřeného signálu v čase x_{n+1} . Přičemž platí $x_n < x_{n+1}$ a $t_i \in [x_n, x_{n+1}]$. Závorky $[]$ znamenají uzavřený interval.

1.2.3 Dominantní frekvence signálu

V této práci je pojem dominantní frekvence definována následovně.

Nechť existuje konečná komplexní posloupnost o velikosti N , reprezentující diskrétní Fourierovu transformaci (1.1) reálného signálu se vzorkovací frekvencí f_s . Tato posloupnost je značena $x[n] \in \mathbb{C}$. Dominantní frekvenci se určí tak, že se spočte absolutní hodnota každého komplexního čísla $x[n]$ čímž je získána reálná posloupnost $y[n]$ (1.5).

$$y[n] = |x[n]| \quad (1.5)$$

Z této reálné posloupnosti pak určen index n_{max} maximální hodnoty, reprezentující normalizovanou maximální frekvenci (1.6).

$$n_{max} = \arg \max(y[n]) \quad (1.6)$$

Dominantní frekvenci pak spočtena dle vzorce

$$f_{dom} = \frac{f_s \cdot n_{max}}{N} \quad (1.7)$$

Pokud byl reálný signál, ze kterého vznikla posloupnost $x[n]$, vzorkován v čase, pak je dominantní frekvence f_{dom} v Hz.

1.2.4 Energie a efektivní hodnota signálu

Spojité definice

Energie obecného signálu $x(t)$ je definována jako (1.8)

$$E = \int_{-\infty}^{\infty} |x(t)|^2 dt \quad (1.8)$$

Diskrétní definice

Energie diskrétního signálu $x[n]$ se vzorkovací periodou T_s je definována jako (1.9)

$$E = T_s \sum_{n=-\infty}^{\infty} |x[n]|^2 \quad (1.9)$$

Efektivní hodnota

$$x_{ef} = \sqrt{\lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T |x(t)|^2 dt} \quad (1.10)$$

Kapitola 2

Současný stav monitorování pohybových aktivit

V této kapitole jsou popsány různé způsoby využití inerciálních senzorů v mobilních telefonech. Jsou zde zmíněny aplikace monitorující člověka celý den pomocí inerciálních senzorů, které pak následně klasifikují jaké pohybové aktivity dělal během dne. Dále bude popsána aplikace pozorující spánek uživatele pomocí inerciálních a jiných mobilních senzorů, díky čemuž aplikace dokáže stanovit optimální dobu buzení. Nakonec budou popsány aplikace, které pozorují spánek uživatele, avšak jejich úkol není stanovit optimální dobu buzení, ale určit, jestli uživatel netrpí nemocí zvanou obstrukční spánková apnoe (OSA).

2.1 Aplikace rozpoznávající typ činnosti uživatele

Vědcům z University of Massachusetts [2] se podařilo vytvořit mobilní aplikaci, která dokáže pomocí inerciálních senzorů rozpoznávat denní aktivity uživatele. Klasifikaci aktivit rozdělili do dvou případů umístění telefonu. První případ je, když telefon držen v ruce, a druhý je, když se telefon nachází v kapse. Aplikace rozpoznává následující druhy aktivit.

- Pomalá chůze
- Rychlá chůze
- Běh
- Pohyb po schodech nahoru
- Pohyb po schodech dolů
- Tanec (Aerobik)

Tabulka 2.1: Výsledky testování aplikace pro jednotlivé klasifikátory [2, s. 455]

Klasifikátor	Přesnost (v ruce)	Přesnost (v kapse)
Vícevrstvá perceptronová síť	89.48 %	89.72 %
SVM	88.76 %	77.27 %
Náhodný les	87.55 %	85.15 %
LMT	85.89 %	85.04 %
Simple logistic	85.41 %	85.05 %
LogitBoost	82.54 %	82.24 %

Tabulka 2.2: Výsledky kombinací klasifikátorů (VPS = Vícevrstvá perceptronová síť)

V ruce	
Kombinace klasifikátorů	Přesnost
VPS, LogitBoost, SVM	91.15 %
VPS, LogitBoost, SVM, LMT	90.90 %
VPS, LogitBoost, SVM, Náhodný les	90.90 %
VPS, LogitBoost	88.51 %
VPS, SVM	88.27 %
VPS, LogitBoost, SVM, Náhodný les, LMT	81.10 %
V kapse	
Kombinace klasifikátorů	Přesnost
VPS, Náhodný les, Simple logistic	90.34 %
VPS, LogitBoost, Simple logistic, Náhodný les	90.34 %
VPS, LogitBoost, Simple logistic	88.47 %
VPS, Náhodný les, LMT, Simple logistic	88.16 %
VPS, LMT, Simple logistic	86.92 %
VPS, LogitBoost, Simple logistic, Náhodný les, LMT	83.18 %

Pro klasifikaci naměřených dat použili klasifikátory Náhodný les, Vícevrstvá Perceptronová síť, Support vector machines (SVM), Logistic model tree (LMT), Simple logistic a LogitBoost. Tyto klasifikátory byly natrénovány a otestovány pomocí metody křížové validace. Výsledky jejich zjištění přesnosti pro jednotlivé klasifikátory lze nalézt v tabulce 2.1.

Pro zlepšení klasifikace se pak rozhodli zkombinovat výsledky jednotlivých klasifikátorů. Výsledkem těchto kombinací je tabulka 2.2. Jak je vidět, kombinací klasifikátorů se nám zvýšila maximální přesnost z 89.72 % na 91.15 %.

2.2 Aplikace detekující spánkové cykly

Další aplikace využívající inerciálních senzorů jsou aplikace monitorující uživatelův spánek a jeho spánkové cykly. Díky znalosti, ve kterém spánkovém cyklu se uživatel nachází, je aplikace schopna určit optimální dobu vstávání. Tyto aplikace tvrdí, že uživatel se pak díky této funkci bude cítit více odpočatý a bude se mu lépe vstávat [17, 20, 23].

Podobnou aplikaci vyvinul kolektiv W. Gu et al. z Číny z Tsinghua University [12]. Jejich aplikace nazvaná Sleep Hunter využívá několik senzorů, které jsou přístupné na mobilním telefonu. Z inerciálních senzorů získá záznam z akcelerometru tzv. aktigrafie, dále získá záznam z mikrofonu, ze senzoru intenzity světla, informaci o délce spánku a informaci o uživateli. Informace o délce spánku je doba, jak dlouho aktuálně probíhá výpočet detekce spánkových cyklů. Jinými slovy se počítá počet sekund od doby, kdy uživatel zapne aplikaci. Informace o uživateli je pouze informace o věku uživatele.

S těmito daty byli schopni naprogramovat aplikaci pro operační systém Android, která dokázala klasifikovat spánkové cykly s 64.55% přesností. Dle autorů je to prozatím nejpřesnější z aplikací pro detekci spánkových cyklů, které využívají tyto senzory a informace.

2.2.1 Spánkový cyklus

Fyziologické komunity obvykle dělí spánkový cyklus na 3 fáze. Konkrétně na fázi rapid eye movement (REM) v překladu z angličtiny rychlý pohyb očí, potom fáze hlubokého spánku a fáze lehkého spánku [12]. REM fáze se obvykle spojuje se sny.

Do těchto tří tříd je pak spánek klasifikován. Aplikace snaží se o optimální čas probuzení se snaží odhadnout, kdy budete ve fázi lehkého spánku a v té vás vzbudit, protože lehký spánek je údajně pro probuzení nejlepší.

2.2.2 Algoritmus

Kolektiv W. Gu et al. vytvořil pro každý použitý senzor klasifikátor, který určoval, jaké události se podle senzoru staly.


Pro mikrofon vytvořili klasifikátor Support Vector Machine (SVM), který klasifikuje do tříd kašel, mluvení ze spaní, apneusis (zástava dýchání v trvalém nádechu)[21], tachypnoe (zrychlené dýchání)[1], chrápání a obyčejný spánek.

Pro záznam z akcelerometru vytvořili práh ξ , který odlišoval šum senzorů od pohybové události. Dále pak tyto události klasifikovali do dvou tříd. První třída nazvaná micro body movement byla definovaná jako událost kratší než 1s a druhá třída nazvaná macro body movement byla definovaná jako událost delší než 2.8 sekundy.

Pro senzor intenzity světla vymysleli klasifikátor s pevnými prahy. Klasifikace probíhala do 3 tříd - slabé osvětlení, střední osvětlení, silné osvětlení s danými prahy 10 lx a 2000 lx.

Výsledný obrazový vektor pro klasifikátor spánkových cyklů je popsán v rovnici (2.1).

$$X_t = \{N_B(t); N_A(t); N_I(t); N_D(t); N_P\} \quad (2.1)$$



Obrázek 2.1: Časový průběh detekce spánkových cyklů [12, str. 9] (Zeo = přístroj pro měření EEG a detekci spánkových cyklů)

kde $N_B(t)$ je počet výskytů micro body movement a macro body movement v čase t ; $N_A(t)$ je počet detekcí všech tříd, kromě obyčejného spánku, v čase t ; $N_I(t)$ je index třídy osvětlení v čase t ; $N_D(t)$ je doba od spuštění detekce (doba spánku) v čase t a N_P je věk uživatele.

2.2.3 Výsledky

Pro tento obrazový vektor pak následně vytvořili klasifikátor conditional random field (CRF). Po otestování klasifikátoru bylo zjištěno, že přesnost detekce aplikace Sleep Hunter dosahuje 64.55 %. Přesnost aplikace nejlépe vystihuje obrázek 2.1, který popisuje jak byl klasifikátor schopen správně zařadit daný časový úsek do správného typu spánkového cyklu.

2.3 Aplikace pro detekci obstrukční spánkové apnoe

2.3.1 Obstrukční spánková apnoe

Spánková apnoe je definována jako výskyt zástav dechu ve spánku (apnoických nebo hypopnoických pauz), které trvají nejméně 10 sekund a opakují se více než 5 krát za hodinu spánku [13].

Obstrukční spánková apnoe (OSA) je definována jako apnoe při které přetrvává dýchací úsilí [13].

Centrální spánková apnoe je definována jako apnoe, při které není přítomno dýchací úsilí [13].

Apnoe se nazývá smíšenou, jestliže začíná jako centrální (bez dýchacího úsilí), ale dýchací úsilí se během jejího trvání obnoví, tedy končí jako obstrukční [13].

2.3.2 Současný stav

Díky sensorům v mobilním telefonu se nabízí možnost neustálého sledování uživatele-pacienta a díky tomu pak lékař nebo dokonce samotný telefon může určit zda člověk má či nemá OSA. Byly nalezeny dvě vědecké práce zabývající se detekcí obstrukční spánkové apnoe [3, 16]. Obě tyto práce používají ke klasifikaci mobilní telefon respektive jeho akcelerometr a mikrofón. Dále

ale potřebují pro klasifikaci i polysomnografický signál (PPG). PPG signál se většinou získává pomocí pulsního oxymetru, který se umísťuje na prst.

Ani jednu z těchto vědeckých prací tedy není možné v praxi provést výhradně za použití mobilního telefonu. Navíc Behar et al. [3] doporučují umístit mikrofon k nosu a na hrud' a akcelerometr (telefon) připevnit k paži pacienta. V práci od Al-Mardini et al. [16] doporučují umístit mikrofon na krk a akcelerometr (telefon) na paži pacienta. Obě z těchto podmínek by mohly být pro uživatele během spánku nepříjemné a tudíž nevhodné pro dlouhodobé pozorování. V dalších sekcích budou tyto práce rozebrány podrobněji.

2.3.3 Detekce OSA vyvinutá Behar et al.

V první studii od Behar et al. [3] natrénováli klasifikátor Support Vector Machine na 735 pacientech a otestovali na 121 pacientech. Výsledkem byla klasifikace s přesností 92.2 %. Hlavním cílem této práce bylo klasifikovat uživatele do jedné ze dvou skupin. Do skupiny zdravých uživatelů netrpících OSA a do skupiny trpících OSA.

Jakmile byla aplikace spuštěna, počkala 30 minut než uživatel usne a následně pak 4 hodiny sbírala data. Po dokončení sběru dat provedla aplikace klasifikaci.

Jak už bylo řečeno, telefon musí být umístěn na paži uživatele a mikrofon z telefonu musí být umístěn u nosu uživatele.

