

České vysoké učení technické v Praze

Fakulta elektrotechnická

Katedra kybernetiky



Diplomová práce

**Monitorování kvality spánku pomocí analýzy audio záznamu**

*Bc. David Slezák*

Vedoucí práce: Ing. Daniel Novák, Ph.D.

Studijní program: Kybernetika a Robotika, magisterský

Obor: Robotika

7. května 2014



## Prohlášení autora práce

Prohlašuji, že jsem předloženou práci vypracoval samostatně a že jsem uvedl veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze dne .....

.....  
Podpis autora práce



## Poděkování

Na tomto místě bych chtěl poděkovat mé rodině a snoubence za umožnění studia na vysoké škole a za nesmírnou podporu a motivaci během celého období mého studia.

Poděkování patří také Ing. Petru Nálevkovi Ph.D. za množství prospěšných nápadů, připomínek, pomoc při testování aplikace a poskytnuté kódy a data, MUDr. Martinu Brunovskému Ph.D. a celému týmu spánkové laboratoře PCP za poskytnutí spánkových záznamů.

Dále bych rád poděkoval vedoucímu mé práce, panu Ing. Danielu Novákovi Ph.D., za výtečné vedení, pravidelné konzultační schůzky, nespočet cenných rad, poskytnutý hardware a perfektní organizaci celého projektu.



České vysoké učení technické v Praze  
Fakulta elektrotechnická

Katedra kybernetiky

## ZADÁNÍ DIPLOMOVÉ PRÁCE

**Student:** Bc. David Slezák  
**Studijní program:** Kybernetika a robotika (magisterský)  
**Obor:** Robotika  
**Název tématu:** Monitorování kvality spánku pomocí analýzy audio záznamu

### Pokyny pro vypracování:

1. Seznamte se s monitorováním kvality spánku a detekce apnotických událostí.
2. Implementujte detekci apnotických událostí v operačním systému Android.
3. Aplikaci otestujte na vzorku 5 pacientů.

### Seznam odborné literatury:

- [1] Moussavi Z., Yadollahi A., Camorlinga S.: Breathing sound analysis for detection of sleep apnea/popnea events. US patent US20080243014 A1, 2008.
- [2] Fiz J.A., Abad J., Jané R., Riera M., Mañanas M. A., Caminal P., Rodenstein D., Morera J.: Acoustic analysis of snoring sound in patients with simple snoring and obstructive sleep apnoea. Eur Respir J. 1996 Nov;9(11):2365-70.

Vedoucí diplomové práce: Ing. Daniel Novák, Ph.D.

Platnost zadání: do konce letního semestru 2014/2015

L.S.

doc. Dr. Ing. Jan Kybic  
vedoucí katedry

prof. Ing. Pavel Ripka, CSc.  
děkan

V Praze dne 10. 1. 2014





## Abstract

The topic of this thesis is the development of a workflow for monitoring sleep quality using smart mobile phone with operating system Android. The objective is to design and implement an application for evaluating patient's quality of sleep. The application enables the acquisition and analysis of patient's sounds during sleep using an embedded microphone and its following analysis reveals snoring and symptoms of obstructive sleep apnea (OSA). Analytical algorithm of the record is capable of determining whether the patient was snoring or suffered apnoic events during the sleep. The algorithm is based on fast Fourier transform (FFT), frequency spectrum analysis and detection of symptoms typical for simple snoring and eventually obstructive sleep apnea. This algorithm is able to detect simple snoring and potentially distinguish it from snoring caused by obstructive sleep apnea syndrome. Thus the outcome is an analyzed audio record as well as information about snoring time, and potential detection of OSA.

## Abstrakt

Tématem této práce je vývoj postupu určeného ke sledování kvality spánku pomocí chytrého mobilního telefonu s operačním systémem Android. Cílem je navrhnout a implementovat aplikaci pro vyhodnocení kvality spánku pacienta. Aplikace umožní pořízení a analýzu pacientova zvukového záznamu při spánku za pomoci vestavěného mikrofonu, při jehož následné analýze bude detekováno chrápání a příznaky obstrukční spánkové apnoe (OSA). Analyzační algoritmus záznamu je schopen určit, jestli pacient chrápal, nebo se u něj vyskytly apnoické události. Algoritmus je založen na rychlé Fourierově transformaci (FFT), frekvenční analýze a následném vyhledání příznaků typických pro chrápání, eventuálně spánkovou apnoe. Tento algoritmus by měl být schopen rozpoznat obyčejné chrápání a případně ho odlišit od chrápání způsobeného syndromem spánkové apnoe. Výstupem je tedy analyzovaný záznam a informace o době chrápání a potenciální odhalení obstrukční spánkové apnoe.



# Obsah

<b>1.</b>	<b>Úvod .....</b>	<b>1</b>
1.1.	Obecný úvod .....	1
1.2.	Cíle práce .....	4
<b>2.</b>	<b>Aktigrafie.....</b>	<b>5</b>
2.1.	Princip aktigrafie.....	5
2.2.	Aktigraf .....	6
2.3.	Vztah aktigrafie a kvality spánku .....	7
2.4.	Možnosti analýzy aktigrafického záznamu.....	7
2.4.1.	Algoritmus Scripps Clinic .....	8
2.4.2.	Coleův algoritmus .....	8
2.4.3.	Sadehův algoritmus .....	9
<b>3.</b>	<b>Chrápání a spánková apnoe .....</b>	<b>11</b>
3.1.	Obyčejné chrápání .....	11
3.1.1.	Definice, vznik a projevy obyčejného chrápání .....	11
3.1.2.	Akustické vlastnosti obyčejného chrápání .....	13
3.2.	Obstrukční spánková apnoe a polysomnografie .....	15
<b>4.</b>	<b>Implementace aktigrafického měření .....</b>	<b>19</b>
4.1.	Získání dat.....	19
4.2.	Validace klasifikačního algoritmu .....	21
<b>5.</b>	<b>Detekce chrápání a apnotických událostí.....</b>	<b>25</b>
5.1.	Zpracování dat .....	25
5.1.1.	Získání surových dat .....	25
5.1.2.	Decimace signálu .....	27
5.1.3.	Filtrace signálu .....	29
5.1.4.	Uložení signálu.....	29

5.2.	Příprava na klasifikaci .....	30
5.2.1.	Rychlá Fourierova transformace.....	30
5.2.2.	Kepstrum.....	32
5.2.3.	Výběr příznaků .....	32
5.3.	Klasifikace chrápání .....	34
5.3.1.	Množina záznamů pro klasifikátor .....	35
5.3.2.	Křížová validace .....	35
5.3.3.	Naivní Bayesův klasifikátor .....	36
5.3.4.	Klasifikátor k-nejbližších sousedů (k-NN).....	38
5.3.5.	Support Vector Machine (SVM) .....	40
5.3.6.	Rozhodovací strom .....	41
5.3.7.	Adaboost .....	44
5.4.	Detekce spánkové apnoe .....	45
<b>6.</b>	<b>Závěr.....</b>	<b>49</b>
<b>7.</b>	<b>Literatura.....</b>	<b>53</b>
<b>8.</b>	<b>Přílohy .....</b>	<b>59</b>
8.1.1.	Vizualizace rozhodovacího stromu RepTree .....	59
8.1.2.	Obsah příloženého CD.....	60

## Seznam obrázků

<i>Obr. 1: Typický aktigraf ve tvaru hodinek, převzeto z [1]</i> .....	6
<i>Obr.2: Srovnání běžného dýchání a chrápání</i> .....	12
<i>Obr. 3: Spektrum prostého průběhu (vlevo) a komplexní průběhu (vpravo) při prvním dechu chrápání, převzeto z [18]</i> .....	14
<i>Obr.4: Spektrum prostého průběhu (vlevo) a komplexní průběhu (vpravo) při druhém dechu chrápání, převzeto z [18]</i> .....	14
<i>Obr.5: Frekvenční spektrum chrápání, převzeto z [17]</i> .....	14
<i>Obr. 6 – Pacient podstupující polysomnografii, převzeto z [42]</i> .....	17
<i>Obr. 7 – Příklad surových nasnímaných dat</i> .....	19
<i>Obr. 8 – Porovnání hypnogramu pacienta s výrazně fragmentovaným spánkem sestaveného z logů z PSG (modře) a pomocí akcelerometru v mobilním telefonu (červeně)</i> .....	21
<i>Obr. 9 - Porovnání hypnogramu pacienta s méně fragmentovaným spánkem sestaveného z logů z PSG (modře) a pomocí akcelerometru v mobilním telefonu (červeně)</i> .....	22
<i>Obr. 10: Porovnání různých záznamů při stejném zvuku – převzeto z [1]</i> .....	26
<i>Obr. 11: Typické spektrum získané ze záznamu chrápání – převzeto z [1]</i> .....	31
<i>Obr. 12 – ROC křivka pro naivní Bayesův klasifikátor</i> .....	38
<i>Obr.13 Ilustrace klasifikace pomocí 3-NN, převzato z [61]</i> .....	39
<i>Obr. 14- Názorné zobrazení SVM pro 2 dimenze</i> .....	40
<i>Obr. 15 – ROC křivka pro RepTree rozhodovací strom</i> .....	43
<i>Obr. 16 Vizualizace rozhodovacího stromu RepTree</i> .....	43
<i>Obr. 17 – ROC křivka nejúspěšnějšího klasifikátoru pro detekci spánkové apnoe (Adaboost s RepTree základem)</i> .....	48



## Seznam tabulek

<i>Tab. 1: Porovnání naměřených hodnot jednotlivých pacientů mobilem a PSG .....</i>	<i>23</i>
<i>Tab. 2 Matice konfuze pro aktigrafické snímání .....</i>	<i>23</i>
<i>Tab. 3 Senzitivita, specificita a Youdenův index pro aktigrafické měření .....</i>	<i>23</i>
<i>Tab. 1 – přehled decimálních faktorů pro různé vzorkovací frekvence .....</i>	<i>28</i>
<i>Tab. 5– přehled vybraných příznaků použitých k detekci chrápání nebo apnoické události .....</i>	<i>34</i>
<i>Tab. 3 Matice konfuze pro naivní Bayesův klasifikátor .....</i>	<i>37</i>
<i>Tab. 4 Senzitivita, specificita a Youdenův index pro Naivní Bayesův klasifikátor .....</i>	<i>37</i>
<i>Tab. 5 Matice konfuze pro k-NN klasifikátor .....</i>	<i>39</i>
<i>Tab. 6 Senzitivita, specificita a Youdenův index pro k-NN klasifikátor .....</i>	<i>40</i>
<i>Tab. 7 Matice konfuze pro SVM klasifikátor .....</i>	<i>41</i>
<i>Tab. 8 Senzitivita, specificita a Youdenův index pro SVM klasifikátor .....</i>	<i>41</i>
<i>Tab. 9 Matice konfuze pro J48 rozhodovací strom .....</i>	<i>42</i>
<i>Tab. 10 Matice konfuze pro RepTree rozhodovací strom .....</i>	<i>42</i>
<i>Tab. 11 Senzitivita, specificita a Youdenův index pro rozhodovací stromy J48 a RepTree .....</i>	<i>42</i>
<i>Tab. 12 Matice konfuze pro Adaboost s RepTree jako weak learnerem .....</i>	<i>44</i>
<i>Tab. 13 Matice konfuze pro Adaboost s naivním Bayesovým klasifikátorem jako weak learnerem .....</i>	<i>45</i>
<i>Tab. 14 - Senzitivita, specificita a Youdenův index pro Adaboost s RepTree a naivním Bayesovým klasifikátorem .....</i>	<i>45</i>
<i>Tab. 14 - Senzitivita, specificita a Youdenův index pro všechny testované klasifikátory pro detekci spánkové apnoe .....</i>	<i>47</i>





# Kapitola 1

## Úvod

### 1.1. Obecný úvod

Tématem této diplomové práce je navrhnutí algoritmů umožňujících detekovat chrápání a příznaky obstrukční spánkové apnoe. Implementace těchto algoritmů na telefonu s operačním systémem Android a využití hardwaru, který typický telefon s tímto operačním systémem nabízí. Právě hardwarová omezení telefonu jsou největší překážkou na cestě k dosažení ideálních výsledků, které by alespoň částečně dosahovaly spolehlivosti výsledků získaných polysomnografií.

Část práce se také zabývá snímáním aktigrafického záznamu pomocí akcelerometru v mobilním telefonu, čímž navazuje na předchozí bakalářskou práci [1]. Analýzou tohoto záznamu sice nezískáme pro účely detekce chrápání a apnoických událostí tak cenná data jako z mikrofonu, nicméně i tak se ale jedná o užitečnou část, kterou lze skloubit s analýzou zvukového záznamu tak, že je možné dosáhnout zpřesnění výsledků.

Jako standardní spolehlivá metoda k analýze spánku pacienta a srovnávací „etalon“ pro tuto práci tvoří lékařem anotovaný záznam z polysomnografie. V této práci se pokusím nastínit, jakým způsobem je možné malou část právě polysomnografického snímání velmi zjednodušeně a pro jeden konkrétní účel nahradit v domácích podmínkách mobilním

telefonem. Monitorování kvality spánku v domácích podmínkách má pro pacienty výhodu hlavně v daleko větším pohodlí, než se mu může dostat v laboratoři, nicméně je jasné, že plné polysomnografické vyšetření nemůže nikdy nahradit. Pro sledování kvality spánku slouží také metoda zvaná aktigrafie, která je ve srovnání s polysomnografií daleko méně náročná jak na vybavení, tak z finančního hlediska. Přesnost aktigrafie zdaleka nedosahuje přesnosti polysomnografie a navíc při použití polysomnografu lze odhalit mnoho věcí, které by samotná aktigrafie odhalit nedokázala. I přes všechny tyto nevýhody je aktigrafie velmi rozšířená, všeobecně uznávaná a rychle se rozvíjející metoda, což dokládá např. fakt, počet studií, které se zabývají právě aktografií rok od roku narůstá větším tempem, než počet publikací zabývajících se spolehlivější, zato zdrojově daleko náročnější polysomnografií.[2]

Sběr dat a jejich vyhodnocování mobilním telefonem lze, jak již bylo zmíněno, provozovat i v domácím prostředí, což je rozhodně obrovská výhoda. Bohužel, takové snímání má i své značné nevýhody. Co se týče snímání zvuku, tak je potřeba řešit to, že narozdíl od laboratorních podmínek se u pacienta doma nedá vyloučit nežádoucí hluk (např. z ulice, od sousedů etc.), takže je potřeba s těmito parazitními zvuky počítat a nastavit algoritmus tak, aby je dokázal rozpoznat a nebrat v potaz. Co se týče doplňkového snímání akcelerometrem pro aktigrafické účely, zde vyvstává otázka, kam telefon umístit, aby bylo snímání co nejpřesnější. Dále je u smartphonu nutno brát v potaz omezenou výdrž na baterii, nepřesný akcelerometr u starších modelů a také omezený výpočetní výkon. Z tohoto důvodu je zejména na starších telefonech velmi problematické snímat jak mikrofonem, tak akcelerometrem zároveň.

