


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ  
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH  
TECHNOLOGIÍ  
ÚTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION  
DEPARTMENT OF BIOMEDICAL ENGINEERING

## PŘEDZPRACOVÁNÍ TACHOGRAMU R-R INTERVALŮ PREPROCESSING OF R-R INTERVAL TACHOGRAM

BAKALÁŘSKÁ PRÁCE  
BACHELOR'S THESIS

AUTOR PRÁCE  
AUTHOR

Filip Had

VEDOUCÍ PRÁCE  
SUPERVISOR

Ing. ALENA KUBIČKOVÁ



VYSOKÉ UČENÍ  
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

Ústav biomedicínského inženýrství

# Bakalářská práce

bakalářský studijní obor

Biomedicínská technika a bioinformatika

**Student:** Filip Had

**ID:** 155574

**Ročník:** 3

**Akademický rok:** 2014/2015

## NÁZEV TÉMATU:

**Předzpracování tachogramu R-R intervalů**

## POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši v oblasti předzpracování tachogramu R-R intervalů pro tvorbu signálů variability srdečního rytmu (HRV). 2) Zaměřte se na odstranění trendu, potlačení falešné detekce R vln a ektopických cyklů. 3) Vyberte na základě rešerše teoreticky nejvhodnější přístup pro předzpracování tachogramu. 4) Vybraný přístup realizujte v prostředí MATLAB a použijte ho k předzpracování poskytnutých signálů. 5) Vypracujte studii shrnující a diskutující výsledky práce.

## DOPORUČENÁ LITERATURA:

[1] SO

**Termín zadání:** 9.2.2015

**Termín odevzdání:** 29.5.2015

**Vedoucí práce:** Ing. Alena Kubičková

**Konzultanti bakalářské práce:**

**prof. Ing. Ivo Provazník, Ph.D.**

*Předseda oborové rady*

## UPOZORNĚNÍ:

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

## **ABSTRAKT**

Variabilita srdečního rytmu (HRV) je parametr, sledující proměnlivost časových intervalů mezi jednotlivými srdečními systolami. Signál HRV obsahuje artefakty a trendy, které je nutno před zpracováním odstranit. Tato bakalářská práce obsahuje stručné informace o zpracování signálu HRV a EKG, dále se věnuje popisu nejčastěji využívaných metod, pro předzpracování signálu variability srdečního rytmu. Práce obsahuje krátké zhodnocení jednotlivých metod. Dále jsou realizovány a popsány víceré uvedené algoritmy pro předzpracování signálu HRV. Poslední částí je testování naprogramovaných algoritmů na generovaných datech, jejich zhodnocení a následná ukázka na datech reálných.

## **KLÍČOVÁ SLOVA**

Variabilita srdečního rytmu, EKG signál, Trend HRV, artefakt HRV, metody detrendingu

## **ABSTRACT**

Heart rate variability (HRV) is a parameter, which monitors variability of the time intervals between consecutive heart beats. Signal HRV contains artefacts and trends, which is necessary to remove before further processing. This work contains a brief information about the HRV and ECG signal processing. Further on the most frequently methods of heart rate variability preprocessing are described. The work includes a brief assessment of each method. Further on, several of the mentioned preprocessing algorithms are realized and described in this work. The last part is testing an evaluating of programmed algorithms on generated data and then demonstration on real data.

## **KEYWORDS**

Heart rate variability, ECG signal, HRV trend, HRV artifact, detrendig methods

HAD, F. *Předzpracování tachogramu R-R intervalů*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2015. 55 s. Bakalářská práce. Vedoucí práce Ing. Alena Kubičková.

# PROHLÁŠENÍ

Prohlašuji, že svou bakalářskou práci na téma předzpracování tachogramu R-R intervalů jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne .....

.....

podpis autora

# PODĚKOVÁNÍ

Děkuji vedoucí mé bakalářské práce Ing. Aleně Kubičkové za odbornou pomoc a poskytnutí cenných rad při zpracování mé bakalářské práce .

