

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE

Brno, 2024

Michal Bódi



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

KLASIFIKACE SPÁNKOVÝCH UDÁLOSTÍ Z POLYGRAFICKÝCH DAT

CLASSIFICATION OF SLEEP EVENTS FROM POLYGRAPHIC DATA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Michal Bódi

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Martin Králík

BRNO 2024



Bakalářská práce

bakalářský studijní program **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Michal Bódi

ID: 240485

Ročník: 3

Akademický rok: 2023/24

NÁZEV TÉMATU:

Klasifikace spánkových událostí z polygrafických dat

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou spánkové medicíny a polygrafických vyšetření. Vysvětlíte rozdíl mezi jednotlivými spánkovými událostmi a jednotlivými onemocněními s nimi spojenými. 2) Vypracujte obecnou literární rešerši pravidel současné klasifikace spánkových událostí. 3) Seznamte se s dostupnými daty z polygrafických vyšetření včetně anotací a navrhnete vhodný postup jejich zpracování včetně vhodného předzpracování. 4) Implementujte algoritmus pro detekci spánkových událostí ve zvoleném programovacím prostředí. 5) Na základě detekce určete apnea-hypopnea index u jednotlivých pacientů. 6) Vhodně prezentujte a diskutujte dosažené výsledky, možnosti a problémy klasifikace.

DOPORUČENÁ LITERATURA:

[1] PŘÍHODOVÁ, Iva a DOSTÁLOVÁ, Simona. Spánková medicína v kazuistikách. 2., přepracované a doplněné vydání. Medicina (EEZY Publishing). Praha: EEZY, 2023. ISBN 978-80-88506-01-0.

[2] KANG, Chang-Hoon; ERDENEBAJAR, Urtnasan; PARK, Jong-Uk a LEE, Kyoung-Joung. Multi-Class Classification of Sleep Apnea/Hypopnea Events Based on Long Short-Term Memory Using a Photoplethysmography Signal. Online. Journal of Medical Systems. 2020, roč. 44, č. 1. ISSN 0148-5598. Dostupné z: <https://doi.org/10.1007/s10916-019-1485-0>.

Termín zadání: 5.2.2024

Termín odevzdání: 9.8.2024

Vedoucí práce: Ing. Martin Králík

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

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Táto bakalárska práca rozoberá detekciu a klasifikáciu spánkového apnoe. Najprv vysvetľuje jednotlivé spánkové poruchy a ich príčiny vzniku. Načrtne diagnostiku týchto porúch a možný postup liečby. Uvádza metódy získavania dát a vytvára prehľad získavania používaných signálov. Následne navrhuje postup algoritmu na detekciu za pomoci vlnkovej transformácie a adaptívneho prahovania. Práca pokračuje samotným programovým riešením deleným do funkcií v prostredí Matlab. Jeho vyhodnotenie bolo cez apnoe/hypopnoe index a metriku senzitivity, presnosti a skóre F1. Najnižšia absolútna chyba indexu apnoe/hypopnoe v zázname 6. dosiahla 0,24 za hodinu a celkovo priemerná chyba bola 6,69 za hodinu. Najvyššia hodnota F1 v zázname 5. dosiahla 91,84% a celkovo bola 76,72%. Výsledky boli zobrazené pomocou grafov, matice zámen a vhodnými obrázkami. Vytvorený algoritmus by mal lekárom uľahčiť hľadanie dychových porúch spánku v celonočných záznamoch. Pacientom by umožnil mať výsledky hneď po vyšetrení.

KLÚČOVÉ SLOVÁ

spánkové udalosti, poruchy dýchania v spánku, spánkové apnoe, hypopnoe, polysomnografia, polygrafia, vlnková transformácia, adaptívne prahovanie, detekcia, klasifikácia, apnoe/hypopnoe index, F1 skóre

ABSTRACT

This bachelor's thesis discusses the detection and classification of sleep apnea. First, it explains individual sleep disorders and their causes. It outlines the diagnosis of these disorders and the possible course of treatment. It lists the data acquisition methods and creates an overview of the acquisition of the used signals. Subsequently, it proposes an algorithm procedure for detection using wavelet transformation and adaptive thresholding. The work continues with the program solution itself divided into functions in the Matlab environment. Its evaluation was through the apnea/hypopnea index and the metric of sensitivity, accuracy and F1 score. The lowest absolute error of the apnea/hypopnea index in record 6 was 0.24 per hour, and the overall average error was 6.69 per hour. The highest value of F1 in record 5 reached 91.84% and the total was 76.72%. The results were displayed using graphs, a confusion matrix and appropriate figures. The created algorithm should make it easier for doctors to search for sleep breathing disorders in all-night recordings. It would allow patients to have results immediately after the examination.

KEYWORDS

Sleep Events, Sleep-related Breathing Disorders, Sleep Apnea, Hypopnea, Polysomnography, Polygraphy, Wavelet Transform, Adaptive Thresholding, Detection, Classification, Apnea/Hypopnea Index, F1 Score

BÓDI, Michal. *Klasifikácia spánkových udalostí z polygrafických dát*. Bakalárska práca. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2024. Vedúci práce: Ing. Martin Králík

Vyhlásenie autora o pôvodnosti diela

Meno a priezvisko autora: Michal Bódi
VUT ID autora: 240485
Typ práce: Bakalárska práca
Akademický rok: 2023/24
Téma záverečnej práce: Klasifikácia spánkových udalostí z polygrafických dát

Vyhlasujem, že svoju záverečnú prácu som vypracoval samostatne pod vedením vedúcej/cého záverečnej práce, s využitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autor uvedenej záverečnej práce ďalej vyhlasujem, že v súvislosti s vytvorením tejto záverečnej práce som neporušil autorské práva tretích osôb, najmä som nezasiahol nedovoleným spôsobom do cudzích autorských práv osobnostných a/alebo majetkových a som si plne vedomý následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona Českej republiky č. 121/2000 Sb., o práve autorskom, o právach súvisiacich s právom autorským a o zmene niektorých zákonov (autorský zákon), v znení neskorších predpisov, vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia časti druhej, hlavy VI. diel 4 Trestného zákonníka Českej republiky č. 40/2009 Sb.

Brno

.....

podpis autora*

*Autor podpisuje iba v tlačenej verzii.

POĎAKOVANIE

Rád by som poďakoval vedúcemu bakalárskej práce pánovi Ing. Martinovi Králíkovi za konzultácie, rady a trpezlivosť so mnou. Taktiež som vďačný všetkým, čo na mňa mysleli.

Obsah

Úvod	10
1 Spánkové udalosti	11
1.1 Klasifikácia spánkových porúch	13
1.2 Definície pojmov	13
1.3 Poruchy dýchania v spánku	14
2 Diagnostika spánkových porúch	17
2.1 Polysomnografia	17
2.2 Polygrafia	17
2.3 Súčasné pravidlá klasifikácie	19
2.4 Automatizačné nástroje	19
2.4.1 Vlnková transformácia	20
2.4.2 Štatistická analýza	22
2.4.3 Strojové učenie	23
2.5 Metrika hodnotenia klasifikátorov	23
3 Softvérové riešenie	25
3.1 Návrh riešenia	26
3.2 Kód programu	29
3.2.1 Zdrojový kód main.m	29
3.2.2 Funkcia detector.m	29
3.2.3 Funkcia scoring.m	31
4 Výsledky	32
4.1 Diskusia	34
Záver	37
Literatúra	38
Zoznam symbolov a skratiek	42
A Obsah elektronickej prílohy	44

Zoznam obrázkov

1.1	Príklad spánkových udalostí	12
1.2	Typy apnoe	15
1.3	Skórovanie Mallampati	16
2.1	Polysomnografia a hlavica na zapojenie snímačov	18
2.2	Štruktúra vlnkovej transformácie	20
2.3	Príklady typov vlniek	21
3.1	Bloková schéma algoritmu	26
3.2	Spektrogram vlnkovej transformácie	27
3.3	Adaptívne prahovanie	28
3.4	Príklady hodnotenia	28
3.5	Krabicový graf	30
4.1	Matica zámen	33
4.2	Nesprávne určenie dychovej frekvencie	34
4.3	Zvýšený prah lokálnymi maximami	35
4.4	Porovnanie časti detekcie	36
4.5	Histogram výsledkov	36

Zoznam tabuliek

2.1	Multirozklad vlnkovej transformácie	22
3.1	Obsah databázy DREAMS Apnea	25
3.2	Vzťah škálovacieho merítka a frekvencie	27
4.1	Index apnoe/hypopnoe	32
4.2	F1 skórovanie detekcie	33

Úvod

Práca sa zameriava na vyhodnocovanie spánkových udalostí spojených s dýchaním. Konkrétne teda apnoe, čo je zástava dychu, a hypopnoe, čo je zníženie prietoku vzduchu dýchacími cestami. Dôvodom je buď prerušenie práce dýchacích svalov alebo zúženie dýchacích ciest, ktoré je oveľa častejšou príčinou. Prejavuje sa chrápaním, budením uprostred noci, bolesťou hlavy a nevyspatosťou cez deň. Dlhodobé neliečenie môže viesť k vážnym ochoreniam. Napríklad veľmi silná korelácia existuje medzi spánkovým apnoe a ischemickou cievnu mozgovou príhodou.

Práca má slúžiť na rozšírenie povedomia o tejto téme a ako pomôcka na diagnostiku pacientov s touto poruchou. Tí obyčajne netušia, že niečo nie je v poriadku, kým ich to neobmedzuje v každodennej práci. Výsledok zistia až pri vyšetrení v spánkovom laboratóriu, kde sa snímajú rôzne signály. Dlhé celonočné záznamy sa ťažko vyhodnocujú a tento algoritmus by mohol významne pomôcť lekárom pri ich práci. Znamenalo by to zrýchlenie skórovania snímaného záznamu pre spánkových špecialistov a okamžitý výsledok pre pacienta.


Motiváciou bolo poskytnutie pomocného nástroja lekárom, ktorí majú veľa práce a vedel im ušetriť čas. To by sa samozrejme prejavilo väčším počtom vyšetrených pacientov a teda aj skorším príjmom. Prístroje poväčšine obsahujú automatizačné nástroje, ktoré však nezachytia niektoré prípady alebo nie sú časom aktualizované. Práve toto bolo inšpiráciou pre túto prácu.

