

# Zpracování signálů z optovláknových mřížkových senzorů pro monitorování dechové aktivity

Processing of Signals from Fiber-Optic Bragg Grating Sensors for Respiratory Activity Monitoring

Martin Lajdolf

Bakalářská práce

Vedoucí práce: Ing. René Jaroš, Ph.D.

2022

## Zadání bakalářské práce

Student: **Martin Lajdolf**

Studijní program: B0714A060016 Biomedicínská technika

Téma: Zpracování signálů z optovláknových mřížkových senzorů pro monitorování dechové aktivity  
Processing of Signals from Fiber-Optic Bragg Grating Sensors for Respiratory Activity Monitoring

Jazyk vypracování: čeština

Zásady pro vypracování:

Zásady pro vypracování:

Bakalářská práce se zaměřuje na prostudování možnosti využití optovláknových mřížkových (FBG) senzorů v biomedicínských aplikacích. Student provede praktická měření dechové aktivity pomocí FBG senzoru. V dalším kroku bude náplní studenta vytvořit SW aplikaci, která bude schopna zpracovat a analyzovat dechovou aktivitu z mřížkových senzorů. Pro realizaci bude využito vývojové prostředí MATLAB nebo LabVIEW.

Body zadání práce:

1. Popište základní principy šíření světla v optických vláknech, optická vlákna a princip funkce Braggovské mřížky. Dále popište možnosti monitorování dechové aktivity v klinické praxi.
2. Prostudujte a vyberte různé metody extrakce požadovaného signálu pro následnou analýzu.
3. Navržení a realizace SW aplikace pro zobrazení, úpravu a analýzu signálu naměřeného pomocí mřížkových senzorů ve vývojovém prostředí MATLAB nebo LabVIEW.
4. Ověření funkcionality SW aplikace pomocí vhodné metodiky a analýza výsledků.
5. Provedení diskuse dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] Krohn, D. A., MacDougall, T., & Mendez, A. (2014). Fiber optic sensors: fundamentals and applications. Bellingham, Washington, USA: Spie Press.
- [2] López-Higuera, J. M. (Ed.). (2002). Handbook of optical fibre sensing technology. Wiley.
- [3] Kotturu, V. M., & Komalla, A. R. (2016) Signal Processing Methods for Extraction of Respiratory Activity. ISBN 978-3-659-95305-7.
- [4] Sprager, S., Donlagic, D., & Zazula, D. (2011, December). Estimation of heart rate, respiratory rate and motion by using optical interferometer as body sensor. In Proceedings of the IASTED International Conference on Signal and Image Processing (pp. 280-287).

Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí bakalářské práce: **Ing. René Jaroš, Ph.D.**

Datum zadání:

Datum odevzdání:

---

prof. Ing. Jiří Koziorek, Ph.D.  
*vedoucí katedry*

---

prof. Ing. Jan Platoš, Ph.D.  
*děkan fakulty*

## **Abstrakt**

Tato práce se zabývá zpracováním signálů získaných z vyvíjeného senzoru složeného z optického vlákna s implementovanou braggovskou mřížkou. Ke zpracování byly použity 3 metody pokročilého zpracování dat. Jedná se o empirickou modální dekompozici, Savitzky-Golay filtr a metodu založenou na vlnkové transformaci. Použití metod ke zpracování signálů hraje zásadní roli v následné analýze signálů, při které jsou extrahovány časové pozice zaznamenaných nádechů. Výsledné hodnoty jsou následně porovnávány s referenčními hodnotami, jež byly získány extrakcí časových hodnot nádechů z referenčního signálu naměřeného hrudním pásem využívajícího piezoelektrický senzor. Cílem práce je posoudit, jestli vyvíjený optovláknový senzor dosahuje v porovnání s referenčním měřidlem dostatečných výsledků a porovnat mezi sebou použité metody pokročilého zpracování signálů. Výsledné algoritmy pro zpracování a analýzu signálů a následné hodnocení výsledků jsou implementovány do uživatelské aplikace, která zajišťuje uživatelsky přehledné a intuitivní prostředí, ve kterém je uživatel schopen jednoduše měnit důležité parametry, na kterých závisí funkce jednotlivých metod. Nejeftivnější metodou pro zpracovávání signálů byl v tomto případě Savitzky Golay filtr, který dosahoval nejlepších průměrných výsledků přesnosti.

## **Klíčová slova**

dechová aktivita, optovláknový senzor, empirická modální dekompozice, Savitzky-Golay filtr, vlnková transformace

## **Abstract**

This thesis deals with the processing of signals obtained from the developed sensor composed of optical fiber with implemented Bragg grating. 3 methods of advanced data processing were used for processing. These are the empirical modal decomposition, the Savitzky-Golay filter and the wavelet transform method. The use of signal processing methods plays a crucial role in the subsequent signal analysis, in which the time positions of the recorded breaths are extracted. The resulting values are then compared with reference values obtained by extracting breath time values from a reference signal measured by the chest band using a piezoelectric sensor. The aim of this work is to assess whether the developed fiber optic sensor achieves sufficient results in comparison with the reference meter and to compare the methods of advanced signal processing. The resulting algorithms for signal processing, analysis and subsequent evaluation of results are implemented in a user application that provides a user-friendly and intuitive environment in which the user is able to easily change important parameters on which the functions of individual methods depend. The most efficient method for signal processing in this case was the Savitzky Golay filter, which achieved the best average accuracy results.

## **Key words**

breath activity, fiber optic sensor, empirical, mode decomposition, Savitzky-Golay filter, wavelet transform

## **Poděkování**

Chtěl bych poděkovat vedoucímu mé bakalářské práce, panu Ing. Renému Jarošovi, Ph.D., se kterým jsem konzultoval postup této bakalářské práce. Dále bych chtěl poděkovat panu Ing. Michalu Kostelánskému, který propůjčil optovláknový senzor, díky kterému bylo možné provést sérii měření

# Obsah

Seznam použitých zkratek .....	8
Seznam obrázků.....	9
Úvod.....	11
1 Technologie optických vláken a snímání dechové aktivity.....	12
1.1 Šíření světla v optických vláknech.....	12
1.1.1 Index lomu .....	12
1.1.2 Odraz a lom světla .....	13
1.1.3 Úplný odraz světla .....	13
1.2 Optická vlákna a jejich základní parametry .....	14
1.2.1 Útlum optického vlákna.....	14
1.2.2 Numerická apertura.....	14
1.2.3 Přenosová kapacita.....	14
1.3 Braggovská mřížka.....	14
1.4 Optovláknové senzory .....	15
1.5 Monitorování dechové aktivity v klinické praxi .....	16
1.5.1 Pneumotachograf .....	16
1.5.2 Elektrokardiograf (EKG) .....	17
1.5.3 Kapnograf.....	17
1.5.4 Teplotní senzory .....	17
1.5.5 Odporové snímače.....	18
1.5.6 Piezoeletrický snímač .....	18
2 Možnosti zpracovávání signálu dechové aktivity.....	19
2.1 Filtrace signálu .....	19
2.1.1 Základní selektivní filtry .....	20
2.1.2 Wienerův vlnkový filtr .....	21
2.2 Adaptivní metody.....	21
2.3 Fourierova transformace (FT) .....	22
2.4 Vlnková transformace (WT) .....	23
2.5 Empirická modální dekompozice (EMD).....	24
2.6 Shrnutí metod zpracování signálu.....	26
3 Dataset .....	27
3.1 Předzpracování signálů.....	28
3.2 Extrakce referenčních hodnot nádechů .....	30
4 Algoritmy .....	31

4.1 Použité metody pokročilého zpracování signálů .....	31
4.1.1 Empirická modální dekompozice (EMD) .....	31
4.1.2 Savitzky-Golay filtr (SG) .....	33
4.1.3 Vlnková transformace (WT) .....	34
4.2 Kombinace metod .....	36
4.3 Algoritmus detekce nádechů a výdechů.....	38
4.4 Algoritmus hodnocení výsledků.....	41
5 Softwarová aplikace .....	43
6 Výsledky.....	46
7 Diskuse .....	55
Závěr .....	58
Literatura.....	60
Přílohy .....	65

## Seznam použitých zkratk

EKG	Elektrokardiogram
EEG	Elektroencefalogram
PPG	Fotopletysmograf
EIT	Elektrická impedanční tomografie
CO <sub>2</sub>	Oxid uhličitý
FIR	Finite impulse response filtry
IIR	Infinite impulse response filtry
SG	Savitzky-Golay filtr
LMS	Last mean square
RLS	Recursive mean square
ANFIS	Adaptive neuro-fuzzy interface system
FT	Fourierova transformace
DFT	Diskrétní Fourierova transformace
FFT	Rychlá Fourierova transformace
STFT	Krátkodobá Fourierova transformace
WT	Vlnková transformace
HT	Hilbertova transformace
EMD	Empirická modální dekompozice
EEMD	Ensemble Empirical Mode Decomposition
CEEMDAN	Complete Ensemble Empirical Mode Decomposition
FBG	Optovláknový mřížkový senzor



## Seznam obrázků

Obr.1: Struktura optického vlákna.....	12
Obr.2: Znázornění lomu ke kolmici a lomu od kolmice.....	13
Obr.3: Braggova mřížka v optickém vlákně (upraveno) [8].....	15
Obr.4: Schéma pneumotachografu s rozdílovým manometrem [12].....	16
Obr.5: Přibližný průběh kapnogramu.....	17
Obr.6: Průběh měření. ....	27
Obr.7: Optovláknový senzor.....	27
Obr.8: Hrudní pás pneumotrace II. ....	28
Obr.9: Použití FIR filtru na signálu z optovláknového senzoru. ....	29
Obr.10: Porovnání frekvenčních spekter referenčního signálu před a po filtraci. ....	29
Obr.11: Rozložení signálu na IMF pomocí EMD.....	32
Obr.12: Zobrazení 4 typů vlnek. ....	35
Obr.13: Porovnání aplikace jednotlivých metod na signálu apnoe. ....	36
Obr.14: Porovnání aplikace EMD, WT a jejich kombinace metod na signálu klidové vleže.....	37
Obr.15: Grafické znázornění detekce nádechů. ....	39
Obr.16: Vývojový diagram detektoru nádechů. ....	40
Obr.17: Načtení signálu v softwarové aplikaci. ....	43
Obr.18: Náhled záložky předzpracování signálu v aplikaci.....	44
Obr.19: Náhled záložky nastavení jednotlivých metod pokročilého zpracování signálu. ....	45
Obr.20: Náhled pododdílu hodnocení výsledků. ....	45
Obr.21: Znázornění schopnosti WT srovnat amplitudy v signálu apnoe. ....	56

## Seznam tabulek

Tabulka 1: Shrnutí metod zpracování signálů. ....	26
Tabulka 2: Přesnost jednotlivých metod.....	46
Tabulka 3: Senzitivita jednotlivých metod. ....	47
Tabulka 4: Pozitivní prediktivní hodnota jednotlivých metod.4.....	48
Tabulka 5: Hodnota harmonického průměru mezi SE a PPV jednotlivých metod.....	49
Tabulka 6: Přesnost pro kombinace metod. ....	50
Tabulka 7: Senzitivita pro kombinace metod. ....	51
Tabulka 8: Pozitivní prediktivní hodnota pro kombinace metod. ....	52
Tabulka 9: Hodnota harmonického průměru mezi SE a PPV pro kombinace metod. ....	53
Tabulka 10: Porovnání průměrných hodnot přesnosti mezi globálním nastavením a nastavením pro individuální signály.....	54

# Úvod

Snímání dechové aktivity je považováno v klinické praxi za velmi důležitý údaj, na základě kterého lze u pacienta diagnostikovat různé problémy, přičemž některé z nich mohou být život ohrožující. Mezi velmi vážné patologické jevy patří například apnoe, jenž představuje zástavu dechu, která nastává při spánku a představuje jisté riziko udušení pacienta. K monitoringu dechové aktivity v klinické praxi slouží 2 typy systémů. Prvním systémem je nepřímá metoda snímání dechu, u které je dechová aktivita až sekundárním parametrem, což znamená, že je odvozována z jiného signálu. Příkladem je například elektrokardiogram. Druhým typem monitoringu dechu je přímé snímání dechové aktivity, které využívá senzory primárně vyvinuté k tomuto účelu. Mezi tyto senzory lze zařadit například termistory situované na nosní kyslíkové cévce, nebo senzory instalované do hrudních pásů. Tyto hrudní pásy mohou obsahovat buď odporový senzor, jehož odpor se v závislosti na roztažnosti hrudníku mění a nebo piezoelektrické senzory, které při těchto pohybech generují elektrické napětí. Optický senzor představuje zajímavou alternativu k používaným sensorům, poněvadž je poměrně cenově nenáročný a přináší mnoho způsobů využití, které se v poslední době pomalu dostávají i do několika odvětví medicínských věd.

Teoretická část této bakalářské práce je zaměřena na popis fyzikálních zákonů spojených se šířením světla v optickém vlákne, teoretickým rozborem a základním principem optovláknového mřížkového senzoru, metodami monitoringu dechové aktivity a v závěru teoretické části také teoretickým rozborem a popisem metod, které je možné použít jak k základnímu předzpracování signálů, tak i pokročilejších metod, které lze uplatnit k propracovanějšímu zpracování signálů.


Cílem praktické části je využít několik algoritmů, pomocí kterých lze provést základní a pokročilé předzpracování dat, extrahovat z referenčních signálů hodnoty referenčních nádechů k závěrečnému hodnocení hodnot získaných z algoritmu detektoru, který slouží k analýze dat získaných optovláknovým senzorem. Všechny tyto algoritmy jsou následně použity v softwarové aplikaci, pomocí které lze intuitivně provést výše zmíněné úpravy signálů, jejich analýzu a hodnocení.

# 1 Technologie optických vláken a snímání dechové aktivity

Objev optického vlákna způsobil revoluci nejen v telekomunikační technice. Do této doby bylo k přenosu dat využíváno (kromě rádiového transferu) klasických metalických vedení, ve kterých byla informace přenášena pomocí toku volných elektronů. Nevýhod metalického vedení signálu lze nalézt mnoho. Mezi hlavní lze zařadit vysoké riziko vzniku šumu při nekvalitním odstínění a nižší přenosovou rychlost. Ovšem stále je toto médium hojně využíváno díky nižší pořizovací ceně. Naopak obrovskou výhodou je značně nižší náchylnost na mechanické poškození, které je u optických kabelů velkým problémem [1] [2] [3] [4].

## 1.1 Šíření světla v optických vláknech

Konstrukce optického vlákna je rozdělena na dvě hlavní části – jádro a plášť viz Obr.1:. Těmito částmi je vytvořeno rozhraní dvou optických prostředí (opticky hustší prostředí s vyšším indexem lomu – jádro a opticky řidší prostředí s nižším indexem lomu–plášť), díky kterému nastává úplný (totální) odraz světla, na jehož principu jsou optická vlákna založena [1] [4].



Obr.1: Struktura optického vlákna.

### 1.1.1 Index lomu

Jedná se o bezrozměrnou veličinu charakterizující poměr rychlosti světla  $c$  ve dvou různých optických prostředích. Lze od sebe rozlišit absolutní index lomu a relativní index lomu. V případě absolutního indexu lomu je udáváno, kolikrát je rychlost světla v určitém prostředí menší, než rychlost světla ve vakuu. Jinými slovy absolutní index lomu je vztažen k vakuu [5] [6].

$$n = \frac{c}{v}, \quad (1.1)$$

kde  $n$  představuje ve vzorci index lomu,  $c$  představuje rychlost světla ve vakuu a  $v$  je rychlost světla v daném prostředí.

Poměr rychlostí světla ve dvou různých optických prostředích je pak popsán relativním indexem lomu.

$$n_{12} = \frac{v_1}{v_2}, \quad (1.2)$$

kde  $v_1$  a  $v_2$  ve vzorci představují rychlosti světla v optických prostředích.

### 1.1.2 Odraz a lom světla

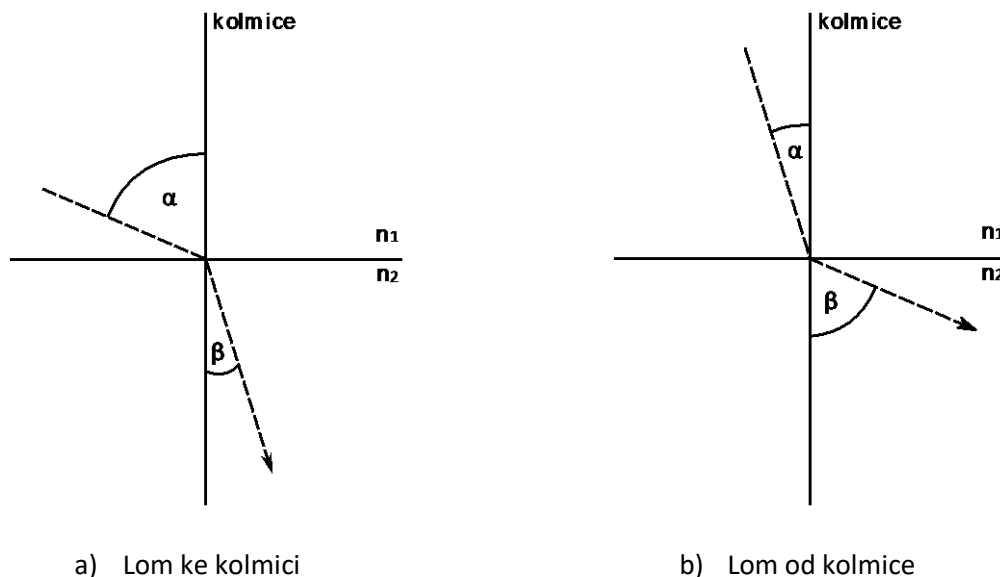
Pokud světelný paprsek dopadá na rozhraní dvou optických prostředí s různými indexy lomu, pak se světlo z části odráží a z části láme do druhého optického prostředí [5] [6] .

Lom světla lze popsat zákonem lomu (také znám jako Snellův zákon), který je vyjádřen rovnicí:

$$\frac{\sin \alpha}{\sin \beta} = \frac{n_2}{n_1}, \quad (1.3)$$

kde  $\beta$  ve vzorci představuje úhel odrazu,  $\alpha$  představuje úhel dopadu,  $n_1$  a  $n_2$  jsou indexy lomu dvou prostředí.

Na základě zákona lomu mohou nastat dvě situace znázorněné na Obr.2.: Je-li zaznamenán přechod světla z opticky řidšího prostředí do opticky hustšího prostředí ( $\beta < \alpha$ ), lze pozorovat lom světla ke kolmici. V opačném případě, kdy je indikován přechod světla z opticky hustšího prostředí do opticky řidšího ( $\beta > \alpha$ ), pak se jedná o lom od kolmice. [5] [6] [7].



Obr.2: Znázornění lomu ke kolmici a lomu od kolmice.