Pro klasifikaci použili následující údaje ze signálů

Aktigrafie

Telefon umístili během detekce na paži uživatele. Se vzorkovací frekvencí 4 Hz pak získali zrychlení ve všech osách x,y,z a pak spočetli celkovou amplitudu zrychlení signálu, přičemž použili high-pass filtr pro odstranění gravitace. Následně pak z měřeného intervalu spočítali logaritmovanou varianci signálu během jedné sekundy (2.2). Hodnota pak byla použita jako obraz do obrazového vektoru.

$$X_{akceleromer}(n) = X_{ac}(n) = \log(\text{var}(M(n)) + 1), \quad (2.2)$$

kde $M(n)$ je posloupnost naměřených dat mezi časy $(n - 1)T$ a nT . T je perioda výpočtů rovna 1 s.

Z aktigrafie a gyroskopu pak také určovali pozici těla. Klasifikační třídy pro pozici těla zvolili následovně: ležení na zádech, sezení, ležící na břiše a ležící na boku. Tyto pozice pak použili v klasifikačním algoritmu.

Zvukový záznam

Ze zvukového záznamu získali logaritmovanou varianci zvukového záznamu během jedné sekundy se vzorkovací frekvencí 8 kHz (2.3). Perioda výpočtů byla jedna sekunda. Klasifikace vychází

z předpokladu, že 75% energie zvukového záznamu pacientem trpící OSA je pod frekvencemi 2 kHz.

$$X_{zvuk}(n) = X_{au}(n) = \log(\text{var}(M(n)) + 1), \quad (2.3)$$

kde $M(n)$ je posloupnost naměřených dat zvukového záznamu mezi časy $(n-1)T$ a nT . T je perioda výpočtů rovna 1 s.

Oxygen Desaturation Index

Ze signálu PPG se vzorkovací frekvencí 75 Hz získali Oxygen Desaturation Index (ODI), což je počet, kolikrát za hodinu klesne nasycení kyslíku pod 4 % normální (střední) hodnoty, alespoň na 10 sekund [16, část IV.A].

Údaje o uživateli

Uživatel vyplnil standardizovaný klinicky ověřený dotazník [14], který mu na konci přidělil pravděpodobnost, že trpí OSA.

2.3.4 Detekce OSA vyvinutá Al-Mardini et al.

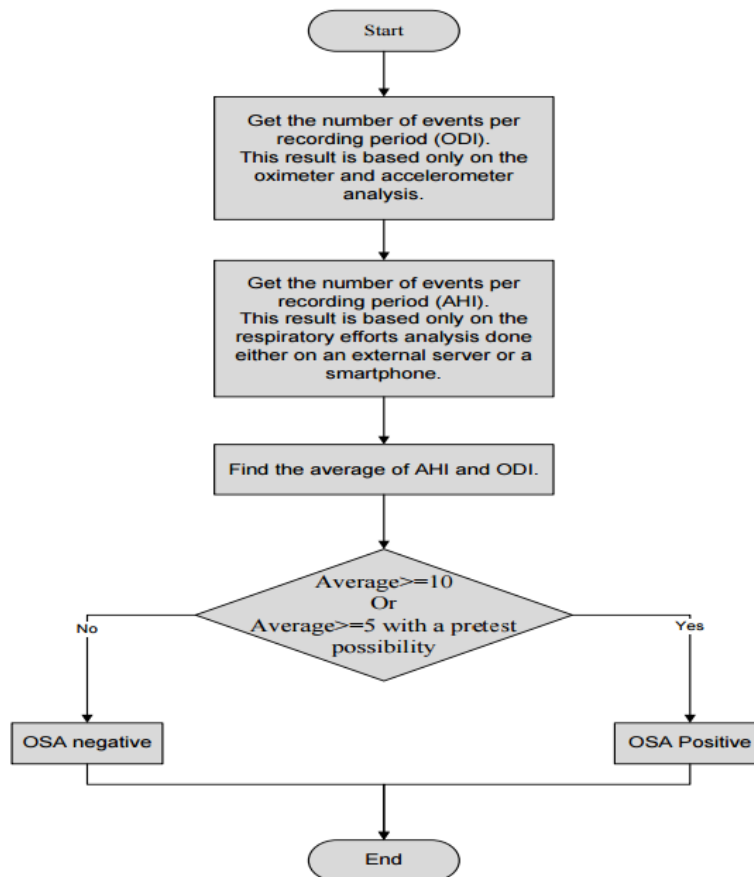
Druhá studie od Al-Mardini [16] et al. používá pro klasifikaci stejné signály jako první, jenom provádí jiné výpočty. Stejně jako u první práce získali vědci oxygen desaturation index (ODI). V této práci však za pomoci inerciálních senzorů vyfiltrují z ODI okamžiky, kdy se pacient převaloval v posteli, protože převalování může způsobit nežádoucí ODI událost.

Dále pak určili ze záznamu z mikrofonu takzvaný apnea/ hypopnea index (AHI). Signál naměřený z mikrofonu analyzovali každou sekundu. Spočetli energii signálu a následně určili, zda je tato energie menší než 90% obvyklé (průměrné) hodnoty. Pokud ano, pak určili, jak dlouho tento stav trvá. Pokud tento stav vydržel více jak 10s, pak událost obtížného dýchání byla detekována. Počet takovýchto událostí během jedné hodiny spánku se nazývá apnea/ hypopnea index (AHI).

Nakonec použili pro klasifikaci dotazník, který určoval pravděpodobnost zda uživatel má či nemá OSA. Tato pravděpodobnost je označena jako pretest.

Pro klasifikaci pak použili průměr z AHI a ODI a výsledek z dotazníku označený jako pretest. Konečná diagnóza se stanoví dle diagramu na obrázku 2.2.

Telefon během měření doporučují umístit na paži pacienta, mikrofon na krk pacienta a snímač PPG signálu na prst pacienta.



Obrázek 2.2: Klasifikační diagram [16]. pretest possibility je výsledek dotazníku zda máte či nemáte OSA

2.4 Aplikace detekující epileptické záchvaty pomocí akcelerometru a elektrodermální aktivity

Disertační práce napsanou inženýrem Ming-Zher Poh [18] se zabývá návrhem náramku a algoritmu pro detekci epileptických záchvatů. Inženýr Ming-Zher Poh navrhl náramek, který dokáže pohodlně měřit elektrodermal activity a aktigrafii. Pomocí těchto signálu pak navrhl algoritmus, který dokáže detekovat tonicko-klonické záchvaty. Jeho algoritmus byl testován 4213 hodin na 80 pacientech, které pozoroval během celého dne. Dokázal detekovat 94 % tonicko-klonických záchvatů s malým počtem falešných alarmů, přibližně 1 falešný alarm za den.

Elektrodermální aktivita

Elektrodermální aktivita je záznam změny odporu kůže v čase mezi dvěma časovými okamžiky [10]. Měří se pomocí tzv. Elektropsychometru neboli E-meter (převzato z angličtiny). E-meter bývá součástí polygrafu. Polygraf je přístroj pro záznam fyziologických změn v těle jako je například právě elektrodermální aktivita.

2.4.1 Způsob měření

Autor [18] analyzoval vždy 10 sekundové intervaly přičemž používal sliding window s 75% překrytím předchozího signálu. To znamená, že analyzoval 75% dat z předchozích signálů a 25% nových dat. Vzorkovací frekvence je 32 Hz.

2.4.2 Redukce dat

Kvůli omezeným výpočetním kapacitám a omezené výdrži baterie je vhodné, než se začne klasifikovat, data filtrovat na ty, kde se děje pohyb a na ty, ve kterých se nic neděje. K této filtraci použil Ming-Zher Poh modus signálu akcelerometru na daném intervalu a následně spočítal směrodatnou odchylku. Interval, který měl směrodatnou odchylku menší než 0.1g, byl vyhodnocen jako záznam bez pohybu a byl vyřazen pro další klasifikaci. Ostatní intervaly byly vyhlazeny pomocí vyhlazovací funkce a následně byla spočítána diskretní Fourierova transformace (DFT), jak je definována v rovnici (1.1).

Generalizované tonicko-klonické (GTC) záchvaty se skládají ze dvou fází. Tonické a klonické fáze. Tonická fáze zahrnuje flexe a natažení svalů. Během klonické fáze se začnou svaly rychle stahovat a roztahovat s frekvencí nad 2 Hz [18]. Tuto vlastnost pak využil pro další redukci dat.

V každém výpočtu byly nalezeny důležité frekvence, které definoval následujícím způsobem. Předpokládal, že absolutní hodnoty koeficientů DFT neperiodického signálu jsou rozdělené podle exponenciálního rozdělení (2.4), kde λ je střední hodnota signálu.

$$f(x) = \lambda e^{-\lambda x} \quad (2.4)$$

Z této distribuční funkce určil práh T_h , který určoval důležité frekvence.

$$T_h = -\frac{\ln(p)}{\lambda}, \quad (2.5)$$

kde $p = 0.01$ je pravděpodobnost související s intervalem spolehlivosti. Velikost intervalu spolehlivosti je tedy 99%.

Signál, který měl všechny frekvence menší než T_h , byl vyhodnocen tak, že žádný záchvat nenastal. Pokud se tyto frekvence našly, byla z těchto frekvencí nalezena dominantní frekvence viz definice v odstavci 1.2.3.

Jestliže tato dominantní frekvence byla menší než 2 Hz, bylo opět vyhodnoceno, že nenastal záchvat. Jinak byl tento údaj použit dál pro klasifikaci.

2.4.3 Extrakce vlastností po redukci dat

Celkem 19 vlastností signálů bylo extrahováno.

Analýza signálu v časové oblasti

Z časové analýzy získal střední hodnotu, směrodatnou odchylku, efektivní hodnotu signálu (1.10) a odhad síly, kterou získal sčítáním amplitud signálu (2.6) přes 10 sekundový interval.

$$a = \int_n^{n+\Delta} |a_x(t)| + |a_x(t)| + |a_x(t)| dt \quad (2.6)$$

Analýza signálu ve frekvenční oblasti

Většina energie signálu z denních aktivit spadá mezi frekvence 0.3 Hz až 3 Hz, kdežto během záchvatu je většina energie koncentrována na frekvencích větší než 2 Hz [18].

Po použití vyhlazovací funkce spočetl spektrální analýzu signálu pomocí Welchovy metody. Následně pak celé spektrum (0-10 Hz) bylo rozděleno na 8 intervalů. Každému intervalu pak následně spočetl celkovou integrovanou energii (1.8), kterou pak použil do obrazového vektoru. Následně byla nalezena dominantní frekvence 1.2.3 spolu se svojí amplitudou. Ty také pak byly použity do obrazového vektoru.

Nelineární analýza

Pro zjištění skrytých vzorců chování a nelineárních vlastností signálu se spočetla entropie a laminarita signálu.

2.4.4 Shrnutí

Ming-Zher Poh určil celkem 16 vlastností signálu, které použil jako obrazový vektor. 4 vlastnosti z časové oblasti (střední hodnotu, směrodatnou odchylku, efektivní hodnotu signálu a odhad síly), 10 vlastností z frekvenční analýzy (dominantní frekvence, její amplituda, a 8 hodnot energií intervalů signálu) a 2 vlastnosti z nelineární analýzy (entropii a laminaritu).

Kapitola 3

Vlastnosti měření na systému Android

V této kapitole je popsán systém Android jako rozhraní pro práci se senzory na mobilním telefonu. Jsou zde rozebrány třídy, metody a konstanty potřebné pro práci se senzory.

Pro systém Android byla naprogramována aplikace, na které byly všechny metody popsané v této kapitole testovány. Rozhraní bylo otestováno na mobilním telefonu od společnosti Samsung s číslem modelu SM-G903F. Nakonec byly poznamenány rozdíly vlastností senzorů oproti deklarovaným hodnotám v dokumentaci.

3.1 Senzory

Pro přístup k senzorům v telefonu s operačním systémem Android slouží třída `SensorManager`. Z této třídy je možno zažádat o daný typ senzoru (třída `Sensor`), který daný telefon má, a s jeho pomocí zaregistrovat `SensorEventListener` pro záznam hodnot.

Třída `Sensor` reprezentuje daný typ senzoru na telefonu. Z této třídy je možno získat vlastnosti senzorů deklarované výrobcem senzoru. V následujícím výčtu je uvedeno několik metod pro zjištění vlastností senzoru.