V Brně dne .....

.....

podpis autora

# OBSAH

Úvod.....	1
1 Elektrokardiogram.....	2
1.1 Vlny EKG .....	2
1.2 Intervaly EKG.....	3
2 Variabilita srdečního rytmu.....	4
2.1 Interpretace HRV .....	4
2.2 Vlivy ovlivňující HRV.....	6
2.2.1 Vnitřní faktory ovlivňující HRV .....	6
2.2.2 Vnější faktory ovlivňující HRV .....	6
3 Analýza HRV .....	7
3.1 Analýza v časové oblasti.....	7
3.1.1 Statistické metody .....	7
3.1.2 Geometrické metody .....	7
3.2 Analýza ve frekvenční oblasti.....	8
3.2.1 Frekvenční oblasti spektra.....	8
3.2.2 Hodnocení spektrální analýzy .....	8
3.3 Trendy vyskytující se v HRV .....	9
4 Metody detrendingu .....	12
4.1 Metoda SPA.....	12
4.2 Metoda EMD .....	13
4.3 Metoda vlnkové transformace .....	14
5 Falešné detekce a ektopické cykly .....	16
5.1 Vyhledání artefaktů v HRV .....	16
5.2 Náhrada artefaktů v HRV .....	18
6 Výběr nejvhodnějšího předzpracování.....	21
7 realizace algoritmů .....	23
7.1 Algoritmus metody empirického rozkladu (EMD).....	23
7.2 Popis algoritmů pro vyhledání artefaktů HRV .....	24
7.2.1 Algoritmus a .....	25
7.2.2 Algoritmus b.....	26
7.2.3 Algoritmus c .....	26
7.2.4 Algoritmus d.....	26
7.2.5 Algoritmus e .....	26

7.2.6	Algoritmus f.....	27
7.3	Algoritmy pro náhradu detekovaného artefaktu .....	27
7.3.1	Nahrazení pomocí lineárního splajnu .....	28
7.3.2	Nahrazení pomocí kubického splajnu .....	29
7.3.3	Nahrazení pomocí mediánu .....	29
7.3.4	Nahrazení pomocí náhodného prvku z okolí.....	29
7.3.5	Vynechání vzorku s artefaktem .....	29
8	Testování algoritmů .....	30
8.1	Detekce artefaktů v tachogramu .....	30
8.1.1	Detekce artefaktů v signálu s lineárním trendem .....	30
8.1.2	Detekce artefaktů v signálu s Gaussovským trendem .....	31
8.1.3	Detekce artefaktů v signálu s hrotovým trendem .....	32
8.1.4	Detekce artefaktů v signálu se zlomovým trendem.....	33
8.1.5	Závěrečné hodnocení algoritmů pro detekci artefaktů .....	34
8.2	Náhrada artefaktů v tachogramu.....	36
8.2.1	Náhrada pomocí lineárního splajnu.....	38
8.2.2	Náhrada pomocí kubického splajnu .....	38
8.2.3	Náhrada pomocí mediánu z okolí.....	39
8.2.4	Náhrada pomocí náhodného prvku z okolí artefaktu .....	40
8.2.5	Úprava signálu pomocí vynechání prvku s artefaktem .....	41
8.2.6	Závěrečné zhodnocení algoritmů pro odstranění artefaktů .....	42
8.3	Odstranění trendu pomocí metody EMD.....	43
8.3.1	Odstranění lineárního trendu .....	43
8.3.2	Odstranění Gaussovského trendu .....	45
8.3.3	Odstranění hrotového trendu .....	46
8.3.4	Odstranění Zlomového trendu.....	47
8.3.5	Závěrečné zhodnocení odstranění trendu pomocí EMD .....	49
8.4	Testování vybraného postupu .....	49
9	závěr .....	52
	Literatura .....	54