### 1.1.3 Úplný odraz světla

Při průchodu světla z opticky hustšího prostředí do opticky řidšího prostředí dochází k lomu od kolmice a při dovršení mezního úhlu dopadu  $\alpha_m$  bude úhel odrazu  $\beta$  roven  $90^\circ$ . Jedná se o maximální úhel, při kterém se světlo stále láme. Pokud bude úhel dopadu větší, než mezní úhel, pak již nedochází k lomu světla, ale světlo se pouze odráží. Tomuto jevu se říká úplný odraz světla na jehož principu fungují optická vlákna. [5] [6] [7]

## 1.2 Optická vlákna a jejich základní parametry

V optickém vlákně je k transferu informací využito světlo. Technologie byla dlouho limitována tím, že neexistoval zdroj světla se správnými parametry. Vše bylo změněno při objevu laseru, u kterého byly zajištěny všechny požadované vlastnosti [3].

**Optická vlákna lze rozdělit na dvě hlavní skupiny:**

- jednovidová vlákna
- mnohovidová vlákna

Jednovidová vlákna přenášejí pouze jeden vid světelného záření. To je zajištěno velmi malým průřezem jádra optického vlákna. Mnohovidová optická vlákna přenášejí množství vidů závislé na velikosti průřezu jádra. Dále je možné rozdělení podle materiálu, ze kterého je vytvořeno optické vlákno (křemenné, plastové, skleněné) [3].

### 1.2.1 Útlum optického vlákna

Tento parametr popisuje velikost poklesu intenzity signálu mezi dvěma danými body (začátek a konec vlákna). Jednotkou obvykle bývá dB/km [3] [1].

Útlum optického vlákna lze vyjádřit rovnicí:

$$\mu(\lambda) = 10 \log_{10} \frac{P_2}{P_1}, \quad (1.4)$$

kde  $P_1$  představuje výkon na začátku vlákna a  $P_2$  vyjadřuje výkon na konci vlákna.

### 1.2.2 Numerická apertura

Tato bezrozměrná veličina tvoří důležitý prvek při napojování světelného zdroje na optické vlákno a také při spojování optických vláken. Pokud by u spoje mělo vlákno, které emituje světelné záření, vyšší numerickou aperturu, než vlákno, které záření přijímá, zvýšil by se útlum soustavy [1] [2].

### 1.2.3 Přenosová kapacita


K popisu velikosti přenesených dat je využita přenosová kapacita. Tato kapacita je ovlivněna disperzními ztrátami (závislé na indexu lomu a vlnovými vlastnostmi užitého světla). Vlivem disperzních ztrát přenosová kapacita mnohovidových vláken rapidně klesá v závislosti na délce vedení. U jednovidových vláken jsou ztráty mnohonásobně menší, a proto se využívají na dálková vedení [1].

## 1.3 Braggovská mřížka

Difrakční mřížka je optická struktura, která obsahuje periodicky se opakující štěrbiny. K tomu, aby nastalo vzájemné působení mezi mřížkou a světlem, musí být na mřížce obsaženo alespoň 1000 period změn indexu lomu a zároveň musí splňovat podmínku, která udává, že mezi maximem a minimem indexu lomu ve stavbě mřížky musí být velký rozdíl [8] [9].

Braggovu mřížku lze definovat jako difrakční mřížku, která splňuje Braggovu podmínku difrakce, což znamená, že perioda změn indexu lomu mřížky musí být rovna jedné polovině vlnové délky světla, které je v optickém vlákne využito [8] [9].

Na Obr.3: lze vidět optické vlákno, do jehož jádra byla vložena struktura mřížky. Tato struktura tvoří periodické změny indexu lomu v jádře optického vlákna. Při interakci světla s mřížkou se určitá vlnová délka (Braggova vlnová délka  $\lambda_B$ ) odráží zpátky ke světelnému zdroji [8] [9].



Obr.3: Braggova mřížka v optickém vlákne (upraveno) [8].

## 1.4 Optovláknové senzory

Senzory využívající Braggovskou mřížku tvoří rozsáhlou skupinu s velkým polem působnosti. Tyto senzory lze využít jak pro medicínské účely, tak pro dopravu, stavebnictví a mnoho dalších oborů. Jejich obrovskou výhodou je jejich malý rozměr, hmotnost a poměrně jednoduchá a finančně méně náročná výroba. Jako hlavní přednost optovláknových senzorů je jejich odolnost proti elektromagnetickému rušení. Tyto senzory tvoří velice zajímavý poměr mezi cenou a výkonem [4].

Princip tohoto senzoru spočívá v tom, že světlo, které je přenášeno vlákem, interferuje s braggovskou mřížkou. Výsledkem této interference je změna ve fyzikálních vlastnostech procházejícího světla (vlnová délka, fáze). Jako zdroj světla pro tyto senzory obvykle slouží několik typů laserů. Pokud je dostačuje menší výkon světelného zdroje, pak lze využít LED diody [4].

## 1.5 Monitorování dechové aktivity v klinické praxi

Respirace je jedním z nejdůležitějších dějů v lidském těle. Při dýchání se v plicích sklípcích váže plynný kyslík na odkysličenou krev, ze které se zároveň dostává přebytečný oxid uhličitý generovaný při buněčném dýchání zpátky do atmosféry [10] [11].

Dechovou aktivitu lze monitorovat dvěma způsoby – přímou a nepřímou metodou. Monitorování přímou metodou znamená, že ke snímání je využit senzor primárně navržený k tomuto úkonu. V praxi, když je pacient dlouhodobě monitorován, je přímá metoda nevýhodná a pacientovi z dlouhodobého hlediska i nepříjemná. Daleko využívanějším způsobem je metoda nepřímá, kdy je k monitoringu využit jiný snímací systém, ze kterého lze dechovou aktivitu odvodit. Pro pacienta je tato metoda mnohem pohodlnější už jen díky tomu, že na něj není napojeno o další snímací zařízení více [10] [11].


### 1.5.1 Pneumotachograf

Pneumotachograf je přístroj užívaný ke spirometrickým měřením a měří objemový průtok  $q_v$  ( $l \cdot s^{-1}$ ) respiračních plynů. Oproti klasickému spirometru, který tvoří uzavřený měřicí systém a tedy pacient nadechuje a vydechuje stejný vzduch, je výhodný v tom, že měření není limitováno postupným nárůstem  $CO_2$  a úbytkem kyslíku [12].

#### Rozdělení pneumotachografů:

- pneumotachograf s rozdílovým (diferenčním) manometrem
- lopatkový pneumotachograf
- ultrazvukový pneumotachograf

V klinické praxi jsou hojně využívány pneumotachografy s diferenčním manometrem, které měří objemový průtok na základě rozdílu tlaků v tubusu přístroje (viz Obr.4:). Druhými velmi využívanými aparáty, které pravděpodobně nahradí předchozí typ přístrojů, jsou ultrazvukové pneumotachografy [12].



Obr.4: Schéma pneumotachografu s rozdílovým manometrem [12].



## 1.5.2 Elektrokardiograf (EKG)


EKG je přístroj užívaný v klinické praxi ke snímání elektrické srdeční aktivity. Přístroj představuje základní zdravotnickou techniku, kterou lze potkat i v ordinaci praktického lékaře. V dnešní době je nejběžnějším typem dvanáctisvodové EKG, které využívá tři typy svodů (Eithovenovy, Goldbergovy a Wilsonovy). Přístroj není primárně určený k monitorování dechové aktivity, ale tyto hodnoty je možné pomocí softwarové analýzy signálu odvodit [11] [13].

Přístroj je jednou z hlavních součástí patientských monitorů, které slouží ke komplexnímu snímání pacienta (EKG, nasycení krve kyslíkem, krevní tlak a mnoho dalších parametrů).

## 1.5.3 Kapnograf

Pomocí kapnografu je monitorováno zastoupení  $\text{CO}_2$  ve vydechovaném vzduchu. Přístroj obsahuje emitor infračerveného záření, jehož intenzita je v závislosti na koncentraci  $\text{CO}_2$  proměnlivá. Tyto změny jsou zaznamenávány kolektorem a dále zpracovávány. Výsledný signál pak nazýváme kapnogram [14].

Výsledný signál lze vidět na Obr.5., na kterém lze lehce segmentovat nádechy a výdechy v respiračním cyklu.



Obr.5: Přibližný průběh kapnogramu.

## 1.5.4 Teplotní senzory

Jednou z přímých metod snímání dechové aktivity je použití senzoru zaznamenávajícího změnu teploty vydechovaného vzduchu. Snímač je umístěn tak, aby byl schopen zaznamenat změnu teploty nadechovaného a vydechovaného vzduchu nosem i ústy [15].

V praxi je nejčastěji využíván senzor s termistorem, který v závislosti na změně teploty mění svoji odporovou charakteristiku a senzor, který využívá termočlánek, který mění svoji napěťovou charakteristiku. Příkladem může být využití perličkového termistoru, který je umístěn do nosu. Tento senzor je však doprovázen značnou problematikou spojenou s tvorbou hlenů v nose. Po krátké době se senzor obalí hlenem a stává se prakticky nepoužitelným [15].

### **1.5.5 Odporové snímače**

Velmi využívanou přímou metodou snímání dechové aktivity je použití snímače, který mění svoji odporovou charakteristiku v závislosti na deformaci materiálu a nebo teplotě (již zmíněný termistor). Příkladem může být odporový hrudní pás, který se obtočí okolo hrudníku a v závislosti na roztažení a stažení hrudi (nádech a výdech) se mění odporová charakteristika materiálu, která je dále zpracovávána softwarově [15].

### **1.5.6 Piezoelektrický snímač**

Tento snímač je podobný odporovému hrudnímu pásu v bodě 1.5.5. Tento senzor využívá piezoelektrického jevu, který lze definovat jako schopnost krystalu generovat napětí vlivem působení vnějších mechanických sil. Jedná se o hrudní pás jehož součástí je senzor tvořený z krystalu. V závislosti na dýchání, kdy je senzor vystavován změnám mechanického tlaku, je generováno napětí, které je dále zpracováváno softwarem [10].

## 2 Možnosti zpracování signálu dechové aktivity

U každého signálu získaného z měřicího systému je nutné provést úpravu, poněvadž se v něm mohou nacházet určité artefakty, které mohou být způsobeny mnoha faktory. Nejčastějším a pravděpodobně všudypřítomným zarušením signálu bývá šum, který může vzniknout mnoha způsoby. Často se jedná o přítomnost nějakého rušivého signálu, který je snímán spolu s měřenou veličinou. Šum také může vzniknout díky špatnému odstínění, nebo nekvalitnímu propojení použitých vodičů (metalických i optických). V tomto případě je námi měřená veličina ovlivňována elektromagnetickým zářením, které se nachází v okolí každého elektrického zařízení a na jehož principu jsou přenášeny také rádiové vlny. Rušení signálu elektromagnetickým zářením lze zamezit takzvanou Faradayovou klecí, do které je zamezeno průchodu rušivého elektromagnetického vlnění. V případě výskytu těchto nechtěných signálů v námi naměřeném signálu je nutno provést softwarovou úpravu, která výsledný signál vyhledá do námi chtěné podoby [16].

Ať už bude řeč o optovláknových senzorech dechové aktivity a nebo o klasických snímacích systémech (teplotní senzory, piezoelektrický snímač), v obou případech se jedná o jednokanálový výstup signálu, který bude následně zpracováván.

### 2.1 Filtrace signálu

Ke zpracování signálů dechové aktivity lze využít mnoho metod. Mezi nejzákladnější patří použití filtrů, které lze rozdělit na základní typy:

- **Dolní propust** – při nastavení mezní frekvence odfiltruje všechny frekvence vyšší, než mezní frekvenci.
- **Horní propust** – filtruje všechny kmitočty, které jsou nižší, než mezní frekvence.
- **Pásmová propust** – musí být nastaveno pásmo tvořené dolní a horní mezní frekvencí, které prochází dále filtrem. Zbylé frekvence jsou odfiltrovány.
- **Pásmová zádrž** – odfiltruje pouze kmitočty náležící zvolenému pásmu.

Volba správného filtru závisí na frekvenční charakteristice snímaného signálu. Filtraci signálu lze zajistit implementací námi zvoleného filtru do snímacího systému, který zajistí prostup pouze důležitých frekvencí, které charakterizují výstup zvolené snímané veličiny. Toto využití filtrů může být velice užitečné k eliminaci různých šumů a je součástí většiny zařízení, kterými je snímaná dechová aktivita. Implementací filtru do snímacího zařízení ovšem nelze zamezit prostupu šumu, jehož frekvence je velice blízká frekvenci snímaného signálu. Tyto nechtěné signály se již musí zpracovávat softwarově tak, aby výsledný průběh měřené veličiny byl čistý. K tomu nám slouží takzvaná digitální filtrace, kterou lze zajistit využitím správného softwaru, ve kterém se nastaví přesné charakteristické hodnoty filtru tak, aby byl výsledný signál zbaven nechtěného šumu [17].

K digitální filtraci dechové křivky je vhodné použít filtr typu pásmová propust, který odfiltruje vše ostatní kromě frekvencí ležících v nastaveném pásmu. Je nutné si uvědomit jakou má snímaná veličina frekvenční charakteristiku, která se v případě dechové aktivity pohybuje v rozmezí 14 až 20 dechů za minutu, čemuž náleží hodnoty frekvence přibližně 0,2 až 0,3 Hz. Tyto hodnoty charakterizují dolní a horní mezní frekvence zvoleného pásma. Nevýhodou této metody je fakt, že pokud se frekvence dýchání dostane na hodnoty, které se nepohybují zvolenému pásmu, tento filtr odstraní samotnou dechovou křivku a výsledný signál bude tím pádem nepoužitelný [17].

## 2.1.1 Základní selektivní filtry

### FIR filtry (finite impulse response):

Jedná se o filtry s konečnou impulsní charakteristikou, k jejichž realizaci se často používá nerekurzivní algoritmus. Tyto filtry jsou velmi stabilní a umožňují získat přesnou lineární fázovou frekvenční charakteristiku. Další velkou výhodou je jejich nenáročnost na vytvoření [18].

Ve studii Schätz a kolektiv [19] byl testován senzor pro měření dechové aktivity v průběhu spánku pacienta. Autoři podotýkají na to, že dosavadní metody snímání dechu v průběhu spánku jsou pro pacienta nekomfortní z důvodu množství kabeláže, která může být některým lidem při usínání nepříjemná. Z tohoto důvodu autoři testovali bezkontaktní metodu, která minimalizuje diskomfort pacienta. Ve studii byl využit senzor MS Kinect v2, který snímal pohyby hrudníku, analyzoval dýchání a rozpoznal patologie v dýchacím cyklu. Autoři udávají, že deklarovaná použitelná vzdálenost senzoru od těla pacienta, kterou výrobce udává na 4,5m, byla až 8m, přičemž snímání nabývalo hodnot 30 FPS (snímky za sekundu). K odfiltrování rušivých elementů v signálu byl využit dolnoproústný FIR filtr. [18] [19] Ve studii byl tento filtr použit k odfiltrování šumu a zachování signálu dýchání (0,2 až 0,33 Hz). Zároveň je zmíněno, že nejlepší možností filtrace bylo docíleno použitím **Savitzky-Golay** filtrem. Jedná se o FIR filtr na principu polynomičké regrese, kdy jsou hodnoty signálu proloženy polynomem, jehož koeficient je získán metodou nejmenších čtverců. [20] [19] V této studii byla definována mezní frekvence na 0,7 Hz, což odpovídá přibližně 42 dechům za minutu. Následně byla provedena spektrální analýza signálu a hodnocení výsledných dat. Studie potvrdila, že zvolený způsob zpracování dat je efektivní a senzor MS Kinect v2 je vhodný k bezkontaktnímu snímání dechové aktivity v průběhu usínání a spánku [19].

### Savitzky-Golay filtr:

SG filtr je ve své podstatě digitální FIR filtr typu dolní propust. Algoritmus tohoto filtru funguje podobně, jako metoda klouzavého průměru, která je využita v detektoru dýchání s tím rozdílem, že jednotlivé vzorky algoritmus nezprůměruje, ale proloží je polynomem o určitém stupni. Dále je využita metoda nejmenších čtverců. SG filtr představuje zajímavou a efektivní metodu ke zpracování signálů a oproti standardním FIR filtrům nese výhodu v tom ohledu, že při filtraci dat se na výstupu objeví vyhlazený signál, který zároveň není zdeformovaný, což představuje značnou výhodu oproti klasickým typům filtrace.

### IIR Filtry (infinite impulse response):

Jedná se o filtry s nekonečnou impulsní charakteristikou, pro jejichž realizaci se vždy používá rekurzivní algoritmus. Průběh těchto filtrů není lineární. Nevýhodou oproti FIR filtrům je jejich složitost (náročné na sestavení) [18].

Ve studii Ballal a kolektiv z roku 2012 [21] je testován bezkontaktní senzor ke snímání dechové aktivity. Experimentálním měřícím přístrojem byl SleepMinder, který funguje na principu radaru. Jedná se o dvoukanálový senzor, který detekuje pohyb hrudníku a také pohyby celého těla k zamezení vzniku nepřesností. Tento přístroj se umísťuje 0,3 až 1,5 m od pacienta. Data jsou přímo senzorem filtrována dolnoproústným filtrem a dále převzorkovaná na frekvenci 64 Hz a uložena na paměťovou kartu. K získání hodnot bylo provedeno měření na 10 dospělých osobách, přičemž se nadále pracovalo se

signály, jejichž průběh trval 15 minut. Pro následnou úpravu signálů byly využity adaptivní IIR filtry typu pásmová zadrž, který využívá algoritmus LMS, o kterém bude řeč v kapitole 2.2. Celé zpracování signálů probíhalo ve vývojovém prostředí MATLAB. Autoři této studie došli k závěru, že při použití této metody k bezkontaktnímu snímání dechové aktivity lze docílit lepších a přesnějších výsledků, než u dosavadních v praxi využívaných metod [21].

### 2.1.2 Wienerův vlnkový filtr

Tento filtr je využíván k filtraci šumu, přičemž spektrum šumu se prolíná se spektrem signálu. Pomocí tohoto filtru se upravuje frekvenční spektrum zkoumaného signálu se šumem tak, aby ve výsledku vznikl co nejlepší odhad spektra signálu [22].

## 2.2 Adaptivní metody

Adaptivní metody představují poměrně rozsáhlou skupinu metod ke zpracování signálů. Myšlenkou těchto metod je vylepšit efektivitu zpracování signálů jejichž průběh není ve všech ohledech známý. V adaptivních metodách je použit rekurzivní algoritmus, který začíná zpracovávat s předdefinovanými počátečními hodnotami a postupně se adaptuje a upravuje své koeficienty tak, aby výsledný signál měl co nejlepší podobu.

#### **Last Mean Square (LMS):**

LMS lze zařadit mezi stochastické gradientní algoritmy, které byly založeny na teorii Wienerovy filtrace. Tento představitel je velmi využívaným algoritmem mezi adaptivními metodami, poněvadž je poměrně efektivní a jeho velkou výhodou je jeho výpočetní nenáročnost. V současnosti existují další algoritmy, které vychází z LMS systému a snaží se jej ještě více zefektivnit.

#### **Recursive Last Square (RLS):**

Tento postup se řadí do třídy rekurzivních algoritmů, jenž vychází z teorie Kalmanovy filtrace, metody nejmenších čtverců a časového průměrování. Rozdílem oproti LMS algoritmu je to, že tento algoritmus pracuje s průměrnými hodnotami veličin, které jsou z časových vývoje počítány. Ke snížení výpočetní náročnosti algoritmu RLS byl vytvořen takzvaný NLRLS, který přináší normalizaci samotného RLS. Algoritmus pracuje s méně proměnnými a využívá méně svých částí vlastní struktury.