- `getMinDelay()` - Maximální nastavitelná vzorkovací frekvence
- `getMaxDelay()` - Minimální nastavitelná vzorkovací frekvence
- `getPower()` - Hodnota v mA kolik spotřebuje senzor, pokud je používán.
- `getResolution()` - Rozlišení senzoru v daných jednotkách. **Pozn.** Rozlišení senzoru je nejmenší možná oblast, kterou senzor dokáže rozpoznat.
- `getMaximumRange()` - Maximální obor hodnot, který dokáže měřit
- `getVendor()` - Výrobce senzoru

Operační systém Android má 4 druhy měřících režimů. První je kontinuální, to je režim, kdy s konstantní vzorkovací periodou dostáváme data ze senzorů. Další typ je on-change, tedy čekající na změnu. Tento typ senzoru se ohlásí, pokud dojde ke změně hodnoty senzoru, například změna orientace telefonu. Třetí typ je jednorázový senzor. Ten vrátí hodnotu pouze jednou a pak se uspí. Příkladem může být *Significant motion sensor*, který indikuje, že nastal náhlý a velký pohyb. A pak jsou speciální režimy, které jsou specifické pro daný senzor [15].

Operační systém Android má pro první režim, tedy kontinuální režim, předpřipravené vzorkovací periody pro typické případy užití. Tyto konstanty se nachází ve třídě `SensorManager`. Seznam konstant je vypsán v následujícím seznamu.

- `SENSOR_DELAY_FASTEST` nejrychlejší možná vzorkovací frekvence
- `SENSOR_DELAY_NORMAL` vhodný pro detekování změny orientace obrazovky
- `SENSOR_DELAY_UI` vhodné při zobrazování naměřených hodnot v uživatelském rozhraní, tak aby nebylo přetížené a stíhalo naměřené hodnoty zobrazovat
- `SENSOR_DELAY_GAME` vhodné k hrám, které ke své funkcionalitě potřebují akcelerometr


V této práci jsou zkoumány dva akcelerometry zabudované v mobilním telefonu. První akcelerometr je obyčejný akcelerometr, který snímá zrychlení v osách x,y,z jak je naznačeno na obrázku 3.1. Druhý akcelerometr se nazývá lineární akcelerometr a vrací stejné hodnoty jako obyčejný akcelerometr, akorát dokáže navíc s pomocí gyroskopu odfiltrovat ze signálu gravitaci.

U obou akcelerometrů je porovnána deklarovaná konstanta `SENSOR_DELAY_FASTEST` oproti skutečné vzorkovací periodě. Je vhodné doplnit, že samotná konstanta `SENSOR_DELAY_FASTEST` je celé číslo, které pouze indikuje režim vzorkování. Skutečnou deklarovanou vzorkovací periodu v milisekundách musíme získat z metod třídy `Sensor`.

3.2 Deklarované vlastnosti akcelerometru

Následující údaje byly získány přímo z mobilu, přes funkce popsané v Android API. Následuje seznam použitých funkcí a jejich zjištěné hodnoty.

- `getMinDelay()`
Maximální nastavitelná vzorkovací frekvence je 200 Hz, jinak řečeno perioda vzorkování může být minimálně 5000 mikrosekund neboli 0.005 sekund.
- `getMaxDelay()`
Minimální nastavitelná vzorkovací frekvence je 5 Hz, jinak řečeno perioda vzorkování může být maximálně 200 000 mikrosekund neboli 0.2 sekund.



Obrázek 3.1: Osy akcelerometru vzhledem k telefonu.

- `getPower()`
Akcelerometr během používání spotřebuje 0.5 mA.
- `getResolution()`
Rozlišení senzoru je 1.0 m s^{-2} .
- `getMaximumRange()`
Maximální obor hodnot, který dokáže měřit, je dle dokumentace $\pm 10\,240 \text{ m s}^{-2}$.
- `getVendor()`
Výrobce akcelerometru je InvenSense.

3.3 Deklarované vlastnosti lineárního akcelerometru

Tyto údaje byly získány přímo z mobilu, přes funkce popsané v Android API. Následuje seznam použitých funkcí a jejich hodnoty.

- `getMinDelay()`
Maximální nastavitelná vzorkovací frekvence je 100 Hz, jinak řečeno perioda vzorkování může být minimálně 10 000 mikrosekund neboli 0.01 sekund.
- `getMaxDelay()`
Minimální nastavitelná vzorkovací frekvence je 5 Hz, jinak řečeno perioda vzorkování může být maximálně 200 000 mikrosekund neboli 0.2 sekund.

- `getPower()`

Lineární akcelerometr během používání spotřebuje 0.5 mA.

- `getResolution()`

Rozlišení senzoru je 1.0 m s^{-2} .

- `getMaximumRange()`

Maximální obor hodnot, který dokáže měřit, je dle dokumentace $\pm 10\,240 \text{ m s}^{-2}$.

- `getVendor()`

Výrobce lineárního akcelerometru je InvenSense.

3.4 Reálné naměřené vzorkovací frekvence

V této sekci jsou porovnány deklarované maximální frekvence vzorkování z metody `getMinDelay()` a skutečná frekvence vzorkování v případě, že byl nastaven režim vzorkování na `SENSOR_DELAY_FASTEST`.

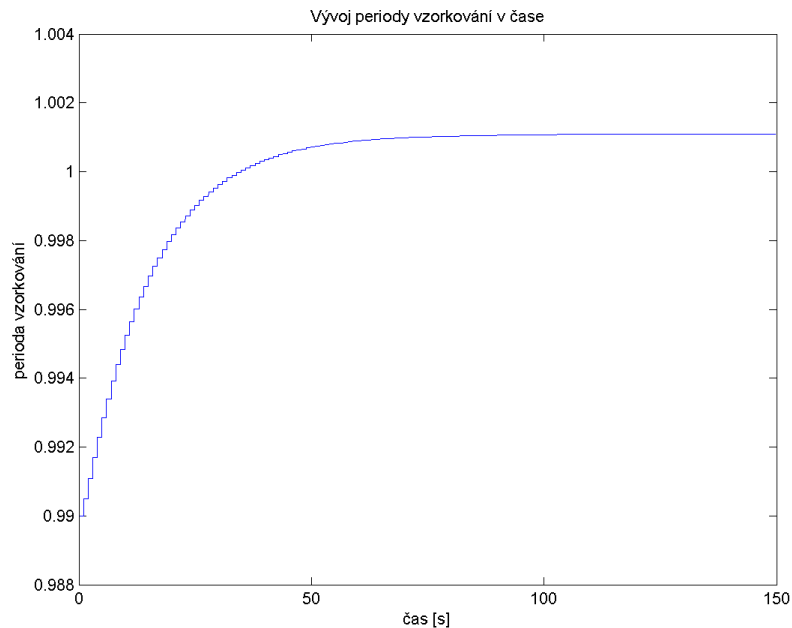
3.4.1 Chyba vzorkovací frekvence v čase

V dokumentaci Android API je psáno, že vzorkovací frekvence je pouze orientační a není garantována stejná perioda vzorkování. Při bližší analýze periody vzorkování bylo zjištěno, že perioda vzorkování skutečně není v čase konstantní, ale má tendenci se blížit ke konstantní periodě vzorkování.

Tato chyba vzorkování je nejspíše způsobena tím, že systém Android nemá na starosti pouze zpracovávání měření z akcelerometru, ale i spoustu jiných procesů, a tak se může perioda vzorkování měnit podle toho, jak je právě zatíženo CPU daného zařízení.

Tvrzení, že se perioda vzorkování blíží ke konstantní periodě při stálém zatížení CPU, dokazuje i graf změny periody vzorkování v čase na obrázku 3.2. Z grafu je poznat, že perioda vzorkování se ustálila přibližně za 70 sekund. Nutno podotknout, že perioda není konstantní, ale mění se maximálně v řádech desítkách nanosekund tzn. 10^{-8} s. Zjištěné hodnoty vzorkování jsou určovány dle `timestamp` neboli časové známce, která je přikládána ke každé naměřené hodnotě a indikuje čas měření. Tato časová známka je v nanosekundách.

Další jev, který je zajímavý, je, že během jedné sekundy byla perioda vzorkování relativně stejná pak, ale náhle stoupla (lze poznat ze schodovitosti grafu na obr. 3.2). Tento náhlý schod se vyskytoval každou sekundu, tedy s frekvencí 1 Hz. Tento jev by mohl mít vliv na Fourierovu transformaci sledovaného signálu.



Obrázek 3.2: Vývoj periody vzorkování v čase

3.4.2 Akcelerometr

Pro model SM-G903F bylo ze dvou měření zjištěno, že frekvence vzorkování u prvního měření je 199.62 Hz a u druhého měření 199.91 Hz. Což odpovídá deklarované maximální frekvenci vzorkování 200 Hz.

3.4.3 Lineární akcelerometr


Pro model SM-G903F bylo ze dvou měření zjištěno, že frekvence vzorkování u prvního měření je 100.32 Hz a u druhého měření 100.75 Hz. Skutečná frekvence vzorkování je tedy dokonce větší než deklarovaná maximální frekvence vzorkování 100 Hz.

3.5 Schopnost detekovat frekvence o různé amplitudě

Na obrázku 3.3 je naznačen obecný generátor signálu generující signál $A \sin(\omega t)$. V obrázku je zobrazena veličina x , která reprezentuje funkční hodnotu signálu v čase t . V případě dokonalého generátoru vibrací, který by generoval pouze signál o frekvenci 1 Hz o amplitudě $A = 1$, by vypadal průběh x jako ideální sinusový signál.

Z funkce průběhu polohy x (3.1) bylo spočteno okamžité zrychlení \ddot{x} (3.3). V sekci 3.3 je napsáno, že minimální zrychlení, které je senzor schopen rozlišit, je 1 m s^{-2} .

Generátor signálu $A \sin(\omega t)$



Obrázek 3.3: Generátor obecného signálu $A \sin(\omega t)$

$$f(t) = A \sin(\omega t) \quad (3.1)$$

$$\frac{df(t)}{dt} = A \cos(\omega t) \omega \quad (3.2)$$

$$\frac{d^2f(t)}{dt^2} = -A \sin(\omega t) \omega^2 \quad (3.3)$$

Tedy aby bylo možno splnit podmínku, že senzor dokáže detekovat změny v signálu 1 m s^{-2} , musí být amplituda zrychlení x větší než 1 m s^{-2} . Musí tedy platit nerovnice (3.4)

$$A \omega^2 \geq M, \quad (3.4)$$

kde M je minimální detekovatelná hodnota v m s^{-2} , která je daná výrobcem senzoru. Pro případ mobilního akcelerometru je $M = 1 \text{ m s}^{-2}$ dle odstavce 3.3.

$$f \geq \frac{1}{2\pi} \sqrt{\frac{M}{A}} = \frac{1}{2\pi} \sqrt{\frac{1}{A}} \quad (3.5)$$

Kapitola 4

Epilepsie

V této kapitole je definována a popsána epilepsie. Jsou zde rozebrány druhy epilepsií a také druhy epileptických záchvatů. Cílem této kapitoly bylo získat znalosti o epilepsii tak, aby tyto znalosti mohly být použity pro detekci epileptických záchvatů.

4.1 Praktická definice epilepsie

Definice epilepsie dle organizace International league against epilepsy (ILAE) [7]. Přeloženo z angličtiny.

Def: Člověk trpí epilepsií pokud splňuje, alespoň jednu s následujícími podmínkami

1. Měl alespoň dva nevyprovokované záchvaty, které se staly minimálně 24 hodin po sobě. To znamená, že doba mezi těmito dvěma záchvaty musí být větší než 24 hodin.
2. Měl jeden nevyprovokovaný (nebo reflexní) záchvat a pravděpodobnost podobných záchvatů, které by mohly nastat v průběhu příštích 10 let, je minimálně 60%.
3. Diagnóza syndromu epilepsie

Epilepsie je považována za vyléčenou pro ty, kteří měli věkově závislý epileptický syndrom a již opustili tuto fázi věku nebo ti, kteří nedostali epileptický záchvat za posledních 10 let a zároveň nebrali žádné antiepileptika za posledních 5 let.

4.2 Epileptický záchvat

Epileptické záchvaty jsou definovány jako přechodně se objevující příznaky, které jsou důsledkem nadměrné či abnormální synchronní aktivity neuronů v mozku. [19].

4.2.1 Dělení epileptických záchvatů

Upravené dělení epilepsie dle dokumentu ILAE Commission [4].