Štruktúra práce sa delí na štyri kapitoly, v ktorých sa postupne predstaví základný prehľad spánkových porúch a bližšie sa predstaví poruchy viazané na dýchanie. V druhej kapitole budú opísané metódy vyhodnocovania týchto porúch a snímanie biologických signálov ako parametrov súvisiacich s apnoickou pauzou. Táto kapitola je rozšírená o možné nástroje spracovania týchto signálov. Následne sa opíše praktický prístup k detekcii spánkových udalostí. Bola použitá časť voľne dostupnej databázy *DREAMS Database* autorky Stephanie Devuyst.[25] Oskórovaných bolo dvanásť celonočných polygrafických záznamov. Posledná kapitola predstavuje dosiahnuté výsledky a rozobratie nedostatkov zvoleného postupu, ktoré zapríčinili zníženie výsledkov.

1 Spánkové udalosti

V dnešnej dobe čoraz viac pribúdajú rôzne poruchy spojené so spánkom. Príznaky prechodnej nespavosti postihujú 30-35% globálnej populácie. V Spojených štátoch amerických nemá doporučený 7 hodinový spánok 35% dospelých ľudí a až 69% študentov nemá doporučených 8-10 hodinový spánok. Prevalencia obštrukčného spánkového apnoe bola 22% u mužov a 17% u žien publikovaná v 11 štúdiách medzi rokmi 1993-2013. To však časom ešte stúplo na 37% u mužov a 50% u žien medzi rokmi 2008-2013. Odhaduje sa, že 80% pacientov nie je diagnostikovaných, pritom obštrukčné spánkové apnoe je komorbidita k obezite a cievnej mozgovej príhode. Uvádza sa to na podporu šírenia povedomia o dôležitosti a závažnosti týchto komplikácií. [1, 2]

Spánkové udalosti – Sleep events (SE) sú deje, pri ktorých dochádza k zmene fyziologických hodnôt spánku. Príkladom môže byť chrápanie, desaturácia kyslíka či pohyb nôh. Tieto SE narúšajú kvalitu spánku a tým pádom znižujú aj psychickú pohodu a fyzickú kondíciu cez deň. SE viazané na dýchanie sú hlavne apnoické a hypopnoické pauzy, desaturácia kyslíka a inaktivita dychového úsilia. Dýchanie je jedna zo základných životných funkcií a už po pár minútach jeho absencie môže spôsobiť úmrtie človeka. Niektoré z nich je vidno na obrázku 1.1, ktorý predstavuje spracovávané signály. [3, 4, 5]



Obr. 1.1: Príklad spánkových udalostí v polygrafických signáloch časti 5. záznamu (normálne dýchanie – bez značenia; hypopnoe – oranžová; apnoe – ružová)

1.1 Klasifikácia spánkových porúch

Spánková medicína je novým oborom, kde zatiaľ len čiastočne rozumieme fyziologickým procesom, ktoré sa v tele dejú. Keďže diagnostikovaných porúch a rôznych problémov viazaných na spánok pribúda, bolo žiadúce zaviesť medzinárodné normy. *Americká akadémia spánkovej medicíny – American Academy of Sleep Medicine (AASM)* vydala normu *International Classification of Sleep Disorders – Third Edition, Text Revision*, podľa ktorej sa spánkové poruchy rozdeľujú do 6 kategórií. Práca sa zameriava na poruchy dýchania v spánku, a preto uvádza ich hlbšie členenie [3]:

1. Insomnia – Insomnia Disorders
2. Poruchy dýchania v spánku – Sleep-Related Breathing Disorders
 - Obštrukčné spánkové apnoe dospelých
 - Obštrukčné spánkové apnoe detí
 - Centrálné spánkové apnoe
 - Hypoventilácia viazaná na spánok
 - Hypoxémia viazaná na spánok
 - Izolované varianty (chrápanie, nočný groaning)
3. Centrálna hypersomnia – Central Disorders of Hypersomnolence
4. Poruchy cirkadiálneho rytmu spánok-bdenie – Circadian Rhythm Sleep-Wake Disorders
5. Parasomnie – Parasomnias
6. Poruchy pohybu asociované so spánkom – Sleep-Related Movement Disorders

1.2 Definície pojmov

Apnoe – zástava dýchania zapríčinená prekážkou alebo zúžením dýchacích ciest, poruchou nervového systému na úrovni dychového centra alebo zmiešaním oboch.

Hypopnoe – pokles dýchania zapríčinený prekážkou alebo zúžením dýchacích ciest, poruchou nervového systému na úrovni dychového centra alebo zmiešaním oboch.

Apnoe index (AI) – vyjadruje počet apnoe za hodinu spánku. Nepoužíva sa tak často.

Apnoe/hypopnoe index (AHI) – vyjadruje počet apnoe a hypopnoe za hodinu spánku. Norma u dospelých je pod 5, pri deťoch je pod 1. Používa sa na stanovenie závažnosti poruchy dýchania.

Desaturácia – pokles saturácie krvi kyslíkom minimálne o 3%. Na zmeranie sa používa pulzoxymeter. Najčastejšie sprevádza apnoické alebo hypopnoické pauzy, môže sa však vyskytovať aj u pacientov s hypoventiláciou.

Prebudenie na dýchacie úsilie – Respiratory Effort-Related Arousal (RERA) – respiračná epizóda, ktorá končí prebudením. Nespĺňa podmienky apnoe ani hypopnoe, trvá minimálne 10 sekúnd a je spojená so zvýšeným dychovým úsilím alebo je prítomné zníženie prietoku vzduchu cez nos. Jej skórovanie je dobrovoľné.

Cheyne-Stokesovo dýchanie – séria 3 a viac po sebe nasledujúcich centrálnych apnoických/hypopnoických páuz, medzi ktorými je dychový vzorec s crescendo/decrescendovým tvarom a daný cyklus trvá aspoň 40 sekúnd. [3, 4, 6]

1.3 Poruchy dýchania v spánku


Spánkové apnoe je rozšírená porucha spánku spojená s významnými zdravotnými rizikami. Spánkové apnoe zahŕňa čiastočné alebo úplné zastavenie dýchania, zatiaľ čo hypopnoe je charakterizované abnormálne plytkým dýchaním. Na obrázku 1.2a je uvedený príklad hypopnoe. Tieto poruchy narúšajú normálne spánkové vzorce, čo vedie k roztrieštenému spánku, nadmernej dennej ospalosti a kardiovaskulárnym komplikáciám. [3]

Podľa príčin sa rozdeľuje na:

- *Obštrukčné spánkové apnoe (OSA)*
- *Centrálna spánková apnoe (CSA)*
- *Zmiešané spánkové apnoe*


Príčinou OSA je, ako sám názov napovedá, obštrukcia dýchacích ciest, čiže ich zúženie v spánku. Dôvodom tohto zúženia môže byť prirodzená anatómia horných dýchacích ciest, ich zapchatie alebo utlačenie zväčša tukovými ložiskami na krku alebo hrudi. Sprievodnými znakmi bývajú ronchopatia, ľudovo nazývané chrápanie, opakované zobudzanie, ktoré si niekedy pacient ani neuvedomuje, ezofagálny reflux, nočná polyuria a pocit nevyspatosti. To spôsobuje nadmernú dennú spavosť. V rozvinutom štádiu pacient zaspáva bez predchádzajúcej ospalosti a môže znamenať aj odobratie vodičskej spôsobilosti. Predispozície k OSA sú fajčenie, obezita, hypertenzia a iné kardiologické poruchy. Je zaujímavé, že aj poloha v posteli, vie u niektorých pacientov ovplyvniť, či budú dýchacie cesty priechodné. To popisovala kazuistika, v ktorej na zaistenie polohy pacient použil ruksak, aby mu zabránil spať na chrbáte. [3]

Z fyziologického hľadiska OSA znamená vznik apnoickej pauzy, nepriechodnosť dýchacích ciest a ich spriechodnenie býva obnovené až prebudením a zvýšením svalového tonusu, ktorý býva v spánku znížený. Je to odpoveď mozgu na nedostatočný prísun kyslíka. Taktiež dochádza k zvýšeniu srdečnej a dychovej frekvencie a krvného tlaku. Opakovaná fragmentácia spánku znemožňuje dosiahnuť REM (Rýchly pohyb očí – Rapid eyes movement) štádium, takzvanú fázu hlbokého spánku. Na obrázku 1.2b je uvedený príklad obštrukcie dýchacích ciest. [3]



(a) Hypopnoe

(b) Obštrukčné apnoe




(c) Centrálné apnoe

(d) Zmiešané apnoe

Obr. 1.2: Príklady typov apnoických páuz

Ako bolo spomínané na začiatku tejto podkapitoly, anatómia ústnej dutiny a horných dýchacích ciest môže byť rozhodujúca pri liečbe. Dôležitejšie ako nadváha je rozloženie tuku v krčnej oblasti. Klasický apnoik má široký a krátky krk. Viditeľnosť čapíku, mäkkého podnebia, veľkosť krčných mandlí a koreňa jazyka poukazuje na zníženú priechodnosť. Mallampatiho klasifikácia, ktorá je uvedená na obrázku 1.3, hodnotí priechodnosť podľa pohľadu do ústnej dutiny. V tomto prípade je chirurgický zákrok ďalšou možnosťou liečby. Pred operáciou treba dobre lokalizovať miesto zúženia, pričom platí, že ťažké apnoe s vysokým AHI sa robí viacerými menšími zákrokmi. [3]

Na liečbu OSA sa najčastejšie používa prístroj *Kontinuálny pretlak v dýchacích cestách* – *Continuous positive airway pressure* (CPAP), ktorý má vysokú úspešnosť.