Jako nejvhodnější pozice telefonu pro snímání bylo zvoleno jeho umístění do pouzdra, které však ponechá volně dostupný mikrofon a jeho připevnění k prostěradlu ne kraji postele, ideálně v úrovni hlavy nebo hrudníku. Pokud se pacient pohne, bude tento pohyb citelný i na matraci a díky tomu je možné ho zaznamenat akcelerometrem. Volný mikrofon v úrovni hlavy zajistí co možná nejčistší přenos zvuku od pacienta až do digitální podoby. Zvuk je snímán vždy po určitou dobu, poté zpracován a následně začne nové snímání. Prodlevy mezi jednotlivými snímáními se liší v závislosti na výkonu daného telefonu. Během sběru dat pro nalezení hledání co nejlepšího algoritmu byl nasnímaný záznam posílán na server a nedocházelo k jeho uložení do lokální databáze v telefonu. V aplikaci určené pro uživatele se

však záznam ukládá jak do lokální databáze, tak je odeslán na server, kde může posloužit např. pro budoucí realizaci webového portálu, k analýze pacientovým ošetřujícím lékařem, který může provést další analýzu, ohonocení, konzultovat spánek s pacientem atd.

Nasnímaný záznam je nejprve převeden do spektrální oblasti pomocí Diskrétní Fourierovy transformace. Konkrétně její nejpoužívanější implementace FFT. Ve spektrální oblasti je signál automaticky analyzován a jsou v něm hledány příznaky odpovídající chrápání a apnoickým událostem.

K nápadu využít pro účel detekce chrápání mobilní telefon zřejmě vedl fakt, že každý telefon má vestavěný mikrofon, díky kterému lze pořídit zvukový záznam. Chytré mobilní telefony, které umožní i analýzu takového záznamu přímo na přístroji jsou již nyní velmi rozšířené. Ve Spojených Státech přes 60% dospělých osob vlastní chytrý mobilní telefon [3], situace v Evropě velmi podobná.[4] Podíl lidí, kteří vlastní chytré telefony se velmi rapidně zvyšuje. Srovnáním [3] a [5] zjistíme, že jen za druhou polovinu roku 2013 vrostl tento podíl asi o 3%.

Mezi všemi operačními systémy používanými v tzv. smartphonech má jednoznačně nejvýznamnější postavení systém Android -79% trhu, druhý iOS -14,2% již znatelně ztrácí. Za zmínku stojí ještě Windows Phone a Blackberry – 3,3% a 2,7 %. [6] Právě z těchto statistik je vidět, proč byl k implementaci zvolen zrovna systém Android. Operační systém Android je open-source systém založený na operačním systému Linux a k vývoji aplikací se používá převážně programovacího jazyku Java. Pro účely této implementace byla zvolena verze Androidu 4.1 (Jelly Bean), která má mezi uživateli již většinové zastoupení a oproti předchozím verzím obsahuje mnoho pozitivních změn.

Tato práce je rozdělena na pět částí. První dvě se týkají aktigrafie, chrápání a apnoe z teoretického hlediska. Třetí a čtvrtá část jsou zaměřeny na implementaci algoritmů a podpůrných metod pro diagnózu spánkových poruch. Poslední částí je závěr, kde jsou vyhodnoceny a okomentovány dosažené výsledky.

## **1.2. Cíle práce**

Cílem této práce je seznámit se s problematikou detekce chrápání a sledováním pohybové pro účely vyhodnocování kvality spánku a problematikou detekce spánkové apnoe ze zvukového záznamu spícího pacienta. Výstupem je algoritmus implementovaný v jazyce Java a pracující v operačním systému Android, který umožňuje pořízení audio záznamu, jeho uložení a analýzu k nalezení chrápání a apnoických událostí. Dále algoritmus, který na základě pohybové aktivity bude tuto analýzu podporovat. Posledním výstupem budou výsledky testování a porovnání výsledků algoritmu s výsledky polysomnografu alespoň pro 5 pacientů.

## Kapitola 2

# Aktigrafie

Problematice aktigrafického snímání a možností jeho využití pro monitorování kvality spánku pacienta je věnována téměř celá práce [1], a proto zde nedostává tolik prostoru, jako kapitola následující, věnující se detekci chrápání a spánkové apnoe. Přesto aktigrafické snímání je důležitou součástí monitorování kvality spánku pomocí mobilního telefonu.

### 2.1. Princip aktigrafie

„Aktigrafie je neinvazivní, na rozdíl od polysomnografie levná a snadno dostupná metoda sledování aktivity pacienta. Jejím základem je sběr a ukládání dat, která jsou generována pohybem pacienta. Snímání se provádí v předem určených intervalech zařízením zvaným aktigraf a data jsou ukládána do paměti aktigrafu. Profesionální aktigrafy tímto způsobem shromažďují data po delší dobu, např. týdny, nebo měsíce. Po dokončení snímání jsou data analyzována většinou automaticky za pomoci hodnotícího algoritmu. Těchto algoritmů existuje celá řada, stejně tak, jako aktigrafů a neustále jsou vyvíjeny další a další. [7] Zpracování univerzálního algoritmu je velmi obtížné, jestli ne dokonce nemožné z toho důvodu, že existuje velké množství různých aktigrafů s různou citlivostí, vzorkovací frekvencí a dalšími parametry. Aktigrafie, pokud je používána bez dalších metod sledování kvality spánku, nemůže být zcela přesnou metodou k určení, kdy pacient spal a kdy byl vzhůru, přesto může fungovat jako validní nástroj ke zkoumání aktivity pacienta [8]. Navíc k tomtu závěru autoři došli po výzkumu s profesionálním aktigrafem na těle pacienta a dá se tedy předpokládat, že výsledky získané pomocí metody, kdy aktigraf (mobilní telefon) je pouze umístěn na pacientově matraci budou ještě daleko nepřesnější.“[1]

## 2.2. Aktigraf

„Aktigraf je přístroj určený k pořízení aktigrafického záznamu. Ve většině případů se jedná o malé zařízení ve tvaru hodinek, které se nosí většinou na nedominantním zápěstí, takže pro pacienta představuje jen nepatrnou zátěž. Existují jak studie, které naznačují, že rozdíl mezi aktigrafem na dominantním a nedominantním zápěstí není příliš velký [9], tak ty které tvrdí, že zápěstí není nejvhodnějším místem pro aktigraf [10]. Některé aktigrafy mohou být programovatelné, např. s nastavitelnou citlovností, vzorkovací frekvencí etc. Každý aktigraf obsahuje senzor, který je schopen měřit pohyb a to nejlépe ve všech třech osách. K tomuto účelu je nejčastěji použit akcelerometr. Dále mohou aktigrafy obsahovat i další pomocné senzory jako např. fotodiodu k detekci intenzity osvětlení. Velmi také záleží na umístění aktigrafu vzhledem k pacientovi. Pokud je jako aktigraf použit mobilní telefon položený na matraci, dochází k výraznému snížení vypovídající hodnoty výsledného záznamu, jelikož pohyb pacienta je měřen jen nepřímo, zprostředkovaně pomocí pohybu matrace. Dalším problémem použití mobilního telefonu k tomuto účelu je velké množství telefonů, přičemž různá zařízení mají vestavěny odlišné akcelerometry s lišícími se specifikacemi.“[1]



*Obr. 1: Typický aktigraf ve tvaru hodinek, převzeto z [1]*

## 2.3. Vztah aktigrafie a kvality spánku

„Samotnou aktigrafii nelze použít k detekci spánkové apnoe ani ke zjištění její závažnosti, nicméně je vhodná jako doplněk zjednodušené verze polysomnografie, při které se monitorují pouze respirační funkce. Dále se dá využít k určení fáze pacientova spánku, což je také důležitým faktorem ve sledování jeho kvality. Právě použití aktigrafie může zvýšit citlivost takto zjednodušené polysomnografie při detekci obstrukční spánkové apnoe až na dvojnásobek [11]. Detekci obstrukční apnoe, nikoliv však pomocí aktigrafie, ale analýzou zvukového záznamu pacientova chrápání se zabývá následující kapitola této práce.”[1]

Hlavní výhodou aktigrafie je tedy nenáročnost a ekonomická dostupnost. Problémem ovšem je, že se téměř v žádných případech nedá využít zcela samostatně. Buďto plní pouze funkci jakéhosi podpůrného nástroje k polysomnografii, nebo je třeba důsledného vedení spánkových záznamů pacientem. Některé studie došly k závěru, že aktigrafie může dosahovat téměř stejných výsledků jako polysomnograf, nicméně je k tomu nezbytně nutná podpora právě v podobě vedení detailních záznamů o spánku. [12] Jiný výzkum tvrdí, že aktigrafie by neměla být použita jako jediný prostředek k diagnóze poruch spánku a je vhodná pouze jako doplňková metoda. [7] Zatímco studie [13] došla k závěru, že „Velmi nízká schopnost aktigrafie rozpoznat bdění vrhá pochybnosti na její validitu, co se týká měření kvality spánku ve skupinách s fragmentovaným spánkem, nebo v situacích, kdy se jedná o rytmicitu spánku“. Jak je tedy vidno ze zcela rozdílného názoru jednotlivých autorů na aktigrafii, je její přínos sice nepochybný, jen jeho velikost ještě stále není dost zřejmá.[1]

## 2.4. Možnosti analýzy aktigrafického záznamu

„Analýza získaných dat je nedílnou součástí aktigrafie, jelikož ruční skórování záznamů sice je důslednější, ale zároveň také náročnější na čas lékaře a navíc automatické skórování může brát v potaz spoustu proměnných, které lékař ze záznamu nemůže být schopen identifikovat. K analýze aktigrafických dat bylo vyvinuto již mnoho algoritmů, z nichž některé jsou určeny pouze pro specifické podmínky a jiné by měly teoreticky fungovat

všeobecně. Nicméně co je vlastní všem těmto skórujícím algoritmům je fakt, že všechny předpokládají aktigraf nošený na zápěstí a nikoliv položený na matraci. Různé studie [11,14,15], dokládají vysokou spolehlivost různých algoritmů, nicméně zde je také vhodné podotknout, že veškeré tyto validační studie probíhaly v laboratorních podmínkách a nikoliv v domácím prostředí pacienta.

Základní myšlenka všech algoritmů k analýze aktigrafického záznamu je vždy velmi podobná. Jedná se o označení daného intervalu jako spánku, nebo bdění na základě vážené sumy pohybové aktivity a dalších proměnných v dané chvíli a několika intervalech předchozích a budoucích. Většina těchto algoritmů využívá vzorkování po minutě, nebo třiceti sekundách“.[1] Dále pro lepší představu uvádím některé z možných algoritmů, které byly již zkoumány v práci [1]. Jejich detailnější popis lze najít v [1,11,14-16]

### 2.4.1. Algoritmus Scripps Clinic

„Tento algoritmus byl vyvinut v roce 2010 pro Actiwatch-L, což je typický zápěstní aktigraf. Autoři studie [16] došli k závěru, že optimálním algoritmem pro použití Actiwatch-L je:

$$D = 0.3(0.0064x_{-10} + 0.0074x_{-9} + 0.0112x_{-8} + 0.0112x_{-7} + 0.0118x_{-6} + 0.0118x_{-5} + 0.0128x_{-4} + 0.0188x_{-3} + 0.0280x_{-2} + 0.0664x_{-1} + 0.0300x_0 + 0.0112x_1 + 0.0100x_2)$$

(2.1)

Kde epocha  $x$  je označena jako bdění, pokud  $D > 1$ , jinak je epocha označena jako spánek a  $x_{-10}$ - $x_2$  reprezentují pohybové aktivity za 10 předchozích a 2 následující epochy [16]. Tento algoritmus počítá s jednou ucelené epochy snímání 30s.“[1]

### 2.4.2. Coleův algoritmus

„Tento algoritmus pochází z roku 1992. Je založen na stejném principu jako Scripps Clinic s tím rozdílem, že bere v potaz pouze 4 předcházející epochy a nikoliv 10. Byl jedním z prvních, který se dokázal přiblížit svou účinností polysomnografií. Na testovacím vzorku



pacientů měl účinnost přes 87 %, čímž ve své době dokázal odborné veřejnosti, že aktigrafie může být cenným nástrojem ve spánkové medicíně. Coleův algoritmus :

$$D = 0.0033(1.06x_{-4} + 0.54x_{-3} + 0.58x_{-2} + 0.76x_{-1} + 2.3x_0 + 0.74x_1 + 0.67x_2) \quad (2.2)$$

Kde epocha  $x$  je označena jako bdění, pokud  $D > 1$ , jinak je epocha označena jako spánek a  $x_{-4}$ - $x_2$  reprezentují pohybové aktivity za 4 předchozí a 2 následující epochy. Tento algoritmus počítá s dobou trvání jedné ucelené epochy snímání jedna minuta.“[1]

### 2.4.3. Sadehův algoritmus

„Prakticky totožných výsledků jako algoritmus Coleův dosáhl dle studie algoritmus Sadehův vyvinutý roku 1994. Tento algoritmus se od předchozích uvedených liší tím, že v potaz bere 5 předcházejících, ale také 5 následujících epoch, z nichž bere v potaz průměr aktivity. Sadehův algoritmus je vypočítáván následovně :

$$PS = 7.601 - 0.065MW5 - 1.08NAT - 0.056SD6 - 0.073 \ln (ACT) \quad (2.3)$$

Kde  $MW5$  je průměr aktivit aktuální epochy a okna pěti předcházejících a pěti následujících epoch.  $NAT$  je počet epoch, ve kterých během 11 minutového okna pěti předcházejících a pěti následujících epoch je počet aktivit mezi 50-100.  $SD6$  je směrodatná odchylka počtu aktivit během dané epochy a pěti předcházejících a  $\ln (ACT)$  je přirozený logaritmus 1+počtu aktivit v právě skórované epoše. Pokud je  $PS$  čili pravděpodobnost spánku vyšší, než 0 je právě hodnocená epocha klasifikována jako spánek.

Při použití tohoto algoritmu bylo dosaženo velmi odlišných výsledků pokud byl aktigraf na dominantním nebo nedominantním zápěstí. Tento rozdíl dle autorů [15] vznikl z neznámých příčin. Právě kvůli těmto rozdílům se dá předpokládat, že při pouhém umístění aktigrafu na matraci by tento algoritmus nebyl spolehlivý, a proto se k danému účelu více hodí způsob, který je využíván některým ze dříve zmíněných algoritmů.”[1].