- Generalizované záchvaty
 - tonicko-klonické (of any kind)
 - Absence
 - * Typické
 - * Atypické
 - * Absence se speciálními prvky
 - * Myoklonické absence
 - * Myoklonia očního víčka
 - Myoklonické
 - * Myoklonické
 - * Myoklonické atonické
 - * Myoklonické tonické
 - Klonické
 - Tonické
 - Atonické
- Fokální (parciální) záchvat
- Neznámé
 - Epileptické křeče
 - (Události, které ještě nebyly jednoznačně diagnostikovány do předešlých kategorií)

4.2.2 Popis častých druhů epileptických záchvatů

Průběhy a popis častých typů záchvatů, zdroj Epilepsy Foundation [8]

- Klonické záchvaty zahrnují opakované škubání, jsou vzácné (trvajících pár sekund až minutu)
- Tonické záchvaty svaly na těle ztuhnou, neztrácí se vědomí, (trvajících méně než 20 sekund)

- Tonicko-klonické záchvaty
kombinace předchozích, tzn. nejprve tělo ztuhne a pak se začne třást (obvykle 1-3 minuty, při delších než 5 minut jde o život)
- Myoklonické záchvaty
krátké křečovité záškuby (obvykle trvající 1-2 sekundy)
- Atonický záchvat
náhlá ztráta tonu svalu, stojící člověk většinou nekontrolovaně spadne (trvající obvykle 15 sekund)
- Absenční záchvat
koukání do prázdna, nereaguje na okolí (10-20 sekund)

4.3 Shrnutí

Z uvedených epileptických záchvatů bude v této práci analyzováno pouze detekování generalizovaných tonicko-klonických záchvatů z několika důvodů. První důvod je, že při generalizovaném tonicko-klonickém záchvatu jde skutečně o život, protože trvá-li záchvat více než 5 minut, je nutné zavolat lékaře [8]. Dalším důvodem je fakt, že při těchto záchvatech produkuje pacient velké pohyby, které by mohly být snadno detekovány. A nakonec také proto, že tento typ záchvatů je lidmi nejvíce spojován s epilepsií.

Kapitola 5

Analýza naměřených dat

V této kapitole jsou analyzována naměřená data, která byla získána pomocí telefonu Samsung Galaxy S5 Neo model SM-G903F. Byla naprogramována aplikace, která zaznamenávala hodnoty ze senzoru a ukládala je do souboru. Po dokončení měření byl soubor z telefonu extrahován a analyzován. Výsledky těchto měření jsou popsány v této kapitole.

Nejdříve bude analyzován šum měření, dále pak budou analyzována "teoretická" data, to jsou data, která jsou naměřena tak, jak bylo předpokládáno, že by takový záznam z akcelerometru epileptického záchvatu mohl vypadat. Při porovnání se skutečnými naměřenými daty se ukázalo, že předpoklad byl špatný. Nakonec budou analyzována data skutečného epileptického záchvatu.

5.1 Naměřená data v klidu

V této sekci bude analyzován šum měření na senzoru. Časový průběh akcelerometru pokud je zařízení v klidu můžeme vidět na obrázku 5.1. Je předpokládáno, že tento šum je bílý šum s normálním rozdělením. Při měření šumu byl telefon položen na stůl obrazovkou nahoru. Po analýze naměřeného signálu byly určeny odhadované parametry rozdělení (5.1).

$$\mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma}), \quad \boldsymbol{\mu} = 10^{-4} \cdot \begin{pmatrix} 4.869 \\ 1.178 \\ -57.77 \end{pmatrix}, \quad \boldsymbol{\Sigma} = 10^{-4} \cdot \begin{pmatrix} 1.335 & 0 & 0 \\ 0 & 1.295 & 0 \\ 0 & 0 & 3.893 \end{pmatrix} \quad (5.1)$$

V praxi se však ukázalo, že se střední hodnoty (offsety senzorů) v čase mění a je nutné je čas od času kalibrovat.

Z grafu Fourierovy transformace měřeného signálu 5.2 je zřetelné, že téměř odpovídá Fourierově transformaci bílého šumu s nulovou střední hodnotou, který má amplitudy Fourierovy transformace na všech frekvencích konstantní.

Analýza chybných frekvencí v šumu okolo 10 Hz

U Fourierovy transformace signálu akcelerometru se na obrázku 5.2 v ose Z vyskytly vyšší amplitudy u frekvencí okolo 10 Hz. Tyto chybné frekvence se čas od času vyskytovaly ve všech osách, pokud se měřil pouze šum. Předpokládalo se, že tyto chybně detekované frekvence jsou způsobeny chybnou periodou vzorkování, která se na začátku měření mění s frekvencí 1 Hz, jak je popsáno v odstavci 3.4.1.

Toto tvrzení se nepotvrdilo a po několika opakovaných pokusech se tyto frekvence okolo 10 Hz stále vyskytovaly a to i po několika minutách měření, kdy se perioda vzorkování již ustálila.

Další možný důvod výskytu těchto frekvencí by mohl být, že byl použit lineární akcelerometr pro měření. Lineární akcelerometr je virtuální senzor vytvořený pro systém Android, který dokáže ze záznamu z akcelerometru odfiltrovat gravitační zrychlení. To znamená, že s daty bylo již manipulováno a chyba mohla být zanesena do měření softwarově.

Proto byl otestován obyčejný akcelerometr, který je dle dokumentace **Hardware senzor**. To znamená, že tento senzor není virtuální a skutečně fyzicky existuje. Měří tedy přímo reálné hodnoty prostředí. Z toho vyplývá, že s daty nebylo nijak významně manipulováno a tudíž by v nich neměla být žádná softwarová chyba.


Po otestování hardwarového akcelerometru bylo zjištěno, že se frekvence 10 Hz v signálu stále vyskytují.

Nebyla tedy zjištěna zjevná příčina výskytu frekvencí okolo 10 Hz v naměřených signálech. Další možný důvod by mohl být, že časové známky nejsou dostatečně přesné a perioda vzorkování je nadále i chybná, přestože časové známky tomu nenasvědčují.


5.2 Naměřená data při převalování na posteli

V tomto odstavci bude analyzován signál, který byl nasimulován účastníkem výzkumu. Tento signál simuluje převalování člověka v posteli. Časový záznam je vidět na obrázku 5.3. Graf je rozdělen do několika částí. První tři řádky reprezentují časový průběh celého signálu v osách x, y, z . Dále na dalších třech řádcích je v lichých sloupcích časový průběh vyříznutého intervalu signálu v osách x, y, z a v sudých sloupcích je Fourierova transformace daného vyříznutého intervalu.

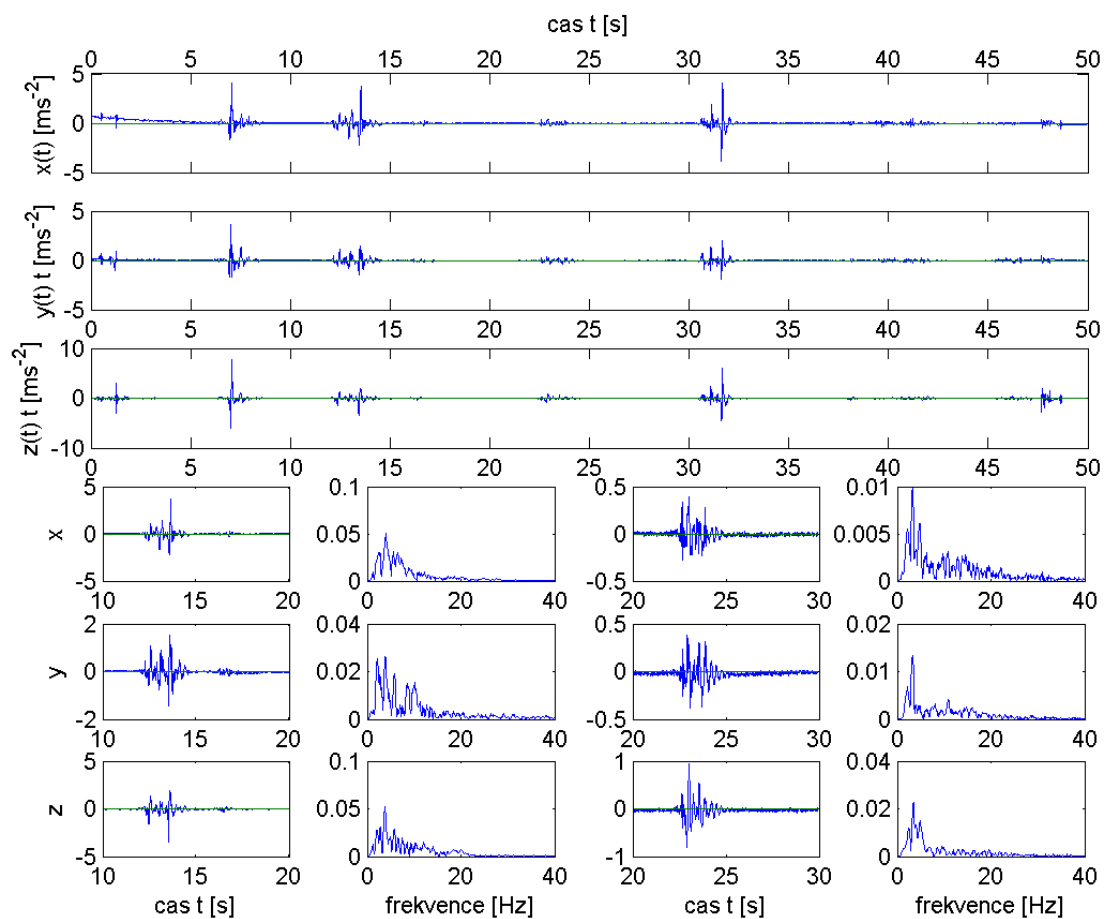
Byly analyzovány intervaly v čase 10-20 s a v čase 20-30 s. Na Fourierovy transformace analyzovaných intervalů byl použit stejný frekvenční filtr s horní propustí, jako byl použit v práci [18]. Z analyzovaných intervalů na grafu je vidět, že dominantní frekvence a energie frekvenčního amplitudového spektra se soustředí ve frekvenčním pásmu od 0-5 Hz. Toto tvrzení pak bude využito při návrhu teoretického klasifikátoru.



Obrázek 5.1: Nefiltrovaný časový průběh záznamu z akcelerometru, pokud je zařízení v klidu



Obrázek 5.2: Pravá strana Fourierovy transformace nefiltrovaného signálu z obrázku 5.1



Obrázek 5.3: Grafy průběhu záznamu akcelerometru při převalování na posteli. První tři řádky jsou grafy s celým časovým průběhem záznamu. Další tři řádky obsahují v lichých sloupcích filtrovaný časový průběh výřezu daného času a v sudých sloupcích je Fourierova transformace daného signálu. Analýza intervalů 10-20 sec a 20-30 sec

5.3 Naměřená data při simulovaném epileptickém záchvatu

V této kapitole je popsáno, jak bylo předpokládáno, že by takový záznam z akcelerometru během epileptického záchvatu mohl vypadat. Data byla nasimulována na účastníkovi výzkumu, který si přečetl popis epileptického záchvatu a následně se podíval na video s průběhem takového záchvatu. Poté se pak tento epileptický záchvat snažil napodobit. Výsledné grafy z měření jsou na obrázku 5.4. Telefon byl při simulaci umístěn pod polštářem obrazovkou nahoru jako je na obrázku 5.5.

Z grafu 5.4 je poznat, že celková doba simulace trvala 50 s. První tři řádky obsahují časový průběh záznamu z akcelerometru. Na dalších třech řádcích je zobrazen graf 10 s intervalu z celkového signálu a vpravo od něj je graf Fourierovy transformace tohoto intervalu.

Z Fourierovy transformace obou 10 s intervalů je vidět, že se největší amplitudy vyskytují ve frekvencích 5-10 Hz. Návrh frekvenčního klasifikátoru by tedy mohl vypadat následovně. Pokud budou dominantní frekvence soustředěné v intervalu 5-10 Hz, bude signál vyhodnocen jako záchvat. Pokud budou frekvence soustředěné kolem 0-5 Hz bude záznam vyhodnocen jako převalování na posteli.

Posléze bylo zjištěno, že teoretická data neodpovídají skutečně naměřeným datům. Tvrzení, že dominantní frekvence jsou soustředěné v intervalu 5-10 Hz, se pro zvolený způsob měření nepotvrdilo.