Obr. 1.3: Skórovanie ústnej dutiny podľa Mallampatiho Zdroj: [7]

Pacient si nasadí masku a prístroj CPAP udržuje vyšší tlak. Preto steny dýchacích ciest nekolabujú a zostávajú priechodné. Stojí za zmienku, že OSA a cievna mozgová príhoda majú úzku spoločnú väzbu. Jedno môže viesť k druhému a naopak. Vyššie spomínané kardiologické a angiologické komplikácie len potvrdzujú možnú ischémiu myokardu alebo mozgového tkaniva. Táto skutočnosť ukazuje na priame rizikové faktory OSA a je varovným signálom. [3]

Menej častou variantou je CSA, kde zlyháva dýchací systém už pri svaloch. CSA pramení z nervového systému alebo pri jeho prenose na dychové svalstvo. Príčinou CSA bývajú srdcové zlyhanie, cievna mozgová príhoda, renálna insuficiencia, neurodegeneratívne ochorenia, nervosvalové ochorenia, lieky alebo látky tlmiace dychové centrum v mozgu. Na obrázku 1.2c je uvedený príklad. Odporúča sa diagnostikovať pomocou polysomnografie, a ako liečba je volená adaptabilná servoventilácia v prípade, že nepomáhajú jednoduchšie pretlakové metódy. [4]

Zmiešané spánkové apnoe je kombinácia obštrukčného a centrálného. Na začiatku epizódy sa podobá obštrukčnému, kde je prítomné dychové úsilie, ktoré v druhej časti prechádza postupne do centrálného bez dychového úsilia. Na obrázku 1.2d je uvedený príklad. [4]

2 Diagnostika spánkových porúch

Súčasný prístup k diagnostike SE zahŕňa dotazníky na stanovenie kvality spánku ako aj rizikové faktory k určitým poruchám spánku. *Polysomnografia* (PSG) je zlatý štandard diagnostiky, alebo *Polygrafia* (PG), čo je jej menej náročný variant. Obe však vyžadujú manuálne skórovanie odborníkmi na spánok. Zatiaľ čo PSG poskytuje komplexné údaje, jej robustnosť a náročnosť na finančné zdroje obmedzuje jej rozširovanie. Manuálne skórovanie predstavuje subjektívny pohľad lekára a je časovo náročné. Automatizačné metódy sú preto kľúčové riešenie pre efektívnu a objektívnu diagnostiku SE. Najúspešnejšie z nich využívajú na klasifikáciu strojové učenie. [5, 8]

2.1 Polysomnografia

PSG je prvou voľbou analýzy spánku a diagnostiky. Často sa k nej pridáva aj videozáznam z dôvodu nočných pohybov, polohy tela na lôžku a nočných zvukov. Pozostáva z celonočného záznamu rôznych signálov ako napríklad *Elektroencefalogram* (EEG), *Elektrookulogram* (EOG), *Elektromyogram* (EMG), *Elektrokardiogram* (ECG), *Prietok vzduchu v nosnej dutine – Nasal airflow* (NAF), periférna *Saturácia kyslíka v krvi* (SpO₂), *Dýchacie úsilie hrudného koša s indukčnou pletyzmografiou* (VTH), *Dýchacie úsilie brucha s indukčnou pletyzmografiou* (VAB) a iné. Na obrázku 2.1 je vidieť hlavica na zapájanie snímačov a pacienta, ktorý je k nej pripojený. Jej komplexný pohľad na fyziologické deje počas spánku sa dá využiť na stanovenie všetkých doteraz známych porúch spánku. Vyšetrenie vyžaduje odborníka a špeciálne prístroje, ktoré nie sú mobilné. Pre pacienta, ktorý musí spať v spánkovom laboratóriu a je zapojený do spleti káblov, to vytvára nepohodu. Aj keď pacient súhlasí s vyšetrením, nie každé zdravotnícke zariadenie môže poskytnúť tieto prístroje k diagnostike, pretože sú veľmi drahé. Z týchto dôvodov sú spánkové poruchy bežne prehliadané. [5]

2.2 Polygrafia

PG je snímanie kombinácie respiračných a kardiologických signálov. Jeho výhodou je mobilnosť a nižšia náročnosť ako pri PSG, ktorá bola spomínaná v predchádzajúcej podkapitole 2.1. To umožňuje domáce meranie a komfort v posteli doma. Na druhej strane prichádza o ďalšie signály, ktorými sa vyhodnocujú spánkové štádiá, kvalita spánku alebo pohyby. Podľa AASM sa PG môže použiť v diagnostike OSA ako alternatíva ku PSG vyšetreniu len u pacientov s vysokou pravdepodobnosťou stredne závažného až závažného spánkového apnoe, alebo u pacientov, u ktorých nie je možné



Obr. 2.1: Pacient zapojený do polysomnografického prístroja a hlavica na zapojenie káblov jednotlivých snímačov Zdroj: [4]

realizovať PSG vyšetrenie. Dôvodom môže byť napríklad imobilita pacienta alebo zdravotné ťažkosti. [4, 9]

NAF je jeden z najspoľahlivejších ukazovateľov apnoe, hlavne kvôli jeho normálnemu kolísavému charakteru. Meria sa pomocou termistora, hadičky zavedenej do nosnej dierky alebo masky pokrývajúcej ústa a nos. Termistor registruje zmeny teploty prúdiaceho vzduchu, pričom vdychovaný vzduch je chladnejší ako vydychovaný. Je umiestnený nad hornou perou a pred nosom. Jeho citlivosť však závisí od okolitej teploty v miestnosti a preto zlyháva, ak je teplota v priestore vysoká. Presnosť snímania sa znižuje aj vtedy, ak sa používa súčasne s prístrojom CPAP. Tlakový snímač prietoku vzduchu registruje dýchanie nosom alebo ústami na základe zmeny tlaku medzi vdychovaným a vydychovaným vzduchom. Umiestnenie kanyly je rovnaké ako pri termistore. Podľa kritérií AASM je oronazálny termistor určený na registráciu apnoických páуз a nazálny tlakový snímač na detekciu hypopnoe. V prípade poruchy sú tieto snímače zastupiteľné, preto sa pri PSG zázname používajú súčasne obidva typy senzorov. Počas titračnej noci je parameter prúdenia vzduchu registrovaný tzv. PAP signálom z prístroja CPAP alebo BiPAP. [4]

SpO₂ je fyziologicky oveľa závažnejší jav, pri ktorom sa pacient pri určitej hranici zobudí na to, že nemá dostatočne okysličené telo. Pulzná oxymetria zaznamenáva pulz a saturáciu hemoglobínu kyslíkom pomocou snímača, ktorý sa prichytí na prst nedominantnej ruky. Je potrebná na registráciu desaturácií krvi kyslíkom počas spánku. Využíva červené a infračervené svetlo na zmenu absorpcie určitých vlnových

dĺžok. Hemoglobín s viazaným kyslíkom má rozdielnu absorpciu ako hemoglobín bez kyslíka, čo sa využíva na stanovenie hladiny saturácie. [4]

Respiračné pohyby hrudníka a brucha pomáhajú pri dýchaní. Inspírium je usilovné (človek musí vynaložiť energiu) a prekonať gravitačnú a odporovú silu. Dychové úsilie sa zaznamenáva ezofageálnou manometriou, alebo pomocou hrudného a brušného pásu s indukčnou pletyzmografiou (VAB, VTH). Tá registruje zmeny obvodu pásu počas inspíria a expíria, teda jeho rozpínanie a sťahovanie. [4]

2.3 Súčasné pravidlá klasifikácie

V súčasnosti je spánkové apnoe klasifikované na základe štyroch hlavných signálov a niektorých dodatkových signálov. Hlavnými sú SpO₂, NAF, VTH a VAB. Dodatkovými sú napríklad ECG, EEG, EOG alebo submenálny EMG, ktoré sa tiež podieľajú na presnom stanovení apnoickej pauzy. [3, 4, 6]

Apnoická pauza sa určuje ako zníženie NAF o $\geq 90\%$ a trvajúce ≥ 10 sekúnd. Dá sa určovať aj ako interval ≥ 2 dychových cyklov. Obštrukčné apnoe je zapríčinené zúžením dýchacích ciest alebo prekážok v nich. Pohyby dýchacích svalov pretrvávajú. Centrálné apnoe je zapríčinené poruchou na úrovni dychového centra a pohyby dýchacích svalov úplne vymiznú. Zmiešané apnoe je kombinácia oboch. Začína ako obštrukčné, kde aktivita svalov je badateľná a postupne prechádza do centrálneho, bez pohybu dýchacích svalov. [3, 4, 6]

Hypopnoická pauza sa určuje ako zníženie NAF o $\geq 30\%$ a trvajúce ≥ 10 sekúnd spojené spolu s poklesom SpO₂ o $\geq 3\%$ alebo prebúdajúcou reakciou. Dá sa určovať aj ako interval ≥ 2 dychových cyklov. [3, 4, 6]

Tieto všeobecné pravidlá sú zavádzané kolektívom expertov AASM, ktorí pravidelne usporadúvajú medzinárodné kongresy somnológov. [3, 4, 6]

2.4 Automatizačné nástroje

Existuje veľa rôznorodých prístupov a nástrojov k automatizácii. K jedným z najpopulárnejších nástrojov automatizácie diagnostiky patrí *Strojové učenie – Machine Learning* (ML). V tejto práci sa na detekciu zvolila kontinuálna *Vlnková transformácia – Wavelet Transformation* (WT), ktorá umožňuje spektrálny rozklad, podobne ako Fourierová transformácia, ale nedochádza k strate časovej osi. Na klasifikáciu sa použilo ML. [5, 10, 11]

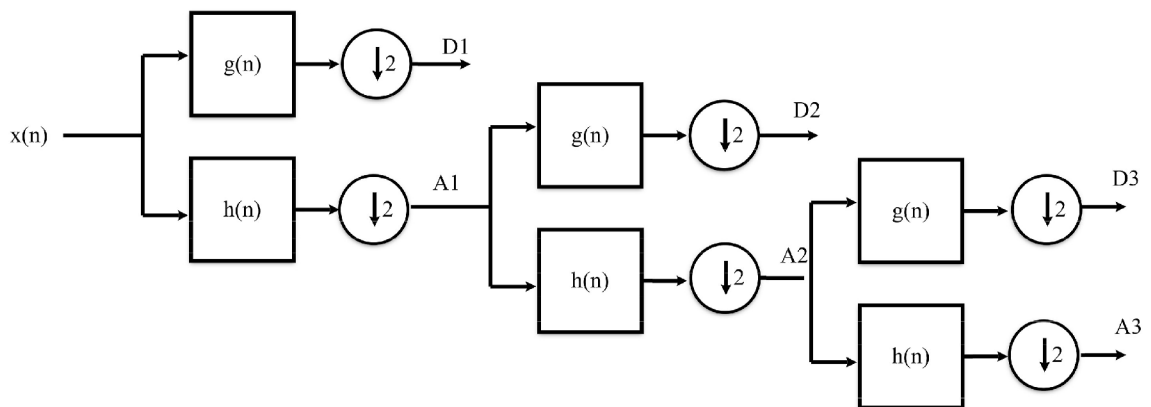
2.4.1 Vlnková transformácia

WT je súbor transformácií so spoločnou črtou, ale líšiacim sa podľa zvoleného okna. Toto okno sa nazýva materskou alebo aj bázovou vlnkou a je definované funkciou:

$$\psi_{\tau,s}(t) = \frac{1}{\sqrt{s}}\psi\left(\frac{t-\tau}{s}\right)$$

kde parameter s rozťahuje alebo zužuje materskú vlnku a parameter τ predstavuje pozíciu na časovej osi. Výhodou je, že umožňuje časovo-frekvenčnú analýzu. [12]