## Kapitola 3

# Chrápání a spánková apnoe

Nejdůležitější částí této práce detekce chrápání a spánkové apnoe. K tomuto účelu jsem se rozhodl použít frekvenční analýzu zvuku snímaného mikrofonem. Aby byla tato metoda úspěšná, bylo nutné se nejprve seznámit s akustickými vlastnostmi chrápání a apnoických událostí a následně vyvinout algoritmus, který tyto dvě události dokáže rozpoznat. Posledním krokem byla implementace vzniklého algoritmu do mobilního telefonu.


### 3.1. Obyčejné chrápání

#### 3.1.1. Definice, vznik a projevy obyčejného chrápání

Chrápání je dle definice „Respirační zvuk vznikající během spánku, jenž může být jak noční, tak i denní“ [17]. „Chrápání je pro člověka, který jím trpí velmi nepříjemné, jelikož může vážně narušovat jeho společenský a především rodinný život, kde samozřejmě závisí na tom, jak je partner schopen chrápání vnímat a snášet, jelikož jak naznačuje studie [19], různí lidé vnímají chrápání zcela odlišně. Dále je známo, že chrápání je rizikovým faktorem pro cerebrovaskulární onemocnění [24,25]. Statistiky ohledně procentuálního zastoupení lidí trpících chrápáním se pohybují mezi 40-60% [18,19] a zhoršují se se stoupajícím věkem, což indikuje, že jde o globální problém většiny populace.

Chrápání vzniká v hltanové části horních cest dýchacích tím, že při průchodu vzduchu touto oblastí příslušná tkáň vibruje. „Přesněji řečeno, chrápání je charakteristická oscilace měkkého patra, faryngální (hltanové) stěny, hrtanové příklopy a jazyka“ [19]. Chrápání také

rozhodně není homogenním po celou dobu spánku, právě naopak je to jev velmi různorodý, jehož vlastnosti podléhají mnoha vlivům jako např. fáze spánku (v této oblasti se výrazně liší pacienti s různě závažným stupněm chrápání [26]), poloha těla, způsob dýchání (nosem, ústy, nebo obojím). Projevy chrápání se samozřejmě liší během jednotlivých nocí i u stejného pacienta. Mezi hlavní parametry, které jsou u chrápání sledovány patří jeho intenzita, načasování, členitost a délka v průběhu spánku. Pro tuto práci je taktéž důležité, že chrápání je prvním a nejčastějším příznakem dysfunkce horních cest dýchacích, která může vést právě až k syndromu spánkové apnoe.



Obr.2: Srovnání běžného dýchání a chrápání

- 1) dutina nosní
- 2) dutina ústní
- 3) jazyk
- 4) měkké patro
- 5) obstrukce nosní cesty

Na obrázku 2 je vidět rozdíl v postupu vzduchu horními cestami dýchacími při normální dýchání a při chrápání. Při běžném dýchání je otevřena jak nosní, tak ústní cesta, zatímco při chrápání se měkké patro a patrový čípek zhroutnou na zadní stěnu a tím zablokují nosní cestu.‘[1]

### 3.1.2. Akustické vlastnosti obyčejného chrápání

„Drtivá většina pokusů o analýzu akustických vlastností chrápání byla provedena právě kvůli detekci syndromu spánkové apnoe a to zejména kvůli faktu, že zlatý standard, kterým vždy byla a nejspíše ještě dlouho bude polysomnografie je finančně nákladný a pro pacienta značně nepohodlný (zářným příkladem této motivace je výzkum [23]). Další motivací pro hledání těchto vlastností je snaha naleznout objektivní způsob vyhodnocení chrápání, protože jak již bylo řečeno dříve, jeho vnímání je silně subjektivní záležitostí.


Podle výsledků studií [18-20] se obyčejné chrápání dá rozdělit podle dvou hlavních vzorů, které se v něm vyskytují a jsou od sebe značně rozdílné. Jedná se o prostý průběh a komplexní průběh. Typicky se u každého pacienta vyskytují oba dva vzory, avšak v různé míře [20]. Celkově se většina výkonu nachází do 2000Hz a hlavní peak do 500Hz [18].

Komplexní průběh by měl mít ve frekvenční oblasti hlavní peak v rozmezí 62-136 Hz a dále by měl obsahovat 3-7 menších peaků v rozmezí 240-970 Hz. Střední frekvence<sup>1</sup> těchto vyšších frekvencí v komplexním průběhu by měla být přibližně 430-770 Hz [20]. Celkově se ve spektru tento průběh dá poznat podle několika peaků rozdílných amplitud, jenž jsou velmi blízko u sebe. Spektra komplexního průběhu v různých fázích chrápání jsou na obrázku 5 a 6 .


Prostý průběh lze podle spektra identifikovat podle jednoznačně určitého hlavního peaku, nacházejícího se v oblasti 100-240 Hz a také, na rozdíl od komplexního průběhu, jasně rozlišitelných harmockých na vyšších frekvencích. Spektra prostého průběhu v různých fázích chrápání jsou na obrázcích 5 a 6. V porovnání se spektrem z [17] (obr.7) je patrná odlišnost.“[1]

---

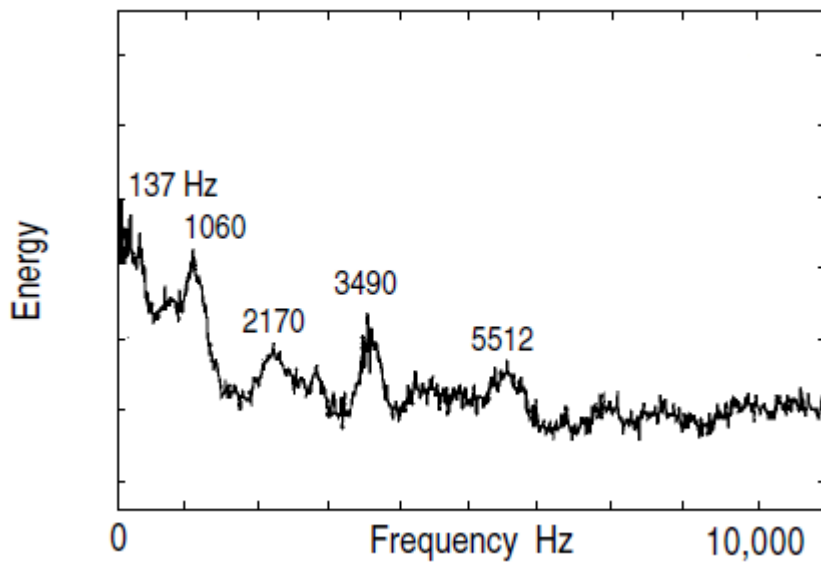
<sup>1</sup> Střední frekvence je taková frekvence, do které se vyskytuje polovina celkového výkonu spektra



Obr. 3: Spektrum prostého průběhu (vlevo) a komplexní průběhu (vpravo) při prvním dechu chrápání, převzeto z [18]



Obr.4: Spektrum prostého průběhu (vlevo) a komplexní průběhu (vpravo) při druhém dechu chrápání, převzeto z [18]



Obr.5: Frekvenční spektrum chrápání, převzeto z [17]

## 3.2. Obstrukční spánková apnoe a polysomnografie

„Spánková apnoe je problémem zdravotním s výrazným dopadem především na kardiovaskulární systém (dnes je považována za nejčastější příčinu sekundární hypertenze) a metabolismus, ale také problémem sociálně-ekonomickým, celkově zhoršujícím kvalitu života těchto nemocných.” [27] Je definována jako přerušení proudu vzduchu do plic po dobu alespoň deseti vteřin. [28, 29] Existují dvě hlavní příčiny spánkové apnoe, mechanická a neurologická. Apnoe způsobená neurologicky se nazývá centrální. Vzniká v důsledku centrální poruchy respiračních mechanismů při vrozených nebo získaných kmenových lézích na úrovni prodloužené míchy. [30] „Bývá často u Cheyneova-Stokesova dýchání, většinou v případě městnavé srdeční slabosti a u akutního a subakutního stadia cévních mozkových příhod nebo u nervosvalových a neurodegenerativních onemocnění. Může se vyskytnout po užívání dlouhodobě působících opioidů. Centrální spánková apnoe bývá také při periodickém dýchání ve velké nadmořské výšce, kdy se cyklicky opakují periody centrálních apnoí a hyperpnoí.” [27] Centrální typ je výrazně vzácnější, jeho zastoupení je pouze 5-10%. [29]

Mechanickou příčinou je kolaps v horních cestách dýchacích a výsledná apnoe se nazývá obstrukční spánková apnoe (OSA). Nejčastějšími důsledky obstrukční spánkové apnoe jsou únava, zhoršené kognitivní funkce, srdeční potíže, hypertenze a v extrémním případě i ischemická choroba srdeční [29, 31]. Mezi rizikové faktory patří např. obezita, mužské pohlaví, vyšší věk, hypertenze. Často bývá doprovázena hlasitým chrápáním [29].

„U pacientů s OSA bývá zúžení horních dýchacích cest, které vede ke zvýšené rezistenci hltanu a vyššímu negativnímu faryngeálnímu tlaku v průběhu inspirace, je vyšší kontrakce svalů dilatujících hltan než u zdravé populace, což svědčí o nepoměru mezi silou kolabující hltan a kontrakcí svalů dilatujících hltan. Jde o opakující se kolaps horních dýchacích cest ve spánku s přerušením nebo omezením průchodnosti vzduchu (apnoickými nebo hypopnoickými pauzami), který vede k tranzitorní hypoxémii. Je přítomna fragmentace spánku kvůli četným mikroprobuzením přispívajícím ke zvýšené denní spavosti

Patofyziologickým podkladem apnoí a hypopnoí může být překážka anatomická nebo fyziologická. Anatomická překážka je buď v oblasti kostěných struktur (abnormality mandibuly a maxily, zmenšení kostěného faryngálního prostoru) či v oblasti měkkých tkání

(hypertrofie tonzil, uvuly, prodloužení měkkého patra, tuková depozita pod sliznicí hypofaryngu, makroglosie). Fyziologickou příčinou apnoí může být ochabnutí svalů horních cest dýchacích, podtlak při nádechu. Kolaps dýchacích cest bývá víceúrovňový nebo může být na úrovni měkkého patra či kořene jazyka [27].

Váženost spánkové apnoe se určuje podle tzv. Apnea-Hypopnea indexu (AHI), což je počet apnoických pauz během jedné hodiny. Aby byla pacientovi diagnostikována spánková apnoe, musí se během jeho spánku vyskytovat alespoň 10 apnoických pauz za hodinu, čili  $AHI \geq 10$  [30]. Obstrukční spánková apnoe je celosvětový zdravotnický problém. Přibližně 9% žen a 24% mužů ve věku od 30 do 60 let má podle studie [32] více než 5 apnoických či hypopnotických událostí za hodinu, což se již označuje jako syndrom spánkové apnoe. Oproti tomu studie [33,34] udávají, že obstrukční spánkovou apnoe trpí pouze 2-4% populace.


Studie [35] ukazuje, že neléčená spánková apnoe je velmi nákladná, jelikož pacienti, kteří jí trpí, využívají různá zdravotnická zařízení až dvakrát častěji. Přesto u mnoha pacientů se spánkovou apnoe tato nemoc nebyla diagnostikována [35]. Hlavním důvodem této situace je, že stále neexistují levné a dostupné nástroje pro masový screening.

Konzervativní léčba spánkové apnoe spočívá v redukci nadváhy, změně polohy ve spánku (na boku, nikoliv zádech). Dále je možnost obstrukční apnoe léčit pomocí přípravků, které se vkládají do úst a fixují jazyk, nebo dolní čelist [36]. U těžších forem je indikována metoda trvalého přetlaku (CPAP). Pacient spí trvale s maskou, kterou je řízeným ventilátorem vháněn vzduch do horních cest dýchacích a optimální přetlak zabrání vzniku apnoických pauz [30].

Standardem pro diagnózu spánkové apnoe je polysomnografie (PSG), prováděná přes celou noc [37-39]. Polysomnografie se skládá z nahrávání různých pacientových signálů, jako EEG, EOG, ECG, EMG, pohybu břicha a hrudníku a oxymetrie, která měří saturaci krve kyslíkem  $S_pO_2$ . „Současné jsou registrovány a nahrávány dýchací zvuky, pacient je snímán ve spánku videokamerou v infračerveném osvětlení. Při polysomnografii je možnost, na rozdíl od limitované polygrafie, zaznamenat mikroprobouzení. Tato vyšetření se provádějí přes noc ve spánkových laboratořích, či spánkových centrech.“ [27] Zkoumáním těchto signálů může specializovaný lékař určit typ spánkové poruchy (např. diagnostikovat spánkovou apnoe). [40,41] Bohužel analýza pomocí PSG vyžaduje, aby pacient strávil noc ve spánkové



laboratoři s mnoha měřicími elektrodami na těle, což je pro pacienta jednak dost nepříjemné a druhá ho to stojí hodně času- viz následující obrázek. Právě z toho důvodu je potřeba najít zjednodušený nástroj schopný odhalit spánkovou apnoe i v domácím prostředí [32].



*Obr. 6 – Pacient podstupující polysomnografii, převzeto z [42]*

V nedávné době proběhlo několik pokusů vyvinout přenosnou technologii, která by cílila právě na domácí snímání [37,43]. Navrhované systémy však stále potřebují být zapojeny, spuštěny a nastaveny expertem v místě použití. Další nevýhodou je, že všechny navrhované způsoby počítají alespoň s jedním snímačem umístěným přímo na tělo pacienta.



## Kapitola 4

# Implementace aktigrafického měření

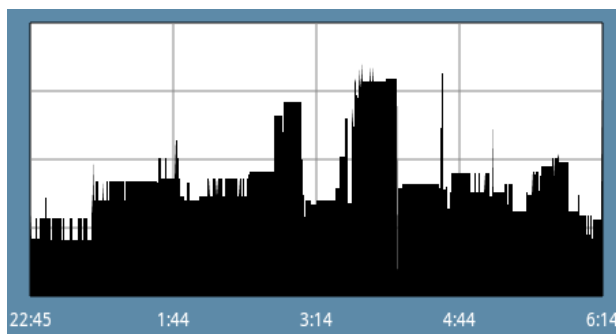
Hlavní motivací pro část této práce v oblasti aktigrafie byla validace výsledků práce [1], popřípadě navrzení úprav k jejich vylepšení.