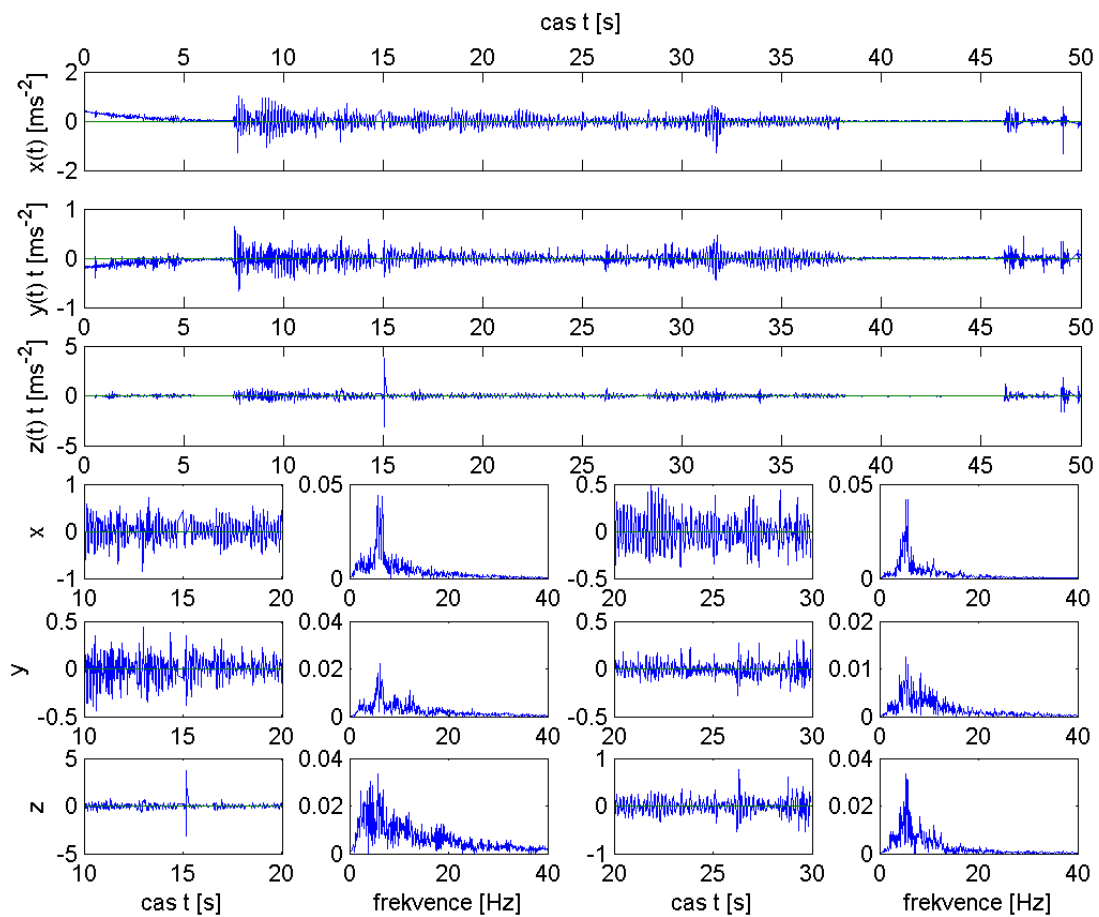
5.4 Naměřená data skutečného epileptického záchvatu

V této sekci budou analyzována data, která byla naměřena při skutečném epileptickém záchvatu. Na všechny Fourierovy transformace naměřených dat, byl použit frekvenční filtr s horní propustí. Byl použit stejný filtr jako v práci [18].

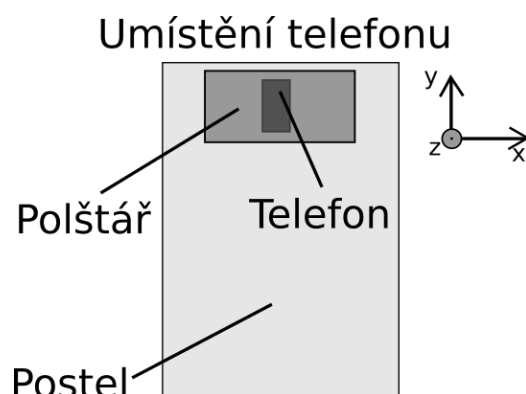
5.4.1 Způsob měření

Telefon s aplikací a návodem byl propůjčen pečovateli, který se stará o pacienta s epilepsií. Ten pak dle návodu měřil průběh epileptického záchvatu pomocí akcelerometru v telefonu. Pečovatel dostal pokyn, aby umístil telefon dle vlastního uvážení na více druhů míst, aby bylo zjištěno, které místo je pro detekci nejlepší. Pečovatel nakonec umístil telefon na dvě místa a to na pozici pod polštářem a na pozici u nohou. Druhou pozici u nohou zvolil proto, že pacient údajně nejvíce při záchvatu třese nohama.

Bohužel je nutné konstatovat, že nebyl zvolen vhodný způsob měření, protože z naměřených dat nebylo možno se 100% jistotou říci, jestli se pacient nepřevaloval nebo jestli skutečně dostal epileptických záchvat. Pečovatel sice poznamenal čas v minutách, od kdy do kdy záchvat probíhal, ale pro přesnější analýzu by byl potřeba záznam popisující průběh záchvatu v každé sekundě. Pro získání této informace by byl potřeba EEG signál, který je dostatečně přesný



Obrázek 5.4: Grafy simulovaného epileptického záchvatu. První tři řádky jsou grafy s celým časovým průběhem záchvatu. Další tři řádky obsahují v lichých sloupcích filtrovaný časový průběh výřezu daného času a v sudých sloupcích je jejich Fourierova transformace



Obrázek 5.5: Umístění telefonu při měření pod polštářem

pro detekování epileptických záchvatů a je považován za standard pro detekci epileptických záchvatů [18].

5.4.2 Naměřená data

Telefon umístěn pod polštářem


Na základě poznamenaných časových údajů od pečovatele byl extrahován časový signál průběhu záchvatu. Umístění telefonu během měření je naznačeno na obrázku 5.5. Celý tento signál je zobrazen na grafu 5.6. Dle poznámek pečovatele je celková doba záchvatu přibližně 2-3 minuty.

Z grafu 5.6 lze v čase rozpoznat pohybové události, avšak nedá se z nich určit, o jaký typ události se jedná. Aby bylo možné určit o jaký pohybový typ události se jedná, tzn. rozlišení zda jde o epileptický záchvat nebo pouze o nějak lehký pohyb na posteli, je potřeba znát časový průběh EEG signálu. Tento signál však není k dispozici a tak je předpokládáno, že všechny pohybové události v daném signálu jsou součástí epileptického záchvatu.

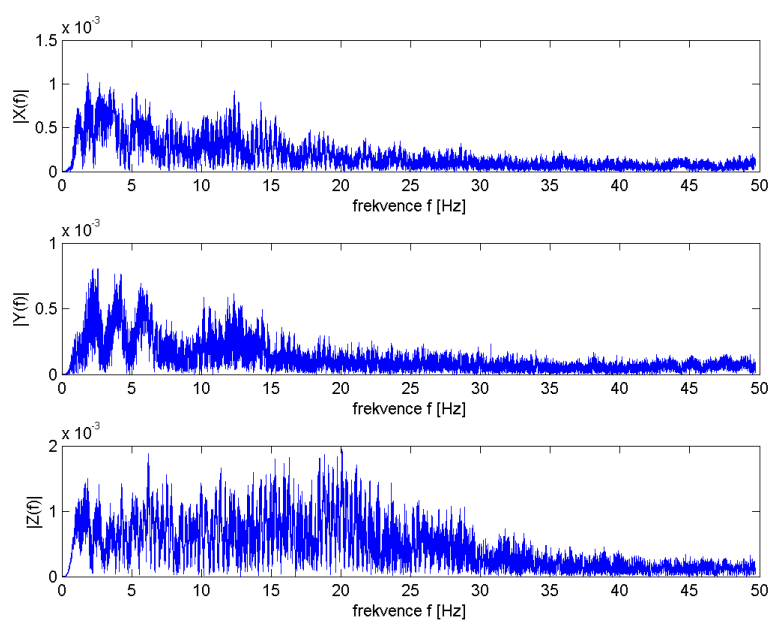
Dále budou analyzovány důležité časové úseky s délkou $T = 10$ sec. Graf intervalu od 100 do 110 sekundy lze vidět na obrázku 5.8. A Fourierova transformace tohoto intervalu je na grafu 5.9. Ze spektrální analýzy je poznat, že v signálu jsou v osách x, y dominantní frekvence kolem 2 Hz a kolem 13 Hz. Amplitudy frekvencí v ose Z jsou rozmístěny po celém spektru a rozmístění amplitud má tvar rovnoramenného trojúhelníku s krajními body v 0 a 35 Hz.

Další výřez byl zvolen od 120. do 130. sekundy. Časový průběh lze vidět na obrázku 5.10 a Fourierova transformace je na obrázku 5.11. Z této spektrální analýzy nebylo získáno moc informací o průběhu epileptickém záchvatu, protože amplitudy ve spektrální analýze jsou v řádech 10^{-3} , což už jsou řády šumu na senzorech, jak je zmíněno v odstavci 5.1.


Bohužel z těchto výřezů ani z celkového signálu není poznat žádná charakteristická frekvence pro epileptické záchvaty a proto původní teoretický návrh klasifikátoru nebude nejspíš fungovat.




Obrázek 5.6: Nefiltrovaný časový průběh celého záchvatu, pokud je telefon pod polštářem, intervaly a) a b) určeny pro podrobnější analýzu




Obrázek 5.7: Filtrovaná pravá strana Fourierovy transformace signálu průběhu záchvatu z obrázku 5.6




Obrázek 5.8: Interval a), výřez 10 sekundového signálu z průběhu záchvatu z obr. 5.6. Telefon umístěn pod polštářem, výřez z 100-110 sec



Obrázek 5.9: Filtrovaná Fourierova transformace časového intervalu na obr. 5.8, výřez časového úseku 100-110 sec



Obrázek 5.10: Interval b), výřez 10 sekundového signálu z průběhu záchvatu. Telefon umístěn pod polštářem, výřez z 120-130 sec



Obrázek 5.11: Filtrovaná Fourierova transformace časového intervalu na obr. 5.10, výřez časového úseku 120-130 sec

Telefon umístěn u nohou


Pro druhý způsob měření byla zvolena pozice u nohou pacienta. Přesná pozice telefonu na posteli je naznačena na obrázku 5.12. Na obrázku 5.13 je časový průběh záznamu a na obrázku 5.14 je graf filtrované Fourierovy transformace celého časového průběhu.

Podobně jako v předchozím případě bylo provedeno několik výřezů pro podrobnější analýzu signálu. První vyříznutý interval signálu byl v čase 60 - 70 s. Grafy tohoto intervalu jsou na obrázcích 5.15 a 5.16. V daném časovém intervalu je vidět, že do 64 s nebyla zaznamenána žádná pohybová událost. Pak začalo kmitání s mírnými otřesy, následované několika sekundami rychlého kmitání.


Po spektrální analýze signálu se ukázalo, energie a dominující frekvence signálu se soustředí v pásmu 0-5 Hz. Další významné energetické pásmo bylo 5-10 Hz pro osy x, y a pro z bylo druhé nejvýznamnější pásmo 15-20 Hz, které sice neobsahovalo dominantní frekvence, ale mohlo by mít stejnou energii signálu jako v pásmu 5 Hz.

Další analyzovaný interval byl v čase 80-90 sec. Graf časového průběhu intervalu je na obrázku 5.17 a filtrovaná Fourierova transformace je na obrázku 5.18. Na časovém průběhu je vidět, že pohybové události v signálu jsou soustředěny mezi 80-83 s. Po analýze spektrálního signálu bylo zjištěno, že v ose z je energie signálu rozložena mezi frekvence 5 Hz až 25 Hz. Přičemž dominantní frekvence jsou v pásmu 15 Hz-20 Hz. V osách x, y vznikaly píky v jednotlivých frekvencích. Dominantní frekvence v těchto osách náleží intervalu 0-5 Hz.


Z obou těchto intervalů ani z celkového měření opět nebylo možno poznat žádná charakteristické vlastnosti ani frekvence pro epileptické záchvaty a původní teoretický návrh klasifikátoru tedy opět nebude s velkou pravděpodobností fungovat.




Obrázek 5.12: Umístění telefonu při měření u nohou




Obrázek 5.13: Časový průběh celého záchvatu, pokud je telefon u nohou; vyznačené intervaly c),d) vybrány pro podrobnější analýzu




Obrázek 5.14: Filtrovaná pravá strana Fourierovy transformace signálu na obrázku 5.13.