Vznikla ako alternatíva k Fourierovej transformácii, ktorá neumožňuje zachovať časové rozlíšenie. Variantou je spraviť Fourierovú transformáciu s plávajúcim oknom (STFT). Jej rozlíšenie je kompromisom medzi frekvenciou a časom. Lepšie frekvenčné rozlíšenie využíva väčšie okná, ktoré znižuje časovú presnosť a naopak. WT optimálne zachováva aj časovú aj frekvenčnú zložku. Pre nízke frekvencie je okno širšie, pre vysoké užšie, čo znamená lepšie časové rozlíšenie pre vysoké frekvencie a horšie pre nízke. Názorne sa WT dá reprezentovať ako súbor filtrov hornej a dolnej priepuste radených za sebou ako na obrázku 2.2. Postupne sa znižuje časová oblasť a filtruje sa vyššia frekvencia signálu. [13, 14]




Obr. 2.2: Štruktúra vlnkovej transformácie zobrazená pomocou filtrov dolnej a hornej priepuste. Zdroj: [14]

Materská vlnka mení celkový výsledok transformácie na základe jej tvaru. Na obrázku 2.3 sa uvádzajú niektoré z nich. Rickerová vlnka, podľa svojho tvaru často označovaná ako mexický klobúk, (2.3a) vznikla ako druhá derivácia Gaussovej distribúcie pravdepodobnosti (normálne rozdelenie). Morletová vlnka (2.3b) sa vytvorí sínusovým signálom modulovaným normálnym rozložením. Haarová vlnka (2.3c) je zostrojená obdĺžnikovými signálmi a je definovaná po častiach. Z toho vyplýva, že nie je spojitá, čo je jej najväčšia nevýhoda. Vlnka Daubechies (2.3d) predstavuje skupinu vlniek rôzneho rádu $N \geq 1$ pričom $N = 1$ je Haarová vlnka. Výber sa


robí empiricky s ohľadom na dve súvislosti. Komplexné vlnky a vlnky s viacnásobným zvlhnením lepšie zachytávajú oscilácie. Čisto reálne vlnky s málo osciláciami sú vhodnejšie na detekciu špičiek a výrazných zmien v signále. [12, 15]




(a) Rickerová vlnka



(b) Morletová vlnka



(c) Haarová vlnka



(d) Vlnka Daubechies druhého rádu

Obr. 2.3: Príklady typov bázových vlniek

Vlastnosťami WT sú linearita, invariancia k času a k zmene merítka. Linearita znamená, že súčet spektier signálov je rovný spektru súčtu tých istých signálov. Invariancia vzhľadom k času znamená, že spektrum signálu sa po posunutí signálu o daný čas tiež posunie o rovnaký čas. Invariancia vzhľadom na zmenu merítka znamená, že pri dilatácii alebo kontrakcii signálu sa spektrum tiež dilatuje alebo kontrahuje. [13]

WT zachováva celkový tvar signálu nachádzajúci sa v nižších frekvenčných pásmach. Ako sa postupne rozkladá signál na menšie detaily, znižuje sa nám časové okno, čo znamená lepšie rozlíšenie transformácie. Materská vlnka upravuje výstup podľa jej podobnosti so signálom. Súbor všetkých výstupov vytvára analýzu viacnásobným rozkladom (Multiresolution analysis). Názorne je to ukázané v tabulke 2.1. [16]

Tab. 2.1: Multirozklad signálu pomocou vlnkovej transformácie vzhľadom na jeho časové okná a frekvenčné pásma Zdroj: [16]

Úroveň rozkladu	Veľkosť okna	Frekvenčné pásmo
1	1024	1
2	512	2 – 3
3	256	4 – 7
4	128	8 – 15
5	64	16 – 31
6	32	32 – 63
7	16	64 – 127
8	8	128 – 255
9	4	56 – 511
10	2	512 – 1023

2.4.2 Štatistická analýza

Štatistická analýza sú základné charakteristiky signálov definované ako stredná hodnota, energia a výkon signálu. Okrem toho sa pracovalo aj s rozptylom, smerodajnou odchýlkou, minimálnou a maximálnou hodnotou. Stredná hodnota je prostredná hodnota súboru dát, zatiaľ čo energia signálu je suma štvorcov všetkých hodnôt signálu. Výkon signálu je potom energia signálu delená počtom hodnôt. Rozptyl je miera variability hodnôt okolo strednej hodnoty a smerodajná odchýlka je druhá odmocnina z rozptylu. Minimálna a maximálna hodnota sú najmenšia a najväčšia hodnota v súbore dát. Vyhodnocuje sa aj periodicita a korelácia. Periodicita je opakovanie vzorca hodnôt v signále a korelácia je miera vzťahu medzi dvoma signálmi. [17, 18]

Dáta by mali byť v Gaussovskej distribúcii (známe aj ako normálne rozdelenie), čo je rozdelenie pravdepodobnosti, kde hodnoty sú najviac pravdepodobné okolo strednej hodnoty a menej pravdepodobné, ako sa vzdalujú od strednej hodnoty. Odlahlé hodnoty sú hodnoty, ktoré sa výrazne líšia od ostatných hodnôt v súbore dát. Tieto hodnoty môžu výrazne ovplyvniť výsledok analýzy, pretože môžu skresliť priemernú hodnotu a iné štatistické ukazovatele. Preto je dôležité identifikovať a správne zaobchádzať s odlahlými hodnotami pri štatistickej analýze. [19]

Popisná štatistika je kľúčová pri zoznamovaní sa s veľkými dátami. Je to prvý krok v analýze dát, ktorý nám umožňuje zhrnúť a interpretovať informácie v dátovom súbore. Pomocou popisnej štatistiky môžeme získať základné charakteristiky dát, ako sú stredná hodnota, rozptyl, minimálna a maximálna hodnota, a mnoho ďalších. Popisná štatistika je často zobrazovaná pomocou tabuliek alebo grafov. Tabuľky sú

užitočné pre prezentáciu presných hodnôt a umožňujú nám vidieť konkrétne čísla. Avšak, v prípade veľkých dátových súborov môže byť čítanie tabuliek náročné a neefektívne. [17]

Preto sa častejšie používajú grafy. Grafy nám umožňujú vizualizovať dáta a lepšie pochopiť ich distribúciu a vzťahy. Existuje mnoho typov grafov, vrátane stĺpcových, bodových, koláčových a krabicových. Každý typ grafu má svoje výhody a je vhodný pre rôzne typy dát a analýz. Napríklad, histogram je užitočný pre vizualizáciu distribúcie jednej premennej, zatiaľ čo bodový diagram je užitočný pre vizualizáciu vzťahu medzi dvoma premennými. Koláčové grafy sú dobré pre zobrazenie percentuálneho rozdelenia kategórií a krabicové grafy sú užitočné pre zobrazenie rozptylu a odlahlých hodnôt. Popisná štatistika a jej vizualizácia sú neoddeliteľnou súčasťou analýzy veľkých dát a umožňujú nám lepšie pochopiť a interpretovať naše dáta. [18]

2.4.3 Strojové učenie

ML, podobne ako počítačové videnie a expertné systémy, je podmnožinou umelej inteligencie a významným nástrojom na automatizáciu analýzy signálov. Existujú rôzne typy ML, vrátane dozorovaného, nedozorovaného, semi-dozorovaného a posilňovaného učenia. Každý z týchto typov má svoje výhody a nevýhody a je vhodný pre rôzne úlohy a dátové súbory. [20, 21, 22]

Rôzne algoritmy ML, napríklad neurónové siete, rozhodovacie stromy, *Support Vector Machines* (SVM) a *K-Nearest Neighbors* (KNN), sa používajú na analýzu signálov. Pri stavbe modelu je dôležité použiť vhodné príznaky a vlastnosti. Tieto príznaky a vlastnosti môžu byť získané z pôvodných dát alebo môžu byť vytvorené pomocou rôznych techník predspracovania dát. Predspracovanie dát a výber príznakov sú kľúčové aspekty ML. Surové dáta z prístrojov sú často zatažené šumom a nežiadúcimi vplyvmi, a preto je dôležité tieto faktory eliminovať predtým, ako sa dáta použijú na tréning modelu. [20, 21, 23]

Existujú mnohé príklady úspešného použitia ML v analýze signálov. ML sa používa na rozpoznávanie reči, klasifikáciu obrazov, predikciu časových radov a mnoho ďalších aplikácií. Napriek mnohým výhodám automatizácie analýzy signálov pomocou ML existujú aj nevýhody. Napríklad, vyžaduje veľké množstvo dát na tréning a môže obsahovať náročné výpočtové operácie vyžadujúce viac času. Navyše, výsledky ML môžu byť ťažko interpretovateľné. [23]

2.5 Metrika hodnotenia klasifikátorov

Najprv sa uvádza označenie pre všetky možné prípady, ktoré môžu nastať pri porovnávaní dosiahnutých výsledkov so skutočnosťou. *Pravdivo pozitívne* – *True Posi-*

tive (TP) sú prípady, ktoré algoritmus správne identifikoval ako pozitívne. *Falošne pozitívne* – *False Positive* (FP) sú prípady, ktoré algoritmus nesprávne identifikoval ako pozitívne. *Falošne negatívne* – *False Negative* (FN) sú prípady, ktoré algoritmus nesprávne identifikoval ako negatívne. *Pravdivo negatívne* – *True Negative* (TN) sú prípady, ktoré algoritmus správne identifikoval ako negatívne. [24]

Tieto prípady sa zobrazujú v matici zámen, tiež známej ako konfúznej alebo chybovej matici. Obsahuje v riadkoch skutočnú hodnotu predpovedaného znaku a v stĺpcoch výsledok algoritmu, väčšinou predpoveď klasifikátora. Matica zámen je veľmi užitočná pri hodnotení výkonnosti, pretože poskytuje podrobný pohľad na predpoveď každej triedy. Navyše sa z nej vypočítavajú nasledujúce metriky. [24]

Senzitivita, tiež známa ako pokrytie alebo skutočný pozitívny pomer, je metrika, ktorá nám hovorí, koľko pozitívnych prípadov model správne identifikoval. Vypočíta sa ako [24] :

$$\text{Senzitivita} = \frac{TP}{TP + FN}$$

Prediktivita, tiež známa ako presnosť alebo pozitívna predikčná hodnota, je metrika, ktorá nám hovorí, koľko z identifikovaných pozitívnych prípadov bolo skutočne pozitívnych. Vypočíta sa ako:

$$\text{Prediktivita} = \frac{TP}{TP + FP}$$

Selektivita, tiež známa ako špecifita, je metrika, ktorá nám hovorí, koľko z negatívnych prípadov model správne identifikoval ako negatívne. Vypočíta sa ako:

$$\text{Selektivita} = \frac{TN}{TN + FP}$$

F1 skóre je metrika, ktorá kombinuje presnosť a pokrytie do jednej hodnoty. Je to harmonický priemer presnosti a pokrytia a je obzvlášť užitočný, ak máme nevyvážené triedy. F1 skóre sa vypočíta pomocou vzorca:

$$F1\text{skóre} = 2 \cdot \frac{\text{senzitivita} \cdot \text{prediktivita}}{\text{senzitivita} + \text{prediktivita}}$$

3 Softvérové riešenie

Bola použitá databáza DREAMS, ktorá obsahovala polysomnografické dáta s rôznymi poruchami. Vybraná bola len jej časť DREAMS Apnea. Bola voľne dostupná na stránke [25]. Rozdelená bola do troch priečinkov. Nižšie sa uvádza aj tabuľka 3.1 konkrétnych záznamov databázy.