### 4.1. Získání dat

Data byla z akcelerometru mobilního telefonu získávána zcela stejným způsobem jako v předchozí práci [1]. To znamená, že snímání probíhá nonstop přes celou noc a jako jedna ucelená epocha je zvolen interval 5 sekund. V každé takové epoše se zaznamená vždy největší pohyb v každé ose a podle nich se vypočítá celková velikost pohybu jako :

$$x_i = \sqrt{a_x^2 + a_y^2 + a_z^2}$$

(4.1)



Obr. 7 – Příklad surových nasnímaných dat

Poté, co je záznam kompletně nasnímán a jsou tedy k dispozici surová data (viz. obrázek 7), je záznam analyzován následujícím způsobem (stejně jako v [1]). „Je vytvořen podzáznam několika největších pohybů (jejich počet se rovná dvěma tisícinám celkového počtu záznamů). Jelikož algoritmus nevyužívá absolutních hodnot záznamu, nýbrž relativního přístupu k datům (což je nezbytně nutné vzhledem k rozdílným akcelerometrům a jiným parametrům jednotlivých telefonů, na kterých může aplikace fungovat), tak právě tyto velké a často nežádoucí pohyby jeho funkci velmi negativně ovlivňují. Dokonce do takové míry, že algoritmus je pak zcela nefunkční. Z takto vytvořeného podseznamu je potom určen medián a výsledek označen jako největší pohyb obsažený v záznamu, ze kterého potom následný algoritmus čerpá. Je lepší tímto způsobem ztratit několik validních dat s velkým pohybem, než se orientovat podle největší hodnoty z původního záznamu, která bude pravděpodobně způsobena nežádoucím jevem, jako např. velmi velkým nasnímaným pohybem na konci záznamu, kdy uživatel telefon zvedne, aby vypnul snímání etc.“[1]

Vyhodnocovací algoritmus navržený v [1] bere v potaz určitý počet předchozích vzorků závislý na vzorkovací frekvenci snímání, v tomto případě pro jeden záznam za 5s se považuje za relevantní 10 předchozích vzorků. V matematickém zápise tento algoritmus vypadá takto:


$$D = 0.04x_{-10} + 0.04x_{-9} + 0.04x_{-8} + 0.04x_{-7} + 0.04x_{-6} + 0.24x_{-5} + 0.24x_{-4} + 0.24x_{-3} + 0.24x_{-2} + 0.24x_{-1} + x_0 \quad (4.2)$$

přičemž každý vzorek je oklasifikován jako spánek s pohybem, spánek bez pohybu, nebo bdění v závislosti na velikosti  $D$ . Pokud je největší pohyb považován za jednotkový, pak vzorek, který nabyde hodnoty  $D \in (0,8; 1 >$  je klasifikován jako bdění, vzorek s hodnotou nižší je klasifikován jako spánek, přičemž hodnota pod 0,3 by měla značit hlubší spánek. Detailněji je tento algoritmus popsán v [1].


## 4.2. Validace klasifikačního algoritmu

Algoritmus byl validován proti hypnogramu, který byl sestaven na základě logů z polysomnografu v Psychiatrickém centru Praha v Bohnicích (hlavní rozdíl oproti práci [1], kde byla správnost algoritmu validována převážně na základě subjektivního pocitu pacientů).

V laboratoři byl umístěn mobilní telefon, který akcelerometrem snímal pohyb pacientů, jenž podstupovali polysomnografii. Data nasnímaná mobilním telefonem byla odesílána na server, exportována do MATLABu a následně porovnávána s log souborem, který je jedním z výstupů polysomnografie. Do srovnání bylo zařazeno celkem 10 pacientů. Následující obrázky ukazují srovnání nevyfiltrovaného hypnogramu z log souboru PSG a dvoustavového (spánek-nespánek) „hypnogramu“ sestaveného pomocí nasnímaných dat z mobilního telefonu analyzovaných algoritmem popsáním v předchozí sekci. Záznam z mobilního snímání byl manuálně upraven tak, aby jeho začátek a konec souhlasil se začátkem a koncem záznamu PSG (s odchylkou max.  $\pm 5$  vteřin).



*Obr. 8 – Porovnání hypnogramu pacienta s výrazně fragmentovaným spánkem sestaveného z logů z PSG (modře) a pomocí akcelerometru v mobilním telefonu (červeně)*



*Obr. 9 - Porovnání hypnogramu pacienta s méně fragmentovaným spánkem sestaveného z logů z PSG (modře) a pomocí akcelerometru v mobilním telefonu (červeně)*

Z předchozích obrázků je dobře vidět, že algoritmus pro analýzu aktigrafického záznamu není zcela dokonalý. Na změnu reaguje výrazně pomaleji, než PSG, což vede k potížím při analýze fragmentovanějšího spánku. Právě kvůli pomalejší reakci algoritmu se při častých změnách fáze spánku stává, že je vzorek zaklasifikován chybně. Největším problémem aktigrafické detekce za použití tohoto algoritmu je však REM fáze spánku, která by teoreticky měla u dospělého člověka představovat 20-25% spánku. REM fázi algoritmus označí jako spánek či nespánek nejčastěji tak, aby byla ve shodě s fází předcházející, tudíž na přechod do REM fáze často nereaguje.

Algoritmus by se dal podle mého názoru zlepšit tím, že by se pracovalo s úseky kratšími, než 5 vteřin. Tím by se zrychlila odezva algoritmu na změny. Nicméně se domnívám, že ani tato změna by nepomohla vylepšit úspěšnost klasifikace REM fáze.

	Změřená doba spánku - telefon	Změřená doba bdění - telefon	Změřená doba spánku - PSG	Změřená doba bdění - PSG
Pacient 1	6:54:25	0:31:20	7:04:44	0:21:00
Pacient 2	4:21:10	2:49:55	4:23:00	2:48:04
Pacient 3	3:22:55	2:42:45	3:26:41	2:39:00
Pacient 4	5:39:50	1:12:55	5:40:13	1:12:30
Pacient 5	6:45:35	1:12:50	6:20:25	1:38:00
Pacient 6	6:56:50	0:29:20	6:58:40	0:27:30
Pacient 7	6:44:05	0:43:00	7:16:36	0:10:30
Pacient 8	5:49:00	1:54:50	6:22:18	1:21:30
Pacient 9	7:01:55	0:45:30	7:07:57	0:39:30
Pacient 10	3:25:35	3:07:55	3:18:58	3:14:30

*Tab. 1: Porovnání naměřených hodnot jednotlivých pacientů mobilem a PSG*

Následující tabulka ukazuje matici konfuze pro správně a špatně zaklasifikované pětivteřinové etapy. Na základě této tabulky je dále spočtena senzitivita a specificita algoritmu, kdy jako pozitivní vzorek je určen spánek.

Beze spánku	Spánek	
9165	1387	Beze spánku
7526	34228	Spánek

*Tab. 2 Matice konfuze pro aktigrafické snímání*

Senzitivita	0,820
Specificita	0,869
Youdenův index	0,689

*Tab. 3 Senzitivita, specificita a Youdenův index pro aktigrafické měření*

Výše uvedené výsledky ukazují, že algoritmus nefunguje zcela bezchybně. Nicméně se dá říct, že pro takto nepřiliš sofistikovaný algoritmus jsou výsledky vcelku nad očekávání a jako podpůrná metoda pro jiné postupy a algoritmy se dá bez problémů použít. Naměřené se v některých bodech přiliš neshodují s výsledky uvedenými v práci [1]. Je to dáno s velkou pravděpodobností tím, že v uvedené práci byl algoritmus validován na základě subjektivního dojmu pacienta. V tomto případě to vypadá, že pacienti měli tendenci výrazně podceňovat dobu, kdy ve skutečnosti nespali.



## Kapitola 5

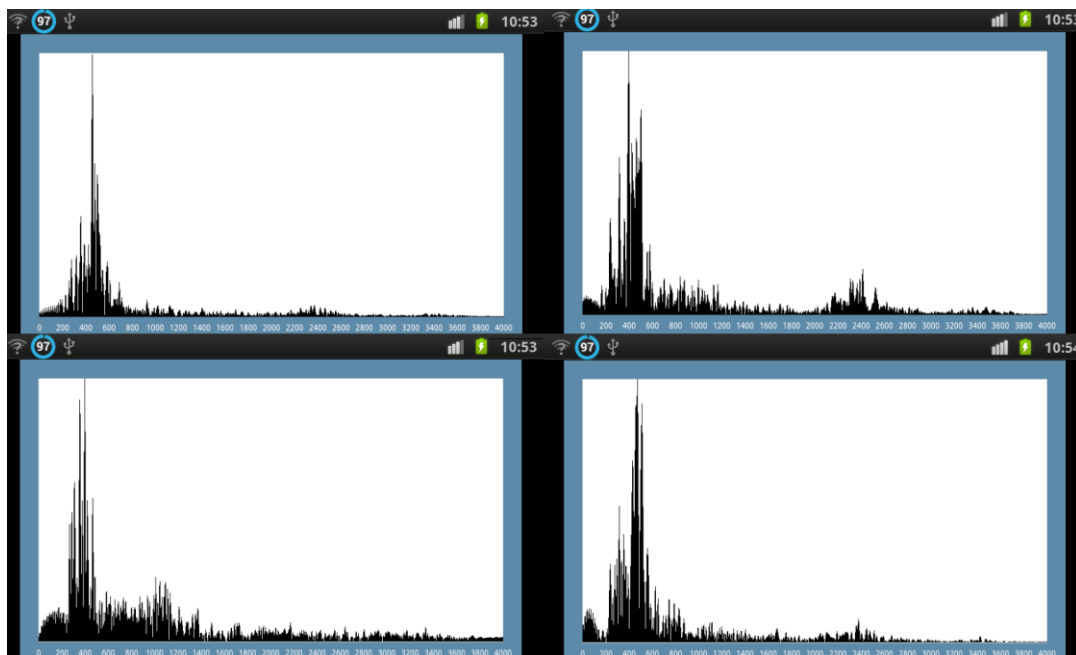
# Detekce chrápání a apnotických událostí

### 5.1. Zpracování dat

#### 5.1.1. Získání surových dat

První fází nutnou k realizaci detekce chrápání je získání audio záznamu pacientova spánku. Zde je hned několik úskalí, která je třeba vzít v úvahu. Detekce má probíhat v aplikaci v systému Android, jehož výhodou je to, že je velmi rozšířen, nicméně tento fakt se pro potřeby získání audio záznamu mění ve velkou nepříjemnost spojenou s faktem, že Android běží na přibližně 12 000 různých zařízeních s odlišným hardwarem a tudíž i mikrofonem. Bohužel dokonce i při použití stejného telefonu se jeden záznam při několika měřeních nasnímá rozdílně viz. obrázek 10.

Čistě teoreticky by všechna zařízení s Androidem měla mít mikrofon podporující vzorkovací frekvenci 44,1 kHz. Bohužel praxe je jiná a zejména low-endové telefony od exotičtějších výrobců tuto frekvenci nepodporují. Nastavení vzorkovací frekvence je tudíž nutno najít podle mikrofonu konkrétního zařízení, na kterém aplikace běží. Naštěstí se dá spolehnout alespoň na to, že bude podporována některá ze standardních vzorkovacích frekvencí (8000,11025,16000,22050,44100) Hz. Z těchto kmitočtů se vždy vybere ten nejvyšší podporovaný.



Obr. 10: Porovnání různých záznamů při stejném zvuku – převzeto z [1]

Pro kvalitu záznamu a tudíž jednodušší a přesnější detekci je také důležité umístění telefonu vzhledem k pacientovi. Naprosto ideální by byla varianta telefonu zavěsit nad pacientovu hlavu tak, aby mikrofon směřoval směrem k pacientovi a tím pádem dobře snímal zvuky, které pacient vydává, co nejvíce potlačoval zvuky okolí a navíc byl v dostatečné vzdálenosti, aby signál nebyl zašuměn. Tato možnost je podrobně diskutována v [44], kde je navržena vzdálenost 30 cm od úst pacienta, zatímco jiní autoři [45, 46] navrhují větší vzdálenost.

Zavěšení telefonu nad pacienta se dá označit minimálně jako problematické a pro účely mobilní aplikace se nehodí a navíc další velkou komplikací tohoto přístupu je to, že v této pozici telefon nemá žádnou šanci akcelerometrem jakkoliv snímat pohyb pacienta. Z těchto důvodů jsem jako nejlepší umístění telefonu pro snímání určil pozici, kdy je telefon připevněn pomocí pouzdra k matraci na úrovni hlavy pacienta. Pouzdro musí být dostatečně měkké, aby neblokovalo signály snímané akcelerometrem a nesmí zakrývat mikrofon. Vzhledem k obvyklé velikosti lůžka pacienta je v tomto případě nereálné umístit telefon do vzdálenosti větší, než navrhuje [44], což je 30 cm. I tak se během spánku může pacient různě posouvat a otáčet. Nejhorší situace by nastala v případě, že by pacient telefon zalehl, což

vzhledem k jeho umístění není příliš pravděpodobné. Další nežádoucí situací je pozice pacienta zády k telefonu. Tato situace je mnohem pravděpodobnější a buhužel se jí nedá nijak předcházet.

Audio záznam se nahrává v opakujících se cyklech, kdy se 40 vteřin záznam nahrává, poté je záznam zpracován, vyhodnocen a uložen (případně odeslán na server). Poté se celý cyklus opakuje. Prodlevy mezi jednotlivými cykly se liší v závislosti na výkonu právě používaného telefonu a v případě přenosu dat na server ještě rychlosti připojení k internetu. Vzhledem k velikosti záznamu (přestože se výrazně sníží během předzpracování) je žádoucí přenášet data přes Wi-Fi a nikoliv mobilní síť. V případě mobilní sítě (i když zanedbáme případné poplatky účtované operátorem) mohou být kvůli nízké rychlosti velké prodlevy mezi jednotlivými cykly snímání. Další fází je předzpracování dat, které je prováděno na základě teoretických znalostí o akustických vlastnostech chrápání.

### 5.1.2. Decimace signálu

Poté, co získáme surová audio data pacienta, nastává předzpracování dat. Cílem této fáze je upravit signál tak, aby měl co nejlepší vlastnosti pro následnou analýzu, uložení, odeslání na server etc. Jako první se provede decimace signálu za účelem snížení počtu vzorků. Toto snížení má velký význam hned z několika hledisek popsaných níže.

Přestože moderní smartphony již mají dostatečný výkon na zpracování surového signálu, stále je mnoho uživatelů se slabšími telefony, kterým by zpracování celého 40s surového záznamu trvalo dlouhou dobu a tím pádem by byly příliš dlouhé prodlevy mezi jednotlivými cykly snímání. Druhým důvodem pro snižování počtu vzorků je fakt, že se ušetří jak čas, tak pásmo při přenosu dat na server. V tomto ohledu by bez snížení utrpěli všichni bez ohledu na výkon používaného hardwaru. Při decimaci signálu je důležité dávat pozor, abychom nesnížili počet vzorků natolik, že by byl porušen vzorkovací teorém.

$$F_s > 2F_{max} \tag{5.1}$$

Na maximální nezbytné frekvenci pro detekci se všichni autoři [18-23] v podstatě shodují. Zejména [18] se věnuje podrobně frekvencím, které jsou klíčové pro detekci jak chrápání, tak obstrukční apnoe. Dle uvedených studií by chrápání mělo mít všechny důležité frekvence nižší než 1kHz. Apnoické události by měly ve frekvenční oblasti mít ještě jeden výrazný peak v oblasti právě kolem 1kHz.[18,24,47] Tento peak by se teoreticky měl dát použít právě k odlišení benigního chrápání od apnoické události. Podle těchto studií by tedy byla dostatečná vzorkovací frekvenci cca 2200 Hz. O něco vyšší vzorkovací frekvenci doporučuje studie [48].