Obrázek 5.15: Interval c), výřez z časového signálu 60-70 sekundy na obrázku 5.13



Obrázek 5.16: Filtrovaná Fourierova transformace časového intervalu na obr. 5.15, výřez časového úseku 60-70 sec



Obrázek 5.17: Interval d), výřez z časového signálu 80-90 sekundy z grafu na obrázku 5.13



Obrázek 5.18: Filtrovaná Fourierova transformace časového intervalu na obr. 5.15, výřez časového úseku 80-90 sec

5.5 Analýza umístění telefonu

Bylo zjištěno, že jeden z hlavních problémů pro detekci epileptických záchvatů pomocí mobilního telefonu bylo zvolení umístění pro telefon během měření. V dalších kapitolách budou proto diskutovány možnosti umístění mobilního telefonu společně s jejich výhodami a nevýhodami.

Telefon umístěn pod polštářem

První návrh umístění telefonu bylo umístit telefon pod polštář. Na první pohled se může zdát jako nejlepší a zároveň nejjednodušší řešení, avšak po analýze a otestování, bylo zjištěno, že to není vhodné umístění.

Je předpokládáno, že vibrační frekvence se do mobilu přenáší dvěma směry. První směr přenášení vede přes polštář a druhý směr přenášení vede přes matraci postele. Protože byl telefon umístěn pod polštářem, který působí jako tlumič, jsou frekvence, které se přenášejí přes polštář, tlumené, a jejich velikost závisí na celkovém tlumení polštáře. Frekvence, které jsou přenášeny přes matraci do telefonu, jsou také tlumené, ale záleží na tvrdosti a celkové pružnosti postele a její schopnosti přenášet tyto vibrační frekvence do mobilu. Jelikož telefon má minimální hodnotu, kterou dokáže rozlišit (viz odst. 3.5), není telefon vždy schopen všechny tyto tlumené frekvence zachytit. A tudíž klasifikace nemusí být vždy možná.

Telefon umístěn u nohou


Druhý návrh je podobný tomu prvnímu. Telefon je umístěn k nohám. Kvůli této konfiguraci se na telefon přenáší frekvence pouze přes matraci. Platí tedy omezení jako v odstavci 5.5. Výhodou oproti prvnímu umístění může být, že pacient by mohl u nohou generovat větší amplitudy u daných frekvencí, než kdyby je generoval horní polovinou těla. Díky tomu by mohl být telefon schopen detekovat lépe důležité frekvence v signálu.

Avšak jak bylo zmíněno v analýze naměřeného signálu s telefonem umístěným u nohou, ani v tomto případě nebyly detekovány žádné charakteristické vlastnosti a frekvence pro epileptický záchvat.

Telefon umístěn na provázku

Poslední navržený způsob měření byl zvolen tak, že se mobilní telefon uvázal na provázek jako je naznačeno na obrázku 5.19. Tento způsob měření však nebyl v praxi otestován a nejsou známy vlastnosti tohoto způsobu měření. Provázek je umístěn napříč postelí, takže uživatel při jakémkoliv pohybu na posteli by způsobil, že by se telefon začal pohybovat ve směru x, jak je naznačeno na obrázku 5.19.

Nevýhodou této konfigurace je, že je složitější na konstrukci, avšak výhody tohoto umístění telefonu jsou oproti předchozím návrhům velké. Za prvé je měření záznam pouze v jedné ose telefonu, čímž se nám sníží výpočetní nároky na telefon a zároveň bude na detekci působit pouze šum z jedné osy akcelerometru. Kdyby detekce kombinovala měření ze všech tří os, tak



Obrázek 5.19: Návrh způsobu měření s telefonem na provázku

by se tento šum sčítal a násobil a mohl by značně ovlivnit přesnost detekce. Další výhodou je, že nám na telefon dle modelu působí slabé tlumení dané tvrdostí postele, takže telefon by měl být teoreticky schopen detekovat frekvence přesněji.

Kapitola 6

Algoritmus a programování aplikace

6.1 Navrhnutý algoritmus

Zde je popsán navrhnutý algoritmus pro zpracovávání dat z akcelerometru a následnou klasifikaci dat, zda došlo k možnému epileptickému záchvatu. Nejdříve se řeší redukce dat, díky které se omezí zátěž baterie a výpočetních nároků na mobilní telefon, a následně se zde rozebírá princip klasifikace dat.

6.1.1 Redukce dat

Protože mobilní telefon má omezenou baterii a nemá takové výpočetní schopnosti jako obyčejný stolní počítač, musí být kvůli těmto omezením data filtrována. Filtrace dat, tj. rozhodnutí, která data budou dále zpracována a která budou vyřazena, se odehrává dle algoritmu v následujícím odstavci. Tato filtrace dat byla inspirovaná disertační prací od inženýra Poh, Ming-Zher [18].

Spočte se velikost vektoru zrychlení (6.1)

$$a = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (6.1)$$

a pokud je směrodatná odchylka signálu menší než $0.1g$, kde g je gravitační zrychlení, tak je signál považován bez pohybu a další zpracování není nutné.

6.1.2 Algoritmus - Zpracování dat

Naměřená data byla zpracována dle následujícího postupu. Nejdříve byla spočtena lineární interpolace, protože systém Android negarantuje stejné vzorkovací periody. Touto interpolací byla tato chyba napravena. Dále byla interpolovaná data ověřena, zda se nemusí vyřadit, tj. zda variance těchto dat není menší než $0.1g$.

Pak byla na vektor naměřených hodnot, který měl většinou kolem 1000 prvků, použita vysokofrekvenční propust. Byla použita stejná propust jako v práci [18], která ji převzala z [22]. Tato vysokofrekvenční propust má podle [22] mezní frekvenci 0.043 Hz.

Po použití frekvenčního filtru byla použita Diskrétní Fourierova transformace (1.1) s 1024 prvky. Prvky, které chyběly do počtu 1024, byly nahrazeny nulami. Pro spočítání Fourierovy transformace byla použita metoda z knihovny od Apache Software Foundation Foundation, konkrétně třída `FastFourierTransformer`.

Jakmile byl získán komplexní vektor Fourierovy transformace, byla určena dominantní frekvence (viz odstavec 1.2.3), která pak byla použita pro klasifikaci měřeného signálu.

6.1.3 Princip klasifikace

Z dizertační práce [18, odst. 5.3.5, str.94] byla převzata znalost, že signál měřený při generalizovaném tonicko-klonickém (GTC) záchvatu typicky obsahuje frekvence nad 2 Hz. Byla navržena jednoduchá aplikace, která, pokud bude dominantní frekvence signálu do 2 Hz, vyhodnotí měření jako "záchvat nenastal", jinak měření vyhodnotí jako "záchvat nastal".

6.2 Programování aplikace

Pro vytvoření aplikace bylo použito Android studio, což je oficiální IDE (Integrated Development Environment) pro vytváření Android aplikací od Googlu. Zdrojové kódy jsou uloženy na CD, které se přikládá společně s bakalářskou prací.

Pro tuto aplikaci byly vytvořeny celkem tři aktivity, které tvořily uživatelské rozhraní. Byly pojmenovány `MainActivity`, `KalibraceActivity` a `GrafActivity`. Čtenář snadno dle názvů nahlédne, že `KalibraceActivity` měla na starosti kalibraci senzorů akcelerometru, `GrafActivity` měla na starosti vykreslování grafů a poslední `MainActivity` řídila všechny procesy v aplikaci.

Pro kontinuální sběr dat, tj. pro sběr dat, i když je telefon "ve spánku", byla vytvořena služba jménem `ServiceDetekce`, která běžela na popředí tzv. `Foreground Service`. Tato služba má kontrolu nad všemi vlákny, ve kterých probíhají výpočty a zápisy na disk. Sama běží na svém vlastním vlákně, aby nezasahovala do běhu uživatelského rozhraní. Aby tato služba nebyla z optimalizačních důvodů vypnuta, když je telefon dlouho ve spánku, byla jí nastavena priorita stejná, jako mají přehrávače hudby. Navíc si tato služba při spuštění získala zámeček tzv. `wakeLock`, což je způsob, jak udržet CPU v běhu, i když se telefon "tváří", že je ve spánku (má vypnutou obrazovku).

Tato služba každých deset sekund měření analyzuje naměřené hodnoty a výsledky pošle do `MainActivity`, aby zobrazila výsledky uživateli. Aktivita `MainActivity` by mohla případně poslat tyto výsledky do `GrafActivity`, která vykreslí grafy s danými výsledky.

Pro komunikaci mezi vlákny byly použity třídy `Handler`. Každá třída `Handler` je asociována pouze s jedním vláknem, na kterém pak zpracovává příkazy (`Messages`), které byly do `Handleru` poslány.

Pro vykreslování grafů v `GrafActivity` byla použita knihovna `GraphView` [11], která poskytuje jednoduché ovládání pro vykreslování grafů.

Kapitola 7

Testování aplikace

Testování aplikace bylo provedeno na vibračním generátoru sestaveném na katedře Kybernetiky. Telefon byl postaven na zařízení obrazovkou nahoru, tak aby se snímaly kmity pouze v ose z viz obrázek 3.1. Bylo provedeno celkem 5 měření. Nejdříve zařízení vyvolávalo kmity o frekvencích 1 Hz, 5 Hz, 10 Hz a následně produkovalo kombinaci sinusoid s frekvencemi 1 Hz, 5 Hz, 10 Hz a následně kombinaci s frekvencemi 1 Hz, 2 Hz a 3 Hz. V měření se objevil jev zvaný zázněje. Ten je zde matematicky popsán a odůvodněn, proč se v měření vyskytl.

7.1 Měření

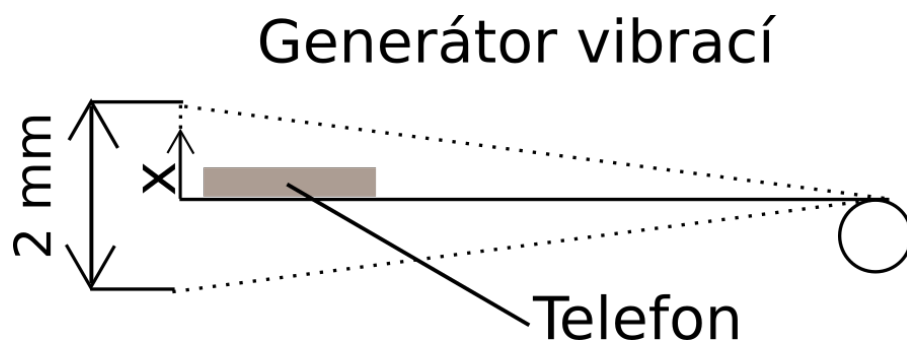
Pro měření byl použit mobilní telefon SM-G903F a pro kontrolu byl použit průmyslový akcelerometr od firmy Kistler typ 8640A50.

Průmyslový akcelerometr od firmy Kistler je jednoosý analogový piezoelektrický senzor s následujícími vlastnostmi, které byly získány z oficiálního data sheetu [6]. Rozpětí měřeného signálu může být v intervalu $\pm 50g$, kde g je 9.80665 m s^{-2} . Citlivost senzoru je 100 mV/g . Pro podrobnější specifikace odkazuje autor na oficiální data sheet [6].


Jednoduchý model generátoru vibrací je na obrázku 7.1. Fotka z měření je pak na obrázku 7.2.

7.2 Zázněje v signálu

Zázněj je zvláštní případ složeného kmitání, kdy se skládají v signálu dvě blízké frekvence. Důsledkem tohoto jevu se amplituda výsledného signálu periodicky zmenšuje a zvětšuje. Tento jev bude stručně matematicky odvozen.



Obrázek 7.1: Model generátoru vibrací



Obrázek 7.2: Fotka použitého generátoru vibrací společně s umístěným telefonem

Součet funkcí sinus

Nechť v systému existuje signál $x(t) \in \mathbb{R}$. Tento signál je složen ze součtu dvou funkcí sinus s nulovou fází a různou frekvencí. První funkce sinus popisuje frekvenci budícího signálu systému a druhá frekvence popisuje vlastní frekvenci systému. Platí následující rovnice:

$$x(t) = A_1 \sin(\omega_1 t) + A_2 \sin(\omega_2 t) \quad (7.1)$$

po použití goniometrických vzorců a úpravách vznikne rovnice

$$x(t) = (A_1 + A_2) \sin\left(\frac{\omega_1 + \omega_2}{2}t\right) \cos\left(\frac{\omega_1 - \omega_2}{2}t\right) + (A_1 - A_2) \cos\left(\frac{\omega_1 + \omega_2}{2}t\right) \sin\left(\frac{\omega_1 - \omega_2}{2}t\right) \quad (7.2)$$

Jestliže budou amplitudy A_1 a A_2 stejné, dostaneme následující rovnici

$$x(t) = 2A \cos\left(\frac{\omega_1 - \omega_2}{2}t\right) \sin\left(\frac{\omega_1 + \omega_2}{2}t\right) \quad (7.3)$$

Rovnice (7.3) lze interpretovat jako funkce $\sin\left(\frac{\omega_1 + \omega_2}{2}t\right)$ s frekvencí $\omega_1 + \omega_2$ a proměnlivou amplitudou $2A \cos\left(\frac{\omega_2 - \omega_1}{2}t\right)$. Tato interpretace odpovídá skutečným naměřeným hodnotám (viz odstavec 7.3).