# SEZNAM OBRÁZKŮ

Obr. 1 – Ideální EKG křivka s vyznačenými vlnami.....	2
Obr. 2 – Ideální EKG křivka s vyznačenými intervaly.....	3
Obr. 3 – Zobrazení tachogramu 10 s EKG .....	4
Obr. 4 – Interpolace intervalového tachogramu .....	5
Obr. 5 – Výkonové spektrum signálu HRV v logaritmickém měřítku.....	9
Obr. 6 – Typy jednotlivých trendů .....	11
Obr. 7 – Vygenerovaný tachogram pomocí MS Excel s ektopickými cykly .....	17
Obr. 8 – Vygenerovaný tachogram pomocí MS Excel s chybějící detekcí vlny .....	18
Obr. 9 – Metoda nahrazování chybných RR intervalů pomocí mediánu.....	19
Obr. 10 – Metoda nahrazování chybných intervalů pomocí náhodné hodnoty z okolí..	20
Obr. 11 – Vývojový diagram metody EMD .....	24
Obr. 12 – Vývojový diagram pro detekci artefaktů .....	25
Obr. 13 – Vývojový diagram pro náhradu artefaktů.....	28
Obr. 14 – Detekce artefaktů na signálu s lineárním trendem.....	30
Obr. 15 – Detekce artefaktů na signálu s Gaussovským trendem .....	32
Obr. 16 – Detekce artefaktů na signálu s hrotovým trendem .....	33
Obr. 17 - Detekce artefaktů na signálu se zlomovým trendem.....	34
Obr. 18 – Aplikované algoritmy na reálných datech .....	35
Obr. 19 – EKG signál v pozicích artefaktů.....	36
Obr. 20 – Originální signál s artefakty .....	37
Obr. 21 – Výkonové spektrum originálního signálu bez artefaktů.....	37
Obr. 22 – Náhrada artefaktů pomocí lineárního splajnu.....	38
Obr. 23 – Náhrada artefaktů pomocí kubického splajnu .....	39
Obr. 24 – Náhrada artefaktů pomocí mediánu z okolí.....	40
Obr. 25 – Náhrada artefaktů pomocí náhodného prvku z okolí.....	41
Obr. 26 – Úprava signálu vynecháním artefaktů .....	42
Obr. 27 – Spektrum a průběh tachogramu s lineárním trendem.....	43
Obr. 28 – Signály s odstraněným lineárním trendem .....	44
Obr. 29 – Výkonová spektra signálů s odstraněným lineárním trendem.....	44
Obr. 30 – Spektrum a průběh tachogramu s Gaussovským trendem.....	45

Obr. 31 – Signály s odstraněným Gaussovským trendem .....	45
Obr. 32 – Výkonová spektra signálu s odstraněným Gaussovským trendem.....	46
Obr. 33 – Spektrum a průběh tachogramu s hrotovým trendem.....	46
Obr. 34 – Signály s odstraněným hrotovým trendem. ....	47
Obr. 35 – Výkonová spektra signálu s odstraněným hrotovým trendem.....	47
Obr. 36 – Spektrum a průběh tachogramu se zlomovým trendem .....	48
Obr. 37 – Signály s odstraněným zlomovým trendem.....	48
Obr. 38 – Výkonová spektra s odstraněným zlomovým trendem.....	49
Obr. 39 – Výstup z řídicího skriptu pro generovaný signál.....	50
Obr. 40 – Srovnání signálu bez trendu a artefaktů a výsledného signálu ze skriptu .....	50
Obr. 41 – Výsledek skriptu pro náhodně vybraný reálný signál .....	51