Ve studii od Islam a kolektiv [23] se zkoumá efektivita dronu, který je vybaven duálním radarem ke skenování oblastí a budov, kde došlo k nějaké nehodě. Drony mají za úkol odhalit přeživší pomocí radaru, který detekuje jejich dechovou aktivitu. Testování tohoto projektu bylo prováděno v laboratorních podmínkách, kde se jako zdroj dechové aktivity použil fantom imitující lidské dýchání. Součástí studie bylo také porovnání efektivit adaptivních metod (LMS a RLS) pro eliminaci šumu. Při experimentu byl jeden radar zaměřen na dechový fantom a druhý radar byl zaměřen na nepohyblivou zeď, díky čemuž byl získán referenční signál. Ke zpracování signálů bylo použito vývojové prostředí MATLAB. Ve výsledcích studie je zmíněno, že metoda LMS vykazuje jistou nepřesnost oproti referenční hodnotě. V případě RLS metody byla nepřesnost oproti referenčnímu signálu zanedbatelná. Metoda RLS přináší lepší schopnost adaptace, tím pádem pracuje přesněji [23].

### **Adaptive neuro-fuzzy interface systém (ANFIS):**

Pod zkratkou ANFIS se skrývá umělá neuronová síť pracující na fuzzy interferenčním systému (typ Tagaki-Sugeno). V systému je využit algoritmus neuro-adaptivního učení, pomocí kterého se určuje vztah mezi vstupními a výstupními daty. Obrovskou výhodou tohoto systému je schopnost učení, tedy vysoká schopnost adaptace. [24]

Studie od Živčák a kolektiv z roku 2021 [25] představuje návrh a zhotovení plicního ventilátoru BreaThU určeného primárně pacientům s onemocněním covid-19. Autoři studie uvádějí, že se má jednat o ventilátor, který bude cenově nenáročný a zároveň bude konstrukčně velmi jednoduchý, aby byla zajištěna jeho dostupnost při globální pandemii jako je nynější pandemie onemocnění covid-19. Algoritmus řídicího systému pro monitorování umělé plicní ventilace, který identifikuje nádechy, výdechy a objem respiračních plynů vychází ze systému ANFIS. Ventilátor má fungovat na principu AmbuBag (ruční mechanický ventilátor). Systém je řízen Arduinem, přičemž hodnoty dechového objemu mají náležet do intervalu 0,1 až 0,8 l a hodnota dechové frekvence je nastavena od 5 do 40 nádechů/min. Závěrem studie autoři sdělují, že s výsledky ventilátoru jsou spokojeni a že použití systému ANFIS bylo velmi vhodné. Monitor má být dále biologicky testován. Dle slov autora se bude jednat o testování na zvířatech, přičemž funkčnost monitoru bude upravována tak, aby se co nejrychleji dal využít v klinické praxi [25].

## **2.3 Fourierova transformace (FT)**

Díky Fourierově transformaci je zprostředkována proměna signálu z časové oblasti do frekvenční oblasti a naopak. Metodu lze aplikovat jak na analogové signály, tak i na digitální. Pomocí FT se signál rozkládá na jednotlivé harmonické složky, čímž vzniká spojitá funkce frekvence, která se nazývá spektrum signálu. Existuje několik provedení Fourierovy transformace, přičemž každé má poněkud rozdílné využití. [17] [13] [26]

Diskrétní Fourierova transformace (DFT) umožňuje práci s diskrétními signály. Dále je pak popsána takzvaná Rychlá Fourierova transformace (FFT), která zahrnuje výpočet, jehož velkou výhodou je menší složitost oproti klasické DFT. Využití FFT je poměrně rozsáhlé a s algoritmem tohoto typu FT se můžeme setkat v mnoha medicínských přístrojích a nebo ve většině digitálních osciloskopů, ve kterých FFT představuje jednu z matematických operací. Hlavním aspektem rozsáhlého využití FFT v přístrojové technice je fakt, že tento algoritmus je schopen provádět výpočty v reálném čase, což je zajištěno poměrnou jednoduchostí tohoto algoritmu. [17] [13] [26]

V práci od Riedl z roku 2020 [15] se zkoumá možnost uplatnění senzoru zaznamenávajícího vlhkost vzduchu k měření dechové frekvence člověka. Celkem 9 měření bylo provedeno v laboratorních podmínkách na několika osobách a byly simulovány různé situace (klid, zátěž...). Samotný senzor byl umístěn na sluchátkách tak, aby byl schopen zaznamenávat dýchání testovaných subjektů. Jako referenční měřidlo k porovnání dat byl využit hrudní pás, který představuje pravděpodobně nejvyužívanější měřicí systém dechové aktivity. Následně byla po předzpracování dat zkoumána korelace (vzájemná podobnost) signálu ze snímače vlhkosti vzduchu a signálu naměřeného hrudním pásem. Ve výsledcích byla zřetelná výrazná podobnost obou průběhů měřených veličin. Zpracování signálu bylo provedeno dvěma způsoby. Prvním způsobem byla rychlá Fourierova transformace (FFT), která zobrazí, jaké kmitočty jsou v signálu dominantní. Následně byly krajní

hodnoty výsledného signálu vynulovány a zpětně transformovány. Tímto způsobem se získal původní signál, který byl ovšem zbaven šumu. Jako druhý typ zpracování signálu bylo využito standardizované skóre (Zscore), kdy byla použita část signálu, u které byla zjištěna střední hodnota. Každé hodnotě signálu bylo přiřazeno určité skóre v závislosti na vzdálenosti od střední hodnoty. Ve výsledcích měření bylo zjištěno, že začátky výdechů byly zaznamenány přesněji, než konce výdechů, což bylo způsobeno nižší senzitivitou vlhkoměru na nízký průtok vydechovaných plynů na konci výdechu. Veškerá měření korelovala s referenčními hodnotami.

#### **Krátkodobá Fourierova transformace (STFT):**

Při STFT je signál rozdělen na segmenty. STFT představuje okenní funkci, která se pohybuje po sekvenci dat a provádí u jednotlivých částí signálu časově-frekvenční analýzu, při které vzniká spektrum onoho signálu. Následně jsou jednotlivá spektra seřazena vedle sebe, z čehož získáváme spektrogram signálu. Hlavním rozdílem oproti FFT je rozdělení signálu na segmenty, které pak zpracovává okenní funkce a tvorba spektrogramu [27] [28].

## **2.4 Vlnková transformace (WT)**

Použitím Fourierovy transformace je zprostředkována proměna signálu z časové oblasti do frekvenční oblasti a naopak, ovšem nedostaneme z ní časové podrobnosti. Vlnková transformace představuje pokročilejší metodu zpracování signálu. Oproti Fourierově transformaci dokáže WT zobrazit zastoupení daných frekvencí včetně jejich časové informace. Další výhodou oproti FT je fakt, že WT zkoumá signál v několika rovinách-měřítkách (FT pouze v jedné), což je z hlediska přesnosti zpracování klíčové. Některé části, či charakterystiky signálu nemusí být vždy patrné pouze v jednom měřítku. Pokud se na signál zaměříme z více měřítek, pak bude zajištěno detekování a segmentování i těchto drobných charakterů signálu [17] [13] [26] [29] [30].

Využití metod na základě vlnkové transformace je ve zpracovávání signálu dechové aktivity poměrně vhodné a při porovnání s metodami založenými na Fourierově transformaci zde získáváme poměrně přesné informace o tom, kde se daná frekvence nachází [17] [13] [26] [29] [30].

V práci od Vaněk z roku 2016 [31] se zkoumá průběh umělé plicní ventilace a vyvíjí metoda detekce spontánního dýchání pacienta. Pracuje se signálem, který byl zaznamenán senzory (tlakový a diferenční) připojenými k experimentálnímu přístroji iMon firmy National Instruments. Pomocí senzorů je detekován tlak a průtok respiračních plynů. Z výsledných signálů je dále vyvozována dechová křivka. Signály byly získány tak, že byly přístroje připojeny na aparaturu, která má napodobovat lidský respirační systém. Jako referenční signál byl použit výstup z tlakově diferenčního senzoru. Výstupem senzorů je signál představující časový průběh napětí. Napěťový průběh z tlakového senzoru je převeden na časový průběh tlaku a v případě diferenčního senzoru je signál přetransformován na průtok. Sestavený algoritmus (navržený v prostředí MATLAB) provádí frekvenční spektrální analýzu naměřeného signálu v čase tak, aby byl schopný odhalovat patologické jevy v dýchání a rušivé elementy, pomocí kterých by se snížila šance detekce dechového cyklu. V algoritmu byla ke zpracování signálu použita kontinuální vlnková transformace, díky které bylo možné provést detekci dechového cyklu. Z výsledků práce bylo zjištěno, že experimentální zařízení iMon bylo při použití správného algoritmu schopné měřit a vyhodnocovat data snímaná ze systému napodobujícího

umělou plicní ventilaci. Autor práce sděluje, že s použitím tohoto algoritmu se může posunout oblast využitelnosti tohoto experimentálního přístroje i do klinické praxe [31].

Ve studii od Fleming a Tarassenko z roku 2007 [32] se pracuje se signálem z fotopletysmografu a porovnávají se tři různé metody zpracování. Ve studii se pracovalo se 7 signály získanými z databáze Physiobank a následně byly zpracovány metodami: vlnkový rozklad vycházející z vlnkové transformace, digitální filtrace a metoda využívající autoregresivní modelování. V prvním případě byl signál rozložen pomocí vlnkové transformace za použití Morletovy vlnky (komplexní sinusoida, symetrická) k vytvoření škálogramu, ze kterého lze identifikovat frekvenci související s tepovou frekvencí lidského těla a frekvencí související s dechovou aktivitou. Další porovnávanou metodou zpracování signálu je digitální filtrace, v níž je využit filtr typu pásmová propust s nastaveným rozsahem pásma 0,1 až 0,3 Hz, což má odpovídat rozsahu 6 až 18 nádechů za minutu. Nejpodstatnější metodou v této studii je využití autoregresivního modelování, přičemž autoři studie sdělují, že tuto metodu sami vynalezli. Metoda umožňuje měření dechové frekvence na základě identifikace signálu z fotopletysmografu. Tato metoda byla aplikována na mnoha fyziologických signálech (EEG), ale pro analýzu dechu nikoliv. Frekvenční rozsah signálu získaného z fotopletysmografu se pohybuje od 100 do 250 Hz, přičemž samotný signál popisující charakter dechové aktivity je výrazně menší. Díky tomuto faktu by vznikaly nepřesnosti v měření, takže je nutné naměřený signál převzorkovat tak, aby byly zřetelné i nízkofrekvenční složky popisující dechovou aktivitu. Výsledky studie ukazují, že metoda autoregresivního modelování vykazuje lepší výsledky při zpracovávání signálu dechové aktivity, než využití vlnkové transformace a nebo digitální filtrace signálu [32].

#### **Hilbertova transformace (HT):**

Pomocí Hilbertovy transformace je možné vytvořit z reálného signálu analytický (komplexní) signál, který lze definovat jako součet reálného signálu s Hilbertovým obrazem tohoto signálu. Důvodem, proč se HT používá je, že vytvořený komplexní signál obsahuje ve svém rozkladu vektory, které se pohybují pouze jedním směrem [33] [34].

## **2.5 Empirická modální dekompozice (EMD)**

Při této metodě dochází k rozkladu číselných řad na různé složky s určitými vlastnostmi. Jednotlivé vnitřní modální funkce (IMF) signálu jsou seřazeny podle frekvence od nejvyšší po nejnižší se zbytkem, přičemž je zároveň možné jednotlivé modální funkce upravovat podle vlastní potřeby. Spektrum signálu, který projde EMD je velmi úzké. EMD je velmi účinnou metodou pro analýzu biosignálů, které jsou obvykle nelineární a nestacionární a na rozdíl od Fourierovy nebo vlnkové transformace nepotřebuje žádné předdefinované funkce, které definují signál, ale pracuje pouze s vlastním algoritmem [35] [36] [37].

Ve studii Garde a kolektiv z roku 2013 [38] byla vyvíjena metoda odhadu dechové a zároveň srdeční frekvence s použitím empirické modální dekompozice. Do studie bylo zapojeno 42 subjektů (29 dětí a 13 dospělých), které podstoupily měření fotopletysmografem. K získání referenčních signálů byl použit kapnograf, přičemž každý subjekt byl monitorován 8 minut. Pomocí EMD byly signály získané z fotopletysmografu rozděleny na 5 modálních funkcí a zbytky. Následně byla provedena výkonová spektrální analýza každé modální funkce ke zlepšení frekvenčního rozlišení. V posuvném okně vývojového prostředí byl PPG signál rozdělen na segmenty rozložené na modální funkce, které byly



analyzovány ve spektrální doméně, přičemž pro každou modální funkci byl hodnocen peak s největším výkonem. Modulace signálu popisující srdeční aktivitu proběhla přidáním modální funkce, jejíž frekvence se pohybuje v rozsahu srdeční frekvence člověka. Podobný postup proběhl u modulace signálu náležího dechové aktivitě, ke kterému byla přidána modální funkce, jejíž frekvence se blížila frekvenci dechové aktivity člověka. Určení dechové a srdeční aktivity proběhlo následnou spektrální analýzou těchto signálů. Ve výsledcích studie je v grafech viditelné, že dechové aktivitě odpovídaly hodnoty přibližně od 16 do 21 dechů za sekundu a v případě srdeční aktivity se jednalo o rozmezí mezi přibližně 100 až 109 tepů za minutu. Zároveň v porovnání s referenčním měřidlem lze vidět drobné nepřesnosti. Ve studii je udávaná chyba pro dechovou aktivitu 1,13 dechů za minutu a v případě srdeční frekvence se jedná o 0,59 tepů za minutu. Autoři zároveň zmiňují, že tato metoda přináší velkou výhodu v tom, že je adaptivní, cenově méně náročná a poměrně přesná [38].

#### **Ensemble Empirical Mode Decomposition (EEMD):**

Jedná se o vylepšení klasické EMD. Tato metoda je schopna zajistit univerzální časově-frekvenční analýzu signálu. EEMD lze aplikovat na nelineární a nestacionární signály, které následně rozloží na několik IMF. Rozdílem oproti klasické EMD je to, že do algoritmu EMD je implementován princip datové analýzy pomocí šumu, který probíhá přidáním bílého šumu do originálního signálu [39].

Ve studii Orphanidou z roku 2016 [39] se využívá signál získaný z elektrokardiografu a fotopletysmografu k určení dechové frekvence za použití EEMD. Použitá data a signály byly získány z databáze korespondující se studií, která zkoumala komerčně využitelný senzor. Je známo, že v předchozí studii byli zapojeni dospělí pacienti, přičemž data byla získána z Equivital EQ-02 Monitoru, který byl umístěn na pacientův hrudník. Respirační frekvence byla z PPG a EKG odvozena s pomocí algoritmu EEMD, přičemž výsledky z EKG a PPG byly velice podobné. Referenční data byla získána z indukční dechové pletysmografie (RIP), přičemž průměrná referenční hodnota činila 17,5 dechů/min. Z výsledků studie vychází, že při použití EEMD u EKG signálu byla absolutní chyba přibližně 1,8 nádechů/minutu, (před použitím EEMD 2,52 nádechů/minutu). U signálu získaného z PPG byla absolutní chyba redukována z 3,15 nádechů/ minutu na 1,95 nádechů/minutu [39]

#### **Complete Ensemble Empirical Mode Decomposition (CEEMDAN):**

Tato metoda je další nadstavbou EEMD. U klasické EMD může nastat problém, že se různé periody smísí do jednoho IMF, což způsobí nepřesnosti. Algoritmus CEEMDAN zahrnuje přidání adaptivního šumu do klasické EMD, čímž zvýší efektivitu zpracování dat [40].

## 2.6 Shrnutí metod zpracování signálu

Ke shrnutí kapitoly 2 slouží Tabulka 1.; ve které jsou znázorněny základní charakteristiky jednotlivých metod, které byly v této části práce zkoumány.

Tabulka 1: Shrnutí metod zpracování signálů.


Metoda	Charakteristika
<b>FIR filtrace</b>	jednoduchost; stabilita; náročnost na paměť, ideální na bandpass a bandstop filtry
<b>IIR filtrace</b>	nižší frekvenční závislost; lepší využití pro lowpass a highpass typ filtru
<b>LMS</b>	jednoduchost; výpočetní nenáročnost; nebere ohled na předchozí data = bez paměti
<b>RLS</b>	složitost; výpočetní náročnost; zahrnuje vlastní paměť = zohledňuje předešlé výsledky
<b>ANFIS</b>	velmi přesná metoda; náročná na sestavení; výpočetní náročnost
<b>FT</b>	zdlouhavý výpočet; tvoří spektrum signálu
<b>FFT</b>	rychlá forma FT; výpočet v reálném čase
<b>STFT</b>	analyzuje jednotlivé segmenty signálu; tvoří spektra jednotlivých segmentů, ze kterých vytvoří spektrogram signálu
<b>WT</b>	vysoká efektivita pro nestacionární signály
<b>EMD</b>	výpočetně náročná a pomalá metoda
<b>EEMD</b>	přidává bílý šum do klasické EMD; zvyšuje výpočetní náročnost oproti EMD
<b>CEEDAN</b>	přidává do EMD adaptivní šum; snižuje chybovost; ještě složitější než EEMD

### 3 Dataset

Všechny signály byly naměřeny na několika jedincích v různých časových intervalech. Součástí měření byly také provedeny simulace různých okolností k robustnímu otestování algoritmu pro detekci dechu. K měření byly použity dva senzory, přičemž snímání proběhlo současně na obou senzorech. Hrudní pás obsahující piezoelektrický senzor byl použit jako referenční měřidlo podle jehož signálů byly stanoveny referenční hodnoty nádechů. Optovláknový senzor byl implementován do obličejové masky. Vzorkovací frekvence obou senzorů byla nastavena na 1 kHz. Fotografie z průběhu měření je zobrazena na Obr.6:. Použitý optovláknový senzor je zobrazen na Obr.7: a referenční senzor na Obr.8:.



Obr.6: Průběh měření.



Obr.7: Optovláknový senzor.



Obr.8: Hrudní pás pneumotrace II.

### 3.1 Předzpracování signálů


Poněvadž oba signály byly díky obsahu rušivých frekvencí prakticky nepoužitelné k další analýze, muselo proběhnout předzpracování dat, díky kterému byly odstraněny zmíněné rušivé frekvence. Důvodů přítomnosti různých rušivých elementů v biosignálech může být mnoho. Často přítomným jevem bývá síťové rušení odpovídající 50 Hz, které zrovna u signálů dechové aktivity nepředstavují velké riziko vzniku problémů, poněvadž frekvenci dechu odpovídá rozmezí od 0,1 do 2 Hz, přičemž obě hodnoty představují hraniční dechovou frekvenci. Dalším možným typem rušení, který už může v signálech dechové aktivity způsobit problémy jsou pohybové artefakty, které je obtížné odstranit. Příklad filtrace signálu lze vidět na Obr.9:.