Po převedení rovnice (7.3) z úhlové frekvence na frekvenci v Hz, díky vztahu $\omega = 2\pi f$, je získána rovnice

$$x(t) = 2A \sin \cos\left(2\pi \frac{f_1 - f_2}{2}t\right) \left(2\pi \frac{f_1 + f_2}{2}t\right) \quad (7.4)$$

Z rovnice (7.4) je vidět, že frekvence zánějů v Hz je $f_z = f_1 - f_2$ a frekvence změny amplitudy je $f_a = f_1 + f_2$, protože během jedné periody funkce \sin a \cos nabývá dvou maxim. Pro shrnutí tedy platí

$$x(t) = A_1 \sin(\omega_1 t) + A_2 \sin(\omega_2 t)$$

$$x(t) = 2A \cos\left(2\pi \frac{f_1 - f_2}{2}t\right) \sin\left(2\pi \frac{f_1 + f_2}{2}t\right)$$

kde frekvence zánějů f_z a frekvence změny amplitudy f_a výsledného signálu $x(t)$ je dána

$$f_z = f_1 - f_2 \quad (7.5)$$

$$f_a = f_1 + f_2 \quad (7.6)$$

Pokud je známa Fourierova transformaci signálu, je možno z ní určit frekvence f_1 a f_2 a určit z nich frekvenci zánějů f_z a frekvenci změny amplitudy f_a . Geometrický význam f_a a f_z v grafech je naznačen na obrázku 7.5.

7.3 Výsledky měření

Všechny generované sinusoidy mají nulový fázový posun. Při měření se vyskytl v měřených signálech jev zvaný záněje. Tento jev je matematicky popsán a vysvětlen v předchozím odstavci 7.2.

7.3.1 1. Měření - 1 Hz

V prvním měření byl generován sinusový signál o frekvenci 1 Hz. Měřený signál mobilního akcelerometru a průmyslového akcelerometru v časové oblasti lze vidět v obrázku 7.3. Na obrázku 7.4 lze vidět jejich Fourierovu transformaci. Z tohoto grafu je vidět, že průmyslový akcelerometr byl přesnější a správně identifikoval frekvence pouze kolem 1 Hz konkrétně frekvence 0.67 Hz a 1.27 Hz.

Mobilní akcelerometr sice také správně identifikoval hlavní frekvenci 1 Hz, ale zobrazily se zde také frekvence okolo 7 Hz. Tato frekvence nebyla detekována na průmyslovém akcelerometru, takže z nosníku tato frekvence nejspíše nepochází. Tato chybná frekvence může být důsledkem špatného vzorkování, jak je popsáno v odstavci 3.4.1.

Toto měření se může zdát, že je v rozporu s podmínkou, která je určena v odstavci 7.4. Podle tohoto odstavce by telefon neměl být schopen tuto frekvenci zaznamenat, jelikož senzor mobilního akcelerometru nemá dostatečné rozlišení. Zde je nutné dodat, že pouze pro generování signálu s frekvencí 1 Hz byla použita amplituda větší než 2 mm.

Pokud je uvažováno, že v signálu vnikaly záněje součtem funkcí sinus, lze určit frekvenci rázů a frekvenci změny amplitudy.

$$f_a = f_1 + f_2 = 1.27 + 0.67 = 1.94 \text{ Hz} \quad (7.7)$$


a frekvence rázů je dána

$$f_z = f_1 - f_2 = 1.27 - 0.67 = 0.6 \text{ Hz} \quad (7.8)$$

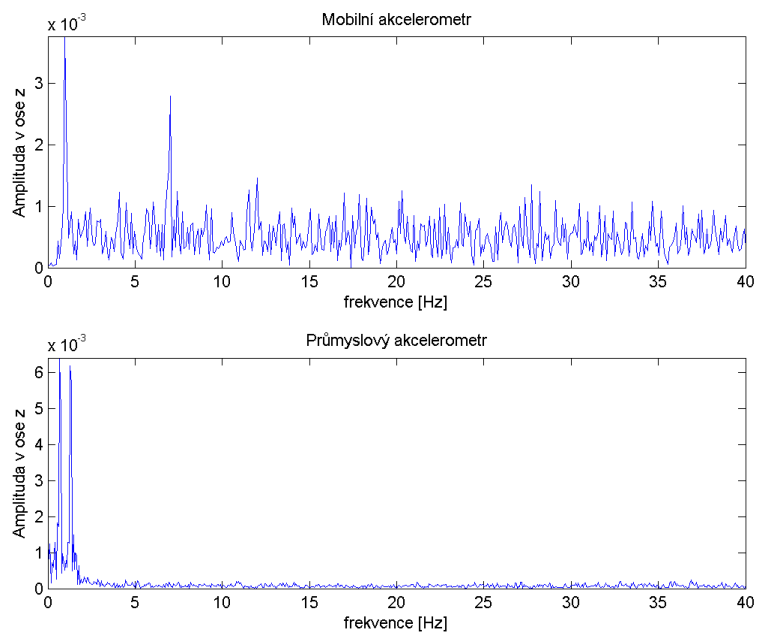
7.3.2 2. Měření - 5 Hz

V druhém měření byl generován sinusový signál o frekvenci 5 Hz. Grafy naměřeného signálu jsou na obrázku 7.5 a Fourierova transformace je na obrázku 7.6. Fourierova transformace signálu z mobilního signálu se zdá být téměř ideální, protože se nám maximální frekvence koncentrují pouze kolem 5 Hz, což je přesně tak, jak bylo míněno. U průmyslového akcelerometru se nám frekvence také koncentrují jen kolem 5 Hz, ale projevují se zde záněje. Co to jsou záněje je popsáno v odstavci 7.2.

Je předpokládáno, že záněje tvoří dva sinusové signály. Vznikají zde záněje vlastní frekvence nosníku a frekvence generovaného signálu. Ve spodním grafu na obrázku 7.5 je dobře vidět, jak takový průběh zánějů vypadá.



Obrázek 7.3: Časový záznam z akcelerometrů se simulovanou sinusoidou s frekvencí 1 Hz



Obrázek 7.4: Pravá strana Fourierovy transformace časového záznamu z obr. 7.3

Zázněje

Fourierova transformace časového záznamu průmyslového senzoru potvrzuje výskyt záznějů v signálu (viz obrázek 7.6). V této transformaci se vyskytují blízko sebe dvě dominantní frekvence. Tyto frekvence byly identifikovány jako 4.7 Hz a 5.3 Hz.


Je předpokládáno, že zázněje jsou způsobené součtem dvou funkcí sinus s danými frekvencemi. S tímto předpokladem je možno určit vlastnosti signálu pomocí vzorců v odstavci 7.2. Frekvence změny amplitudy je určena jako

$$f_a = f_1 + f_2 = 5.3 + 4.7 = 10Hz \quad (7.9)$$

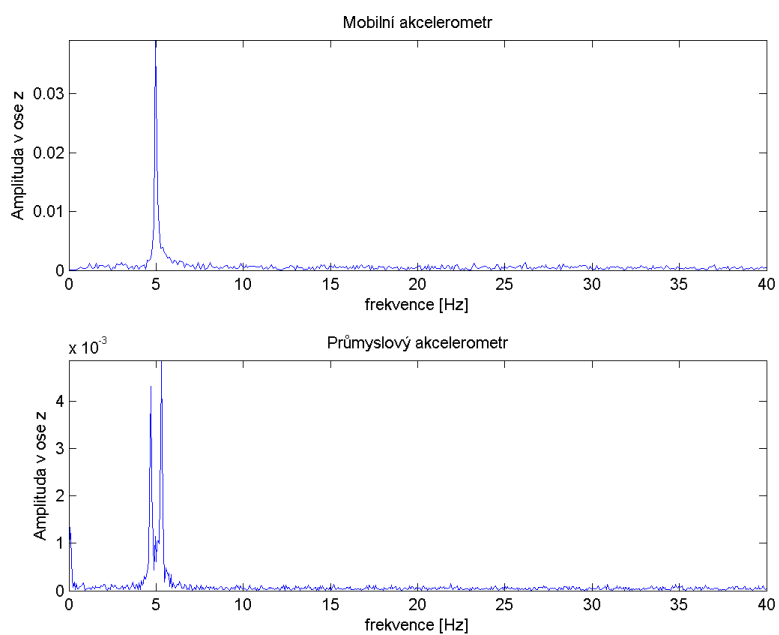
a frekvence rázů je dána

$$f_z = f_1 - f_2 = 5.3 - 4.7 = 0.6Hz \quad (7.10)$$

Čtenář snadno nahlédne, že tyto hodnoty odpovídají grafu na obrázku 7.5.



Obrázek 7.5: Časový záznam z akcelerometrů se simulovanou sinusoidou s frekvencí 5 Hz



Obrázek 7.6: Pravá strana Fourierovy transformace časového záznamu

7.3.3 3. Měření - 10 Hz

Ve třetím měření byl generován signál o frekvenci 10 Hz. Grafy časového záznamu jsou opět naznačeny na obrázcích 7.7 a 7.8. Stejně jako u druhého měření je Fourierova transformace téměř ideální. Z časového a transformovaného záznamu je vidět, že mobilní akcelerometr neměl problém s měřením této frekvence. Fourierova transformace záznamu mobilního akcelerometru je maximální okolo 10 Hz, což je přesně ta frekvence, která byla generována. V časovém záznamu z průmyslového akcelerometru se opět výrazně projeví záněje.

Při bližší analýze záznamu z průmyslového akcelerometru byly identifikovány hlavní frekvence signálu jako 9.7 Hz a 10.3 Hz. S těmito hodnotami opět je možno určit frekvenci zánějů a frekvenci změny amplitudy.

$$f_z = f_1 - f_2 = 10.3 - 9.7 = 0.6 \text{ Hz} \quad (7.11)$$

$$f_a = f_1 + f_2 = 10.3 + 9.7 = 20 \text{ Hz} \quad (7.12)$$

7.3.4 4. Měření - 1 Hz, 5 Hz a 10 Hz

Ve čtvrtém měření byl již generovaný signál součtem několika funkcí sinus. Celkem byly generovány tři funkce sinus o frekvencích 1 Hz, 5 Hz a 10 Hz. Grafy na obrázcích 7.9 a 7.10 už nejsou tak ideální jako v předchozích případech.

Průmyslový senzor celkem správně dokázal rozpoznat hlavní frekvence signálu, tedy frekvence okolo 1 Hz, 5 Hz a 10 Hz. Avšak frekvence v okolí 1 Hz nejsou nijak výrazné.


Fourierova transformace mobilního akcelerometru už nevypadá dle představ. Je zde správně rozpoznána hlavní frekvence 5 Hz a méně výrazná hlavní frekvence okolo 10 Hz, avšak frekvence 1 Hz je utlumena a v signálu není téměř rozpoznatelná.

Z grafů Fourierovy transformace průmyslového akcelerometru vyplývá, co bylo odvozeno v odstavci 3.5 a to, že čím vyšší frekvence, tím je potřeba větší zrychlení pro generování signálu a tudíž je i daná frekvence lépe detekovatelná.


7.3.5 5. Měření - 1 Hz, 2 Hz a 3 Hz

V posledním pátém měření byl analyzován signál s frekvencemi 1 Hz, 2 Hz a 3 Hz. Byly úmyslně zvoleny frekvence "blízko" sebe, aby byly otestovány schopnosti mobilního telefonu k rozpoznání těchto blízkých frekvencí. Dle naměřených dat a Fourierových transformací na obrázcích 7.11 a 7.12 lze konstatovat, že ani průmyslový signál nedokázal bezchybně rozpoznat hlavní frekvence signálu. Průmyslový akcelerometr správně určil pouze frekvence 1 Hz a 3 Hz.