Prvý priečinok obsahoval dáta získané v spánkovom laboratóriu belgickej nemocnice pomocou digitálneho 32-kanálového polygrafu. Pozostávajú z 12 polysomnografických záznamov od pacientov so syndrómom spánkového apnoe. Boli nahrávané dva kanály EOG (P8-A1, P18-A1), tri kanály EEG (CZ-A1 alebo C3-A1, FP1-A1 a O1-A1), submentálny EMG, ECG, NAF, VAB a VTH. Pre ukladanie sa používal štandardný *Európsky dátový formát* (EDF). Vzorkovacia frekvencia bola 200 Hz.

V druhom bolo vizuálne hodnotenie odborníkov SE delené do štyroch kategórií: centrálné, obštrukčné a zmiešané apnoe a hypopnoe. Použité AASM kritériá boli predstavené v podkapitole 2.3. SE definoval čas začiatku a dĺžka. Toto hodnotenie bolo považované ako správne riešenie ktoré by sa malo dosiahnuť.

Tretí priečinok obsahoval hypnogramy, čo je skórovanie v spánkových štádií k každému celonočnému záznamu. Boli použité všeobecne zaužívané kritériá podľa Rechtschaffen a Kalesa. [25, 26]

Tab. 3.1: Obsah databázy DREAMS Apnea, ktorá obsahuje 12 záznamov anotovaných expertmi (H – hypopnoe; OA – obštrukčné apnoe; CA – centrálné apnoe; MA – zmiešané apnoe) Zdroj: [25]


ID	Vek	AHI index	Dĺžka záznamu	Počet			
				H	OA	CA	MA
1	51	50.9/h	09:32:00	249	194	3	6
2	64	16.1/h	08:27:20	47	66	0	1
3	70	49.3/h	09:33:40	38	340	0	0
4	50	95/h	08:36:00	333	389	0	1
5	41	80.9/h	09:22:40	189	350	17	144
6	54	25.1/h	09:12:30	151	66	0	0
7	60	51/h	07:32:00	113	209	1	9
8	50	7.4/h	09:05:20	12	39	0	0
9	54	21.2/h	08:35:20	37	128	0	0
10	51	55.5/h	08:00:00	62	131	69	108
11	51	46.7/h	08:02:40	172	116	1	0
12	51	59.1/h	08:02:00	37	51	43	136

3.1 Návrh riešenia

Načítavali sa iba štyri hlavné signály pre detekciu a klasifikáciu apnoe. Každý záznam bol skrátený z oboch strán o polhodinu. Prvá polhodina približne odpovedala času od spustenia až po zaspanie a polhodina na konci medzi zobudením a vypnutím nahrávania. V týchto častiach by sa nachádzali rôzne artefakty nežiadúce pri hodnotení spánku.

Ako predspracovanie boli použité rôzne filtrácie. Iné úpravy na zlepšenie pomeru signálu k šumu (SNR) už neboli spravené. Signály už boli predspracované v databáze, z ktorej boli sťahované. Na signále NAF snímaného pomocou termistoru, VTH a VAB bol použitý filter hornej priepusti na 0,03 Hz a dolnej priepuste na 10 Hz. Tieto filtre zaistili zachovanie dychových frekvencií v ich rozmedzí a potlačenie ostatných rušení. Podobne signál NAF snímaný cez kanylu bol filtrovaný hornou priepustou na 0.016 Hz a dolnou na 20 Hz, teda sa len zväčšil rozsah frekvencií. Signál SpO2 bol predspracovaný pomocou DC priemerovacieho filtru. Tento typ filtru vyhladzuje skokové zmeny v signále, ktorý zaznamenáva plynulé zmeny. Viac informácií nebolo uvedených v dokumentácii databázy. [25]

Nasledujúci krok je samotná detekcia, ktorá sa delí na vlnkovú transformáciu a prahovanie ako je ukázané na obrázku 3.1.




Obr. 3.1: Blokové schéma algoritmu na detekciu dychových udalostí

Vlnková transformácia ukazuje spektrum frekvencií v čase ako je vidieť z porovnania na obrázku 3.2. Keď je dýchanie často prerušované apnoickou pauzou, tak frekvencia dýchania netvorí súvislú čiaru, ale len krátke úseky.

Dychová frekvencia bola prispôsobená každému pacientovi na mieru, podľa predom počítaného spektra. Zo spektra sa vytiahla dominantná frekvencia, avšak výber bol limitovaný rozmedzím 1,1-0,1 Hz. Transformácia používala Morletovú vlnku škálovanú(dilatovanú) na vybranú frekvenciu, kde vzťah medzi škálovacím merítkom a frekvenciou je naznačený v tabuľke 3.2.

Prah nebol počítaný v skutočnom čase, pretože sa to ani nevyžadovalo. Celý signál však tiež nemohol mať jedno pevne stanovené číslo. Signál naprieč jeho 8 hodinovou dĺžkou nemal stálu amplitúdu, pozri obrázok 3.3, takže pre úseky s nižšou bolo apnoe často falošne detekované, a naopak pri vyššej sa apnoe skrátilo alebo



(a) Normálne dýchanie

(b) Dýchanie s apnoickými pauzami


Obr. 3.2: Spektrogram vlnkovej transformácie s logaritmickým merítkom časti 1. záznamu s viditeľnou dominantnou frekvenciou 0,3 Hz

Tab. 3.2: Vzťah škálovacieho merítka a frekvencie pre Morletovú vlnku a vzorkovaciu frekvenciu 200 Hz. Použitý bol rozsah medzi 0,1-1,1 Hz

Merítka	Frekvencia [Hz]
1	162,500
2	81,250
4	40,625
8	20,313
16	10,156
32	5,078
64	2,539
128	1,270
256	0,635
512	0,317
1024	0,159
2048	0,079

vôbec nedetekovalo. Preto sa prah počítal lokálne v 16 minútovom okne. Čas 16 minút bol zvolený ako kompromis medzi dostatočne dlhým úsekom a výpočtovou náročnosťou.

Samotná detekcia bola zapísaná rovnako ako vizuálne skórovanie odborníkov, teda začiatkom a dĺžkou. Tretí stĺpec je určený na zapísanie predpokladaného typu apnoe pri klasifikácii. Pri hodnotení sa tieto dva zoznamy porovnávajú ako je zobrazené na obrázku 3.4. Tieto príklady ilustrujú rôzne situácie, ktoré pri hodnotení




Obr. 3.3: Adaptívne prahovanie 10. záznamu s 16 minútovým oknom

môžu nastať.

Ľavý horný prípad je správne nájdenie apnoe, ktoré sa prekrýva aspoň z 30% detekcie s referenciou. Takýto prípad označuje správnu detekciu a nájdenú referenciu. V ideálnom prípade by sa pri vyhodnotení vyskytoval len tento prípad.

Pravý horný prípad ilustruje falošnú detekciu, ktorá sa z nedostatočnej časti prekrýva s referenciou. Zároveň referencia je označená ako nezachytená algoritmom. V tomto prípade sa znižuje presnosť kvôli detekcii aj senzitivita vďaka referencii.

Tretí prípad dole ukazuje kombináciu dvoch prípadov hore. Detekcia je správna, lebo prvá referencia je zachytená. Avšak druhá referencia je mimo 30% detekcie. Taktiež treba poznamenať, že pre každú detekciu sa označí práve jedna anotácia, aj keby viac prípadov splňovalo hraničnú podmienku.



Obr. 3.4: Vysvetlenie spôsobu hodnotenia detekcie na príklade (červená – referencia; modrá – detekcia)

3.2 Kód programu

Kód programu bol písaný v prostredí MATLAB R2022b poskytnutý školou. Taktiež sa využívala aj jeho online variant. Väčšina grafov uvedených v práci bolo zostrojených pomocou tohto prostredia.

Bol vytvorený súbor `main.m`, ktorý na začiatku volá funkcie a riadi priebeh celého programu. Na jeho konci je väčšina funkcií až na dve – `detector.m` a `scoring.m`. Tieto funkcie sú zložitejšie a obsiahlejšie, tak sú zapísané vo vlastnom skripte.

3.2.1 Zdrojový kód `main.m`

Najprv sa získal zoznam súborov v priečinku a postupne sa po jednom záznamy prechádzali vo for cykle.

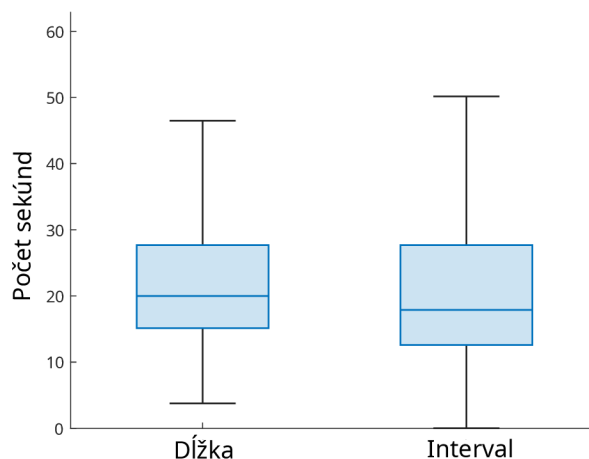
Prvá je volaná funkcia pre prevod `.edf` súboru na dáta, s ktorými sa ďalej pracovalo. Boli to konštanty vzorkovacej frekvencie, dĺžky signálu a veľkosť orezanej časti. Načítané signály boli prietok, saturácia a dýchacie úsilie hrudníka a brucha. Následne sa použila funkcia, aby sa načítali anotácie a uložili sa v zozname. Za tým sú funkcie `detector` a `scoring`, ktoré sú vysvetlené nižšie. Posledná funkcia vo vnútri for cyklu je na zobrazovanie grafov a porovnanie.