#### **FIR filtr:**

FIR filtr představuje nerekurzivní digitální filtraci s konečnou impulsní odezvou. Filtrace signálu je zajištěna pomocí lineární superpozice vstupních dat od aktuální polohy signálu. Tento děj lze popsat následující rovnicí:

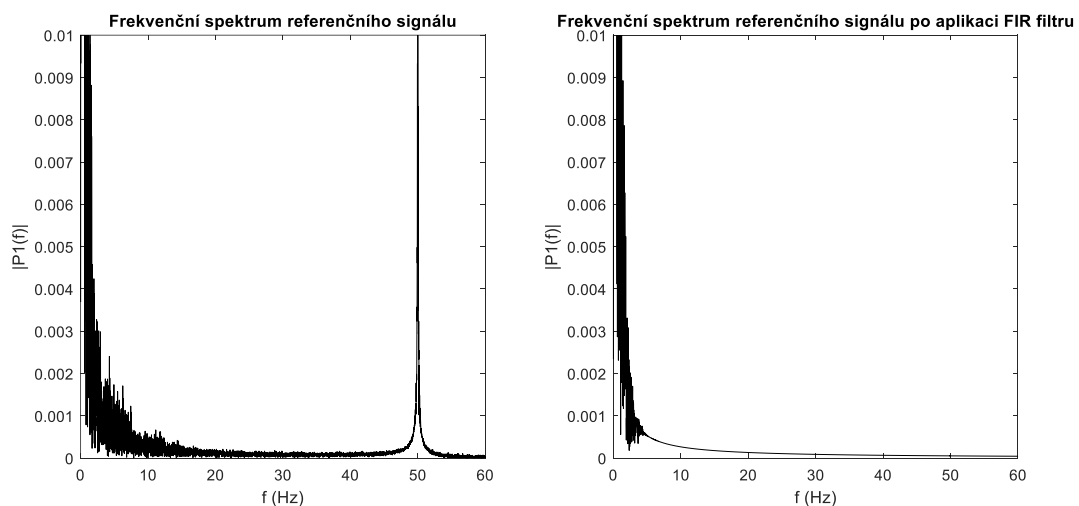
$$y[t] = \sum_{n=0}^N h_n x[t - nT], \quad (3.1)$$

kde  $y[t]$  představuje výstupní signál v aktuálním čase  $t$ ,  $x[t - n]$  vyjadřuje vstupní signál v časovém okamžiku  $t-n$ , pomocí  $h_n$  jsou popsány FIR koeficienty a  $N$  vyjadřuje řád filtru, přičemž funkce proběhne  $N+1$  krát. Výstup funkce je přepočítán na časové intervaly periody  $T$  pomocí vzorkování frekvence  $f_s=1/T$  [41].



Obr.9: Použití FIR filtru na signálu z optovláknového senzoru.

Pomocí FFT bylo analyzováno spektrum jak referenčního signálu zobrazeného na Obr.10; tak zkoumaného signálu, ze kterého bylo možné vyčíst, že například referenční signál obsahoval šum o frekvenci 50 Hz a v případě zkoumaného signálu byl přítomen nízkofrekvenční šum o frekvenci do 0,05 Hz. Proto byl k předzpracování signálu namodelován FIR filtr typu pásmová propust, jehož hodnoty mezních frekvencí byly přednastaveny na rozmezí od 0,1 do 2 Hz, čemuž odpovídá jak v případě dolní mezní frekvence velmi pomalé dýchání (6 nádechů za minutu) a v případě horní mezní frekvence 120 nádechů za minutu, přičemž obě hodnoty zajišťují dostatečnou rezervu k zabránění filtrace důležitých frekvencí. Přednastavená hodnota řádu FIR filtru byla stanovena na  $N=500$ .



Obr.10: Porovnání frekvenčních spekter referenčního signálu před a po filtraci.

## 3.2 Extrakce referenčních hodnot nádechů

Referenční hodnoty nádechů jsou velmi důležitými veličinami při závěrečném hodnocení výsledků, při kterém se zkoumá přesnost stanoveného nádechu z detektoru oproti časové hodnotě referenčního nádechu. Aby bylo možné takzvané anotace referenčního signálu provést, musely být oba signály synchronizovány, aby mezi signály byl minimální (při nejlepším nulový) posuv. Po synchronizaci signálů bylo možné pomocí funkce findpeaks provést detekci nádechů v referenčním signálu. Tyto referenční hodnoty byly vykresleny do grafu k provedení případné kontroly ve smyslu vymazání či přepsání chybných nádechů. Výsledkem tohoto procesu je vektor s časovými hodnotami referenčních nádechů.

## 4 Algoritmy

V první části této kapitoly jsou popsány teoretické principy zvolených pokročilých metod pro zpracování jednorozměrných signálů, možnosti, jak metody nastavit a konkrétní nastavení jednotlivých metod k aplikaci na signály dechu naměřených v rámci této práce. Obsahem druhé části této kapitoly je popis algoritmu detektoru nádechů a algoritmu hodnocení výsledků. Součástí podkapitoly zabývající se algoritmem hodnocení výsledků je také teoretický úvod k jednotlivým statistickým údajům, které jsou algoritmem vygenerovány.

### 4.1 Použité metody pokročilého zpracování signálů

Jedním z cílů této práce bylo provedení porovnání několika metod zpracování signálů. Oba použité senzory fungují na jiné bázi, tím pádem má výsledný průběh signálů v určitých ohledech rozdílné charaktery. Důvodem použití každé z metod bylo zlepšení kvality zkoumaného signálu v tom ohledu, aby se signál z optovláknového mřížkového senzoru nejlépe podobal výsledné křivce průběhu referenčního signálu, jenž byl získán pomocí senzoru, jehož primárním využitím je snímání dechové aktivity. Tím pádem se co nejefektivněji zjednoduší identifikace jednotlivých nádechů algoritmem detektoru. Znázornění použitých metod lze vidět na Obr.13:.

#### 4.1.1 Empirická modální dekompozice (EMD)

Mechanismus EMD spočívá v tom, že nelineární a nestacionární signály jsou složeny z jedné nebo více oscilačních složek. Pomocí metody EMD lze analyzovat signál, zjistit, z kolika oscilačních složek se skládá. Následně tato metoda rozdělí signál na několik modálních funkcí (IMF) a zbytek, což je znázorněno na Obr.11:.. Následným součtem jedné nebo více IMF lze dosáhnout zlepšení kvality signálu, poněvadž do výsledných dat již nebyla zahrnuta složka obsahující rušení [42].

Principem metody EMD je provedení empirického zkoumání jednotlivých oscilačních složek pomocí jejich časových měřítek a následné rozložení signálu na základě této analýzy. Pomocí takzvaného prosévání je umožněna eliminace oscilací, jejichž střední hodnota mezi lokálními extrémy neprochází nulou [42].

Aby mohl být signál rozložen na jednotlivé IMF, je nutno splnit tyto podmínky:

- IMF má pouze jeden lokální extrém mezi dvěma průchody nulou.
- Střední hodnota IMF musí být rovna nule [42].

Algoritmus EMD aplikovaný na signál  $x(t)$  lze rozdělit do následujících kroků:

- Rozpoznání všech lokálních minim a lokálních maxim v signálu.
- Vytvoření obálek signálu  $e_{min}(t)$  a  $e_{max}(t)$ .
- Odvození lokálního průměru  $r(t)$ :

$$r(t) = \left( \frac{e_{min}(t) + e_{max}(t)}{2} \right). \quad (4.1)$$

- Odvození detailů  $d(t)$ :


$$d(t) = x(t) - r(t) \text{ [42].} \quad (4.2)$$

- Opakovat postup až do momentu, kdy zůstane zbytek  $r(t)$ .

Výsledkem EMD je určitý počet IMF závislý na počtu oscilačních složek a zbytek:

$$x(t) = \sum_{i=1}^n h_i(t) + r_n(t), \quad (4.3)$$

kde  $h_i(t)$  představuje IMF a  $r_n(t)$  definuje zbytek [42].



Obr.11: Rozložení signálu na IMF pomocí EMD.



## 4.1.2 Savitzky-Golay filtr (SG)

V případě SG filtru se jedná o FIR filtr, který prokládá vstupní signál polynomem a s pomocí metody posledního souseda vyhlazuje vstupní signál. Funkci SG filtru lze jednodušeji pochopit tak, že si představíme libovolný stupeň polynomu ( $d$ ) a libovolnou délku ( $N$ )  $n$ -rozměrného vektoru vstupních dat ( $x$ ). Pokud lze předpokládat, že délka  $N = 2M+1$ , bude kolem určitého vzorku  $x_0$  rozložení podle následujícího vztahu:

$$x = [x_{-M}, \dots, x_{-1}, x_0, x_1, \dots, x_M]^T \quad [43]. \quad (4.4)$$

$N$  vzorků lze proložit polynomem  $d$  o řádu ( $0 \leq d \leq M$ ) na základě následujícího předpisu:

$$\hat{x}_m = c_0 + c_1 m + \dots + c_d m^d \quad -M \leq m \leq M, \quad (4.5)$$

kde  $\hat{x}_m$  představuje  $m$ -tý vyhlazený vzorek dat, koeficienty  $c$  představují reálná čísla, která by měla být stanovena tak, aby daná polynomiální křivka co nejlépe odpovídala vstupním datům. Následně jsou definovány  $d+1$  polynomiální vektory představeny  $s_i$ , přičemž ( $i = 0, 1, \dots, d$ ), což lze vyjádřit následujícím předpisem:

$$s_i(m) = m^i \quad -M \leq m \leq M \quad [43]. \quad (4.6)$$

Matice  $S$  dále obsahuje prvky  $s_i$  v řádku. Definováno následně:

$$S = [s_0, s_1, \dots, s_d] \quad [43]. \quad (4.7)$$

Vyhlazená data jsou zapsána do vektoru podle následujícího předpisu:

$$\hat{x} = Bx = \sum_{i=0}^d c_i s_i \quad [43] \quad (4.8)$$

Hodnota  $y_0 = \hat{x}_m$  je dána jako střed filtru  $b_0$  takto:

$$y_0 = b_0^T x = \sum_{m=-M}^M b_0(m) x_m \quad [43]. \quad (4.9)$$

$N$  dimenzionální vektor  $x$  může být posunut o  $n$  časových okamžiků:

$$x \rightarrow [x_{n-M}, \dots, x_{n-1}, x_n, x_{n+1}, \dots, x_{n+M}]^T \quad [43]. \quad (4.10)$$

SG filtr o řádu  $d$  a délce  $N$  pro vyhlazování šumu v posloupnosti  $x(n)$  je v ustáleném stavu reprezentován takto:

$$y(n) = \sum_{m=-M}^M b_0(-m) \cdot x \cdot (n - m) \quad [43]. \quad (4.11)$$

V případě konkrétního využití metody SG ke zpracování naměřených signálů dechové aktivity v této práci byla využita předdefinovaná funkce vývojového prostředí MATLAB. Ve funkci je nutné nastavit řád SG filtru a počet vzorků odpovídající jedné iteraci filtrace. K využití této metody byl nastaven řád filtru na hodnotu 3 a počet vzorků na hodnotu 999. Zvolené hodnoty byly vybrány na základě otestování několika dalších nastavení, přičemž v případě tohoto nastavení byly zajištěny

nejlepší výsledky. Je nutné zmínit, že v případě výběru počtu vzorků je důležité zadat číslo, které musí být vždy liché a zároveň nesmí být vyšší, než hodnota řádu filtru.

### 4.1.3 Vlnková transformace (WT)

Vlnkovou transformaci lze rozdělit na dvě hlavní skupiny: kontinuální vlnková transformace (CWT) a diskretní vlnková transformace (DWT). Nejpodstatnějším rozdílem mezi CWT a DWT je, že CWT má podstatně lepší schopnost převést spojitý signál na diskretní v tom ohledu, že převod je podstatně přesnější, než při použití DWT [44].

Vlnková transformace signálu  $x(t)$  je definovaná následujícím předpisem:

$$W_a x(t) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi \cdot \left( \frac{t-b}{\sqrt{a}} \right) dt, \quad a > 0, \quad (4.12)$$

kde  $\psi(t)$  představuje vlnkovou funkci,  $a$  představuje dilatační koeficient (definující měřítko) a daný krok translace  $b$  [42].

Signál  $x(t)$  je rozložen jako lineární kombinace translace škálovaných verzí zvolené škálovací funkce  $\phi(t)$  a derivované vlnkové funkce  $\psi(t)$  následovně:

$$x(t) = \sum_k c_{j_0 k} \cdot \phi_{jk}(t) + \sum_{j=j_0} \sum_k d_{jk} \cdot \psi(t), \quad (4.13)$$

kde  $j_0$  je libovolná startovací škála, přičemž první člen představuje aproximaci na škále  $j_0$  a druhý člen představuje sumu detailů [42].

Získávání aproximačních koeficientů  $c_{j_0 k}$  lze vyobrazit takto:

$$c_{j_0 k} = \int x(t) \cdot \phi_{j_0 k}^*(t) dt, \quad (4.14)$$

přičemž  $\phi_{j_0 k}$  je škálovací funkce, kterou lze předepsat následovně:

$$\phi_{j_0 k} = \frac{1}{\sqrt{2^{j_0}}} \cdot \phi \cdot \left( \frac{t-k \cdot 2^{j_0}}{2^{j_0}} \right) [42]. \quad (4.15)$$

Koeficienty detailů  $d_{j_0 k}$  jsou definovány následovně:

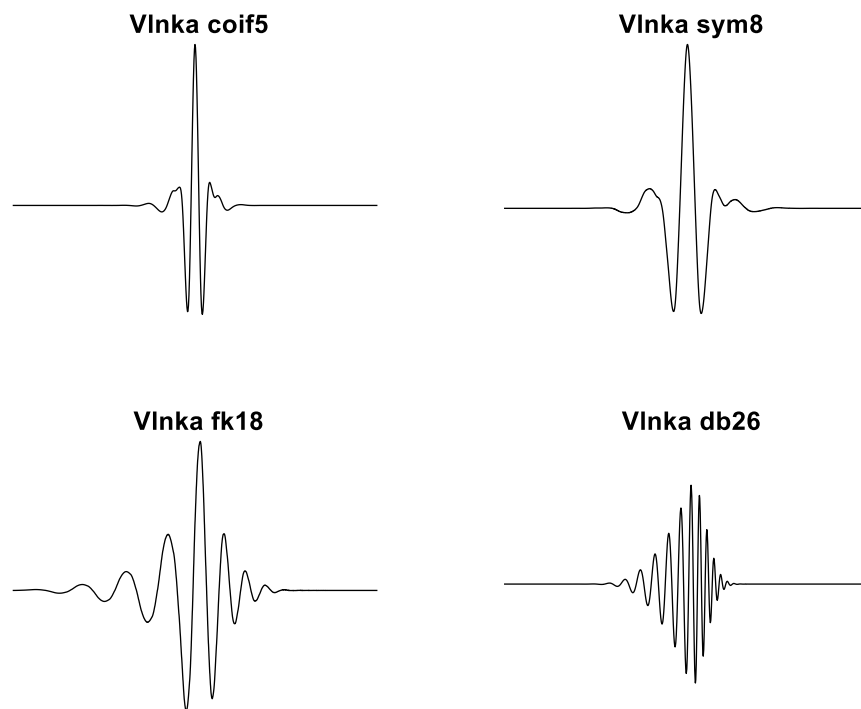
$$d_{j_0 k} = \int x(t) \cdot \phi_{jk}^*(t) dt, \quad (4.16)$$

kde  $\phi_{jk}$  představuje vlnkovou funkci, jenž je možné předepsat takto:

$$\phi_{jk} = \frac{1}{\sqrt{2^j}} \cdot \phi \cdot \left( \frac{t-k \cdot 2^j}{2^j} \right) [42]. \quad (4.17)$$

Metoda WT byla zajištěna využitím předdefinované funkce vývojového prostředí MATLAB, v níž musí být nastaven stupeň rozkladu a typ vlnky, která je následně v procesu použita. Funkce provádí rozklad signálu pomocí DWT. Otestováno bylo hned několik typů vlnek. Poměrně dobrých výsledků bylo docíleno při zvolení vlnky typu Fejer-Korovkinových vlnek (fk18, fk22), dále je možné použít při aplikaci na biosignály vlnky typu Coiflet (coif4, coif5) a vlnky typu Symlets (sym8, sym16,


sym32, sym38), přičemž všechny zmíněné vlnky byly schopny zajistit velmi podobné výsledky. Nejlepších výsledků bylo dosaženo zvolením vlnky typu Daubechies, kterých je namodelováno poměrně dost (db1 až db44). Zvolením vlnky db26 bylo dosaženo perfektních výsledků u všech naměřených signálů. Otestovány byly také vlnky db44, db39 a db31, které byly schopny zajistit u některých signálů ještě lepší výsledky, než zvolená vlnka db26, ale byla zjištěna jejich menší efektivita u jiných naměřených signálů. Zvolená vlnka db26 zajišťuje použitelnost u většiny signálů a tím pádem byla zahrnuta do hlavního algoritmu.



Obr.12: Zobrazení 4 typů vlnek.

Na Obr.12: jsou znázorněny 4 typy vlnek. K lepší ilustraci a představě, jak jednotlivé typy vlnek umí transformovat signál, je v softwarové aplikaci umožněna libovolná volba kterékoliv ze zmíněných vlnek.

Pro získání výsledků byl u metody WT zvolen stupeň rozkladu 9 pomocí vlnky typu Daubechies, konkrétně db26. Výběr tohoto nastavení spočíval v otestování výše zmíněných typů vlnek a několika stupňů rozkladu, přičemž při použití tohoto nastavení bylo dosaženo nejlepších výsledků.



Obr.13: Porovnání aplikace jednotlivých metod na signálu apnoe.

## 4.2 Kombinace metod

Pro robustní otestování zvolených metod byly vytvořeny jejich kombinace. Kombinace metod byly provedeny tak, že v každém případě byly využity pouze dvě z těchto metod.

### Empirická modální dekompozice + Savitzky-Golay filtr:


Kombinace těchto dvou metod byla provedena rozložením signálu pomocí EMD a následným součtem vybraných IMF. Výstup EMD byl dále přefiltrován pomocí SG.

### Vlnková transformace + Savitzky-Golay filtr:

Obdobně jako u předchozí kombinace, tak i v tomto případě byl signál nejprve zpracován pomocí WT a následně na něm byla aplikována metoda SG.

### Vlnková transformace + Empirická modální dekompozice:

U této kombinace byl signál nejprve zpracován WT a následně pomocí EMD. Kombinace je znázorněna a porovnána s jednotlivými metodami na Obr.14:.



Obr.14: Porovnání aplikace EMD, WT a jejich kombinace metod na signálu klidové vleže.

### 4.3 Algoritmus detekce nádechů a výdechů

Důležitou částí této práce je samotná extrakce nádechů. Algoritmus starající se o určování nádechů a výdechů musí fungovat s minimální chybovostí, což při použití u vyvíjeného optovláknového mřížkového senzoru nemusí být vždy jednoduché. Problém může nastat v případě, kdy jednotlivé amplitudy představující nádech obsahují nepřesnosti v podobě drobných amplitud, které by mohly být chybně detekovány jako nádechy. Tento problém má primárně řešit předzpracování signálu a následné použití pokročilé metody ke zpracování dat. Bohužel mohou nastat situace, při kterých se drobné nepřesnosti vyskytují i u signálu, který prošel kompletním zpracováním. Pro upřesnění jednotlivých funkcí a kroků detektoru byl vytvořen vývojový diagram na Obr.16:.