Vzhledem k tomu, že poslední teoreticky významný peak by se měl nacházet na frekvenci kolem 1 kHz, zvolil jsem v souladu se Shannonovým teorémem jako nejnižší vzorkovací frekvenci 2205 Hz. Právě během decimace signálu dojde ke snížení z původní vzorkovací frekvence mikrofonu právě na tuto hodnotu. Tento krok se později ukázal jako chybný, jelikož u nasnímaných signálů docházelo k frekvenčním posunům. Výrazně lepší by bylo zvolit vyšší vzorkovací frekvenci.

Následující tabulka ukazuje decimační faktory pro všechny standardní frekvence podporované mikrofony v mobilních telefonech. Mírně nepříjemné jsou v tomto ohledu frekvence 8000 Hz a 16000 Hz, kde je nutné i po decimaci zachovat vyšší kmitočet, než by bylo nezbytně nutné. Při použití vyššího decimačního faktoru by kmitočet již byl pouze 2 kHz, což by mohlo být nedostatečné.

Původní vzorkovací frekvence [Hz]	Decimační faktor	Výsledná frekvence [Hz]
8000	2	4000
11025	5	2205
16000	4	4000
22050	10	2205
44100	20	2205

Tab. 4 – přehled decimačních faktorů pro různé vzorkovací frekvence

### 5.1.3. Filtrace signálu

Když má signál již sníženou vzorkovací frekvenci na 2205 Hz nebo 4000 Hz, otevírá se možnost signál filtrovat horní propustí. Horní propust je typ filtru, který vyhladí nízké frekvence v signálu. Tímto způsobem by se mohly vyhladit frekvence nižší než 60 Hz, které při detekci chrápání nejsou příliš důležité (přestože z [18] vyplývá jejich potencionální užitečnost pro odlišení chrápání a apnoických událostí). Nicméně hlavní motivací pro použití takové horní propustě je fakt, že signál z mikrofonu mobilního telefonu je na těchto nízkých frekvencích natolik zašuměn ( $SNR_{0-60} \cong 0.1$ ), že není možné tyto nízké frekvence během zpracování nijak použít.

Přestože výše uvedené důvody k použití horní propusti přímo nabádají, rozhodl jsem se signál v této fázi nefiltrovat z následujících důvodů. Následný způsob zpracování umožňuje velmi jednoduše tyto nízké frekvence vynechat a vzhledem k tomu, že filtrace by na rozdíl od tohoto vynechání trvala nějakou dobu se domnívám, že filtrace v této fázi by ve výsledku algoritmus pouze zpomalovala bez jakýchkoliv pozitivních účinků. Navíc zde je možnost, že existuje, nebo bude existovat telefon, který má natolik kvalitní mikrofon, že odstup signál-šum bude daleko příznivější a i nízké frekvence půjde využít.

### 5.1.4. Uložení signálu

Signál se tedy ihned po decimaci odesílá přes Wi-Fi na server, kde je uložen do databáze. Ukládání signálu ihned po decimaci bylo zvoleno z toho důvodu, že takto je bez problémů možné již nasnímaná data později zpracovat i zcela odlišnou metodou na jakékoli jiné platformě a nikoliv pouze v aplikaci pro Android. Během vývoje byl nejprve ukládán pouze výsledek detekce a později frekvenční spektrum, nicméně se ukázalo, že ukládání pouze těchto dat nebylo dostatečné, a tak jsem přistoupil právě k ukládání decimovaného signálu v časové oblasti.

Hlavní nevýhodou tohoto přístup je to, že potřebuje mnoho místa na disku. Z tohoto důvodu není možné tento signál ukládat přímo do telefonu. Jelikož je aplikace psaná v Javě a

pro reprezentaci signálu používá datový typ float (32 bitů), dá se celková velikost uloženého záznamu za jednu noc určit následovně

$$V = 32 \cdot F_s \cdot t \cdot c \quad (5.2)$$

kde  $F_s$  je vzorkovací frekvence, která nabývá hodnot 4000 nebo 2205 v závislosti na mikrofonu,  $t$  je doba snímání a  $c$  je koeficient, který udává poměr snímání a zpracovávání (i s odesláním), jeho hodnota silně závisí na výkonu telefonu a rychlosti připojení k internetu, typicky se pohybuje v rozmezí 0,5-0,9. Výsledná velikost záznamu za jednu noc se tedy pohybuje v řádu jednotek GB, což pro serverové datové úložiště nepředstavuje příliš velkou zátěž, nicméně není možné tyto záznamy dlouhodobě ukládat přímo do lokálního úložiště mobilního telefonu.

## 5.2. Příprava na klasifikaci

Automatickou detekce chrápání z audiozáznamu jsem se stejně jako všechny studie, které se zabývají tímto tématem např. [18-23,47-48], rozhodl řešit analýzou ve frekvenční oblasti, (studie [19,23,47] ačkoliv používají i frekvenční analýzu využívají hojně i příznaky z časové oblasti). Pro analýzu ve frekvenční oblasti je nejprve potřeba signál do této oblasti převést. To znamená, že na signál získaný od pacienta je potřeba nejprve aplikovat diskretní Fourierovu transformaci, díky které převede signál do spektrální oblasti. Pokud by zajímavá bylo pouze frekvence a nikoliv rozložení výkonu ve spektru dal by se ještě použít algoritmus Zero-Crossing. Dále je možné aplikovat inverzní diskretní Fourierovu transformaci na absolutní hodnotu logaritmu spektra a tím získat kepsstrum a provést analýzu v kvěfrenční oblasti.

### 5.2.1. Rychlá Fourierova transformace

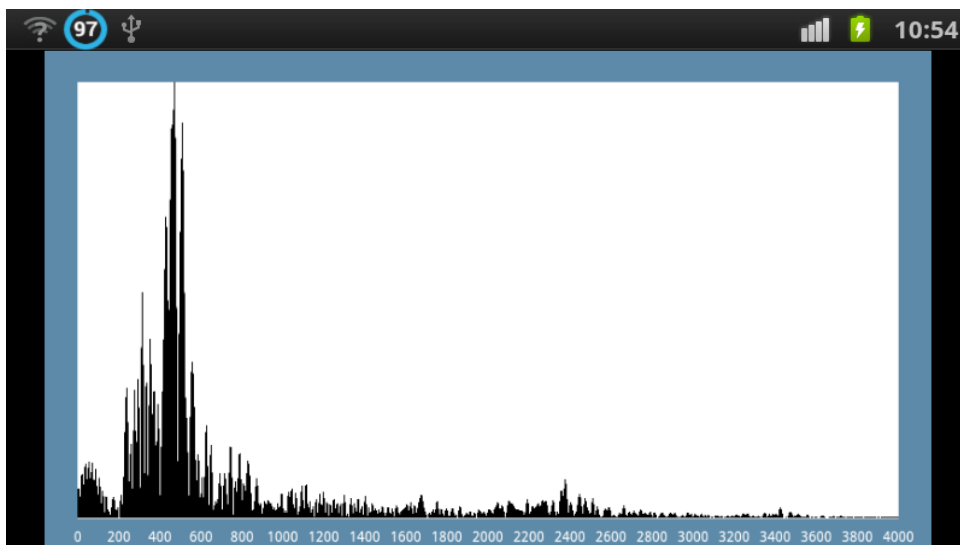
Rychlá Fourierova transformace (FFT) je nejefektivnější implementace diskretní Fourierovy transformace (DFT), která je definována následovně:

$$X_k = \sum_{n=0}^{N-1} x_n e^{-i2\pi k \frac{n}{N}} \quad k = 0, 1, 2, \dots, N - 1 \quad (5.3)$$

kde  $x_0, \dots, x_{N-1}$  jsou obecně komplexní čísla.

Asymptotická složitost DFT je  $O(N^2)$ . Nejpoužívanější algoritmus FFT (Cooley-Tukey)[49], který využívá přístupu rozděl a panuj má složitost jen  $O(N \log_2 N)$ . Nevýhodou této implementace je, že délka původního signálu musí být rovna mocnině dvou. Případná jiná délka vstupního signálu se řeší doplněním nulami. Detailnější rozbor FFT je možné najít v [50].

Jako implementaci rychlé Fourierovy transformace v Javě, která je tudíž velmi dobře použitelná na telefonu s Androidem jsem volně dostupnou knihovnu z [51]. Následující obrázek ukazuje typický výsledek FFT na pozitivním záznamu, jak je vidět, tak téměř všechen výkon je ve spektru soustředěn do oblasti nižší, než 1kHz.



*Obr. 11: Typické spektrum získané ze záznamu chrápání – převzeto z [1]*

### 5.2.2. Kepstrum

Kepstrum je výsledek inverzní Fourierovy transformace (IFT) na logaritmus spektra signálu. Existují komplexní, mocninné, fázové a reálné kepstrum. Nezávislá veličina v kepstru se nazývá kvefrence a je jednotkou času. Stejně jako pro analýzu řeči i pro detekci chrápání a apnoických událostí se dá použít mocninné kepstrum, které je definováno jako

$$C = |\mathcal{F}^{-1} \{ \log ( |\mathcal{F}(f(t))|^2 ) \}|^2 \quad (5.4)$$

Podobně jako spektrum můžeme kepstrum použít k získání příznaků a kvefrenční analýze, na základě které se dá detekovat apnoická událost, kepstrální analýza je použita např. v [37]. Detailnější rozbor kepstra je možné najít v [52].

### 5.2.3. Výběr příznaků

Frekvenční spektrum signálu nabízí celou řadu příznaků, které je možné pro detekci chrápání využít. V tomto ohledu se různí autoři velmi liší a to jak v počtu použitých příznaků, tak v jejich složení. Např. [20] určila jako nejdůležitější parametry:

$f_{peak}$  - frekvence, na které se nachází nejvyšší špička ve spektru

$f_{mean}$  - frekvence, do které se vyskytuje 50% celkového výkonu

$f_{max}$  - frekvence, do které se vyskytuje 90% celkového výkonu

Kromě těchto tří parametrů, které jako jediné k detekci chrápání využívá [18,1] je dalším možným příznakem také rozložení výkonu kolem jednotlivých špiček, kde např u komplexního průběhu chrápání bývá většina výkonu spektra poblíž nejvyšší špičky [18]. Studie [53] využívá pro detekci chrápání daleko více příznaků (konkrétně 22), bohužel neuvádí přesně, které příznaky to jsou. Studie [19,23,47] používají příznaky jak z časové, tak



frekvenční oblasti, z čehož ve spektru si [47] všimá zejména poměru výkonu v určitých pásmech ku celkovému výkonu ve spektru. Studie [54] si jako příznaky vybírá amplitudu peaků a obsah plochy pod křivkou spojující lokální maxima autokorelační funkce. Studie [20] jako příznaky bere pouze pozice peaků ve spektru. Bohužel neexistují žádné guideliny, podle kterých by se ve výběru příznaků dalo řídit. Dále je také možné, že pro detekci chrápání jsou vhodnější jiné příznaky, než pro následnou detekci apnoických událostí.

Pro detekci chrápání pomocí mobilního telefonu se mi po mnoha experimentech jeví jako nejlepší kombinace příznaků z časové oblasti, frekvenční a kvěfrenční oblasti. V časové oblasti jsem zvolil jako příznaky počet sekvencí odpovídající respiračnímu intervalu, které mají celé hodnotu vyšší/nížší, než je průměr vyhlazeného záznamu. Vyhlazení záznamu je prováděno pomocí klouzavých průměrů s velikostí okna odpovídající respiračnímu intervalu. Existují samozřejmě i jiné metody, jak signál vyhladit, jedna z nich je do detailu popsána v [37]. Ve frekvenční oblasti podobně jako [47] výkon v určitých pásmech spektra a pozice peaků. V kvěfrenční oblasti jsem vybral obdobné příznaky jako [37] a jako ve frekvenční, čili pozice peaků. Tyto pozice peaků ukazují, periodicitu ve spektru a tudíž odhalují harmonické složky signálu v časové oblasti. Celkově jsem po několika experimentech zvolil 19 prvotních příznaků (viz. následující tabulka), z nichž pro detekci chrápání je použito pouze prvních 7 z nich, další byly využity pouze k detekci apnoických událostí.

Pořadí	Doména	Popis
1	čas	počet sekvencí odpovídající respiračnímu intervalu, které mají celé hodnotu vyšší, než je průměr vyhlazeného záznamu
2	čas	počet sekvencí odpovídající respiračnímu intervalu, které mají celé hodnotu nižší, než je průměr vyhlazeného záznamu
3	frekvence	Celkový výkon v rozmezí 60 Hz - 180 Hz
4	frekvence	Celkový výkon v rozmezí 130 Hz - 380 Hz
5	frekvence	Celkový výkon v rozmezí 380 Hz - 620 Hz
6	frekvence	Celkový výkon v rozmezí 620 Hz - 900 Hz

7	frekvence	Celkový výkon v rozmezí 900 Hz - 1100 Hz
8	frekvence	Existuje peak v rozmezí 60 Hz - 150 Hz
9	frekvence	Existuje peak v rozmezí 150 Hz - 250 Hz
10	frekvence	Existuje peak v rozmezí 250 Hz - 400 Hz
11	frekvence	Existuje peak v rozmezí 400 Hz - 600 Hz
12	frekvence	Existuje peak v rozmezí 600 Hz - 900 Hz
13	frekvence	Existuje peak v rozmezí 900 Hz - 1200 Hz
14	kvefreence	Existuje peak v rozmezí 1 ms – 3 ms
15	kvefreence	Existuje peak v rozmezí 3 ms – 5 ms
16	kvefreence	Existuje peak v rozmezí 5 ms – 15 ms
17	kvefreence	Existuje peak v rozmezí 15 ms – 25 ms
18	kvefreence	Existuje peak v rozmezí 25 ms – 30 ms
19	kvefreence	Existuje peak v rozmezí 30 ms – 50 ms

Tab. 5– přehled vybraných příznaků použitých k detekci chrápání nebo apnoické události

### 5.3. Klasifikace chrápání

Klasifikace je proces určení, do které třídy dané pozorování patří. V tomto případě jsou třídy dvě a to chrápání a nechrápání. Jako pozorování jsou brány právě 40 vteřin dlouhé záznamy, nahrané mobilním telefonem. Pro nalezení nejlepšího klasifikátoru jsem hojně využíval software WEKA, což je kolekce nástrojů pro strojové učení implementovaná v Javě [55]. Pomocí WEKY jsem našel množství různých klasifikátorů a k odhadu jejich přesnosti jsem použil metodu křížové validace. Import některých klasifikátorů do Javy byl usnadněn tím, že WEKA umožňuje přímo generovat zdrojové kódy pro některé typy klasifikátorů.