Na konci je ešte vypočítanie celkového hodnotenia a jeho vypísanie do príkazového riadku.

3.2.2 Funkcia `detector.m`

Do funkcie vstupuje vektor prietoku z nosa, vektor saturácie krvi kyslíkom, časová os a premenná na zobrazovanie grafov. Výstupom je zoznam udalostí definovaných začiatkom a dĺžkou.

Na úvod sú všetky dôležité premenné. *Velkosť plávajúceho okna* pre adaptívne prahovanie; *Faktor*, ktorým sa znižuje zistené maximum v okne o 90%; *Najkratšia dĺžka apnoe*, ktorá bola odvodená od stanovených kritérií AASM. Aby nevznikali úseky dlhé 3 minúty označené ako apnoe, tak sa stanovila aj *horná hranica dĺžky* na 70 sekúnd. Tá bola určená pomocou analýzy anotovaných apnoe a zisťovania ich dĺžky zobrazenej v krabicovom grafe na obrázku 3.5. Priemerná dĺžka bola 55 a vzhľadom na veľké množstvo odľahlých hodnôt, bolo prihliadnuté aj na výnimočne dlhšie prípady. Najdlhšia mala 113,76 sekúnd a nasledujúcich 13 hodnôt malo medzi 96 a 70. Krabicový graf ukazuje taktiež aj najkratšiu dĺžku apnoe 3,76 sekundy. Je to hodnotenie experta nepodliehajúce striktným podmienkam, pretože nasledujúcich 16 najkratších páuz malo dĺžku medzi 8 a 10 sekundami. Zvyšok bolo dlhších ako 10 sekúnd.



Obr. 3.5: Krabicový graf štatistickej analýzy dĺžky apnoe a intervalu medzi dvoma apnoe

Parametrom je aj *interval po apnoe*, kde sa vôbec nehľadá ďalšie apnoe pre zlepšenie a priblíženie sa realite. Nikto nemá apnoické pauzy tesne za sebou, inak povedané, medzi pauzami je vždy nejaký časový interval, ktorý bol taktiež zobrazený na obrázku 3.5. Spodná hranica je zavádzajúca a ukazuje hodnotu blízku nule, konkrétne interval 0,005 sekundy. To je chyba experta, ktorý pri označovaní jedného apnoe vytvoril dve anotácie tesne vedľa seba. Nasledujúce hodnoty intervalov sú 2,28 sekundy a viac. *Pokles saturácie* o 3% je sprievodný jav apnoickej pauzy, a tak bolo potrebné ho zahrnúť. Hodnota bola tiež uvedená v kritériách pri hypopnoe a taktiež bola konzultovaná s odborníkom. Oneskorený nástup poklesu saturácie je fyziologické prejavenie nedostatočnej výmeny plynov. Preto bolo toto *oneskorenie* nastavené podľa štúdie [27]. *Dĺžka signálu* bola tiež jedným z parametrov.

Na základe spektrogramu 20 minútového úseku zo začiatku signálu sa zistí dominantná frekvencia dýchania pacienta. Podľa nej sa škáluje Morletová vlnka, ktorá transformuje signál prietoku vzduchu nosom z kanyly. Vyhodnotí sa to podľa toho, že daná frekvencia má najvyššiu priemernú hodnotu spomedzi všetkých frekvencií v spektrograme. Niektoré hodnoty škály a ich odpovedajúcej frekvencie sa uvádzajú v tabuľke 3.2. Hodnoty škály sa približne pohybovali medzi 250 – 1350, čo odpovedá frekvenciám medzi 0,12 – 0,63 Hz.

Takto transformovaný signál už sa len prahuje pomocou plávajúceho okna (posúvajúci sa interval signálu) z ktorého sa vyberá maximum a upravuje sa faktorom, aby odpovedal kritériám.

Záverečný krok je prejsť celý signál v dvoch while cykloch, prvý zaisťuje prejedenie celého signálu, a keď signál klesne pod prah, tak podmienka stanoví začiatok

udalosti. Druhý while cyklus hľadá, kde sa signál opäť dostane nad prah. Potom nasledujú podmienky, ktoré ak splní zapíše sa do zoznamu detekovaných udalostí.

3.2.3 Funkcia `scoring.m`

Do funkcie vstupuje zoznam detekovaných udalostí, zoznam anotovaných udalostí a premenná na zobrazovanie grafov. Výstupom je vektor s počtami a metrikami. Druhým výstupom je absolútna chyba AHI.

Prvou časťou funkcie hodnotenia je porovnanie AHI. Odlišnosti boli ukázané pomocou absolútnej hodnoty rozdielu AHI detekcie a anotácie.

Druhá časť funguje tak, že v zozname anotovaných udalostí sa vytvorí stĺpec s jednotkami. Potom sa prechádza zoznam detekovaných udalostí a hľadá sa udalosť označená expertom, ktorá sa s ňou prekrýva aspoň z 30% dĺžky detekovanej udalosti. Ak sa nájde, prirába sa k TP a vo vektore anotácii sa jednotka prepíše na nulu, čo značí, že je nájdená. Ak sa žiadna udalosť označená expertom nenájde, je priradená do FP. Nakonci sa spočíta koľko anotácií nebolo nájdených a pomenuje to ako FN.

Trieda TN predstavuje normálne dýchanie cez noc bez žiadnej spánkovej udalosti, preto sa v kóde vôbec nenachádza a na obrázku 4.1 zostane vždy prázdne políčko. Z týchto hodnôt sa počíta senzitivita, prediktivita a metrika F1.

4 Výsledky

Na zhodnotenie presnosti navrhnutého programu boli zvolené dva spôsoby. Prvým je AHI a druhým sú metriky uvedené v podkapitole 2.5.

Index sa počítal ako počet apnoických a hypopnoických páуз za dobu spánku. Porovnanie bol absolútny rozdiel pôvodného a detekovaného. Najmenšia odchýlka bola 0,24 na 6. zázname a najväčšia bola 17,63 na 12. zázname. Priemerný počet chybných apnoe za hodinu zo všetkých záznamov bol 6,69. Súhrnný prehľad podáva tabuľka 4.1.

Tab. 4.1: Index apnoe/hypopnoe vyjadrujúci priemerný počet apnoických páуз za hodinu

ID	pôvodný	detekovaný	Odchýlka
1	50,16/h	43,48/h	6,68
2	14,35/h	16,36/h	2,01
3	42,40/h	49,99/h	7,59
4	86,58/h	95,26/h	8,68
5	77,59/h	83,32/h	5,73
6	26,19/h	26,44/h	0,24
7	48,06/h	51,43/h	3,37
8	6,18/h	14,22/h	8,04
9	18,84/h	20,82/h	1,98
10	51,00/h	52,43/h	1,43
11	38,04/h	54,93/h	16,89
12	36,54/h	54,17/h	17,63
Priemerná chyba			6,69

Priemerná kvadratická odchýlka (MSE) využívaná na zvýraznenie väčších chýb potlačenie malých. Tu sa uvádza vzorec pre výpočet:

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

kde y_i je skutočné číslo, \hat{y}_i je predpokladané číslo a n je počet všetkých predpokladov.

V tejto práci vyšlo $MSE = 74,38 / h^2$.


Ako druhý pohľad môže slúžiť označenie jednotlivých prípadov ako správne zachytené SE (TP), falošné zachytenie, keď tam SE nebola (FP) alebo nezachytenie SE (FN). Výsledky ukazuje tabuľka 4.2, ktorá na poslednom riadku spočíta prípady zo všetkých záznamov a vypočíta celkové číslo F1. To bolo použité na prevedenie dvoch parametrov, senzitivitu a prediktivitu, na jeden. Senzitivita hovorí o tom,

koľko prípadov apnoe bolo detekovaných zo všetkých reálnych prípadov apnoe. Pozitívna predikčná hodnota naopak hovorí, koľko prípadov apnoe bolo detekovaných správne zo všetkých detekovaných prípadov apnoe.

Tab. 4.2: Skórovanie detekcie cez F1 vypísané pre každý záznam zvlášť (TP – správne detekovaná; FP – falošne detekovaná; FN – nedetekovaná; SEN – senzitivita; PPV – pozitívna predikčná hodnota; F1 – percentuálna úspešnosť)

ID	TP	FP	FN	SEN [%]	PPV [%]	F1 [%]
1	316	55	113	73,66	85,18	79,00
2	61	61	46	57,01	50,00	53,28
3	350	78	23	93,83	81,78	87,39
4	539	185	122	81,54	74,45	77,83
5	619	79	31	95,23	88,68	91,84
6	138	79	78	63,89	63,59	63,74
7	273	63	46	85,58	81,25	83,36
8	14	101	37	27,45	12,17	16,87
9	91	67	52	63,64	57,59	60,47
10	325	42	33	90,78	88,56	89,66
11	210	177	58	78,36	54,26	64,12
12	185	196	72	71,98	48,56	57,99
Celkovo	3121	1183	711	81,45	72,51	76,72

Pre lepšiu predstavu je uvedený obrázok 4.1 s maticami zámen dvoch záznamov, kde obrázok 4.1a mal senzitivitu 95,23%, presnosť 88,68% a metriku F1 91,84% a obrázok 4.1b mal senzitivitu 27,45%, presnosť 12,17% a metriku F1 16,87%.