Prvním krokem detektoru je provedení klouzavého průměru o délce okna 300 vzorků vstupního signálu ke konečnému vyhlazení posledních možných nerovností, které by potenciálně mohly představovat významný problém při detekci nádechů a tím pádem by mohla být negativně ovlivněna přesnost celé metodiky. Druhým krokem algoritmu je zjištění délky signálu, podle které je signál následně rozdělen na kratší úseky, aby byla zajištěna lepší přesnost detekce. Tudíž pokud do detektoru vstupuje signál o délce například 2 minuty, funkce zajistí analýzu tohoto signálu po 20 sekundách. Tím, že je signál rozdělen na kratší úseky, může dojít k situaci, že na rozhraní mezi dvěma částmi signálu bude nádech, který tímto rozdělením nebude možné detekovat. Aby tento problém nenastal, signál byl ve stejném kroku rozdělen na ještě kratší úseky. Pokud tedy nastane zmíněný problém, při kterém nebude možné v krocích o délce  $l$  detekovat nádech, v kratších úsecích o délce  $l/2$  bude detekce možná (viz Obr.16:).

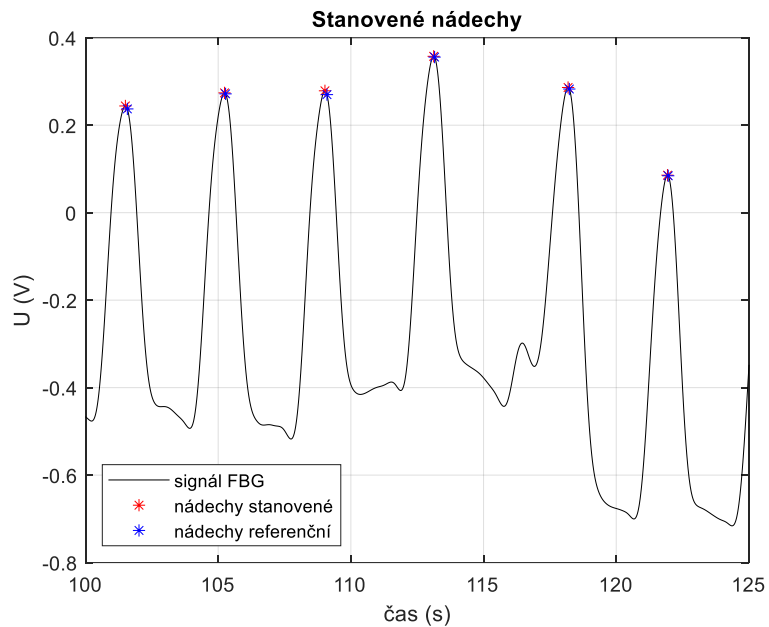
K samotné detekci nádechů je využita funkce *findpeaks*, která hledá lokální maxima v signálu. Funkce je vnořena do cyklu, aby probíhala pro jednotlivé úseky  $l$  a  $l/2$ . Dále jsou nastaveny podmínky, pomocí kterých má funkce *findpeaks* detekovat jednotlivé nádechy. Jednou z podmínek je minimální vzdálenost mezi jednotlivými nádechy a výdechy, který byla nastavena na 0,5 sekund z důvodu použitelnosti algoritmu pro detekci dýchání při mnoha situacích jako například zrychlené dýchání, při kterém je lidský organismus schopen učinit až 2 nádechy za sekundu, což bylo otestováno na signálu zrychleného dýchání. Dalším parametrem určujícím správně detekovaný peak je výtečnost peaku, která v podstatě pracuje s výškovým rozdílem mezi posledním lokálním minimem a aktuálním lokálním maximem (a nebo naopak), což zajistí eliminaci chybně detekovaných výdechů a nádechů.

Zmíněným rozdělením signálu na úseky o délce  $l$  a  $l/2$  by samozřejmě nastala další chyba v tom ohledu, že by na výstupu detektoru vznikaly duplicitní hodnoty. K eliminaci tohoto problému je do detektoru umístěn prvek, který je schopen detekovat duplicitní hodnoty a v případě pozitivního výsledku provést nahrazení těchto hodnot za prázdné pole, které je v dalším kroku vymazáno.

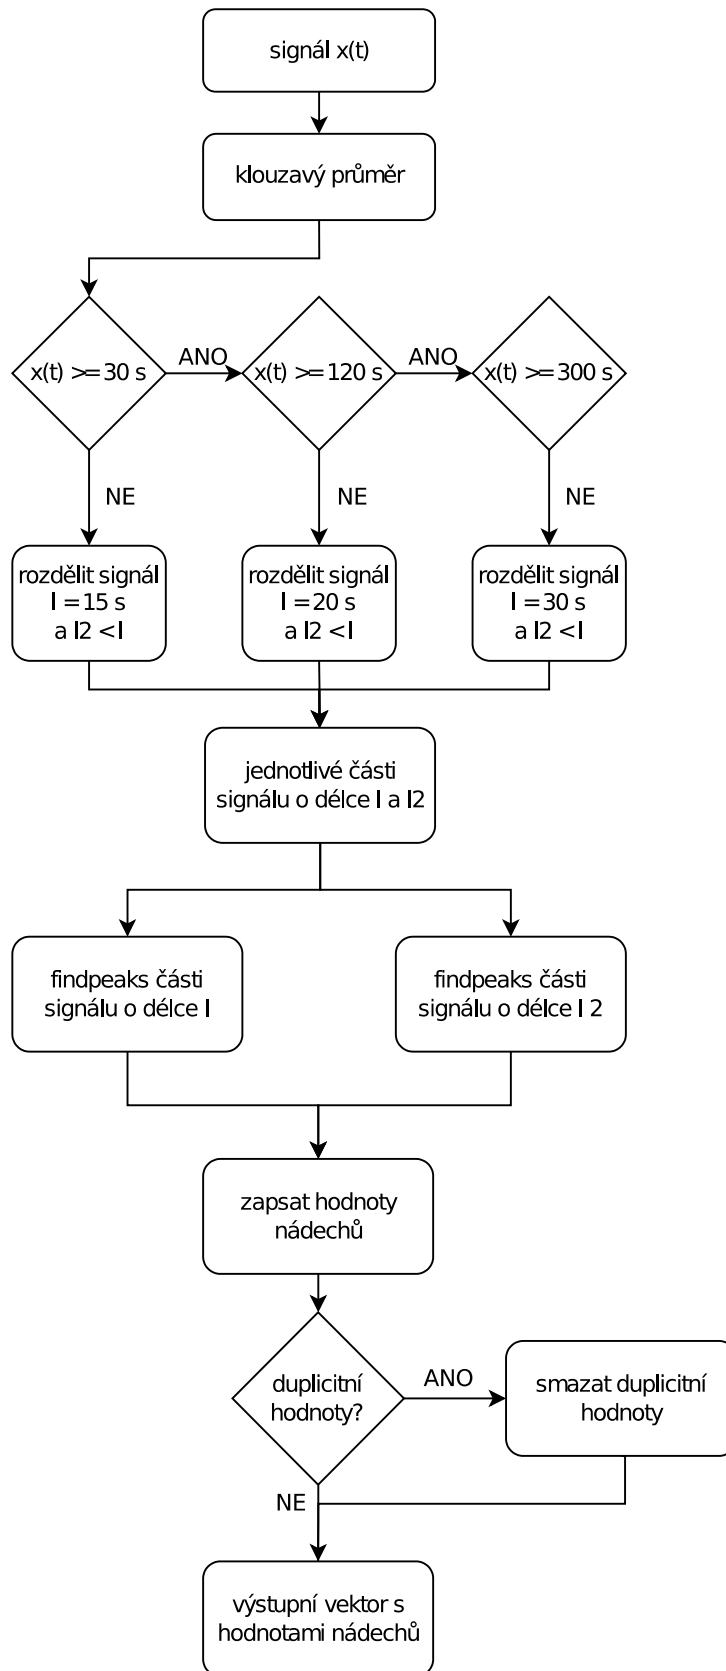
Hodnoty popisující časovou lokalitu jednotlivých nádechů jsou vloženy do vektoru, který bude následně porovnáván s vektorem, v němž jsou uloženy časové hodnoty referenčních nádechů algoritmem provádějícím hodnocení výsledků. Výsledek detekce nádechu je zaznamenán na Obr.15:.

### Klouzavý průměr:

Jedná se o funkci sloužící k vyhlazování signálů. V detektoru byla použita přímo funkce *movmean* patřící k vývojovému prostředí MATLAB. Vstupem této funkce je signál, který byl poslán do detektoru. Následně je potřeba nastavit počet vzorků definující délku okna, ze kterého bude následně vypočítán průměr (300 vzorků).



Obr.15: Grafické znázornění detekce nádechů.



Obr.16: Vývojový diagram detektoru nádechů.



## 4.4 Algoritmus hodnocení výsledků

Aby bylo možné ověřit správnost a efektivitu zpracování a následné analýzy dat, výsledná data z detektoru musí být porovnána s referenčními hodnotami. V první řadě jsou z algoritmu porovnávání výsledků získány hodnoty TP, FP a FN pomocí parametru tolerance  $k$ , který udává, že jednotlivé nádechy mohou mít odchylku oproti referenční hodnotě od  $-k$  až po  $k$  (ve vteřinách).

### **Skutečně pozitivní nádechy (TP):**

Jedná se o případ, kdy jsou výsledky pozitivně predikovány jako správné.

### **Falešně pozitivní nádechy (FP):**

Jedná se o případ, kdy je indikace pozitivního výsledku provedena nesprávně.

### **Falešně negativní nádechy (FN):**

Tento případ popisuje chybnou predikci nesprávného výsledku.

Na základě těchto tří možných typů hodnot je pomocí algoritmu vypočítáno několik statistických veličin popisujících správnost nebo chybovost sestavených algoritmů pro kompletní zpracování dat a jejich následnou analýzu provedenou detektorem nádechů a výdechů. Jedná se o veličiny ACC, SE, PPV a F1, přičemž v případě každé veličiny se jedná o procentuální výsledek.

### **Přesnost (ACC):**

Jedná se o jeden z hlavních statistických parametrů, pomocí kterého lze vyjádřit míru správnosti použité metodiky.

Přesnost lze vypočítat podle vztahu:

$$ACC = \frac{TP}{TP+FP+FN} \cdot 100 \quad [45]. \quad (4.18)$$

### **Senzitivita (SE):**

Senzitivita vyjadřuje schopnost detekovat skutečně pozitivní stav. Jedná o pravděpodobnost, že při detekci bude daný nádech správně detekován.

Senzitivitu popisuje následující vztah:

$$SE = \frac{TP}{TP+FN} \cdot 100 \quad [45]. \quad (4.19)$$

### **Pozitivní prediktivní hodnota (PPV):**

Tato veličina vyjadřuje pravděpodobnost, že výsledný nádech, který byl označen jako správně detekovaný, je opravdu správný.

$$PPV = \frac{TP}{TP+FP} \cdot 100 \quad [45]. \quad (4.20)$$

**Hodnota F1:**

Tato veličina představuje harmonický průměr mezi přesností a pozitivní prediktivní hodnotou.

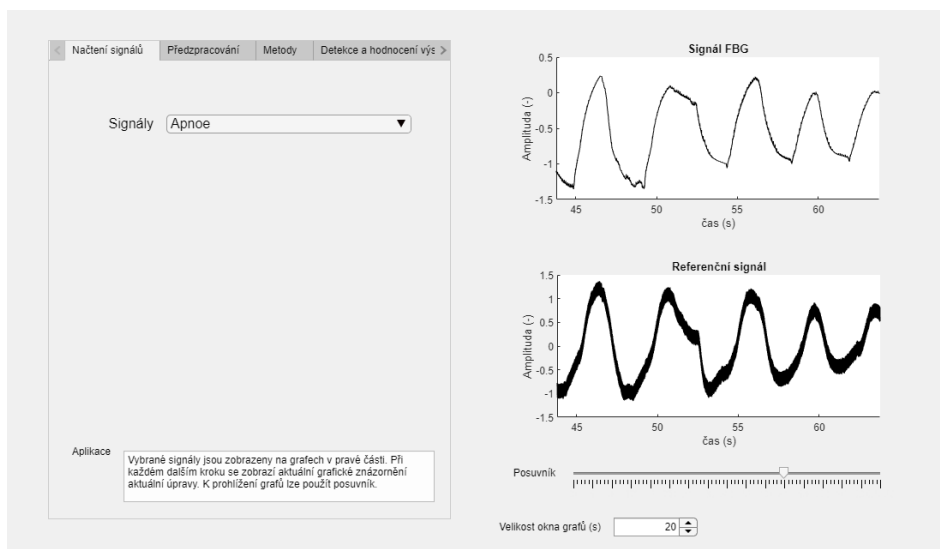
F1 lze popsat následující rovnicí:

$$F1 = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} \cdot 100 \quad [45]. \quad (4.21)$$

## 5 Softwarová aplikace

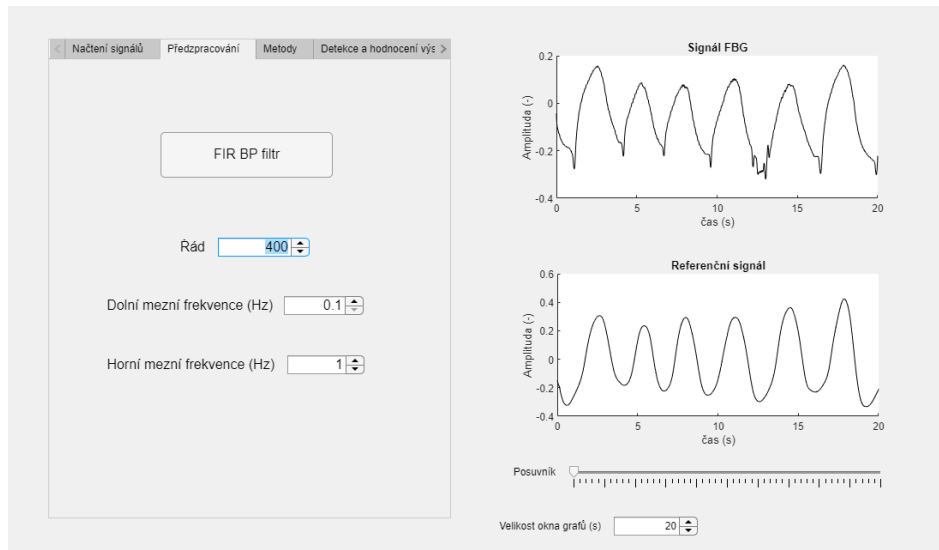
Dalším z cílů této práce byla tvorba uživatelského prostředí, které uživateli zajistí provedení načtení, předzpracování, zpracování a analýzu signálů s jejich následným hodnocením, tak aby bylo pro uživatele ovládání aplikace jednoduché a intuitivní. Softwarová aplikace byla vytvořena v rozhraní App Designer vývojového prostředí MATLAB. Uživatelské prostředí vytvořené aplikace je rozděleno na 2 hlavní segmenty. První částí je panel obsahující záložky příslušící každému kroku práce se signálem (načtení, předzpracování, zpracování, analýza, výsledky). Druhou částí je pak segment obsahující dva grafy a posuvník. Jak referenčnímu, tak i zkoumanému signálu náleží jeden graf, do kterého je vykreslován postupný průběh signálů (od načtení až po výsledné zobrazení nádechů). Poněvadž většina signálů má poměrně dlouhý průběh, pro přehlednost a lepší orientaci v grafech je v zobrazovacím segmentu aplikace situován posuvník, díky němuž je uživatel schopen jednoduše posouvat signály. Posuvník ovládá oba dva signály zároveň, aby bylo zajištěno porovnávání dat ve stejném časovém okamžiku na obou signálech. K nastavení velikosti okna, které bude v grafech vykresleno, bylo vytvořeno tlačítko, ve kterém lze upravovat rozsah časového okna.

V první záložce viz Obr.17: probíhá načtení signálů (zkoumaný signál, referenční signál, anotace-referenční hodnoty nádechů). Načtení signálů je provedeno seznamem, ve kterém jsou vypsané jednotlivé názvy signálů, přičemž při kliknutí na jakoukoliv možnost proběhne načítání celé příslušné sady. K zamezení možných chyb je nastaveno uzamčení všech částí aplikace, které jsou postupně zpřístupněny aplikací jednotlivých kroků (při načtení signálu je zpřístupněna možnost filtrace). Zároveň je zajištěno, aby se uživatel mohl vracet k předchozím krokům a mohl provést načtení například jiného signálu, nebo upravit hodnoty filtru.



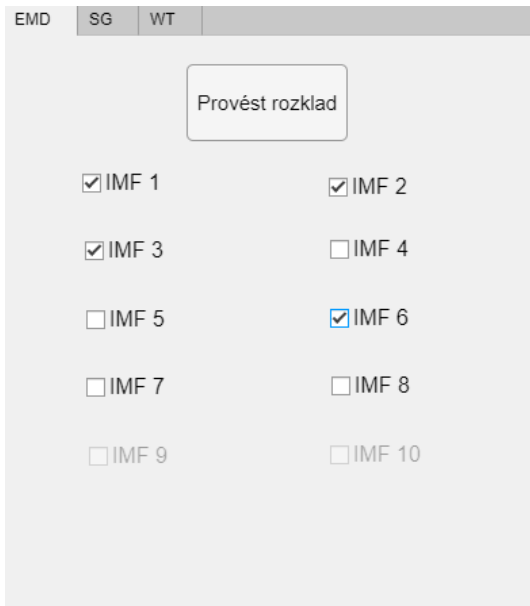
Obr.17: Načtení signálu v softwarové aplikaci.

Další záložka reprezentuje předzpracování zkoumaného signálu pomocí FIR bandpass filtru. Uživatel má možnost změnit hodnoty dolní a horní mezní frekvence a řádu filtru (viz Obr.18:). Pokud uživatel nezadá tyto hodnoty, proběhne filtrace charakterizovaná předdefinovanými hodnotami (frekvence 0.1 až 2 Hz a řád  $N=300$ ). Filtrace provedena uživatelským nastavením je aplikována pouze na FBG signál. Referenční signál má zajištěnu filtraci se stejným nastavením jako při tvorbě anotací. Provedením filtrace je dále zpřístupněna možnost aplikovat jednotlivé metody pokročilého zpracování signálů.