### 5.3.1. Množina záznamů pro klasifikátor

Jelikož všechny zkoušené typy klasifikátorů patří do kategorie strojového učení s učitelem, bylo nejprve potřeba získat množinu správně zaklasifikovaných dat, ze které bude možné model klasifikátoru postavit. Tatu množinu dat jsem získal tak, že jsem prošel nasnímané záznamy od pacientů a ručně oklasifikoval chrápání v každém nasnímaném čtyřicetivteřinovém intervalu. Vzhledem k časové náročnosti tohoto úkonu jsem do finální verze množiny záznamů vybral pouze osm pacientů, nicméně nasnímaná data uložená v databázi na serveru by umožňovala sestavit výrazně rozsáhlejší množinu záznamů. Záznamy jsem doplnil o knihovnu zvuků veřejně dostupných z internetu, o nichž se dá předpokládat, že se mohou během nočního snímání v pacientově okolí objevit a dále o nahrávky, které mi byly poskytnuty autorem aplikace Sleep as Android [56] Ing. Petrem Nálevkou Ph.D. Jedná se o nahrávky zvuků např. následujících událostí: funění, dětské žvatlání, sex, zvuk z ulice, zvuk větráku etc. Celkem jsem takto postavil množinu, která obsahovala 11069 záznamů, z čehož 78% jsou negativní vzorky a 32% pozitivní. Tento nepoměr byl dán skutečností, že negativní vzorky jsou daleko lépe dostupné.

Každý záznam odpovídá 40 vteřinám nahraného zvuku. Vzhledem této délce poměrně často dochází k tomu, že se chrápání vyskytuje pouze v části daného záznamu. Pokud bylo zastoupení chrápání v záznamu alespoň 20%, ponechal jsem tento záznam a anotoval ho jako pozitivní. V případě, že se chrápání v záznamu sice vyskytlo, ale v měří, než uvedené míře, záznam jsem z množiny vyřadil. Po experimentování s různými klasifikátory a různými příznaky jsem dospěl k závěru, že ke klasifikaci chrápání stačí z původně navrhovaných 19 příznaků použít pouze prvních 7, přidání dalších příznaků již mělo na úspěšnost klasifikace zcela zanedbatelný vliv.

### 5.3.2. Křížová validace

Křížová validace je technika validace modelu. Používá se zejména tam, kde je potřeba odhadnout, jak přesně bude nalezený model pracovat s neznámými daty. Množina všech dostupných dat, ze kterých se tvoří model je nejprve rozdělena na trénovací a testovací

množinu. Trénovací množina je použita k vybudování klasifikátoru a testovací množina k odhadu jeho funkčnosti na neznámých datech. Obvykle se dělá několik průběhů křížové validace. Já jsem zvolil variantu s deseti průběhy (10 fold cross-validation). Ta funguje tak, že se data dopředu rozdělí na 10 částí a poté se desetkrát spustí křížová validace tak, že vždy jedna desetina se použije pro testování a zbylých devět desetin se použije pro učení. Tento přístup se nazývá desetinásobná křížová validace a je velmi obvyklý. Další variantou křížové validace, která by se dala teoreticky použít je tzv. leave-one-out křížová validace, která funguje velmi podobně, jen místo desetin dat se vyjme pouze jedno pozorování pro testování a zbylá data se použijí pro učení. Tato metoda nebyla zvolena, protože je výpočetně daleko náročnější. Existují samozřejmě další varianty křížové validace s různými výhodami a nevýhodami. Detailně jsou popsány v [57,58].

### 5.3.3. Naivní Bayesův klasifikátor

Naivní Bayesův klasifikátor je pravděpodobnostní klasifikátor založený na aplikaci Bayesovy věty o podmíněných pravděpodobnostech:

$$P(H|E) = \frac{P(E|H) \cdot P(H)}{P(E)} \quad (5.5)$$

Kde  $P(H)$  je apriorní pravděpodobnost pro danou třídu, která odpovídá samotné znalosti o zastoupení jednotlivých tříd bez ohledu na jakékoliv příznaky. Aposteriorní pravděpodobnost  $P(H|E)$ , určuje, jaká je pravděpodobnost, že pozorování náleží do třídy  $H$ , pokud víme, že nastal jev  $E$ .  $P(E)$  vyjadřuje pravděpodobnost pozorování daného vektoru příznaků. Jelikož zde se rozhodujeme mezi dvěma třídami, postupuje se tak, že se spočítá pravděpodobnost pro obě dvě a z nich se vybere ta, která má vyšší aposteriorní pravděpodobnost.

$$H_v = H_i \text{ iff } P(H_i|E) = \max_t \frac{P(E|H_t) \cdot P(H_t)}{P(E)} \quad (5.6)$$

Klasifikátor se nazývá naivní kvůli tomu, že předpokládá vzájemnou nezávislost zpracovávaných příznaků (v tomto případě tento předpoklad zcela evidentně neplatí). I přes toto značné zjednodušení naivní Bayesův klasifikátor v mnoha (často i složitých) situacích, kde nezávislost není, funguje velmi dobře i když podle studie [59] za některými jinými typy klasifikátorů silně zaostává. Výhodou naivního Bayesova klasifikátoru však je to, že stačí malé množství dat k tomu, aby se dal sestavit relativně dobrý model klasifikátoru. Detailnější popis naivního Bayesova klasifikátoru nabízí [60].

Výsledná matice konfuze (Confusion matrix) pro Bayesův klasifikátor vypadá následovně

Bez chrápání	Chrápání	
7879	847	Bez chrápání
436	1907	Chrápání


*Tab. 6 Matice konfuze pro naivní Bayesův klasifikátor*

Za pomoci předchozí tabulky jednoduše určíme sensitivitu, specificitu a Youdenův index pro naivní Bayesův klasifikátor.

Senzitivita	0,813
Specifická	0,903
Youdenův index	0,716

*Tab. 7 Senzitivita, specifická a Youdenův index pro Naivní Bayesův klasifikátor*


Jelikož Bayesův klasifikátor je velmi rozšířený a často považovaný za jakýsi standard, rozhodl jsem se, přestože mezi nalezenými klasifikátory není nejspolehlivější, ho společně s RepTree stromem (viz. dále) využít ke klasifikaci chrápání. Obrázek 12 ukazuje ROC křivku pro naivní Bayesův klasifikátor. ROC křivka slouží k hodnocení a optimalizaci binárního klasifikátoru. Tato křivka udává vztah mezi specificitou a senzitivitou daného klasifikátoru.



Obr. 12 – ROC křivka pro naivní Bayesův klasifikátor

### 5.3.4. Klasifikátor k-nejbližších sousedů (k-NN)

Trénovací množinou jsou vektory v multidimenzionálním prostoru příznaků, přičemž každý vektor nese označení, do jaké třídy náleží. Fáze učení klasifikátoru se skládá pouze z uložení příznakových vektorů a tříd trénovacích vzorků. V klasifikační fázi je nejprve definována konstanta  $k$  a neklasifikovaný vektor je (v nejjednodušším případě) zařazen do té třídy, která je mezi jeho  $k$  nejbližšími sousedy nejčetnější. Nemusí však jít pouze o četnost mezi sousedy, ale užitečné může být i váhování příspěvků těchto sousedů podle vzdálenosti od neklasifikovaného vektoru. To se uplatní zejména v případě, že trénovací množina je nevyvážená a neklasifikované vzorky mají tudíž tendenci spadat do té třídy, která převažuje (zejména pokud  $k$  je velké). Další možností, jak se vyhnout ovlivnění ve prospěch převažující třídy v trénovací množině je např. tzv. Self organizing map.[61] Vzdálenost od sousedů může být měřena podle různých metrik, přičemž asi nejpoužívanější jsou Euklidovská a Manhattanská metrika. Klasifikátor k-nejbližších sousedů má tedy několik parametrů, podle kterých může pracovat, přičemž tím nejdůležitějším z nich je právě  $k$ . Detailněji je klasifikátor k-NN popsán v [61,62].



Obr.13 Ilustrace klasifikace pomocí 3-NN, převzato z [61]

Stejně jako v případě naivního Bayesova klasifikátoru i zde byl klasifikační model validován desetinásobnou křížovou validací. Experimentálně jsem určil, že vhodný výběr základních parametrů pro k-NN je následující:

$$k - 4$$

$$\text{váhování} - 1/d$$

$$\text{metrika} - \text{Manhattan}$$

Při použití výše uvedeného nastavení jsem s klasifikátorem k-nejbližších sousedů dosáhl následujících výsledků.

Bez chrápání	Chrápání	
8223	503	Bez chrápání
522	1821	Chrápání

Tab. 8 Matice konfuze pro k-NN klasifikátor

Předchozí tabulka opět umožňuje snadno určit sensitivitu, specificitu a Youdenův index pro k-NN klasifikátor.


Senzitivita	0,777
Specifická	0,942
Youdenův index	0,719

Tab. 9 Senzitivita, specifická a Youdenův index pro k-NN klasifikátor

### 5.3.5. Support Vector Machine (SVM)

V tomto přístupu ke klasifikaci se jedná o rozdělení dat pomocí optimální rozdělovací nadplochy. Nejprve jsou určeny důležité body, které leží blízko hranice z obou stran. Pouze tyto body u hranice (support vektory) mají na tuto hranici vliv.

Cílem SVM je maximalizovat tzv. margin, což je šířka pásma, ve kterém se nenachází žádný bod. Intuitivně se pak klasifikátor jeví jako bezpečnější a model je stabilnější vůči změně trénovacích dat, pokud dojde ke změně některého support vektoru.



Obr. 14- Názorné zobrazení SVM pro 2 dimenze

SVM, jenž je ilustrováno na předchozím obrázku je nutno rozšířit tak, aby hranice nemusela být lineární. Provádí se to tak že se transformuje prostor dat do prostoru obrazů. V prostoru obrazů se naučí lineární funkce. Tato lineární funkce se zpět transformuje do původního prostoru. Vznikne tedy nelineární rozdělovací funkce. Díky kernelům ovšem není nutné vlastní mapování provádět. Často používané kernel funkce jsou: Polynomiální, RBF(gausovský). Detailní rozbor SVM a jeho možných variant je v [63]. Experimentálně jsem došel k závěru, že neefektivnější je použít polynomiální kernel a k naučení klasifikátoru



algoritmus Sekvenční minimální optimalizace. Tento algoritmus je podrobně popsán v [64]. Výsledky klasifikace pomocí SVM-SMO ukazuje následující tabulka.

Bez chrápání	Chrápání	
8300	426	Bez chrápání
657	1686	Chrápání

*Tab. 10 Matice konfuze pro SVM klasifikátor*

Předchozí tabulka opět umožňuje snadno určit sensitivitu, specificku a Youdenův index pro SVM klasifikátor.

Senzitivita	0,720
Specificku	0,951
Youdenův index	0,671

*Tab. 11 Senzitivita, specificku a Youdenův index pro SVM klasifikátor*

### 5.3.6. Rozhodovací strom

Mezi všemi data-miningovými technikami rozhodovací stromy patří k nejčastěji využívaným. To je hlavně z důvodu jejich přehlednosti a snadné interpretovatelnosti. Rozhodovací stromy jsou také velmi rychlé (ze všech zde uvedených algoritmů jednoznačně nejrychlejší).

Každý uzel stromu představuje jeden příznak a z tohoto uzlu vede konečný počet hran do dalších uzlů. Je tedy nutné příznaky nejdříve diskretizovat, což se v tomto případě děje rozdělením do konkrétních intervalů. Strom je tvořen algoritmem, který další uzel vybírá podle informační entropie příznaků tak, aby informační zisk v každém následujícím uzlu byl co největší.

Důležité je omezit maximální hloubku stromu, aby nedošlo k přeučení (overfitting), což je jev, kdy je algoritmus natolik napasován na trénovací data, že jeho výsledky na

reálných datech jsou daleko horší. Maximální hloubku stromu jsem nejprve omezil na 7, stejně jako je použitých příznaků a poté snížil na 6, přičemž výsledek byl téměř stejný a strom o dost jednodušší. Pro nalezení stromu existuje množství algoritmů, např. RepTree, ID3, C4 a další. Jejich srovnání se věnuje [65,66]. Po vytvoření rozodovacího stromu je možné strom ještě prořezat (pruning), což je proces, při kterém se některé uzly, které mají zanedbatelný vliv na výslednou klasifikaci. Po prořezání je klasifikační strom menší, přehlednější a pracuje minimálně stejně dobře (díky redukci přeučení často i lépe) a rychleji.[67]. Detailní popis rozhodovacích stromů a metodologie jejich tvorby a práce s nimi lze nalézt v [68]. Výsledky klasifikace pomocí stromů sestavený algoritmy RepTree a J48 ukazují následující tabulky. Další zkoušené algoritmy nedosáhly úspěšnosti uvedených dvou a do tabulek nejsou zaneseny.

Bez chrápání	Chrápání	
8253	473	Bez chrápání
609	1734	Chrápání

Tab. 12 Matice konfuze pro J48 rozhodovací strom


Bez chrápání	Chrápání	
8303	423	Bez chrápání
457	1886	Chrápání

Tab. 13 Matice konfuze pro RepTree rozhodovací strom

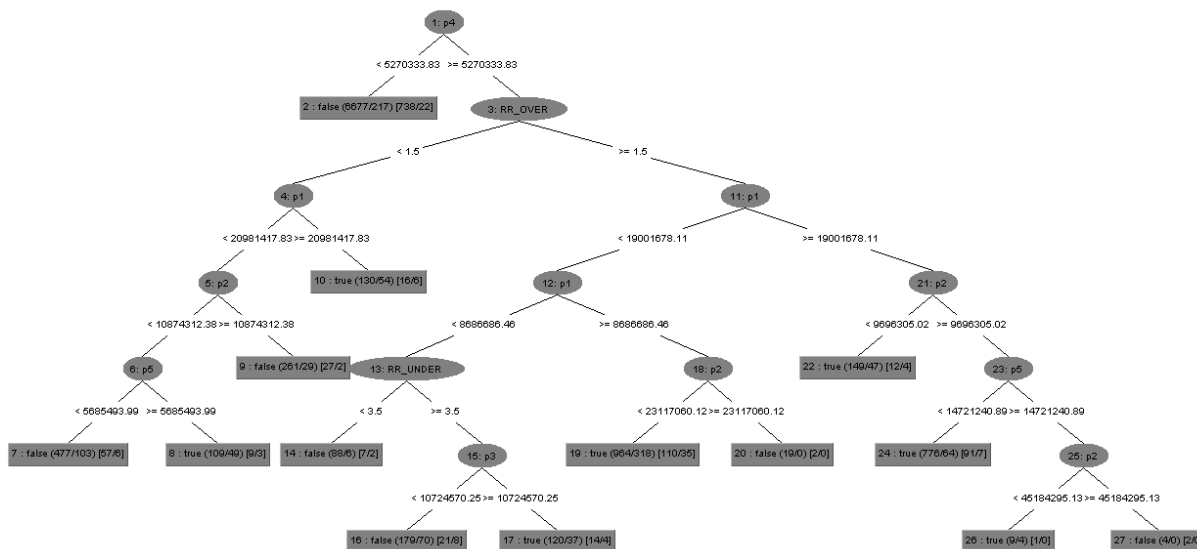
Předchozí tabulky umožňují snadno určit sensitivitu, specificitu a Youdenův index pro rozhodovací stromy. Obrázek 15 zobrazuje ROC křivku pro rozhodovací strom RepTree.