(a) Najlepší výsledok – 5. záznam

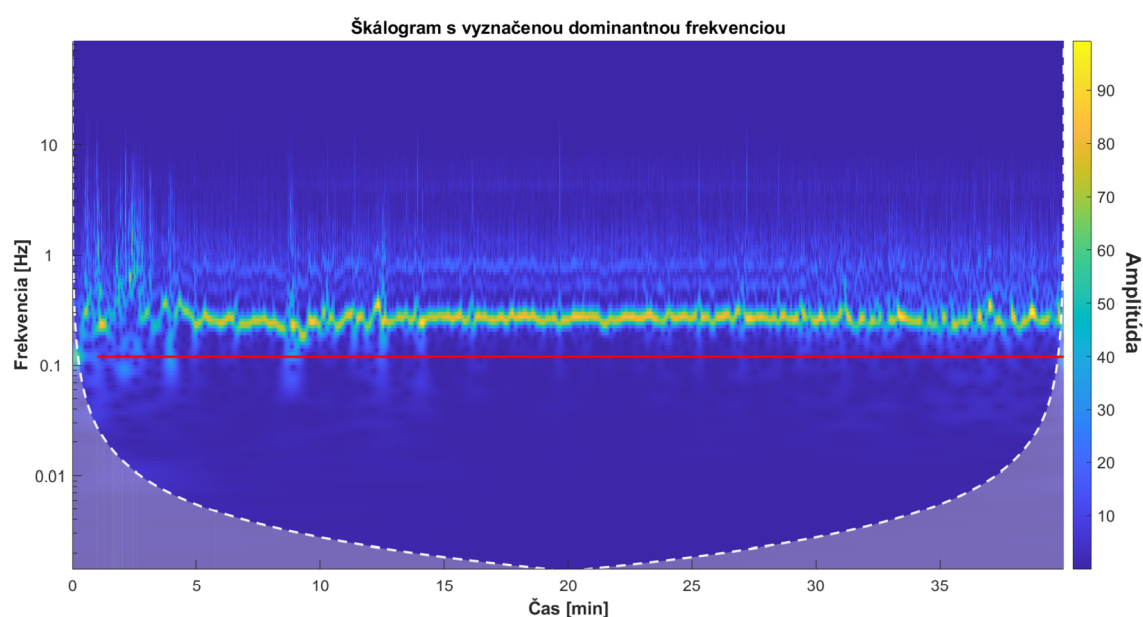
(b) Najhorší výsledok – 8. záznam

Obr. 4.1: Matica zámen detekcie zobrazujúca najvyššiu a najnižšiu úspešnosť

4.1 Diskusia

Výsledky boli obstojné, avšak nedá sa povedať, že by algoritmus patril k najlepším. V literatúre [5, 8, 9, 10] totiž úspešnosť detekcie alebo klasifikácie (kategórie apnoe/hypopnoe alebo centrálné/obštrukčné) dosahovala medzi 75-98%. Navrhnutý algoritmus je použiteľný, ale potrebuje aj dohľad experta. Samotný totiž v niektorých prípadoch zlyháva, ako je vidieť na 8. zázname.


Príčinou je nesprávne vyhodnotenie dychovej frekvencie pacienta a chýb na ňu nadväzujúcich. Ukážkou je obrázok 4.2, ktorý ukazuje nepresné určenie frekvencie. Od nej sa ďalej odvíja nastavovanie prahu a samotné kritéria pre nájdenie apnoickej pauzy. Odhaduje sa, že dôvodom bude šum na nižších frekvenciách, aj keď sa to s istotou tvrdiť nedá.




Obr. 4.2: Nesprávne určenie dychovej frekvencie zobrazené červenou čiarou v spektrograme na časti 8. záznamu

Ďalšia nedokonalosť algoritmu je nastavovanie adaptívneho prahu podľa maxima v danom časovom okne. Pre celkové zvýšenie alebo zníženie amplitúdy v signále toto riešenie poskytovalo spoľahlivé výsledky. Prekážkou však boli lokálne maximá, ktoré zdvíhali prah ako je ukázané na obrázkoch 4.3. Riešením by bolo buď odstránenie týchto špičkových zmien, ich vyhladenie napríklad pomocou mediánového filtru alebo jednoducho zmenšiť časové okno. Nevýhodou posledného riešenia by bola väčšia miera prispôsobenia signálu, a tak zhoršená citlivosť pre hypopnoe.

Spomínané chyby sa prejavajú pri určení apnoe na konkrétnom úseku. Ukážkou môže byť porovnanie na obrázkoch 4.4 s vykreslenou anotáciou a detekciou pod



(a) Zvýšený prah na časti 9. záznamu




(b) Zvýšený prah na časti 8. záznamu

Obr. 4.3: Dve ukážky zvýšených prahov kvôli lokálnym špičkám spôsobujúci falošné apnoe


sebou. Na prvom 4.4a je posunutý prah vyššie, čo spôsobuje častú falošnú detekciu apnoe. Na druhom 4.4b na začiatku je nesprávne detekované normálne dýchanie, ale od polovice sú detekované SE správne až na jeden oveľa dlhší úsek ako v skutočnosti.

Iný návrh hodnotenia by sa dal realizovať aj ako vektor, ktorý udáva či je alebo nie je apnoe. Na základe porovnania takýchto dvoch vektorov detekcie a anotácie by sa zistilo presné percentuálne vyhodnotenie úspešnosti. Tento spôsob hodnotenia bol na začiatku aplikovaný, avšak kvôli strate informácií o počte, dĺžke a type apnoických páuz bolo od tohto prístupu upustené. Taktiež by sa nedal stanoviť AHI.

Zastúpenie v kategóriách správne detekovaných (TP), falošne detekovaných (FP) a nedetekovaných (FN) pre každý záznam osobitne je zobrazené pomocou histogramu na obrázku 4.5. Takto jasne vidieť, že častejšie sa vyskytovala nesprávna detekcia apnoe ako vynechanie jeho reálneho prípadu. Pre zisťovanie, či je pacient apnoik je toto nastavenie lepšie, akoby sa mali prípady častejšie nezachytiť. Aj keď tento postup vyžaduje kontrolu správnosti výsledku, znižuje riziko prehliadnutia ľahšieho apnoika s málo SE.




(a) Porovnanie na časti 8. záznamu



(b) Porovnanie na časti 10. záznamu

Obr. 4.4: Časové a dĺžkové porovnanie detekcie s anotáciou dvoch záznamov



Obr. 4.5: Histogram vyhodnotenia prípadov v jednotlivých záznamom

Záver

Čitateľ bol uvedený do problematiky spánkových porúch a bolo mu ukázané ich rozčlenenie do kategórií. Bol oboznámený s pojmami a definíciami z tejto oblasti. Potom sa predstavili súčasné metódy merania spánkových udalostí, zahrňujúce stručné vysvetlenie fyziológie zachytávania biologických signálov. Spomenuté boli aj oficiálne pravidlá somnológov AASM na stanovenie porúch dýchania v spánku. Taktiež boli opísané nástroje na spracovávanie signálov a automatizáciu detekcie a klasifikácie spánkových udalostí. Dôraz bol kladený na vlnkovú transformáciu ako na zvolené programové riešenie problému.

V praktickej časti bolo ukázané s akými dátami sa pracovalo a akým spôsobom boli predspracované. Spravil sa návrh programu a samotný algoritmus na detekciu spánkového apnoe bol implementovaný v prostredí Matlab¹. Zahŕňal viaceré funkcie, ktoré vykonávali operácie z jednej oblasti, napríklad načítavanie súborov z .edf formátu.

Nakoniec bolo vyhodnotenie výsledkov a ich zobrazenie. Predstavovala sa úspešnosť jednotlivých častí ako aj celkovo dosiahnutá úspešnosť. Práca bola obohatená o tabuľky, obrázky a grafy hlavne z prostredia Matlab.

Dosiahnuté výsledky svedčia o použiteľnom, avšak nie úplne spoľahlivom nástroji na automatizáciu a rýchle vyhodnotenie pre pacienta po celonočnom vyšetrení. Citlivosť na zachytenie spánkovej udalosti celkovo dosiahlo 81,45% a istota, či to je naozaj spánková udalosť vypovedá presnosť, ktorá celkovo dosiahla 72,51%. Každopádne práca tvorí dobrý základ na ďalšie rozvíjanie a testovanie.

Na vytvorenie logickej kostry práce alebo kódu funkcie bol použitý nástroj generatívnej umelej inteligencie [28]. Využitá tiež bola na návrhy riešení menších úloh, ako napríklad zostrojenie grafu.

Nakoniec by sa žiadalo poznamenať, akým smerom sa práca môže rozširovať ďalej. Keďže výsledky nie sú optimálne, dalo by sa porozmýšľať nad zdokonalením programového riešenia alebo vyskúšať iný, celkom nový, prístup. Navrhuje sa odladiť hľadanie dominantnej frekvencie dychu pacienta. Druhá pridaná funkcia by mohla slúžiť na odránenie alebo zníženie lokálnych maxím, ktoré narúšajú správnosť prahovania. Taktiež vytvorením priateľského užívateľského prostredia by sa spríjemnila práca spánkových expertov, ktorí sa pravidelne stretávajú s množstvom rôznorodých dát. Ich prehľadnosť a zrozumiteľnosť je kľúčová na pochopenie a stanovenie diagnóz. Vhodným rozšírením by mohlo byť aj zakomponovanie ďalšej skupiny spánkových porúch.

¹<https://www.mathworks.com/products/matlab.html>

Literatúra

- [1] CHAMBERS, Tom; BAMBER, Harry a SINGH, Nanak. *Perioperative management of Obstructive Sleep Apnoea: Present themes and future directions*. Online. *Current Opinion in Pulmonary Medicine*. 2023, roč. 29, č. 6, s. 557-566. ISSN 1070-5287. Dostupné z: <https://doi.org/10.1097/MCP.0000000000001012>. [cit. 2024-05-27].
- [2] FRANKLIN, Karl A. a LINDBERG, Eva. *Obstructive sleep apnea is a common disorder in the population-a review on the epidemiology of sleep apnea*. Online. *Journal of Thoracic Disease*. Aug 2015, roč. 7, č. 8, s. 1311–1322. Dostupné z: <https://doi.org/10.3978/j.issn.2072-1439.2015.06.11>. [cit. 2024-05-27].
- [3] PŘÍHODOVÁ, Iva a DOSTÁLOVÁ, Simona. *Spánková medicína v kazuistikách*. 2., přepracované a doplněné vydání. *Medicína* (EEZY Publishing). Praha: EEZY, 2023. ISBN 978-80-88506-01-0.
- [4] KLOBUČNÍKOVÁ, Katarína. *Základy fyziologie a porúch spánku*. Online. 1. Univerzita Komenského v Bratislave, Lekárska fakulta: Univerzita Komenského v Bratislave vo Vydavateľstve UK, 2021. ISBN 978-80-223-5338-0. Dostupné z: https://www.fmed.uniba.sk/fileadmin/lf/sluzby/akademicka_kniznica/PDF/Elektronicke_knihy_LF_UK/Klobucnikova._Zaklady_fyziologie_a_poruch_spanku_2021.pdf. [cit. 2023-12-30].
- [5] LAZAZZERA, Remo; DEVIAENE, Margot; VARON, Carolina; BUYSE, Bertien; TESTELMANS, Dries et al. *Detection and Classification of Sleep Apnea and Hypopnea Using PPG and SpO₂ Signals*. Online. *IEEE Transactions on Biomedical Engineering*. 2021, vol. 68, no. 5, s. 1496-1506. ISSN 1558-2531. Dostupné z: <https://doi.org/10.1109/TBME.2020.3028041>. [cit. 2023-12-30].
- [6] *Unlock the secrets of sleep: a physician-s introduction to the field of sleep medicine*. Online. 1. Darien: American Academy of Sleep Medicine, 2016. Dostupné z: https://aasm.org/wp-content/uploads/2018/07/AASM_ChooseSleep_UnlocktheSecrets_16_rebrand.pdf. [cit. 2023-12-30].
- [7] MARCH I NOGUÉ, Jordi. *Mallampati score*. Online. In: Wikipedia. 2011. Dostupné z: <https://upload.wikimedia.org/wikipedia/commons/0/09/Mallampati.svg>. [cit. 2024-05-27].
- [8] SÁNCHEZ-MORILLO, Daniel; L-PEZ-GORDO, Miguel Angel a LE-N, Antonio. *Novel multiclass classification for home-based diagnosis of sleep apnea*