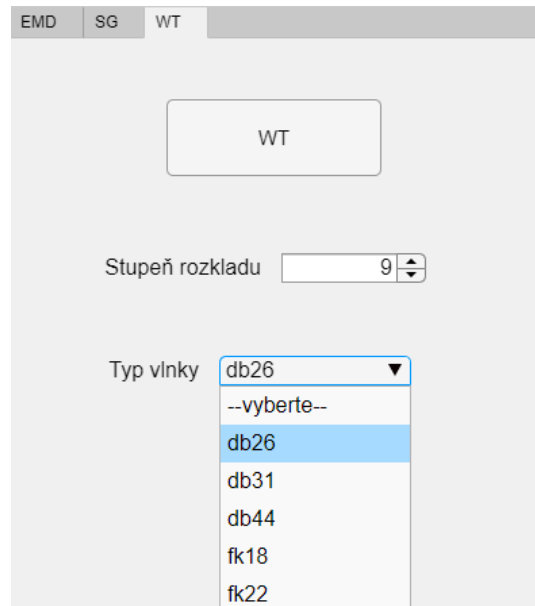


Obr.18: Náhled záložky předzpracování signálu v aplikaci.

Třetí záložka znázorněná na Obr.19: umožňuje výběr metody (nebo kombinace metod) pokročilého zpracování signálů. V případě EMD lze poskládat výsledný signál podle libovolné kombinace IMF. To se dá provést tak, že se nejprve klikne na tlačítko Provést rozklad, díky kterému jsou odemčena příslušná zaškrťávací pole příslušící jednotlivým IMF. Postupným výběrem IMF je do grafu postupně vypsán výsledný signál. U SG je uživatel oprávněn zadat řád SG a počet vzorků, na kterých mají jednotlivé iterace filtru proběhnout. V případě zvolení WT je umožněn výběr typu vlnky a stupeň vlnkového rozkladu. V případě SG a WT jsou opět nastaveny předdefinované hodnoty nastavení těchto metod.



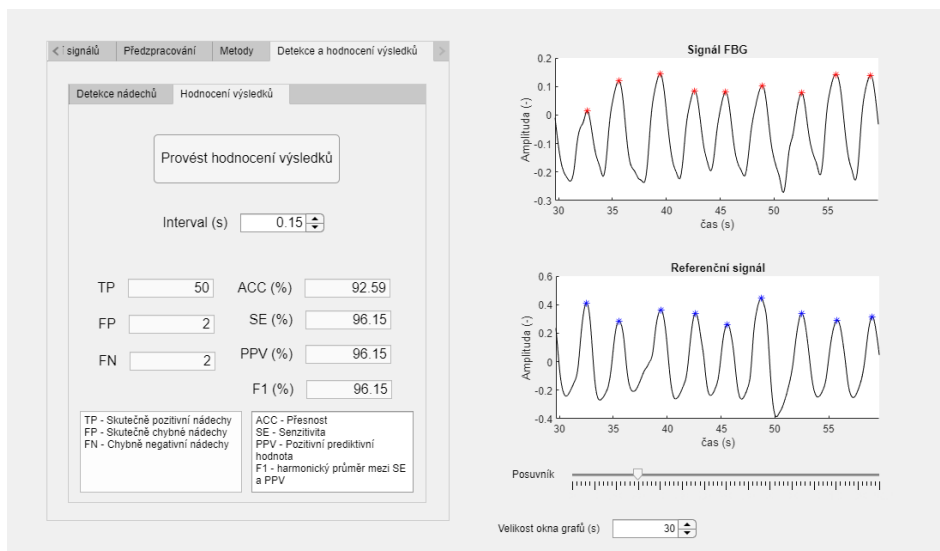
a) nastavení EMD



b) nastavení WT

Obr.19: Náhled záložky nastavení jednotlivých metod pokročilého zpracování signálu.

Poslední záložka obsahuje dva pododdíly. První pododdíl umožňuje uživateli provedení detekce nádechů. V druhém pododdílu jsou po stisknutí tlačítka detekované hodnoty nádechů porovnávány s referenčními. V dolní části aplikace jsou následně vypsány aktuální hodnoty TP, FP, FN, ACC, SE, PPV a F1. Součástí pododdílu hodnocení výsledků je také možnost upravit interval tolerance (viz Obr.20:).



Obr.20: Náhled pododdílu hodnocení výsledků.

## 6 Výsledky

Níže jsou umístěny tabulky, v nichž jsou zaznamenány výsledky pro jednotlivé statistické parametry ACC, SE, PPV a F1. Výsledky jsou rozděleny na 2 sekce po 4 tabulkách, přičemž první sekcí jsou charakterizovány jednotlivé metody EMD, SG a WT. V druhé části jsou vloženy rovněž 4 tabulky popisující jednotlivé hodnotící parametry pro kombinace jednotlivých metod.

### Výsledky jednotlivých metod pokročilého zpracování jednorozměrného signálu:

Tabulka 2: Přesnost jednotlivých metod.

Signál	Tolerance (s)	ACC (%)		
	Metoda	EMD	S-G	WT
Vleže klidové (1)	0,15	100	92,86	100
	0,20	100	100	100
Vleže klidové (2)	0,15	92,59	92,59	89,09
	0,20	96,23	96,23	96,23
Vleže klidové (3)	0,15	92,98	96,43	91,38
	0,20	96,43	96,43	94,74
Vleže klidové (4)	0,15	100	100	100
	0,20	100	100	100
Vsedě klidové (1)	0,15	93,55	93,55	93,55
	0,20	93,55	93,55	93,55
Vleže klidové (5)	0,15	78,95	88,89	78,95
	0,20	100	100	100
Vleže klidové (6)	0,15	87,88	93,75	87,88
	0,20	93,75	93,75	100
Vsedě klidové (2)	0,15	76,47	76,47	76,47
	0,20	100	100	100
Vsedě rychlé a zadržetí dechu	0,15	88	93,75	93,75
	0,20	91,84	93,75	93,75
Vsedě klidové (3)	0,15	96,61	100	100
	0,20	100	100	100
Vsedě rychlé	0,15	79,31	85,71	67,74
	0,20	100	100	92,59
Apnoe a hluboké	0,15	50	60	50
	0,20	60	60	60
Průměr	0,15	<b>86,36</b>	<b>89,50</b>	<b>85,73</b>
	0,20	<b>94,32</b>	<b>94,48</b>	<b>94,24</b>

Tabulka 2: zahrnuje výsledky přesnosti jednotlivých metod při aplikaci na několika signálech. Výsledky byly vygenerovány pro dvě různé hodnoty tolerance, kterou je definovaná maximální možná odchylka detekovaných nádechů od referenčních hodnot (například u tolerance 0,15 s je detekce pozitivního nádechu jako časová hodnota detekovaného nádechu  $\pm 0,15$  s). Na základě průměru přesnosti jednotlivých metod je jasně patrné, že zpracováním signálů dechové aktivity naměřené

optovláknovým mřížkovým senzorem pomocí metody SG bylo dosaženo nejlepších výsledků pro interval 0,15 s. Pro interval 0,2 s byla opět nejlepší metodou SG, ale výsledky pro všechny metody jsou velmi podobné

Tabulka 3: Senzitivita jednotlivých metod.

Signál	Tolerance (s)	SE (%)		
	Metoda	EMD	S-G	WT
Vleže klidové (1)	0,15	100	96,3	100
	0,20	100	100	100
Vleže klidové (2)	0,15	96,15	96,15	94,23
	0,20	98,08	98,08	98,08
Vleže klidové (3)	0,15	96,36	98,18	96,36
	0,20	98,18	98,18	98,18
Vleže klidové (4)	0,15	100	100	100
	0,20	100	100	100
Vsedě klidové (1)	0,15	96,67	96,67	96,67
	0,20	96,67	96,67	96,67
Vleže klidové (5)	0,15	88,24	94,12	88,24
	0,20	100	100	100
Vleže klidové (6)	0,15	93,55	96,77	93,55
	0,20	96,77	96,77	100
Vsedě klidové (2)	0,15	86,67	86,67	86,67
	0,20	100	100	100
Vsedě rychlé a zadržetí dechu	0,15	93,62	95,74	95,74
	0,20	95,74	95,74	95,74
Vsedě klidové (3)	0,15	98,28	100	100
	0,20	100	100	100
Vsedě rychlé	0,15	88,46	92,31	80,77
	0,20	100	100	96,15
Apnoe a hluboké	0,15	66,67	75	66,67
	0,20	75	75	75
Průměr	0,15	92,06	93,99	91,58
	0,20	96,70	96,70	96,65

Tabulka 3: obsahuje záznamy parametrů senzitivity pro 3 použité metody pokročilého zpracování signálu. Nejlepších výsledků dosáhla metoda SG. Při pohledu na interval tolerance 0,2 s je možné vidět, že metoda EMD dosahuje stejných výsledků jako SG.

Tabulka 4: Pozitivní prediktivní hodnota jednotlivých metod.4

Signál	Tolerance (s)	PPV (%)		
	Metoda	EMD	S-G	WT
Vleže klidové (1)	<b>0,15</b>	100	96,3	100
	<b>0,20</b>	100	100	100
Vleže klidové (2)	<b>0,15</b>	96,15	96,15	94,23
	<b>0,20</b>	98,08	98,08	98,08
Vleže klidové (3)	<b>0,15</b>	96,36	98,18	94,64
	<b>0,20</b>	98,18	98,18	96,43
Vleže klidové (4)	<b>0,15</b>	100	100	100
	<b>0,20</b>	100	100	100
Vsedě klidové (1)	<b>0,15</b>	96,67	96,67	96,67
	<b>0,20</b>	96,67	96,67	96,67
Vleže klidové (5)	<b>0,15</b>	88,24	94,12	88,24
	<b>0,20</b>	100	100	100
Vleže klidové (6)	<b>0,15</b>	93,55	96,77	93,55
	<b>0,20</b>	96,77	96,77	100
Vsedě klidové (2)	<b>0,15</b>	86,67	86,67	86,67
	<b>0,20</b>	100	100	100
Vsedě rychlé a zadržetí dechu	<b>0,15</b>	93,62	97,83	97,83
	<b>0,20</b>	95,74	97,83	97,83
Vsedě klidové (3)	<b>0,15</b>	98,28	100	100
	<b>0,20</b>	100	100	100
Vsedě rychlé	<b>0,15</b>	88,46	92,31	80,77
	<b>0,20</b>	100	100	96,15
Apnoe a hluboké	<b>0,15</b>	66,67	75	66,67
	<b>0,20</b>	75	75	75
<b>Průměr</b>	<b>0,15</b>	<b>92,06</b>	<b>94,17</b>	<b>91,61</b>
	<b>0,20</b>	<b>96,70</b>	<b>96,88</b>	<b>96,68</b>

Tabulka 4: vyobrazuje záznamy parametrů pozitivní prediktivní hodnoty pro 3 vybrané metody pokročilého zpracování signálu. Nejlepší výsledky pro interval tolerance 0,15 s zajišťuje metoda SG. Při zvýšení intervalu dosáhla metoda SG opět nejlepších výsledků.



Tabulka 5: Hodnota harmonického průměru mezi SE a PPV jednotlivých metod.

Signál	Tolerance (s)	F1 (%)		
	Metoda	EMD	S-G	WT
Vleže klidové (1)	0,15	100	96,3	100
	0,20	100	100	100
Vleže klidové (2)	0,15	96,15	96,15	94,23
	0,20	98,08	98,08	98,08
Vleže klidové (3)	0,15	96,36	98,18	95,49
	0,20	98,18	98,18	97,3
Vleže klidové (4)	0,15	100	100	100
	0,20	100	100	100
Vsedě klidové (1)	0,15	96,67	96,67	96,67
	0,20	96,67	96,67	96,67
Vleže klidové (5)	0,15	88,24	94,12	88,24
	0,20	100	100	100
Vleže klidové (6)	0,15	93,55	96,77	93,55
	0,20	96,77	96,77	100
Vsedě klidové (2)	0,15	86,67	86,67	86,67
	0,20	100	100	100
Vsedě rychlé a zadržetí dechu	0,15	93,62	96,77	96,77
	0,20	95,74	96,77	96,77
Vsedě klidové (3)	0,15	98,28	100	100
	0,20	100	100	100
Vsedě rychlé	0,15	88,46	92,31	80,77
	0,20	100	100	96,15
Apnoe a hluboké	0,15	66,67	75	66,67
	0,20	75	75	75
Průměr	0,15	92,06	94,08	91,59
	0,20	96,70	96,79	96,66

Tabulka 5: obsahuje hodnoty harmonického průměru mezi SE a PPV pro kombinace pokročilých metod zpracování signálů. Stejně jako u předchozích tabulek, i zde lze vidět, že pro oba intervaly tolerance, je metoda SG nejefektivnější. U výsledků pro interval 0,2 s zajistila metoda EMD také dobrých výsledků.

## Výsledky kombinací použitých metod pokročilého zpracování jednorozměrného signálu:

Tabulka 6: Přesnost pro kombinace metod.

Signál	Tolerance (s)	ACC (%)		
	Metoda	EMD+SG	WT+SG	WT+EMD
Vleže klidové (1)	0,15	100	92,86	100
	0,20	100	100	100
Vleže klidové (2)	0,15	92,59	89,09	92,59
	0,20	96,23	96,23	96,23
Vleže klidové (3)	0,15	96,43	96,43	92,98
	0,20	96,43	96,43	96,43
Vleže klidové (4)	0,15	100	100	100
	0,20	100	100	100
Vsedě klidové (1)	0,15	93,55	93,55	93,55
	0,20	93,55	93,55	93,55
Vleže klidové (5)	0,15	88,89	88,89	78,95
	0,20	100	100	100
Vleže klidové (6)	0,15	93,75	93,75	87,88
	0,20	93,75	93,75	100
Vsedě klidové (2)	0,15	76,47	76,47	76,47
	0,20	100	100	100
Vsedě rychlé a zadržetí dechu	0,15	91,84	93,75	95,83
	0,20	95,83	93,75	95,83
Vsedě klidové (3)	0,15	100	100	100
	0,20	100	100	100
Vsedě rychlé	0,15	100	92,59	67,74
	0,20	100	100	92,59
Apnoe a hluboké	0,15	50	60	47,06
	0,20	60	60	56,25
Průměr	0,15	90,29	89,78	86,09
	0,20	94,65	94,48	94,24

Tabulka 6: zahrnuje výsledky přesnosti pro kombinace metod pokročilého zpracování jednorozměrných signálů. Podle výsledků je patrné, že nejefektivnější kombinací metod je EMD + SG. Velké rozdíly v přesnosti pro jednotlivé intervaly tolerance lze zaznamenat u kombinace metod WT+SG. Zvýšením tolerance o 0,05 s bylo zajištěno výsledků o více než 8 % lepších. Podobný jev lze detekovat i u poslední kombinace metod WT+EMD, která ovšem i pro vyšší interval zajistila nejnižší přesnost detekce nádechů.

Tabulka 7: Senzitivita pro kombinace metod.

Signál	Tolerance (s)	SE (%)		
	Metoda	EMD+SG	WT+SG	WT+EMD
Vleže klidové (1)	0,15	100	96,3	100
	0,20	100	100	100
Vleže klidové (2)	0,15	96,15	94,23	96,15
	0,20	98,08	98,08	98,08
Vleže klidové (3)	0,15	98,18	98,18	96,36
	0,20	98,18	98,18	98,18
Vleže klidové (4)	0,15	100	100	100
	0,20	100	100	100
Vsedě klidové (1)	0,15	96,67	96,67	96,67
	0,20	96,67	96,67	96,67
Vleže klidové (5)	0,15	94,12	94,12	88,24
	0,20	100	100	100
Vleže klidové (6)	0,15	96,77	96,77	93,55
	0,20	96,77	96,77	100
Vsedě klidové (2)	0,15	86,67	86,67	86,67
	0,20	100	100	100
Vsedě rychlé a zadržetí dechu	0,15	95,74	95,74	97,87
	0,20	97,87	95,74	97,87
Vsedě klidové (3)	0,15	100	100	100
	0,20	100	100	100
Vsedě rychlé	0,15	100	96,15	80,77
	0,20	100	100	96,15
Apnoe a hluboké	0,15	66,67	75	66,67
	0,20	75	75	75
Průměr	0,15	94,25	94,15	91,91
	0,20	96,88	96,70	96,83

Tabulka 7: obsahuje parametry senzitivity pro 3 kombinace metod pokročilého zpracování signálu. Nejlepší výsledky zajišťuje kombinace metody EMD a SG. Podobně jako u výsledků charakterizujících přesnost, i u senzitivity lze vidět obdobnou situaci. Kombinace EMD+SG zajišťuje pro oba intervaly tolerance nejlepší výsledky. V porovnání s ostatními kombinacemi, se EMD+SG dostala s výsledky senzitivity v obou intervalech nad 94 %. Zbylé kombinace dosahují nepatrně odlišných výsledků pro interval 0,2 s.

Tabulka 8: Pozitivní prediktivní hodnota pro kombinace metod.

Signál	Tolerance (s)	PPV (%)		
	Metoda	EMD+SG	WT+SG	WT+EMD
Vleže klidové (1)	0,15	100	96,3	100
	0,20	100	100	100
Vleže klidové (2)	0,15	96,15	94,23	96,15
	0,20	98,08	98,08	98,08
Vleže klidové (3)	0,15	98,18	98,18	96,36
	0,20	98,18	98,18	98,18
Vleže klidové (4)	0,15	100	100	100
	0,20	100	100	100
Vsedě klidové (1)	0,15	96,67	96,67	96,67
	0,20	96,67	96,67	96,67
Vleže klidové (5)	0,15	94,12	94,12	88,24
	0,20	100	100	100
Vleže klidové (6)	0,15	96,77	96,77	93,55
	0,20	96,77	96,77	100
Vsedě klidové (2)	0,15	86,67	86,67	86,67
	0,20	100	100	100
Vsedě rychlé a zadržetí dechu	0,15	95,74	97,83	97,87
	0,20	97,87	97,83	97,87
Vsedě klidové (3)	0,15	100	100	100
	0,20	100	100	100
Vsedě rychlé	0,15	100	96,15	80,77
	0,20	100	100	96,15
Apnoe a hluboké	0,15	66,67	75	61,54
	0,20	75	75	69,23
Průměr	0,15	94,25	94,33	91,49
	0,20	96,88	96,88	96,35

Tabulka 8: zahrnuje výsledné parametry pozitivní prediktivní hodnoty pro 3 kombinace metod pokročilého zpracování signálu. Nejlepší výsledky zajišťuje kombinace metody WT+SG. Výsledky pro PPV dokazují, že všechny 3 kombinace dosahují citelně vyšší efektivity při intervalu 0,2 s.

Tabulka 9: Hodnota harmonického průměru mezi SE a PPV pro kombinace metod.

Signál	Tolerance (s)	F1 (%)		
	Metoda	EMD+SG	WT+SG	WT+EMD
Vleže klidové (1)	0,15	100	96,3	100
	0,20	100	100	100
Vleže klidové (2)	0,15	96,15	94,23	96,15
	0,20	98,08	98,08	98,08
Vleže klidové (3)	0,15	98,18	98,18	96,36
	0,20	98,18	98,18	98,18
Vleže klidové (4)	0,15	100	100	100
	0,20	100	100	100
Vsedě klidové (1)	0,15	96,67	96,67	96,67
	0,20	96,67	96,67	96,67
Vleže klidové (5)	0,15	94,12	94,12	88,24
	0,20	100	100	100
Vleže klidové (6)	0,15	96,77	96,77	93,55
	0,20	96,77	96,77	100
Vsedě klidové (2)	0,15	86,67	86,67	86,67
	0,20	100	100	100
Vsedě rychlé a zadržetí dechu	0,15	95,74	96,77	97,87
	0,20	97,87	96,77	97,87
Vsedě klidové (3)	0,15	100	100	100
	0,20	100	100	100
Vsedě rychlé	0,15	100	96,15	80,77
	0,20	100	100	96,15
Apnoe a hluboké	0,15	66,67	75	64
	0,20	75	75	72
Průměr	0,15	94,25	94,24	91,69
	0,20	96,88	96,79	96,58

Tabulka 9: obsahuje záznamy parametrů harmonického průměru mezi senzitivitou a pozitivní prediktivní hodnotou pro 3 kombinace metod pokročilého zpracování signálu. Nejlepší výsledky zajišťuje kombinace metody EMD a SG. Opět lze pozorovat citelné zlepšení pro interval tolerance 0,2 s.