# SEZNAM TABULEK

Tabulka 1 - Průměrná relativní chyba ve spektrální analýze .....	21
Tabulka 2 - Senzitivita, specificita a přesnost předchozích uvedených algoritmů .....	22
Tabulka 3 – Statistické hodnoty při detekci artefaktů při lineárním trendu .....	31
Tabulka 4 - Statistické hodnoty při detekci artefaktů při Gaussovském trendu .....	32
Tabulka 5 - Statistické hodnoty při detekci artefaktů při hrotovém trendu .....	33
Tabulka 6 - Statistické hodnoty při detekci artefaktů při zlomovém trendu .....	34
Tabulka 7 – Statistické hodnoty při detekci artefaktů po zprůměrování .....	35
Tabulka 8 – Statistické hodnoty při detekci artefaktů bez trendu.....	35
Tabulka 9 – Relativní chyby odstranění artefaktů v pásmech HF a LF .....	43

# ÚVOD

Bakalářskou práci lze rozdělit do 3 částí. První část se věnuje teoretickému rozboru jednotlivých vln a impulzů EKG, následně analýzou a zhodnocením signálů variability srdečního rytmu (HRV – heart rate variability). Dále je zde teoretický rozbor trendů, včetně jejich konkrétních druhů, vyskytujících se v signálech HRV a jejich následné odstranění pomocí 3 nejčastěji využívaných metod, kterými jsou přiblížení předešlé hladkosti (SPA - smoothness prior approach), metoda empirického rozkladu (EMD-empirical mode decomposition) a odstranění pomocí vlnkové transformace. Dále je zde teoretická část zabývající se principy šesti algoritmů pro detekci artefaktů, které se vyskytují v signálech HRV a jejich následné odstranění pomocí pěti různých metod.

Druhá část bakalářské práce obsahuje popisy jednotlivých realizovaných programů, které slouží k předzpracování tachogramu. Na základě teoretického posouzení nejlepší metody pro odstranění trendu byla realizována a popsána metoda EMD. Vzhledem k nejednoznačným výsledkům posouzení kvality algoritmů pro vyhledávání artefaktů je v práci popsáno všech 6 algoritmů. Co se týká algoritmů odstranění artefaktů, není nikde jejich posouzení kvality, z toho důvodu je všech 5 metod v práci popsáno.

Třetí, poslední část obsahuje testování naprogramovaných algoritmů na především uměle generovaných datech. Posouzení kvality algoritmů probíhalo v případě detekce artefaktu ze statistického hlediska, které bylo možné snadno vypočítat, dále v případě odstranění artefaktu odečtením spekter výsledného a originálního signálu bez artefaktů a jako poslední způsob posouzení kvality sloužilo vizuální porovnání spekter a výsledných signálů s originálním signálem bez trendu. Na konci práce je určen postup nejvhodnější kombinace algoritmů, které byly v bakalářské práci uvedeny.

# 1 ELEKTROKARDIOGRAM


Elektrokardiogram (dále EKG), znázorňuje signál akčního napětí, šířícího se po myokardu, v závislosti na čase. EKG se skládá z několika úseků, impulzů a vln, které budou v této kapitole dále rozebírány. Akční potenciál (AP) vzniká v sinoatriálním (SA) uzlu, který bývá označován jako primární pacemaker. Funkci sekundárního pacemakeru v patologických stavech přebírá atrioventrikulární (AV) uzel.[1]

## 1.1 Vlny EKG

První vlna, objevující se na elektrokardiogramu, se **označuje P**. Tato vlna vzniká při depolarizaci pravé a levé síně a většinou má pozitivní polaritu. Amplituda vlny P většinou nepřekročí hodnotu  $300 \mu\text{V}$  a doba trvání nepřesahuje  $0,12 \text{ s}$ . Dále se AP šíří na atrioventrikulární uzel, přičemž dochází k žádoucímu zpomalení šíření.[1][2]

Jako další se v EKG objevuje **komplex QRS**, který svědčí o depolarizaci komor, přičemž doba trvání tohoto komplexu bývá mezi  $0,07 \text{ s}$  a  $0,11 \text{ s}$ . První negativní výchylka se značí jako **vlna Q**, následuje nejvyšší **vlna R** a po ní opět negativní výchylka značená jako **S**. Jelikož je QRS nejvýraznější částí EKG, může dosahovat amplituda vlny R až jednotek mV. Díky této vlastnosti se právě QRS komplex nejčastěji využívá pro automatizované detektory tepu, či pro tvorbu tachogramu.[1][2]