	J48	RepTree
Senzitivita	0,740	0,805
Specificita	0,946	0,952
Youdenův index	0,686	0,757

Tab. 14 Senzitivita, specificita a Youdenův index pro rozhodovací stromy J48 a RepTree



Obr. 15 – ROC křivka pro RepTree rozhodovací strom



Obr. 16 Vizualizace rozhodovacího stromu RepTree

Z předchozího srovnání vychází o dost lépe RepTree, který při daném omezení na hloubku stromu maximálně 6 obsahuje 27 uzlů. Obrázek 16 slouží pouze jako ilustrace toho, jak vypadá výsledný strom. Větší a přehlednější vizualizace je k dispozici v příloze. Na základě jeho jednoduchosti implementace jsem se rozhodl k detekci chrápání využít právě RepTree. Teoreticky by se jeho úspěšnost měla dát ještě zvýšit pomocí boostingu, což se však nestalo. viz. následující sekce.

### 5.3.7. Adaboost

Adaboost neboli Adaptive Boosting se využít u mnoha typů klasifikátorů ke zvýšení jejich účinnosti. Výstupy učicích algoritmů (weak learners), které musí být stejného typu, jsou zkombinovány pomocí vážené sumy tak, že tato jejich kombinace určuje výsledný klasifikátor. Tato metoda se nazývá adaptivní proto, že každý následující weak learner je upraven tak, aby preferoval správnou klasifikaci těch pozorování, která byla předchozím weak learnerem klasifikována špatně. Nevýhodou adaboostu je to, že je velmi citlivý na šum a odlehlé hodnoty, naopak výhodou je nízká náchylnost k přeučení. Podmínkou pro každého weak learnera je to, že jeho chyba je menší, než 50%. Testoval jsem dva různé adaboosty, podle předchozích výsledků, jsem zvolil jako weak learnery rozhodovací strom RepTree, jelikož dosahoval nejlepších výsledků a naivní Bayesův klasifikátor. Při zvolení rozhodovací stromu jako weak learnera pro Adaboost se strom v každém následujícím kroku Adaboostu zaměřuje na ty instance, které je těžké klasifikovat. Výsledný klasifikátor bývá silnější, než jednotlivé stromy. Detailnější popis Adaboostu se dá nalézt v [69,70]. Výsledky pro Adaboost, kde je jako weak learner použit RepTree se stejnými parametry, jako v předchozí části, jsou v následujících tabulkách.

Bez chrápání	Chrápání	
8237	489	Bez chrápání
624	1719	Chrápání

Tab. 15 Matice konfuze pro Adaboost s RepTree jako weak learnerem

Bez chrápání	Chrápání	
7879	847	Bez chrápání
432	1911	Chrápání

*Tab. 16 Matice konfuze pro Adaboost s naivním Bayesovým klasifikátorem jako weak learnerem*

Předchozí tabulky umožňují snadno určit sensitivitu, specificitu a Youdenův index pro tyto Adaboosty.

Weak learner ->	RepTree	Naivní Bayes
Senzitivita	0,734	0,816
Specificita	0,944	0,903
Youdenův index	0,678	0,719

*Tab. 17 - Senzitivita, specificita a Youdenův index pro Adaboost s RepTree a naivním Bayesovým klasifikátorem*

Srovnáním výsledků Adaboostu a výsledků jednotlivých klasifikátorů použitých jako weak learners zjistíme, že pokud byl jako weak learner použit rozhodovací strom RepTree, tak boosting výsledek nezlepšil. Zatímco u naivního Bayesova klasifikátoru boostování výsledek vylepšilo, ačkoliv velice mírně.

## 5.4. Detekce spánkové apnoe

Snaha o nalezení algoritmu pro detekci spánkové apnoe probíhala zcela analogicky, jako pokusy o detekci chrápání. Sběr surových dat a jejich předzpracování probíhalo úplně stejně jako je uvedeno v částech 3.3.1-3.4.1. V detekci apnoe jsem tudíž vycházel ze zcela stejných dat, jako při detekci chrápání. Zásadním rozdílem zde byl fakt, že záznamů, ve kterých se u pacienta vyskytují apnoické pauzy jsem měl k dispozici daleko méně, než záznamů, kde se vyskytuje obyčejné chrápání. Kvůli této skutečnosti jsem zařadil do vzorků pro detekci apnoe pouze čtyři pacienty, jejichž vzorky byly nasnímány v laboratoři mobilním telefonem. V záznamech těchto pacientů se apnoické pauzy vyskytovaly v dosti malém

množství, a byly tedy oproti negativním vzorkům v menšině. Z pacientů, jejichž záznamy apnoické pauzy neobsahovaly jsem se rozhodnul zařadit pouze jednoho a to z toho důvodu, že při zařazení většího počtu negativních vzorků by již trénovací množina byla velmi silně nevyvážená.

Na rozdíl od obyčejného chrápání jsou apnoické události také zaneseny ve výstupním logu polysomnografie, takže je možné zcela přesně určit, kde v záznamu se daná událost nachází a tím pádem trénovací množinu pro klasifikátor zcela přesně rozdělit na pozitivní a negativní vzorky bez nutnosti všechny záznamy procházet a ručně klasifikovat. K rozdělení zvukového záznamu za celou noc na jednotlivé úseky a klasifikaci podle logu jsem využil MATLAB.


Podle studií [18-21] by se ve spektru vzorků obsahujících apnoické události měl oproti obyčejnému chrápání vyskytovat peak v oblasti kolem frekvence 1kHz. Teoreticky by tedy tento peak měl být klíčem k rozlišení obyčejného chrápání a spánkové apnoe. Bohužel v žádném z telefonem provedených snímání se tento peak nevyskytoval. Tento fakt je dost možná způsoben tím, že mikrofon mobilního telefonu může mít vestavěný nějaký typ filtru, který ho potlačí, nebo posune na jinou frekvenci. Jako nejpravděpodobnější varianta se jeví frekvenční posun. Tento posun by nebyl problémem, pokud by směřoval k nižším frekvencím, kde by se dal snadno odchytil. V případě (jako je nejspíš i tento), že se však jedná o posun k vyšším frekvencím, které při současném přístupu ke snímání a ukládání dat nelze kvůli vzorkovacímu teorému ji zrekonstruovat, jsou veškeré pokusy o nalezení daného peaku marné. Bohužel příliš vysokým decimálním faktorem zvoleným ještě před začátkem snímání ve spánkové laboratorii se takto ztratil nejnadhjnější příznak pro rozlišení spánkové apnoe a obyčejného chrápání. Pro potvrzení nebo vyvrácení této teorie by bylo nutné opakovat snímání pacienta trpícího spánkovou apnoe a výsledný záznam decimovat nižším faktorem tak, aby vzorkovací teorém umožňoval rekonstruovat frekvence alespoň do 2 kHz.

Zatímco k detekci chrápání bohatě stačilo 7 příznaků, detekce spánkové apnoe je v tomto ohledu výrazně náročnější. Při absenci již zmiňovaného peaku na vyšší frekvenci jsem zvolil v časové oblasti stejné příznaky, ve frekvenční jsem přidal příznaky hledající peaky v určitých frekvenčních pásmech (právě mezi těmito se měl vyskytovat onen klíčový). Bohužel výsledky klasifikace byly zcela nedostatečné, a proto jsem hledal další příznaky, které

by mohli tuto situaci zlepšit. Nakonec jsem se po konzultaci s vedoucím práce rozhodl přidat příznaky na základě keprální analýzy – viz. tabulka 5. Z příznaků uvedených v této tabulce jsem pomocí algoritmu CFS (Correlation feature selection, viz. [71]) zjistil, že nejvhodnější kombinací příznaků jsou příznaky (dle číslování v tabulce 5) 3,5,7,14,15. Což znamená, že při detekci spánkové apnoe nakonec nebyl použit žádný příznak z časové oblasti, naopak jako správné se ukázalo použití keprální analýzy. Použití pouze těchto příznaků sice nalezené klasifikátory významně vylepšilo, nicméně stále je výsledek velmi špatný. Klasifikátory a jejich parametry byly hledány pomocí stejných metod, jako pro detekci chrápání a validovány zcela stejným způsobem. V následující tabulce jsou uvedeny výsledky detekce apnoických událostí. Za povšimnutí stojí celkově nízká úspěšnost klasifikace totální selhání klasifikátoru SVM.

Klasifikátor	Senzitivita	Specifická	Youdenův index
Naivní Bayesův klasifikátor	0.487	0.665	0.152
k-NN	0.259	0.945	0.204
SVM	0	1	0
RepTree	0.292	0.937	0.229
J48	0.238	0.951	0.189
Adaboost - RepTree	0.366	0.908	0.274
Adaboost – Naivní Bayes	0.487	0.665	0.152

*Tab. 18 - Senzitivita, specifická a Youdenův index pro všechny testované klasifikátory pro detekci spánkové apnoe*



Obr. 17 – ROC křivka nejúspěšnějšího klasifikátoru pro detekci spánkové apnoe (Adaboost s RepTree základem)



## Kapitola 6

### Závěr

Výsledkem této diplomové práce je jednak validace výsledků předchozí bakalářské práce [1] a za druhé nalezení vhodného postupu ke sběru dat pro detekci chrápání a spánkové apnoe mobilním telefonem. Kapitoly 2 a 3 poskytly základní teoretický náhled do problematiky aktigrafie, chrápání a spánkové apnoe, zatímco kapitoly 4 a 5 se zabývaly praktickou implementační částí. Všechna data použitá v této práci byla nasnímana ve spánkové laboratoři Psychiatrického centra Praha (PCP) a to buď mobilními telefony s operačním systémem Android verze 2.3.5 a 4.1, nebo polysomnograficky.

Kapitola 4 se stejně jako [1] zabývá problematikou aktigrafického snímání pomocí vestavěného akcelerometru a nabízí porovnání vyvinutého algoritmu s výsledky polysomnografie. V této kapitole jsem došel k závěru, že postup a algoritmus navržený v [1] dosahuje Youdenova indexu téměř 0,7, což považuji za vcelku dobrý a jako doplňkové snímání dostatečný výsledek. Tuto část by bylo možné rozšířit ještě o porovnání s výsledky aktigrafickým hodinek Actiwatch. Předpokládám však, že přesnost hodinek Actiwatch je samozřejmě daleko vyšší, než přesnost snímání mobilním telefonem.

Kapitola 5 nabídla rozšíření práce [1] o způsob detekce chrápání a apnotických událostí za použití audiozáznamu pacientova spánku. Audiozáznamy byly nahrány mobilním telefonem, byly navrženy vhodné příznaky pro detekci chrápání a apnotických událostí. Následně byly popsány některé klasifikátory využívající nalezených příznaků k detekci. Dva z těchto klasifikátorů (Naivní Bayesův klasifikátor a rozhodovací strom RepTree) byly implementovány i v Javě tak, aby fungovaly právě na mobilních telefonech se systémem

Android. Tuto implementaci lze také jednoduše přidat do aplikace Asleep, která byla vyvinuta v rámci předchozí práce [1]. Co se týče detekce chrápání, tak oba implementované klasifikátory dosáhly na množině vzorků získaných z PCP (přes 11000 vzorků po 40 vteřinách) velice solidního Youdenova indexu (0,716 a 0,757). Právě sestavení trénovací množiny pro klasifikátory bylo časově nejnáročnější součástí této práce, protože bylo nutné všechny záznamy projít a manuálně oklasifikovat. Překvapující u detekce chrápání bylo, že úspěšnost klasifikátoru RepTree se nikterak nezlepšila po jeho boostování. viz 5.3.7. Vhodným rozšířením a pokračováním části o detekci chrápání by bylo praktické ověření funkčnosti, kdy by nasnímaná data byla analyzována přímo mobilním telefonem už v průběhu snímání. Toto bylo ještě během předchozí práce nemyslitelné, nicméně dnešní mobilní telefony mají již dostatečný výkon k tomu, aby to mohly zvládnout. Tato práce však počítá s offline zpracováním až po kompletním dokončení celého snímání.

Poslední část práce se věnovala problematice detekce apnotických událostí, taktéž z audiozáznamu pacientova spánku. Tato část byla výrazně komplexnější, než části předchozí. Stejně jako při detekci chrápání byla sestavena trénovací množina skládající se z negativních a pozitivních vzorků. Velkou překážkou zde byl malý počet pacientů trpících spánkovou apnoe v PCP, z čehož plynul malý počet pozitivních vzorků. Naopak výhodou oproti detekci chrápání zde byl fakt, že apnotické události byly anotovány v log souborech z polysomnografie, což sestavení trénovací množiny záznamů velice ulehčilo. Pro detekci apnotických událostí musely také být zvoleny příznaky odlišné od těch, které byly použity pro detekci chrápání. Teoreticky nejlepším příznakem pro detekci apnotických událostí by totiž měl být peak ve frekvenčním spektru záznamu nacházející se přibližně v oblasti 1 kHz. V této části se ukázalo, že na začátku projektu byla až přílišná snaha ušetřit zdroje (zejména místo na disku a přenesená data – viz 5.1.4) a nasnímaný záznam byl decimován až příliš vysokým faktorem. Vzorkovací frekvence uložených záznamů byla tudíž pouze 2205 Hz, což by sice dle vzorkovacího teorému mělo na detekci zmíněného peaku stačit, ale prakticky to tak nebylo. Domnívám se, že během snímání, či zpracovávání signálu došlo k frekvenčnímu posunu směrem k vyšším frekvencím, který způsobil, že zmíněný peak již nebylo možné rekonstruovat a detekovat.

Při použití jiných příznaků žádný z testovaných klasifikátorů nedosáhl očekávaného výsledku. Nejvyššího Youdenova indexu dosáhnul boostovaný RepTree a to 0,274, což bylo velkým zklamáním. Zde by bylo vhodné celý postup opakovat s nižším decimálním faktorem, což by umožňovalo rekonstruovat vyšší frekvence a navrhnout nové příznaky, díky kterým by klasifikace mohla být úspěšnější.