Tabulka 10: Porovnání průměrných hodnot přesnosti mezi globálním nastavením a nastavením pro individuální signály.

Interval (s)	ACC (%)					
	Souhrnné nastavení			Individuální nastavení		
	0,10	0,15	0,20	0,10	0,15	0,20
<b>EMD</b>	63,99	86,36	94,32	63,99	86,36	94,32
<b>SG</b>	65,77	89,50	94,48	67,24	91,11	96,73
<b>WT</b>	65,63	85,73	94,24	66,91	91,71	97,36
<b>EMD+SG</b>	65,91	90,29	94,65	66,77	89,24	94,16
<b>WT+SG</b>	66,48	89,78	94,48	67,42	92,25	97,84
<b>EMD+WT</b>	65,20	86,09	94,24	65,93	91,89	97,22

Tabulka 10: slouží k porovnání přesnosti pro globální nastavení metod (pro všechny signály stejné) a přesnosti pro nastavení upraveného tak, aby zajistilo pro daný signál nejlepší hodnoty. Podrobné porovnání pro intervaly tolerance od 0,1 do 0,2 sekund s krokem 0,01 s je možné dohledat v souboru, který je součástí příloh. Individuální nastavení bylo provedeno na WT a SG pro ještě lepší otestování těchto metod pokročilého zpracování obrazu. Metoda EMD zůstala na globálním nastavení, aby bylo zjištěno, jaká z kombinací metod (EMD+SG a nebo EMD+WT) zajistí znatelně nejlepší výsledky. Pomocí globálního nastavení bylo zjištěno, že pro interval 0,15 s zajišťuje metoda SG nejuniverzálnější metodu, který zajišťuje průměrnou 89,5% přesnost a při intervalu 0,2 s byly zjištěny velmi podobné výsledky u všech 3 metod.


Při úpravě nastavení metody SG a WT pro konkrétní signály bylo docíleno velmi zajímavých výsledků. Jak je možné vidět v Tabulka 10:, pro všechny 3 zmíněné intervaly tolerance dosáhla nejlepších výsledků metoda WT. Na druhém místě je s také výbornými výsledky metoda SG. Co se týče kombinací metod, nejlepšího výsledku bylo docíleno pomocí WT, která byla následně přefiltrována SG filtrem, přičemž pro intervaly 0,15 a 0,2 s se jedná o metodu, která zajišťuje nejlepší výsledky. Druhou efektivní kombinací je EMD+WT, která zajistila při intervalech tolerance 0,15 a 0,2 s jen o něco málo nižší výsledky. U nejnižšího intervalu se naopak jednalo o nejeftivnější metodu.

## 7 Diskuse

Nejllepších výsledků při použití metody pokročilého zpracování signálu dosáhla jednoznačně metoda SG. Důvodem vysoké efektivity této metody může být několik. Prvním a pravděpodobně hlavním důvodem je samotný charakter metody. SG filtr umožňuje vyhlazování signálů s minimální transformací průběhu, která je poměrně razantní u metody WT, která je schopna změnit vzdálenosti mezi jednotlivými amplitudami. EMD je také schopna transformovat signál do podoby, která je k následující analýze takřka nepoužitelná. Důležité je ale zmínit, že SG filtr musí být také správně nastaven, protože pokud by se například při použití řádu filtru 2 nastavil počet vzorků zpracovaných jednou iterací filtru na příliš vysokou hodnotu (například 2000), pak by výstupem metody byl silně deformovaný signál, který by nezajistil dostatečně dobré výsledky. Velikou výhodou SG je fakt, že při použití metody na určitý typ signálů, v tomto případě se vždy jednalo o dechovou aktivitu, je tato metoda se stejným nastavením skoro stejně efektivní pro většinu signálů, což u ostatních dvou metod bylo podmíněno například určitým typem simulovaného charakteru dechu.

Pokud budou hodnotící parametry ignorovány ve smyslu toho, že výsledné nádechy nemusí vždy odpovídat hodnotícímu kritériu představeným časovou tolerancí, pak by byla metoda WT nejefektivnější v tom smyslu, že při použití správného nastavení pro daný signál by byla schopna vygenerovat nejkvalitnější signál. Velikou výhodou metody je to, že je signál rozkládán pomocí zvoleného typu vlnky, což ve výsledku spolu s použitím správného stupně rozkladu zajistí eliminaci artefaktů obsažených v signálech. Myšleny jsou například situace, kdy se vlnka odpovídající nádechu rozdělila před vrcholkem na dvě vlnky. U těchto artefaktů může nastat chybná detekce nádechů, pokud bude vzdálenost těchto dvou vlnek menší, než přednastavená hodnota v algoritmu detektoru. WT má tedy velkou výhodu oproti EMD v tom, že je schopna toto rozdělení vlnek eliminovat a vykreslit ukázkovou vlnku skutečně odpovídající jednomu nádechu.

Zajímavý efekt této metody lze zaznamenat na signálu simulace apnoe znázorněného na Obr.21:, kde lze vidět schopnost metody WT srovnat amplitudu, která má v tomto případě tendenci směřovat doprava. V grafu jsou zaznačeny referenční nádechy a nádechy před a po aplikaci WT. Důvodem, proč je v grafu znázorněna pouze jedna amplituda je, že při zahrnutí delší části signálu by bylo obtížné pozorovat tyto drobné, ale velmi důležité rozdíly. Celý signál je dlouhý přibližně 80 vteřin, přičemž prvních cca 40 vteřin probíhá simulace apnoe, po které následuje úsek zrychleného dýchání. Tento signál je skoro nemožné synchronizovat tak, aby nastala lokální maxima u obou signálů (referenční a zkoumaný) zároveň. Charakter vykreslování nádechu u optovláknového senzoru je v tomto případě naprosto rozdílný, oproti u referenčnímu signálu, poněvadž vlnky jsou vykreslovány s tendencí naklánění se napravo, což znamená, že lokální maxima jsou oproti referenčnímu signálu posunutá o náhodný čas. WT dokázala zajistit nejlepší výsledek při použití tolerance 0,2 s, protože dokázala transformovat některé amplitudy tak, aby se podobaly amplitudám referenčního signálu. Na základě tohoto faktu je nutné prohlásit, že WT je schopná zajistit vynikajících výsledků při přesném nastavení metody na konkrétní signál. Možným efektivním využitím této metody by mohla být aplikace na podobných signálech, jako je signál se simulací apnoe, tedy signál, jehož vykreslené amplitudy mohou být jistým způsobem deformovány.



Obr.21: Znárodnění schopnosti WT srovnat amplitudy v signálu apnoe.

Co se týče využití EMD, její efektivita vyšla o něco lépe, než v případě WT. Použitím této metody bylo dokázáno, že není až tak náchylná na charaktery signálů, bohužel ale ve srovnání se dvěma ostatními metodami, EMD generuje signál, který by mohlo být vhodné ještě nějakým způsobem zpracovat. Myšleno je to, že výsledkem SG a WT jsou signály, jejichž amplitudy jsou až na pár výjimek perfektně upravené. Řeč je o samotném vzhledu, protože výstupem WT a SG jsou ukázkově vyhlazené signály, které pokud jsou analyzovány algoritmem detektoru, nepředstavují pro tento algoritmus takřka žádný problém v tom ohledu, že by byl vrcholek chybně detekován. EMD má schopnost jisté nerovnosti eliminovat a tím zvýšit kvalitu signálu, ale bohužel tyto výhody jsou potlačeny tím, že metoda je zároveň schopna vytvořit nerovnosti tam, kde v původním signálu nebyly. To neznamená, že využitelnost této metody je nízká, protože i přes tyto problémy, které EMD vykazuje, bylo dosaženo velmi dobrých výsledků pro oba zvolené intervaly. Vhodné by bylo metodu ještě dále zkombinovat s nějakou vyhlazovací funkcí, například funkce *smooth*, ve které lze zvolit techniku vyhlazování. Je ale nutné dávat pozor na to, aby vyhlazovací funkce nezneškodila výsledný signál. Lepších výsledků tohoto typu metody by bylo určitě možné dosáhnout pomocí nastaveb EMD, kterými jsou například EEMD a nebo CEEMDAN, u kterých je v algoritmu již zahrnut například generátor šumu, jehož průběh je adaptivně generován v závislosti na vstupních datech a následně je tento šum opět eliminován. Na mysl je to, že pomocí vnoření adaptivního šumu do signálu, který je zrovna zpracováván pomocí EMD, lze dosáhnout znatelně lepších výsledků.

Aby byly všechny 3 metody otestovány co nejlépe, byly vytvořeny jednotlivé kombinace metod. Na základě uvedených výsledků v Tabulka 6: lze jednoznačně usoudit, že použití každé metody zajistilo výstup s poměrně dobrými výsledky. Nejlepších výsledků bylo dosaženo kombinací metody EMD a SG. Tato kombinace zajistila u většiny analyzovaných signálů přesnost vyšší, než 90 %, čímž ji lze objektivně prohlásit jako nejefektivnější kombinaci dříve diskutovaných metod. Spojením funkce EMD a SG filtru bylo provedeno dříve zmíněné vyhlazení EMD. Výsledkem kombinace těchto dvou metod je signál, jehož průběh je velmi podobný průběhu referenčního signálu.



Další kombinací je WT, jejíž signál je následně přefiltrován SG filtrem. Na základě výsledků lze říci, že touto kombinací byly zajištěny nepatrně lepší výsledky, než při použití samotné WT. Snížená přesnost samotné metody WT byla pomocí SG ovlivněna pouze jemně, poněvadž WT je sama o sobě schopná změnit vzdálenosti mezi jednotlivými amplitudami, což SG filtr není schopen kompenzovat.

Výsledky kombinace WT a EMD přinášejí zajímavé parametry. U signálu simulace apnoe lze vidět rozdíl oproti zpracování pomocí samostatných metod. V případě obou nastavení parametru tolerance dosáhla tato kombinace nižších výsledků, než při použití samotných metod. Nevhodnost této kombinace podporují i průměrné výsledky, ve kterých není zaznamenána vyšší efektivita oproti samotným metodám. Tato kombinace se neosvědčila ani při přesném nastavení jednotlivých metod na konkrétní signál. V Tabulka 6: je možné vidět, že kombinací EMD+SG byla snížena přesnost oproti aplikace samotné WT pro interval 0,2 s. U intervalu 0,15 s bylo použitím této kombinace docíleno naopak jemně lepších výsledků (obdobně jako u intervalu 0,1 s).

Důležitým aspektem ovlivňujícím efektivitu všech metod je v případě signálů z optovláknového senzoru délka a charakter onoho záznamu. Při synchronizaci zkoumaného a referenčního signálu bylo možné zpozorovat, že synchronizované signály se vždy v určitém časovém okamžiku rozdělily, čímž vznikly nepřesnosti při následném hodnocení výsledků. Nyní je řeč o signálech, ve kterých je možné zaznamenat několik artefaktů, které jsou představeny náhodným rozeběhnutím určitých vlnek ve zkoumaném signálu. U tohoto jevu je opět velmi důležité, jestli je metoda schopná onen jev eliminovat. Je ovšem nutné zdůraznit, že se tento aspekt týká pouze testovaného senzoru, poněvadž při kontrole jednotlivých vzdáleností mezi amplitudami referenčního signálu nebyly nalezeny rozdíly tak zásadní, jako tomu bylo u signálu z optovláknového senzoru.

Je velmi těžké definovat globální nastavení použitých metod pro všechny signály, ale i přes tuto komplikaci bylo u všech technik docíleno dobrých výsledků. Fakt, že prakticky každý signál má jiný charakter ve smyslu vykreslování jednotlivých amplitud, byl potvrzen provedením nastavení metod WT a SG pro každý konkrétní signál zvlášť. Tímto individuálním nastavením bylo docíleno výsledků řádově až o několik procent lepších, než tomu bylo u souhrnného nastavení. Podrobné výsledky pro každý signál lze nalézt v příloze. Například pro signál simulace apnoe, kde bylo u globálního nastavení docíleno přesnosti okolo 60 %, bylo pomocí individuálního nastavení docíleno přesnosti nad 90 % pro interval 0,2 s. U několika dalších signálů bylo docíleno podstatně lepších výsledků pro velmi nízké intervaly tolerance.

## Závěr

Technologie optických vláken dosahuje prakticky den ode dne lepších výsledků a jejich využití je stále posouváno do dalších oblastí. Optické senzory představují zajímavé parametry pro využití k získávání biosignálů v tom ohledu, že jejich funkce je poměrně jednoduchá a jejich finanční náročnost by neměla být velká. Technologie optických vláken má obrovský potenciál a pravděpodobně představuje budoucnost medicínského přístrojového vybavení.

Cílem této bakalářské práce bylo naměřit signály charakterizující několik možných dechových situací a tyto signály zpracovat pomocí metod k pokročilému zpracování signálů. Metody byly dále mezi sebou hodnoceny a implementovány do softwarové aplikace. Naměřené signály byly frekvenčně analyzovány pomocí FFT a na základě výsledného spektra byla namodelována příslušná metoda zajišťující předzpracování signálu. K tomu byl vybrán FIR filtr, který byl nastaven tak, aby zastával funkci digitálního bandpass filtru, který odfiltruje rušivé frekvence, které nenáleží nastavenému frekvenčnímu rozmezí. Předzpracované signály byly synchronizovány tak, aby byl eliminován posuv mezi jednotlivými signály a bylo možné získat co nejpřesnější anotace referenčních signálů, pomocí kterých byly v dalších bodech hodnoceny získané výsledky ze signálu naměřeném na optovláknovém senzoru. Následně byly namodelovány 3 metody pokročilého zpracování signálů. Vybrány byly metody EMD, SG a WT, které byly zároveň zkombinovány, aby bylo možné zajistit obsáhlejší objem výsledků k důslednému porovnávání mezi jednotlivými metodami a jejich kombinacemi. Signály zpracované pomocí jednotlivých metod a jejich kombinací byly analyzovány vytvořeným detektorem nádechů, který představuje dostatečné parametry ke správné detekci nádechů a zamezení chybných detekcí. Výsledné hodnoty, které byly získány pomocí detektoru byly následně porovnány algoritmem hodnocení výsledků a jednotlivé parametry byly vloženy do několika tabulek.

Dalším bodem zadání bylo vytvoření uživatelského prostředí, které umožňuje jednoduché načtení, předzpracování, zpracování signálů a následné hodnocení výsledků. Softwarová aplikace byla vytvořena pomocí programu MATLAB a zahrnuje obsáhlou možnost nastavení mnoha parametrů jak u předzpracování, tak především u aplikování pokročilých metod zpracování signálů.

Na základě výsledků je možné usoudit, že všechny vybrané metody a jejich kombinace lze aplikovat na signály dechové aktivity. Nejlepších výsledků dosahovalo využití SG filtru, jehož velká výhoda spočívá v tom, že je schopen vyhladit a zejména vyrovnat jednotlivá lokální maxima, která byla v originálním signálu nějakým způsobem deformována. Využití EMD vykazovalo také velmi dobrých výsledků a při testování kombinace EMD a SG bylo zjištěno, že SG filtr je schopen ještě dále vylepšit metodu EMD, přičemž rozdíl mezi samotnou EMD a kombinací s SG činil 3 %. WT dle výsledku vycházela jako nejméně efektivní metoda pro většinu signálů při globálním nastavení. U signálu simulace apnoe měla ovšem nejlepší výsledky, což přivádí myšlenku, že WT má potenciál k vyšší efektivitě oproti ostatním metodám u signálů, které jsou oproti referenčním signálům poměrně deformovány.

V rámci robustního testování bylo provedeno nastavení metod WT a SG pro jednotlivé signály. Díky specifickým nastavením pro jednotlivé signály bylo dosaženo ještě lepších výsledků, než při použití globálního nastavení. Nejlepších výsledků při tomto nastavení bylo možné dosáhnout pomocí WT. V případě kombinací se nejlépe osvědčila WT+SG, která při intervalu 0,2 s dosahovala téměř 98% úspěšnosti.

V této práci byl potvrzen potenciál využití optovláknových mřížkových senzorů jako alternativy ke stávajícím systémům pro snímání dechové aktivity. Při přesném nastavení algoritmu ke zpracování signálů je možné docílit dostatečně přesných výsledků pro využití tohoto senzoru ke sledování dechové aktivity. Veškeré cíle této práce byly splněny.

## Literatura

- [1] DUŠEK, Martin a Michal MAZANEC. *Fyzikální principy optických a optovláknových snímačů* [online]. Brno, 2012 [cit. 2022-01-05]. Dostupné z: [http://www.crr.vutbr.cz/offline/SYSTEM/FILES/BROZURA\\_06\\_1206.PDF](http://www.crr.vutbr.cz/offline/SYSTEM/FILES/BROZURA_06_1206.PDF). Učební texty. VUT.
- [2] MÜNSTRER, Petr. *PARAMETRY SÍŤÍ FTTX* [online]. Brno, 2014 [cit. 2022-01-05]. Dostupné z: [https://www.vut.cz/www\\_base/zav\\_prace\\_soubor\\_verejne.php?file\\_id=92876](https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=92876). Disertační práce. VUT. Vedoucí práce Prof. Ing. Miloslav Fialka, CSc.
- [3] ROUČA, Tomáš. *Limitující faktory optického vlákna na přenosovou kapacitu optických tras* [online]. Brno, 2010 [cit. 2021-10-30]. Dostupné z: [https://www.vut.cz/www\\_base/zav\\_prace\\_soubor\\_verejne.php?file\\_id=30808](https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=30808). Bakalářská práce. Vysoké učení technické v Brně. Vedoucí práce Ing. Pavel Reichert, Ph.D.
- [4] KOSTELANSKÝ, Michal. *Návrh vláknově optického senzoru na bázi Braggovské mřížky (FBG) pro měření tepové frekvence lidského těla* [online]. Ostrava, 2019 [cit. 2022-01-05]. Dostupné z: [https://dspace.vsb.cz/bitstream/handle/10084/136346/KOS0177\\_FEI\\_N2647\\_2601T013\\_2019.pdf?sequence=1&isAllowed=y](https://dspace.vsb.cz/bitstream/handle/10084/136346/KOS0177_FEI_N2647_2601T013_2019.pdf?sequence=1&isAllowed=y). Diplomová práce. VŠB-TUO. Vedoucí práce Ing. Jan Nedoma, Ph.D.
- [5] REICHL, Jaroslav a Martin VŠETIČKA. Úplný odraz světla. In: *Encyklopedie fyziky* [online]. 2006-2022 [cit. 2022-01-05]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/440-uplny-odraz-svetla>
- [6] REICHL, Jaroslav a Martin VŠETIČKA. Lom (refrakce) světla. In: *Encyklopedie fyziky* [online]. 2006-2022 [cit. 2022-01-05]. Dostupné z: <http://fyzika.jreichl.com/main.article/view/438-lom-refrakce-svetla>
- [7] PODSTAWKA, Pavel. *Vytvoření optické sítě pro nácvik měření* [online]. Ostrava, 2011 [cit. 2021-10-30]. Dostupné z: [https://dspace.vsb.cz/bitstream/handle/10084/87285/POD204\\_FEI\\_B2647\\_2612R059\\_2011.pdf?sequence=1](https://dspace.vsb.cz/bitstream/handle/10084/87285/POD204_FEI_B2647_2612R059_2011.pdf?sequence=1). Bakalářská práce. VŠB-TUO. Vedoucí práce Ing. Jan Skapa, Ph.D.
- [8] BURIAN, Tomáš. *Apodizace Braggových vláknových mřížek vyráběných UV expozicí přes fázovou masku* [online]. Brno, 2019 [cit. 2022-01-05]. Dostupné z: [https://www.vut.cz/www\\_base/zav\\_prace\\_soubor\\_verejne.php?file\\_id=191938](https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=191938). Diplomová práce. VUT. Vedoucí práce Doc. Ing. František Urban. CSc.
- [9] FAJKUS, Marcel. *Modelování optovláknových senzorů s Braggovskými mřížkami* [online]. Ostrava, 2017 [cit. 2022-01-05]. Dostupné z: <https://dspace.vsb.cz/handle/10084/127357>. Disertační práce. VŠB-TUO. Vedoucí práce Prof. RNDr. Vladimír Vašínek, CSc.
- [10] JIŘÍK, Dominik. *Snímač dechové frekvence – laboratorní úloha* [online]. Ostrava, 2019 [cit. 2022-01-05]. Dostupné z: [https://dspace.vsb.cz/bitstream/handle/10084/136187/JIR0095\\_FEI\\_B2649\\_3901R039\\_2019](https://dspace.vsb.cz/bitstream/handle/10084/136187/JIR0095_FEI_B2649_3901R039_2019).