Následuje **vlna T**, která svědčí o repolarizaci komor. Tvar, doba i umístění této vlny je značně variabilní v závislosti na tepové frekvenci. Vyskytuje se do  $0,3 \text{ s}$  za komplexem QRS. Vlna T by měla mít stejnou polaritu jako nejvyšší kmit v komplexu QRS. V některých případech se za vlnou T objevuje další vlna označovaná jako **U**, jedná se zřejmě o odraz pozdější fáze repolarizace komor [1][2]. Na Obr. 1 jsou vyznačeny jednotlivé vlny.



Obr. 1 – Ideální EKG křivka s vyznačenými vlnami

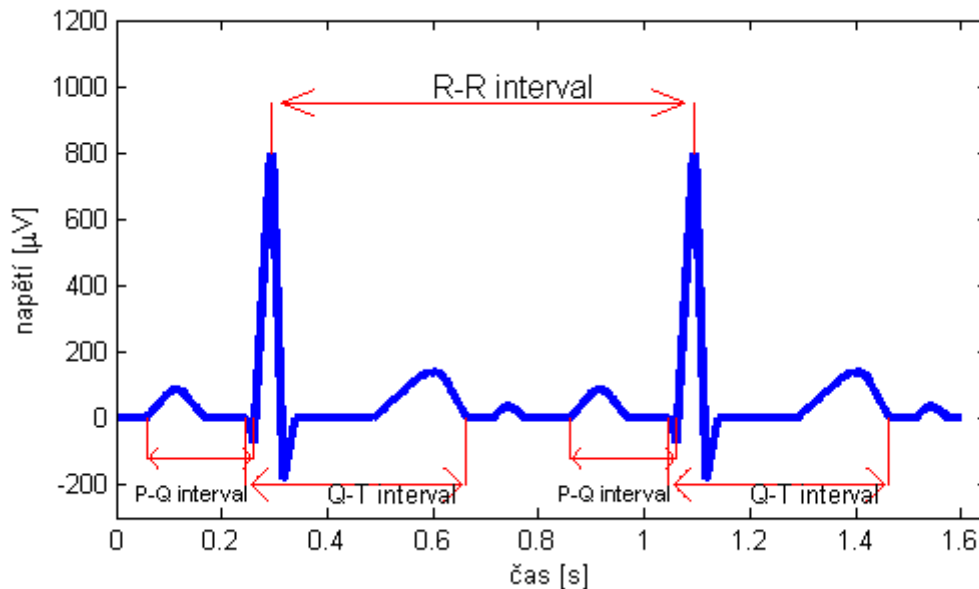
## 1.2 Intervaly EKG

**Interval RR** - jedná se o dobu trvání jednoho srdečního cyklu. Tento interval je základní veličinou, využívanou při každém typu analýzy. Určuje se podle něho tepová frekvence srdce a variabilita srdečního rytmu, z níž se dají zjistit různé srdeční arytmie.[1]

**Interval PQ** je interval od začátku vlny P (síňové depolarizace) do začátku komorové depolarizace (QRS komplexu). Určuje rychlost šíření akčního potenciálu přes komory a následné zpomalení na atrioventrikulárním uzlu.[1]

**Interval QT** informuje době trvání časového úseku trvání komorové depolarizace a její repolarizace. Tento interval je silně závislý na tepové frekvenci, přičemž s rostoucí tepovou frekvencí se zužuje. Výrazné prodloužení může vést ke vzniku komorových arytmií, které mohou způsobit náhlou srdeční smrt. [1]