Lze se tedy domnívat, že měření, respektive generování signálu probíhalo špatně. Jednotlivé frekvence společně s vlastní frekvencí nosníku tvořily záněj, který výsledný signál kvůli nelineárním vlastnostem zdeformoval natolik, že akcelerometr nebyl schopen získat původní frekvence signálu.




Obrázek 7.7: Časový záznam z akcelerometrů se simulovanou sinusoidou s frekvencí 10 Hz



Obrázek 7.8: Pravá strana Fourierovy transformace časového záznamu



Obrázek 7.9: Časový záznam z akcelerometrů se simulovanými sinusoidami s frekvencemi 1 Hz, 5 Hz a 10 Hz



Obrázek 7.10: Pravá strana Fourierovy transformace časového záznamu

Z toho důvodu i mobilní akcelerometr nebyl schopen správně rozpoznat hlavní frekvence signálu. Fourierova transformace signálu z mobilního akcelerometru naznačuje pouze hlavní frekvenci 3 Hz. Dalším důvodem nedetekování nízkých frekvencí může být opět malá amplituda jak je zmíněno v odst. 3.5 a 7.4.

7.4 Nedetekování nízkých frekvencí

Z obrázku 7.1 je zřejmé, že maximální amplituda je 1 mm neboli 0.001 m. Po dosazení M a A do rovnice (3.5) odvozené v odstavci 3.5 bude získána rovnice (7.13). Z té vyplývá, že pro daný mobilní senzor je možno detekovat pouze frekvence větší než přibližně 5 Hz.


$$f \geq \frac{1}{2\pi} \sqrt{\frac{M}{A}} = \frac{1}{2\pi} \sqrt{\frac{1}{0.001}} \cong 5 \text{ Hz} \quad (7.13)$$

7.5 Shrnutí

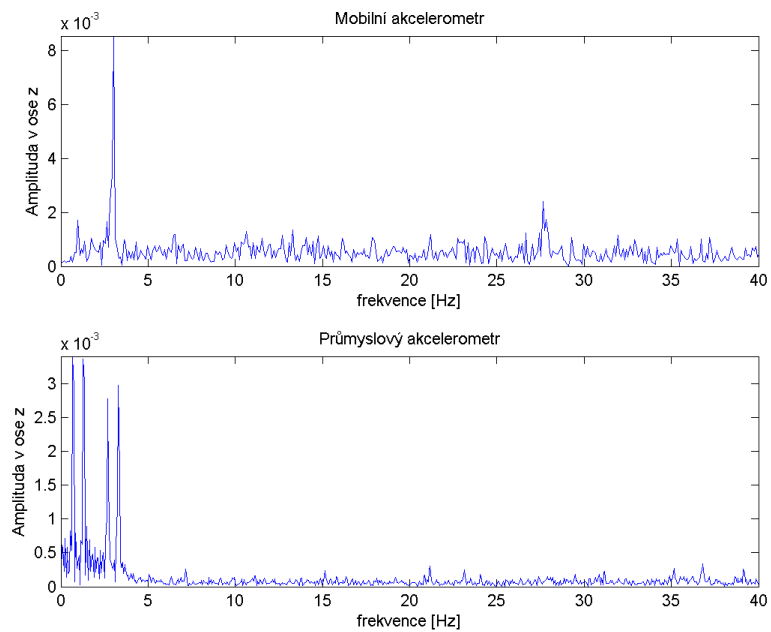
Dle spočtených a naměřených údajů lze konstatovat, že mobilní akcelerometr dokáže spolehlivě detekovat jednotlivé frekvence v signálu, pokud frekvence a amplituda signálu splňuje nerovnici (7.13). Z této rovnice lze konstatovat, že schopnost detekování frekvence v signálu je závislá na amplitudě signálu a na rozlišení senzoru.

Byl matematicky odvozen jednoduchý typ zázněje součtu dvou funkcí sinus a pak byl použit pro vysvětlení jevů, které se odehrávaly při měření. Zázněje byly způsobeny interferencí generovaného signálu a vlastní frekvencí nosníku, který generoval budící signál.

Dále bylo zjištěno, že pokud jsou měřené frekvence blízko u sebe, nemusí být mobilní ani průmyslový akcelerometr schopen buď kvůli příliš malým amplitudám daných frekvencí, nebo kvůli nelinearitám v signálu detekovat tyto frekvence přesně.



Obrázek 7.11: Časový záznam z akcelerometrů se simulovanými sinusoidami s frekvencemi 1 Hz, 2 Hz a 3 Hz



Obrázek 7.12: Pravá strana Fourierovy transformace časového záznamu

Kapitola 8

Závěr

V této bakalářské práci byly popsány vlastnosti inerciálních senzorů na mobilních telefonech s operačním systémem Android. Byly stanoveny omezení, skutečné vlastnosti oproti deklarovaným a možnosti využití těchto senzorů. Mezi tato omezení patří například nerovnice popisující vztah mezi amplitudou, minimálním rozlišením senzoru a velikostí frekvence. Pokud tato nerovnice platí, lze z měřeného signálu, který je zatížený šumem, určit hlavní frekvence signálu pomocí Fourierovy transformace.

Vlastnosti akcelerometru v telefonu byly otestovány na generátoru vibrací sestrojeným na katedře Kybernetiky a porovnány s průmyslovým akcelerometrem od firmy Kistler. Bylo zjištěno, že ačkoliv má průmyslový akcelerometr větší frekvenci vzorkování, frekvenční spektra mobilního akcelerometru a průmyslového akcelerometru se nijak výrazně nelišila a lze proto konstatovat, že mobilní akcelerometr je vhodný pro detekci testovaných frekvencí.

Následně byl popsán návrh algoritmu a způsobu měření pro detekci epileptických záchvatů během spánku. Došlo se k závěru, že navrhovaný algoritmus a způsob měření není vhodný pro použití v praxi a jsou diskutovány alternativy.

Pro lepší návrh algoritmu detekce epileptických záchvatů by bylo vhodné prozkoumat a otestovat další možné způsoby měření. Jinými slovy zjistit a navrhnout praktickou pozici telefonu pro detekci vibrací na posteli tak, aby důležité frekvence byly minimálně tlumeny. Pro zlepšení přesnosti detekce by bylo také vhodné kromě telefonu používat i "chytrý" náramek nebo "chytré" hodinky, které mají v sobě zabudovaný akcelerometr. Neustálý kontakt s tělem by zajišťoval přesnější detekci a taky nové možnosti využití.

Reference

- [1] ABZ knihy a.s., ed. *Tachypnoe - Slovník cizích slov*. URL: <http://slovník-cizich-slov.abz.cz/web.php/slovo/tachypnoe> (cit. 17.04.2016).
- [2] Akram Bayat, Marc Pomplun a Duc A. Tran. “A Study on Human Activity Recognition Using Accelerometer Data from Smartphones”. In: *Procedia Computer Science* 34 (2014). The 9th International Conference on Future Networks and Communications (FNC’14)/The 11th International Conference on Mobile Systems and Pervasive Computing (MobiSPC’14)/Affiliated Workshops, s. 450–457. ISSN: 1877-0509. DOI: <http://dx.doi.org/10.1016/j.procs.2014.07.009>. URL: <http://www.sciencedirect.com/science/article/pii/S1877050914008643>.
- [3] J. Behar et al. “SleepAp: An Automated Obstructive Sleep Apnoea Screening Application for Smartphones”. In: *IEEE Journal of Biomedical and Health Informatics* 19.1 (led. 2015), s. 325–331. ISSN: 2168-2194. DOI: 10.1109/JBHI.2014.2307913.
- [4] Anne T. Berg et al. “Revised terminology and concepts for organization of seizures and epilepsies: Report of the ILAE Commission on Classification and Terminology, 2005–2009”. In: *Epilepsia* 51.4 (2010), s. 676–685. ISSN: 1528-1167. DOI: 10.1111/j.1528-1167.2010.02522.x. URL: <http://dx.doi.org/10.1111/j.1528-1167.2010.02522.x>.
- [5] ČTK. “Počet chytrých telefonů loni poprvé překonal klasické mobily”. In: *Aktualne.cz* (28.led. 2015). URL: <http://zpravy.aktualne.cz/ekonomika/pocet-chytrych-telefonu-loni-poprve-prekonal-klasicke-mobily/r~1961ccb4a6fe11e49e4b0025900fea04/> (cit. 17.04.2016).
- [6] Kistler Eastern Europe. *Miniature PiezoBeam Accelerometer 8640A50*. URL: <https://www.kistler.com/cz/en/> (cit. 17.04.2016).
- [7] Robert S. Fisher et al. “ILAE Official Report: A practical clinical definition of epilepsy”. In: *Epilepsia* 55.4 (2014), s. 475–482. ISSN: 1528-1167. DOI: 10.1111/epi.12550. URL: <http://dx.doi.org/10.1111/epi.12550> (cit. 18.04.2016).
- [8] Epilepsy Foundation, ed. *About epilepsy*. 2014. URL: <http://www.epilepsy.com/learn/> (cit. 18.04.2016).
- [9] The Apache Software Foundation. *Commons Math: The Apache Commons Mathematics Library*. URL: <https://commons.apache.org/proper/commons-math/> (cit. 17.04.2016).

- [10] Don C. Fowles et al. “Publication Recommendations for Electrodermal Measurements”. In: *Psychophysiology* 18.3 (květ. 1981), s. 232–239. DOI: 10.1111/j.1469-8986.1981.tb03024.x. URL: <http://dx.doi.org/10.1111/j.1469-8986.1981.tb03024.x>.
- [11] Jonas Gehring. *GraphView - open source graph plotting library for Android*. URL: <http://www.android-graphview.org/> (cit. 17.04.2016).
- [12] W. Gu et al. “Sleep Hunter: Towards Fine Grained Sleep Stage Tracking with Smartphones”. In: *IEEE Transactions on Mobile Computing* PP.99 (2015), s. 1–1. ISSN: 1536-1233. DOI: 10.1109/TMC.2015.2462812.
- [13] MUDr Milada Hobzová. “Syndrom obstrukční spánkové apnoe”. In: *Interní medicína pro praxi* 12 (2010), s. 148–151. URL: <http://www.internimedicina.cz/pdfs/int/2010/03/08.pdf> (cit. 17.04.2016).
- [14] Frances Chung et al. “STOP Questionnaire”. In: *Anesthesiology* 108.5 (květ. 2008), s. 812–821. DOI: 10.1097/aln.0b013e31816d83e4. URL: <http://dx.doi.org/10.1097/ALN.0b013e31816d83e4>.
- [15] Google Inc. *Android Open Source Project*. URL: <https://source.android.com/devices/sensors/report-modes.html> (cit. 17.04.2016).
- [16] M. Al-Mardini et al. “On the use of smartphones for detecting obstructive sleep apnea”. In: *Bioinformatics and Bioengineering (BIBE), 2013 IEEE 13th International Conference on*. Lis. 2013, s. 1–4. DOI: 10.1109/BIBE.2013.6701674.
- [17] Northcube. *Sleep Cycle alarm clock*. URL: <http://www.sleepcycle.com/> (cit. 17.04.2016).
- [18] Ming-Zher Poh. “Continuous assessment of epileptic seizures with wrist-worn biosensors”. Dis. Cambridge, MA.: Harvard-MIT Division of Health Sciences a Technology, Massachusetts Institute of Technology, 2011. URL: <http://hdl.handle.net/1721.1/68456> (cit. 17.04.2016).
- [19] MUDr Tomáš Procházka. “Epilepsie u dospělých: klasifikace a léčba”. In: *Psychiatr. prax* 12.3 (2011), s. 108–110.
- [20] Runtastic. *Sleep Better with Runtastic*. URL: <https://www.runtastic.com/cs/apps/sleepbetter> (cit. 17.04.2016).
- [21] Maxdorf s.r.o., ed. *Apneusis - Lékařský slovník*. URL: <http://lekarske.slovníky.cz/pojem/apneusis> (cit. 17.04.2016).
- [22] M. P. Tarvainen, P. O. Ranta-aho a P. A. Karjalainen. “An advanced detrending method with application to HRV analysis”. In: *IEEE Transactions on Biomedical Engineering* 49.2 (ún. 2002), s. 172–175. ISSN: 0018-9294. DOI: 10.1109/10.979357.
- [23] Urbandroid Team. *Sleep as Android*. URL: <http://sleep.urbandroid.org/> (cit. 17.04.2016).