- pdf?sequence=1&isAllowed=y. Bakalářská práce. VŠB-TUO. Vedoucí práce Doc. Ing. Marek Penhaker, Ph.D.
- [11] MITRENGOVÁ, Jana. *Metody odhadu dechové křivky z EKG signálu* [online]. Brno, 2019 [cit. 2022-01-05]. Dostupné z: [https://www.vut.cz/www\\_base/zav\\_prace\\_soubor\\_verejne.php?file\\_id=192971](https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=192971). Bakalářská práce. VUT. Vedoucí práce Ing. Martin Králík.
- [12] ROVNÁ, Tereza. *Program pro spirometrická měření* [online]. Brno, 2014 [cit. 2021-10-30]. Dostupné z: [https://www.vut.cz/www\\_base/zav\\_prace\\_soubor\\_verejne.php?file\\_id=86521](https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=86521). Bakalářská práce. Vysoké učení technické v Brně. Vedoucí práce Ing. Vratislav Harabiš, Ph.D.
- [13] SPÁČIL, Jakub. *OPTIMÁLNÍ DETEKCE HRANIC QRS KOMPLEXU V EKG SIGNÁLECH* [online]. Brno, 2010 [cit. 2021-11-28]. Dostupné z: <https://core.ac.uk/download/pdf/30297682.pdf>. Diplomová práce. VUT. Vedoucí práce Ing. Martin Vítek.
- [14] FOLKE, M. *A new capnograph based on an electro acoustic sensor* [online]. [cit. 2022-01-18]. Dostupné z: <https://link.springer.com/article/10.1007/s11517-007-0228-4>
- [15] RIEDL, Karel. *Alternativní metoda snímání dechového vzorce pro účely diagnostiky aktuálního kognitivního stavu operátora* [online]. Praha, 2020 [cit. 2022-01-18]. Dostupné z: [https://dspace.cvut.cz/bitstream/handle/10467/90364/F2-BP-2020-Riedl-Karel-Riedl\\_Bio.pdf?sequence=-1&isAllowed=y](https://dspace.cvut.cz/bitstream/handle/10467/90364/F2-BP-2020-Riedl-Karel-Riedl_Bio.pdf?sequence=-1&isAllowed=y). Bakalářská práce. ČVUT. Vedoucí práce Mgr. Ing. Jakub Jura, Ph.D.
- [16] Měření a zpracování biosignálů. In: *ALISI* [online]. [cit. 2022-01-18]. Dostupné z: <http://alisi.isibrno.cz/mereni-a-zpracovani-biosignalu>
- [17] MAREK, Jan. *Aplikace pro vizualizaci bio-signálů* [online]. Ostrava, 2014 [cit. 2021-11-27]. Dostupné z: [https://dspace.vsb.cz/bitstream/handle/10084/103732/MAR0337\\_FEI\\_N2647\\_2612T025\\_2014.pdf?sequence=1&isAllowed=y](https://dspace.vsb.cz/bitstream/handle/10084/103732/MAR0337_FEI_N2647_2612T025_2014.pdf?sequence=1&isAllowed=y). Diplomová práce. VŠB-TUO. Vedoucí práce Ing. Petr Gajdoš, Ph.D.
- [18] SCHWARZ, Daniel. *Analýza a modelování dynamických biologických dat* [online]. 2-3 [cit. 2022-01-08]. Dostupné z: [https://is.muni.cz/www/98951/41610771/43823411/43823458/Analyza\\_a\\_modelo/44257487/Bi0440-Schwarz-VJ04.pdf](https://is.muni.cz/www/98951/41610771/43823411/43823458/Analyza_a_modelo/44257487/Bi0440-Schwarz-VJ04.pdf)
- [19] SCHÄTZ, Martin a Aleš PROCHÁZKA. *Breathing analysis using MS Kinect* [online]. 1-7 [cit. 2022-01-08]. Dostupné z: [https://www.researchgate.net/profile/Ales-Prochazka/publication/285036183\\_Breathing\\_Analysis\\_Using\\_MS\\_Kinect/links/565aeb3408ae4988a7ba61fc/Breathing-Analysis-Using-MS-Kinect.pdf](https://www.researchgate.net/profile/Ales-Prochazka/publication/285036183_Breathing_Analysis_Using_MS_Kinect/links/565aeb3408ae4988a7ba61fc/Breathing-Analysis-Using-MS-Kinect.pdf)
- [20] L. KENNEDY, Hugh. *Improving the frequency response of Savitzky-Golay filters via colored-noise models* [online]. 2020, 1-9 [cit. 2022-01-08]. Dostupné z: [https://www.sciencedirect.com/science/article/pii/S1051200420300889?casa\\_token=9wZ6RvL9jmAAAAA:rNTB\\_wYIUzukVJ72spHnroNsDTGg\\_RCoJoBVgh3SFISydlczDXI\\_xvgTW27cX9FZjdp5UMujjGM](https://www.sciencedirect.com/science/article/pii/S1051200420300889?casa_token=9wZ6RvL9jmAAAAA:rNTB_wYIUzukVJ72spHnroNsDTGg_RCoJoBVgh3SFISydlczDXI_xvgTW27cX9FZjdp5UMujjGM)

- [21] BALLAL, Tarig. *Breathing Rate Estimation from a Non-Contact Biosensor Using an Adaptive IIR Notch Filter* [online]. Dublin, 2012, 1-4 [cit. 2022-01-08]. Dostupné z: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6172727>
- [22] NOVOTNÝ, Jiří. *FILTRACE SVALOVÉHO RUŠENÍ V EKG SIGNÁLECH* [online]. Brno, 2015 [cit. 2022-01-16]. Dostupné z: <https://core.ac.uk/download/pdf/30300026.pdf>. Diplomová práce. VUT. Vedoucí práce Ing. Lukáš Smital, Ph.D.
- [23] ISLAM, Shekh. *An Adaptive Filter Technique for Platform Motion Compensation in Unmanned Aerial Vehicle Based Remote Life Sensing Radar* [online]. 937-940 [cit. 2022-01-15]. Dostupné z: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9338011>
- [24] ŠAJNOVÁ, Lucie. *Využití adaptivního neuro-fuzzy inferenčního systému ve zpracování plodového EKG* [online]. Ostrava, 2018 [cit. 2022-01-17]. Dostupné z: [file:///C:/Users/marti/Downloads/SAJ0027\\_FEI\\_N2649\\_3901T009\\_2018.pdf](file:///C:/Users/marti/Downloads/SAJ0027_FEI_N2649_3901T009_2018.pdf). Diplomová práce. VŠB-TUO. Vedoucí práce Ing. Jaromír Konečný, Ph.D.
- [25] ŽIVČÁK, Jozef. *An Adaptive Neuro-Fuzzy Control of Pneumatic Mechanical Ventilator* [online]. 1-23 [cit. 2022-01-17]. Dostupné z: <https://www.mdpi.com/2076-0825/10/3/51/htm>
- [26] HORÁK, David. *DISKRÉTNÍ TRANSFORMACE* [online]. Ostrava, Plzeň, 2012 [cit. 2022-01-09]. Dostupné z: [https://mi21.vsb.cz/sites/mi21.vsb.cz/files/unit/diskretni\\_transformace.pdf](https://mi21.vsb.cz/sites/mi21.vsb.cz/files/unit/diskretni_transformace.pdf). Učební text. VŠB-TUO, ZČU.
- [27] ONDRYÁŠ, Ondřej. *Aplikace krátkodobé Fourierovy transformace pro biomedicínské signály – laboratorní úloha* [online]. Ostrava, 2019 [cit. 2022-01-15]. Dostupné z: [https://dspace.vsb.cz/bitstream/handle/10084/136211/OND0206\\_FEI\\_B2649\\_3901R039\\_2019.pdf?sequence=1](https://dspace.vsb.cz/bitstream/handle/10084/136211/OND0206_FEI_B2649_3901R039_2019.pdf?sequence=1). Bakalářská práce. VŠB-TUO. Vedoucí práce Ing. Jan Kubíček, Ph.D.
- [28] KREJČÍ, Michal. *FOURIEROVA TRANSFORMACE A SPEKTROGRAMY V ANALÝZE DNA SEKVENČÍ* [online]. Brno, 2011 [cit. 2022-01-15]. Dostupné z: <https://core.ac.uk/download/pdf/30298212.pdf>. Diplomová práce. VUT. Vedoucí práce Ing. Denisa Maděránková.
- [29] JAROŠ, René. *Neadaptivní metody zpracování plodového elektrokardiogramu* [online]. Ostrava, 2017 [cit. 2022-01-09]. Dostupné z: [https://dspace.vsb.cz/bitstream/handle/10084/119040/JAR0076\\_FEI\\_N2649\\_3901T009\\_2017.pdf?sequence=1&isAllowed=y](https://dspace.vsb.cz/bitstream/handle/10084/119040/JAR0076_FEI_N2649_3901T009_2017.pdf?sequence=1&isAllowed=y). Diplomová práce. VŠB-TUO. Vedoucí práce Ing. Radek Martinek, Ph.D.
- [30] BLAŽEK, Petr. *VLNKOVÁ TRANSFORMACE A CHARAKTERIZACE SIGNÁLŮ AKUSTICKÉ EMISE PRO SHLUKOVOU ANALÝZU* [online]. Brno, 2013 [cit. 2022-01-09]. Dostupné z: [https://www.vut.cz/www\\_base/zav\\_prace\\_soubor\\_verejne.php?file\\_id=69113](https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=69113). Bakalářská práce. VUT. Vedoucí práce Ing. Petr Sedlák, Ph.D.
- [31] VANĚK, Filip. *Detekce a analýza dechového cyklu ze signálu tlaku a průtoku* [online]. Praha, 2016 [cit. 2021-11-27]. Dostupné z: <https://dspace.cvut.cz/bitstream/handle/10467/67485/FBMI-DP-2016-Vanek-Filip->

Vanek\_Filip\_Diplomova\_prace.pdf?sequence=1. Diplomová práce. ČVUT. Vedoucí práce Ing. Jakub Ráfl Ph.D.

- [32] FLEMING, Sussanah a Lionel TERASSENKO. *A Comparison of Signal Processing Techniques for the Extraction of Breathing Rate from the Photoplethysmogram* [online]. 232-236 [cit. 2022-01-18]. Dostupné z: [https://www.researchgate.net/profile/L-Tarassenko/publication/228907148\\_A\\_Comparison\\_of\\_signal\\_processing\\_techniques\\_for\\_the\\_extraction\\_of\\_breathing\\_rate\\_from\\_the\\_photoplethysmogram/links/00463521ce4cc3ca4b000000/A-Comparison-of-signal-processing-techniques-for-the-extraction-of-breathing-rate-from-the-photoplethysmogram.pdf](https://www.researchgate.net/profile/L-Tarassenko/publication/228907148_A_Comparison_of_signal_processing_techniques_for_the_extraction_of_breathing_rate_from_the_photoplethysmogram/links/00463521ce4cc3ca4b000000/A-Comparison-of-signal-processing-techniques-for-the-extraction-of-breathing-rate-from-the-photoplethysmogram.pdf)
- [33] MIK, Šimon. *VÝPOČET OKAMŽITÉHO KMITOČTU* [online]. Brno, 2009 [cit. 2022-01-17]. Dostupné z: [https://www.vut.cz/www\\_base/zav\\_prace\\_soubor\\_verejne.php?file\\_id=15881](https://www.vut.cz/www_base/zav_prace_soubor_verejne.php?file_id=15881). Bakalářská práce. VUT. Vedoucí práce Ing. Radek Kubásek, Ph.D.
- [34] TŮMA, Jiří. *INŽENÝRSKÁ MECHANIKA 2005: TRANSMISSION ERROR MEASUREMENTS USING THE REAL TIME HILBERT TRANSFORMER* [online]. 1-4 [cit. 2022-01-17]. Dostupné z: <https://www.engmech.cz/improc/2005/Tuma-PT.pdf>
- [35] BARNOVÁ, Kateřina. *Hybridní metody pro extrakci plodového elektrokardiogramu* [online]. Ostrava, 2019 [cit. 2022-01-08]. Dostupné z: <https://dspace.vsb.cz/handle/10084/127358>. Diplomová práce. VŠB-TUO. Vedoucí práce Doc. Ing. Radek Martinek, Ph.D.
- [36] *NOVÉ METODY A POSTUPY V OBLASTI PŘÍSTROJOVÉ TECHNIKY, AUTOMATICKÉHO ŘÍZENÍ A INFORMATIKY* [online]. Praha, 2011 [cit. 2022-01-08]. Dostupné z: <http://www1.fs.cvut.cz/cz/u12110/vyzkum/Herbertov11.pdf#page=95>. Sborník odborného semináře. ČVUT.
- [37] PROCHÁZKA, Petr. *ODSTRAŇOVÁNÍ KOLÍSÁNÍ IZOLINIE V EKG POMOCÍ EMPIRICKÉ MODÁLNÍ DEKOMPOZICE* [online]. Brno, 2015 [cit. 2022-01-08]. Dostupné z: <https://dspace.vutbr.cz/bitstream/handle/11012/38909/final-thesis.pdf?sequence=8&isAllowed=y>. Diplomová práce. VUT. Vedoucí práce Ing. Alena Kubíčková.
- [38] GARDE, A. *Empirical Mode Decomposition for Respiratory and Heart Rate Estimation from the Photoplethysmogram* [online]. 1-4 [cit. 2022-01-08]. ISSN 2325-8861. Dostupné z: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6713498>
- [39] ORPHANIDOU, Christina. *Derivation of respiration rate from ambulatory ECG and PPG using Ensemble Empirical Mode Decomposition: Comparison and fusion* [online]. 1-10 [cit. 2022-01-16].
- [40] MARUŠIAK, Ondrej. *Empirická dekompozícia režimov a jej aplikácie v hydrológii* [online]. Bratislava, 2015 [cit. 2022-01-18]. Dostupné z: [https://fmph.uniba.sk/fileadmin/fmfi/studium/autoreferaty/AR\\_Marusiak.pdf](https://fmph.uniba.sk/fileadmin/fmfi/studium/autoreferaty/AR_Marusiak.pdf). Autoreferát dizertační práce. Univerzita Komenského v Bratislavě. Vedoucí práce Doc. RNDr. Ján Pekár, Ph.D.

- [41] AREKAT, Safwan. *Mathematical Techniques for Digital Filtering FIR Filter Symmetry Theory* [online]. 2021, 2-5 [cit. 2022-04-20]. Dostupné z: <file:///C:/Users/marti/Downloads/FIRFilterSymmetryTheory.pdf>
- [42] LABATE, Domenico. Empirical Mode Decomposition vs. Wavelet Decomposition for the Extraction of Respiratory Signal from Single-Channel ECG: A Comparison. *IEEE SENSORS JOURNAL* [online]. 2013, **2013**(7), 2666-2672 [cit. 2022-04-18]. Dostupné z: <https://ieeexplore.ieee.org/abstract/document/6497470>
- [43] DE OLIVEIRA, Mario A. *Use of Savitzky–Golay Filter for Performances Improvement of SHM Systems Based on Neural Networks and Distributed PZT Sensors: Savitzky-Golay filter* [online]. 1-6 [cit. 2022-04-15]. Dostupné z: <https://www.mdpi.com/1424-8220/18/1/152/htm>
- [44] *Continuous and Discrete Wavelet Transforms* [online]. MathWorks [cit. 2022-04-30]. Dostupné z: <https://ch.mathworks.com/help/wavelet/gs/continuous-and-discrete-wavelet-transforms.html>
- [45] BARNOVA, Katerina, Radek MARTINEK, Rene JAROS a Radana KAHANKOVA. Hybrid Methods Based on Empirical Mode Decomposition for Non-Invasive Fetal Heart Rate Monitoring. *IEEE Access* [online]. 2020, **8**, 51200-51218 [cit. 2022-04-30]. ISSN 2169-3536. Dostupné z: [doi:10.1109/ACCESS.2020.2980254](https://doi.org/10.1109/ACCESS.2020.2980254)



## Přílohy

Ve složce *výsledky* se nachází dva soubory programu Excel. V jednom souboru se nachází tabulky s výsledky jednotlivých metod pro intervaly tolerance 0,1; 0,15 a 0,2 s. Druhý soubor obsahuje kompletní výsledky s tolerancemi od 0,1 do 0,2 s o mezikroku 0,01 s. Na úvodním listu souboru s kompletními výsledky se nachází dvě tabulky s průměrnými hodnotami ze všech signálů. V souboru jsou na každém listu vždy dvě tabulky. První obsahuje hodnoty při aplikaci globálního nastavení metod pro všechny signály a druhá tabulka obsahuje výsledky získané na základě individuálního nastavení metod na aktuální signál. Každé nastavení je vypsáno nad příslušnou tabulkou.

Součástí příloh jsou zároveň jednotlivé signály, zdrojové kódy, funkce a softwarová aplikace. Přílohy jsou vloženy v elektronické podobě společně s celou prací v systému EDISON. Pro spuštění softwarové aplikace je nutná instalace *Wavelet Toolbox* a vložení složky *signály* do složky obsahující aplikaci.