- hypopnea syndrome*. Online. Expert Systems with Applications. 2014, vol. 41, no. 4, Part 2, s. 1654-1662. ISSN 0957-4174. Dostupné z: <https://doi.org/10.1016/j.eswa.2013.08.062>. [cit. 2023-12-30].
- [9] SOMMERMEYER, Dirk; ZOU, Ding; GROTE, Ludger a HEDNER, Jan. *Detection of Sleep Disordered Breathing and Its Central/Obstructive Character Using Nasal Cannula and Finger Pulse Oximeter*. Online. Journal of Clinical Sleep Medicine. 2012, vol. 08, no. 05, s. 527-533. Dostupné z: <https://doi.org/10.5664/jcsm.2148>. [cit. 2023-12-30].
- [10] KANG, Chang-Hoon; ERDENEBAJAR, Urtnasan; PARK, Jong-Uk a LEE, Kyoung-Joung. *Multi-Class Classification of Sleep Apnea/Hypopnea Events Based on Long Short-Term Memory Using a Photoplethysmography Signal*. Online. Journal of Medical Systems. 2020, vol. 44, no. 1, s. 14. ISSN 1573-689X. Dostupné z: <https://doi.org/10.1007/s10916-019-1485-0>. [cit. 2023-12-30].
- [11] GLEASON, Kevin; SHIN, Donghoon; RUESCHMAN, Michael; WEINSTOCK, Tanya; WANG, Rui et al. *Challenges in recruitment to a randomized controlled study of cardiovascular disease reduction in sleep apnea: an analysis of alternative strategies*. Online. Sleep. 2014, vol. 37, no. 12, s. 2035-2038. Dostupné z: <https://doi.org/10.5665/sleep.4266>. [cit. 2023-12-29].
- [12] JAN, Jiří. *Číslíková filtrace, analýza a restaurace signálů*. Vyd. 2., rozš. a dopl. Brno: VUTIUM, 2002. ISBN 80-214-2911-9.
- [13] VALTER, Boris a . *Vlnková transformace*. Online, Bakalářská práce, vedoucí Hlávka, Zdeněk. Praha: Univerzita Karlova, Matematicko-fyzikální fakulta, Katedra pravděpodobnosti a matematické statistiky, 2016. Dostupné z: <http://hdl.handle.net/20.500.11956/81479>.
- [14] RAJESH, Kandala.N.V.P.S.; DHULI, Ravindra a KUMAR, T. Sunil. *Obstructive sleep apnea detection using discrete wavelet transform-based statistical features*. Online. Computers in Biology and Medicine. 2021, roč. 130, s. 104199. ISSN 0010-4825. Dostupné z: <https://doi.org/https://doi.org/10.1016/j.combiomed.2020.104199>. [cit. 2024-05-14].
- [15] VYSOKÉ UČENÍ TECHNICKÉ FEKT. *Vlnkové transformace (Wavelet transform)*. Online. Vlnkové transformace (Wavelet transform). 2020. Dostupné z: https://www.uamt.fekt.vut.cz/~richter/vyuka/0910_mпов/tmp/integral_tr_wavelety.html. [cit. 2024-05-14].

- [16] ZHANG, Dengsheng. Wavelet Transform. In: *Fundamentals of Image Data Mining*. Online. 1. Springer International Publishing, 2019, s. 35-44. ISBN 978-3-030-17989-2. Dostupné z: https://doi.org/10.1007/978-3-030-17989-2_3. [cit. 2023-12-25].
- [17] KUNDU, Debasis. Statistical Signal Processing. In: *International Encyclopedia of Statistical Science*. Online. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011, s. 1466-1468. ISBN 978-3-642-04898-2. Dostupné z: https://doi.org/10.1007/978-3-642-04898-2_552. [cit. 2024-05-18].
- [18] ALESSIO, Silvia Maria. Statistical Approach to Signal Analysis. In: *International Encyclopedia of Statistical Science*. Online. Cham: Springer International Publishing, 2016, s. 371-401. ISBN 978-3-319-25468-5. Dostupné z: https://doi.org/10.1007/978-3-319-25468-5_9. [cit. 2024-05-18].
- [19] GRAY, Robert M. a DAVISSON, Lee D. *An Introduction to Statistical Signal Processing*. Online. Stanford University and University of Maryland. Cambridge University Press, 2004. Dostupné z: <https://ee.stanford.edu/~gray/sp.pdf>. [cit. 2024-05-18].
- [20] JORDAN, M. I. a MITCHELL, T. M. *Machine learning: Trends, perspectives, and prospects: Trends, perspectives, and prospects*. Online. Science. 2015, vol. 349, no. 6245, s. 255-260. Dostupné z: <https://doi.org/10.1126/science.aaa8415>. [cit. 2023-12-30].
- [21] SARKER, Iqbal H. *Machine Learning: Algorithms, Real-World Applications and Research Directions*. Online. SN Computer Science. 2021, roč. 2, č. 3, s. 160. ISSN 2661-8907. Dostupné z: <https://doi.org/10.1007/s42979-021-00592-x>. [cit. 2024-05-19].
- [22] ALIM, A. a ISLAM, M. K. *Application of Machine Learning on ECG Signal Classification Using Morphological Features*. In: 2020 IEEE Region 10 Symposium (TENSYP). 2020, s. 1632-1635. ISSN 2642-6102. Dostupné z: <https://doi.org/10.1109/TENSYP50017.2020.9230780>.
- [23] KOTSIANTIS, S. B.; ZAHARAKIS, I. D. a PINTELAS, P. E. *Machine learning: a review of classification and combining techniques*. Online. Artificial Intelligence Review. 2006, roč. 26, č. 3, s. 159-190. ISSN 1573-7462. Dostupné z: <https://doi.org/10.1007/s10462-007-9052-3>. [cit. 2024-05-19].
- [24] VESELOVSKÝ, Martin. *Získávání znalostí pro modelování následných akcí*. Online, Diplomová práce, vedúci Bartík Vladimír. Brno: Vysoké učení technické

- v Brně, Fakulta informačních technologií, 2017. Dostupné z: https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=159547.
- [25] DEVUYST, Stephanie; DUTOIT, Thierry a KERKHOFS, Myriam. *The DREAMS Databases and Assessment Algorithm*. Dataset. 1. Zenodo, 2005. Dostupné z: <https://zenodo.org/records/2650142>. [cit. 2023-12-29].
- [26] SILBER, Michael H.; ANCOLI-ISRAEL, Sonia; BONNET, Michael H.; CHOKROVERTY, Sudhansu; GRIGG-DAMBERGER, Madeleine M. et al. *The Visual Scoring of Sleep in Adults*. Online. Journal of Clinical Sleep Medicine. 2007, roč. 03, č. 02, s. 121-131. Dostupné z: <https://doi.org/10.5664/jcsm.26814>. [cit. 2024-05-27].
- [27] LI, Geng; ZHOU, Mengwei; HUANG, Xiaoqing; JI, Changjin; FAN, Tingting et al. *Time delays between physiological signals in interpreting the body's responses to intermittent hypoxia in obstructive sleep apnea*. Online. Physiological Measurement. 2024, roč. 45, č. 5, s. 055008. ISSN 0967-3334. Dostupné z: <https://doi.org/10.1088/1361-6579/ad45ac>. [cit. 2024-07-25].
- [28] OpenAI (2024). *ChatGPT-3.5 version*. [Large language model]. <https://chat.openai.com>. [cit. 2024-05-28]

Zoznam symbolov a skratiek

SE	Spánkové udalosti – Sleep events
AASM	Americká akadémia spánkovej medicíny – American Academy of Sleep Medicine
AI	Apnoe index
AHI	Apnoe/hypopnoe index
RERA	Prebudenie na dýchacie úsilie – Respiratory Effort-Related Arousal
OSA	Obštrukčné spánkové apnoe
CPAP	Kontinuálny pretlak v dýchacích cestách – Continuous positive airway pressure
CSA	Centrálne spánkové apnoe
PSG	Polysomnografia
PG	Polygrafia
EEG	Elektroencefalogram
EOG	Elektrookulogram
EMG	Elektromyogram
ECG	Elektrokardiogram
NAF	Prietok vzduchu v nosnej dutine – Nasal airflow
SpO2	Saturácia kyslíka v krvi
VTH	Dýchacie úsilie hrudného koša s indukčnou pletyzmografiou
VAB	Dýchacie úsilie brucha s indukčnou pletyzmografiou
ML	Strojové učenie – Machine Learning
WT	Vlnková transformácia – Wavelet Transformation
SVM	Support Vector Machines
KNN	K-Nearest Neighbors
TP	Pravdivo pozitívne – True Positive

FP	Falošne pozitívne – False Positive
FN	Falošne negatívne – False Negative
TN	Pravdivo negatívne – True Negative
EDF	Európsky dátový formát

A Obsah elektronickej prílohy

Obsahom sú kódy, funkcie a upravená databáza na overenie funkčnosti algoritmu. Celá sa kvôli veľkosti nezmestila do príloh. Kódy boli napísané v programe Matlab verzii R2022b. Na spustenie je určený len `main.m`, ostatné súbory sú funkcie alebo pomocné kódy na vygenerovanie priložených súborov. Pre výpis adresárovej štruktúry bol použitý balíček `dirtree`.

```
/.....koreňový priečinok priloženého súboru
├── databáza.....priečinok s upravenými dátami pre tento algoritmus
│   ├── dáta.....upravený signál vo formáte EDF
│   │   └── excerpt10.edf
│   └── anotácie.....upravená anotácia vo formáte TXT
│       └── Annotation_excerpt10.txt
└── matlab.....kódy, funkcie a pomocné súbory
    ├── classifier.m
    ├── detector.m
    ├── main.m
    ├── one_run.m
    ├── scoring.m
    ├── trainClassifierKNN.m
    ├── features_train.csv
    └── norm_features_train.csv
```