Grafické zobrazení zmíněných intervalů jsou na Obr. 2




Obr. 2 – Ideální EKG křivka s vyznačenými intervaly

## 2 VARIABILITA SRDEČNÍHO RYTMU

Variabilita srdečního rytmu (dále HRV – heart rate variability), je signál, vyjadřující proměnlivost doby mezi jednotlivými systolami srdce, který vypovídá o aktivitě sinusového uzlu. Nejčastěji se hodnotí ze signálu EKG, jelikož obsahuje komplex QRS, který je poměrně snadno detekovatelný. HRV je možné detekovat i z jiných signálů, například z fonokardiogramu či tlakové křivky. [1]

### 2.1 Interpretace HRV


Pokud signál hodnotí pouze člověk, je vhodné mít tento signál reprezentovaný ve formě neekvidistantních hodnot, které jsou přehledné a pokud máme pod sebou samotný EKG signál a tachogram HRV, jsme schopni se v něm lépe orientovat. Pokud ale chceme zpracovávat počítačově, je vhodnější mít signál jako intervalový tachogram, ze kterého je počítač schopen lépe odhadovat například falešné detekce, či ektopické cykly. Existuje další způsob, kterým se HRV interpretuje a to je interpolovaná intervalová funkce. Tato interpretace je vhodná zejména pokud chceme provádět spektrální analýzu, nebo detrendování. [1]



Obr. 3 – Zobrazení tachogramu 10 s EKG [6]

Na Obr. 3 jsou znázorněné dva možné způsoby zobrazení HRV, přičemž  $n$  značí

vzorek signálu EKG a  $t$  značí čas v sekundách. Dále  $d_{IT}$  (intervalový tachogram) obsahuje hodnoty rozdílu dvou po sobě jdoucích systol ( $d_{IT}=t_i-t_{i-1}$ ), kde  $i$  značí pořadí aktuálního vzorku signálu HRV. Jako poslední popisná proměnná je  $d_{IF}$  (intervalová funkce), která obsahuje rovněž rozdíly dvou po sobě jdoucích systol, avšak v závislosti na čase  $t$ . Pokud bychom vzali originální EKG a signál  $d_{IF}$ , dostali bychom zobrazení, které je vhodné pro vizuální hodnocení člověkem. Signál  $d_{IT}$  zobrazuje právě intervalový tachogram se zachovanou ekvidistantností, tento signál se dále upraví na  $d_{IF}$  a následně interpoluje pomocí různých metod. Na Obr. 4 je zobrazen způsob interpolace pomocí kubického a lineárního splajnu.



Obr. 4 – Interpolace intervalového tachogramu [3]

První část obrázku nám zobrazuje EKG křivku s detekovanými R-vlnami, které mají mezi sebou časové rozestupy  $t_n$ , další část zobrazuje intervalový tachogram, který je v poslední části obrázku pozměněn na intervalovou funkci, která je interpolovaná lineárním (čárkovaně) a kubickým (tečkovaně) splajnem. [3]

## 2.2 Vlivy ovlivňující HRV

HRV je jedním z nejčastěji zjišťovaných parametrů srdce. Hodnotí se nejčastěji z Holterovského signálu, který se snímá kontinuálně po 24, nebo 48 hodin. Jelikož vyšetřovaný pacient dělá všechny činnosti jako každý jiný den, vyskytují se v signálu různé artefakty, které HRV ovlivňují.

### 2.2.1 Vnitřní faktory ovlivňující HRV

Tepová frekvence srdce je ovlivňovaná aktivitou autonomního nervového systému, i vlivem dýchání.