## Literatura

- [1] Slezák D., *Sledování kvality spánku pomocí chytrého telefonu*. Praha, 2012. Bakalářská práce. ČVUT.
- [2] Sadeh A. *The role and validity of actigraphy in sleep medicine: An update*. Sleep Medicine Reviews 15 (2011) 259e267
- [3] *Cell Phone and Smartphone Ownership Demographics*, PewResearch 2014, Dostupné na stránce: <http://www.pewinternet.org/data-trend/mobile/cell-phone-and-smartphone-ownership-demographics/>
- [4] *Smartphones Reach Majority in all EU Countries*. 15.3.2013, dostupné z: <http://www.comscore.com/2013/03/smartphones-reach-majority-in-all-eu5-countries/>
- [5] Smith A. *Smartphone Ownership – 2013 Update*. Dostupné z <http://pewinternet.org/Reports/2013/Smartphone-Ownership-2013.aspx>
- [6] "Worldwide Smartphone Sales to End Users by Operating System in 2Q13", 14.8.2013. Dostupné z: <http://www.gartner.com/newsroom/id/2573415>
- [7] Sadeh A., Acebo C. *The role of actigraphy in sleep medicine*. Sleep Medicine Reviews, Vol. 6, No. 2, pp 113–124, 2002
- [8] Pollak C, Tryon W, Nagaraja H, Dzwonczyk R. *How accurately does wrist actigraphy identify the states of sleep and wakefulness?* Sleep 2001 Dec 15;24(8):957-65.
- [9] Cook I, Lambert E. *Monitor placement, sources of variance and reliability of free-living physical activity: a pilot investigation*. South African Journal of Sports Medicine (2009). Volume: 21, Issue: 1

- [10] Patterson S, Krantz D, Montgomery L, Deuster P, Hedges S, Nebel L. *Automated physical activity monitoring: Validation and comparison with physiological and self-report measures.*
- [11] Cole R, Kripke D, Gruen W, Mullaney D, Gillin J. *Automatic Sleep/Wake Identification From Wrist Activity.* 1992; *Sleep*, 15(5):461-469
- [12] Kushida CA, Chang A, Gadkary C, Guilleminault C, Carrillo O, Dement WC. *Comparison of actigraphic, polysomnographic, and subjective assessment of sleep parameters in sleep-disordered patients.* *Sleep Med* 2001;2:389-96.
- [13] Paquet J, Karwinska A, Carrier J. *Wake detection capacity of actigraphy during sleep.* *Sleep.* 2007 October 1; 30(10): 1362–1369.
- [14] de Souza L, Benedito-Silva A, Pires M, et al. *Further validation of actigraphy for sleep studies.* *Sleep* 2003;1:81-5.
- [15] Sadeh A, Sharkey K, Carskadon M. *Activity-based sleep-wake identification: An empirical test of methodological issues.* 1994; *Sleep*, 17(3):201-207
- [16] Kripke D, Hahn E, Grizas A, Wadiak K, Loving R, Poceta J, Shadan F, Cronin J, Kline L. *Wrist actigraphy scoring for sleep laboratory patients: algorithm development.* *Journal of sleep research* volume 19 612-619, Dec 2010
- [17] Dalmaso F, Prota R. *Snoring: analysis, measurement, clinical implications and applications.* *Eur Respir J*, 1996, 9, 146–159
- [18] Fiz J, Abad J, Jané R, Riera M, Mananas M, Caminal P, Rodenstein D, Morera J. *Acoustic analysis of snoring sound in patients with simple snoring and obstructive sleep apnoea.* *Eur Respir J*, 1996, 9, 2365–2370
- [19] Pevernagie D, Aarts R, De Meyer M. *The acoustics of snoring.* *Sleep Medicine Reviews* 14 (2010) 131–144
- [20] Beck R, Odeh M, Oliven A, Gavriely N. *The acoustic properties of snores.* *Eur Respir J*, 1995, 8, 2120–2128
- [21] Perez-Padilla JR, Slawinski E, DiFrancesco LM, Feige RR, Remmers JE, Whitelaw WA. *Characteristics of the snoring noise in patients with and without occlusive sleep apnea.* *Am Rev Respir Dis* 1993; 147: 635–644

- [22] Herzog M, Schmidt A, Bremert T, Herzog B, Hosemann W, Kaftan H. *Analysed snoring sounds correlate to obstructive sleep disordered breathing*. Eur Arch Otorhinolaryngol 2008;265(1):105–13.
- [23] Cavusoglu M, Ciloglu T, Serinagaoglu Y, Kamasak M, Eroglu O, Akcam T. *Investigation of sequential properties of snoring episodes for obstructive sleep apnoea identification*. Physiol Meas. 2008 Aug;29(8):879-98. Epub 2008 Jul 4.
- [24] Palomäki H, Partinen M, Erkinjuntti T, Kaste M. *Snoring, sleep apnea syndrome and stroke*. Neurology [1992, 42(7 Suppl 6):75-81; discussion 82]
- [25] Palomäki H, Partinen M, Juvela S, Kaste M. *Snoring as a risk factor for sleep-related brain infarction*. Stroke. 1989;20:1311-1315
- [26] Hoffstein V, Mateika JH, Mateika S. *Snoring and sleep architecture*. Am Rev Respir Dis 1991; 143: 92–96
- [27] Hobzová M. *Spánková apnoe*. [online]. 11. 2. 2014 , Dostupné z : <http://zdravi.e15.cz/clanek/postgradualni-medicina/spankova-apnoe-474122>
- [28] Lucas J., Golish J., Sleeper G., O’Ryan J.A., *Home Respiratory Care*. Englewood Cliffs, NJ: Prentice Hall, 1988, ch. 6, str.132-136.
- [29] Wilkin R.L., *Clinical Assessment in Respiratory Care*. St Louis, MO: Mosby, 1985, str.268-272.
- [30] Nevšimalová S. *Poruchy spánku* [online]. 4. 9. 2008 Dostupné z : <http://www.zdn.cz/clanek/postgradualni-medicina/poruchy-spanku-383319>
- [31] Martin R. J., *Cardiorespiratory Disorders During Sleep*. Mount Kisco, NY: Futura , 1990, ch.4, str 123 -169
- [32] Young T., Patla M., Dempsey J., Skatrud J. , Weber S., Badr S., *The occurrence of sleep-disordered breathing among middle age adults* N. Eng.J.Med., vol.328, str 1230-1235, 1993.
- [33] Mahowald M, Schenck C. *Insights from studying human sleep disorders* NATURE, Vol 437,27, October 2005[doi:10.1038/nature04287.
- [34] Šonka K., Slonková J. *Spánková apnoe dospělého věku*. 2008. Cesk.Slov.Neurologie N 71/104(6) str. 643-656

- [35] Thorpy M.J. *The international classification of sleep disorders: diagnostic and coding manual*. Lawrence KS, ed. Allen Press Inc., USA 1990; pp. 195–197.
- [36] Schmidt-Nowara W, Lowe A, Wiegand L, Cartwright R, Perez-Guerra F, Menn S. *Oral Appliances for the Treatment of Snoring and Obstructive Sleep Apnea*. 1995; *Sleep*, 18(6):501-510
- [37] Abeyratne, U.R. *Pitch-jitter analysis of snoring sounds for the diagnosis of sleep apnea*. Engineering in Medicine and Biology Society, 2001. Proceedings of the 23rd Annual International Conference of the IEEE (Volume:2), ISBN 0-7803-7211-5
- [38] Guilleminault C., Stoohs R., Clerk A., Cetel M., and Maistros P., *A cause of excessive daytime sleepiness-The The upper airway resistance syndrome*, *Chest*, vol. 104, str 781-787, 1993
- [39] Peter J.H, Podszus T., von Wichert P., *Sleep Related Disorders and Internal Diseases*, New York: Springer-Verlag 1987, str, 101-107
- [40] Shepard J.W., Geftter W.B., Guilleminault C, Hoffman E.A., Hoffstein V., Hudgel D.W., Suratt P.M., White D.P., *Evaluation of the upper airway in patients with obstructive sleep apnea*, *Chest* 1988; 94: 87–89.
- [41] Hudgel D.W., *Variable site of upper airway narrowing among obstructive sleep apnea patients*, *J. Appl. Physiol.* Vol. 61, str 1403-1409, 1986
- [42] Ondrasek N. *Perchance to Dream*. Berkeley Science Review 12.5.2011. Dostupné na : <http://sciencereview.berkeley.edu/article/perchance-to-dream/>
- [43] Moussavi Z., Yadollahi A., Camorlinga S. *Breathing sound analysis for detection of sleep apnea/popnea events*. US Patent 7,559,903 B2, 2009
- [44] Ng A.K., Ho Z., Koh T. *Effects of Microphone Position on Snore Signal Quality and Patient Comfort*. Signal Processing, 2008. ICSP 2008. 9th International Conference. ISBN 978-1-4244-2179-4
- [45] Hoffstein V. *Snoring*. *Chest*, vol.109, str. 201-222, 1996
- [46] Karunajeewa A.S, Abeyratne U.R., Hukins C. *Silence-breathing-snore classification from snore-related sounds*. *Physiol.Meas.* 03/2008 DOI:10.1088/0967-3334/29/2/006
- [47] Karunajeewa A.S, Abeyratne U.R., Hukins C. *Multi feature snore sound analysis in obstructive sleep apnoa-hypopnea syndrome*. *Physiol.Meas.* 03/2011 DOI: 10.1088/0967-3334/32/1/006




- [48] Pevernagie D, Aarts R, De Meyer M. *The acoustics of snoring*. Sleep Medicine Reviews 14 (2010) 131–144
- [49] Cooley J. W., Tukey, J. W. *An algorithm for the machine calculation of complex Fourier series*. 1965 Math. Comput. 19: 297–301. doi:10.2307/2003354.
- [50] Cochran, W. T., Cooley, J. Holmdel, N. J., Favon, D.L., Helms, H.D. *What is the Fast Fourier transform*. 1967 Proceedings of the IEEE (Volume:55, Issue: 10) Doi 10.1109/PROC.1967.5957
- [51] Seleno O. *The Fast Fourier transform in Java*. [online], 20.4.2014 dostupné z: [http://www.wikijava.org/wiki/The\\_Fast\\_Fourier\\_Transform\\_in\\_Java\\_\(part\\_1\)](http://www.wikijava.org/wiki/The_Fast_Fourier_Transform_in_Java_(part_1))
- [52] Oppenheim A.V., Schafer R.W. *From frequency to quefreny: A history of the cepstrum*. 2004 Signal Processing Magazine, IEEE (Volume:21 , Issue: 5 )
- [53] Jané R., Sola-Soler J., Fiz J.A., Morera J. *Automatic detection of snoring signals: Validation with simple snorers and OSAS patients* Engineering in Medicine and Biology Society, 2000. Proceedings of the 22nd Annual International Conference of the IEEE (Volume:4 )
- [54] Dafna E., Tarasiuk A., Zigel Y., *Sleep-Quality Assessment from Full Night Audio Recordings of Sleep Apnea Patients*. Conf Proc IEEE Eng Med Biol Soc. 2012;2012:3660-3. doi: 10.1109/EMBC.2012.6346760.
- [55] Holmes G., Donkin A., Witten I.H. *Weka: A machine learning workbench*. 1994 Proc Second Australia and New Zealand Conference on Intelligent Information Systems, Brisbane, Australia.
- [56] Aplikace Sleep as Anroid dostupná na GooglePlay z : [https://play.google.com/store/apps/details?id=com.urbandroid.sleep&feature=search\\_result#?t=W251bGwsMSwxLDEsImNvbS51cmJhbmRyb2lkLnNsZWVwIl0](https://play.google.com/store/apps/details?id=com.urbandroid.sleep&feature=search_result#?t=W251bGwsMSwxLDEsImNvbS51cmJhbmRyb2lkLnNsZWVwIl0)
- [57] Burkman P., *A comparative study of ordinary cross-validation, v-fold cross-validation and the repeated learning-testing methods*. Biometrika (1989) 76 (3): 503-514. doi: 10.1093/biomet/76.3.503
- [58] Brown M.W. *Cross-Validation Methods*. Journal of Mathematical Psychology, Volume 44, Issue 1, March 2000, str. 108–132

- [59] Rish I. *An empirical study of the naive Bayes classifier*. IJCAI 2001 Workshop on Empirical Methods in Artificial Intelligence.
- [60] Murphy K.P., *Naive Bayes Classifiers*. University of British Columbia, 2006, dostupné z : <http://www.ic.unicamp.br/~rocha/teaching/2011s1/mc906/aulas/naive-bayes.pdf>
- [61] Houdek M., Svoboda T., Procházka T. *Klasifikace podle nejbližších sousedů*. FEL ČVUT 2001, dostupné z: [http://cmp.felk.cvut.cz/cmp/courses/recognition/zapis\\_prednasky/zapis\\_01/4/rpz4.pdf](http://cmp.felk.cvut.cz/cmp/courses/recognition/zapis_prednasky/zapis_01/4/rpz4.pdf)
- [62] Cover T., Hart P. *Nearest neighbor pattern classification*. 1967 Information Theory, IEEE Transactions on (Volume:13, Issue: 1) ISSN : 0018-9448
- [63] Scholkopf B., Amola A.J. *Learning with kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. The MIT Press 2001, ISBN 9780262194754
- [64] Platt J.C., *Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines*. Technical Report MSR-TR-98-14, 1998
- [65] Zhao Y., Zhang Y. *Comparison of decision tree methods for finding active objects*. Advances in Space Research, Volume 41, Issue 12, 2008
- [66] Banfield R.E., Hall L.O., Bowyer K.V., Kegelmeyer W.P. *A comparison of decision tree ensemble creation techniques*. 2007 Pattern Analysis and Machine Intelligence, IEEE Transactions on (Volume:29, Issue: 1 ) ISSN: 0162-8828
- [67] Mingers J. *An empirical comparison of pruning methods for decision tree induction*. Machine Learning November 1989, Volume 4, Issue 2, str. 227-243 ISSN: 0885-6125
- [68] Rasoul S., Landgrebe D. *A survey of decision tree classifier methodology*. 1991 Systems, Man and Cybernetics, IEEE Transactions on (Volume:21, Issue: 3) ISSN: 0018-9472
- [69] Freund, Y.; Schapire R., Abe N. *A short introduction to boosting*. Journal-Japanese Society For Artificial Intelligence, 1999, 14.771-780: 1612.
- [70] Schapire, R. E. *A brief introduction to boosting*. In: Ijcai. 1999. str. 1401-1406.
- [71] Dash M., Liu H. *Feature selection for classification*. Intelligent data analysis, 1997, 1.3: 131-156.

# Přílohy

## 8.1.1. Vizualizace rozhodovacího stromu RepTree



### 8.1.2. Obsah přiloženého CD

K této práci je přiloženo i CD, které obsahuje následující data:

- Adresář **pdf** – adresář obsahující tuto práci ve formátu pdf
- Adresář **apk** – adresář obsahující soubor **Apnoe.apk** sloužící pro nainstalování aplikace pro sběr dat k analýze.
- Adresář **source** – adresář obsahující zdrojové kódy aplikace pro Android a další zdrojové kódy použité během implementace.