Aktivita **parasympatického** nervu snižuje tepovou frekvenci a tím i sílu srdeční kontrakce. Přenos je zprostředkován acetylcholinem, který zpomaluje atrioventrikulární převod a snižuje vzrušivost myokardu.[4][5]

Naopak aktivitou **sympatiku**, se tepová frekvence zvyšuje a zároveň s ní síla srdeční kontrakce. Přenos je zprostředkován noradrenalinem, který způsobuje zrychlení atrioventrikulárního převodu a zvyšuje vzrušivost myokardu. [4]

Zejména v karotidě a v aortě se nacházejí **baroreceptory**, které zaznamenávají krevní tlak v těchto cévách a právě signály těchto mechanoreceptorů aktivují, nebo inhibují sympatikus, nebo naopak parasympatikus, který dále řídí tepovou frekvenci. [4]

Jako další vnitřní, a zároveň pro vyšetření nejdůležitější faktor, který může ovlivnit HRV je **ischemická choroba srdeční (ICHS)**. Jedná se o jedno z nejčastějších a nejzávažnějších onemocnění. Jedná se o ischemii myokardu, která může vznikat v klidu, nebo při námaze, když jsou zvýšené požadavky organismu na dodávku kyslíku. Téměř vždy je příčinou ICHS ateroskleróza a jako sekundární příčiny mohou být přítomny embolie, záněty či spazmy tepen. Pod pojmem ischemická choroba srdeční se dá pochopit spektrum poruch od anginy pectoris, přes infarkt myokardu po náhlou srdeční smrt. [5]

### 2.2.2 Vnější faktory ovlivňující HRV

Tepová frekvence lidského těla je regulována i podle vnějšího prostředí. Například při svalové zátěži je nutno pro tělo zvýšit rychlost proudění krve, aby svaly měli dostatek kyslíku.[6]

Za další vnější faktor, který ovlivňuje HRV, se dá považovat psychická zátěž, protože lidské tělo na stresové situace reaguje zvýšením tepové frekvence. Dále je třeba brát při vyšetření ohled na počasí, teplotu nebo hluk okolo pacienta. Téměř všichni lidé nevědomě reagují na počasí mírnou změnou tepové frekvence a to zejména kvůli tlaku, množství kyslíku ve vzduchu apod. Pokud je pacientovi chladno, může mít svalový třes, který zvyšuje nároky na kyslík, tudíž zvyšuje tepovou frekvenci. Je-li kolem pacienta hluk způsobí to značný neklid, který se také může projevit změnou tepové frekvence.[6]

## 3 ANALÝZA HRV

HRV se dá analyzovat různými způsoby, právě protože každá situace vyžaduje jinou oblast zájmu, která z některé analýzy nemusí být patrná. Analýzu HRV se dá rozdělit do tří oblastí: časová oblast, frekvenční oblast a časově-frekvenční oblast. [7]

### 3.1 Analýza v časové oblasti

Analýza HRV v časové oblasti patří mezi nejjednodušší. Stejně jako většina metod se i tato zakládá na informaci o době, která uplynula mezi dvěma R-R intervaly sinusového původu (značený NN – Normal-to-Normal). Interval sinusového původu se pozná z EKG křivky – QRS komplexu musí předcházet vlna P. Parametry, které se zjišťují v časové oblasti, se dají rozdělit na dvě podskupiny a to statistické metody, ve kterých se určuje například střední hodnota nebo směrodatná odchylka a geometrické metody u kterých se hodnotí například histogram nebo Poincarého mapy. [7]

#### 3.1.1 Statistické metody

Abychom dostali statisticky významná data, používají se intervaly NN, které byly naměřeny nejčastěji během 24 hodin. Statistické metody se dají rozdělit do dvou tříd a to:  $[a]$  odvozené z přímého měření NN intervalů nebo okamžité tepové frekvence a  $[b]$  odvozené z rozdílů mezi dvěma NN intervaly. [7]

Jedním ze statistických parametrů je **střední hodnota**, která nám příliš neřekne, ale je nutná pro výpočet významnějšího údaje a tím je **směrodatná odchylka** (SDNN – standard deviation of the NN interval). Jelikož směrodatná odchylka je matematicky rovna celkovému výkonovému spektru, SDNN odráží v sobě všechny periodické komponenty, zodpovědné za variabilitu. Jelikož SDNN je silně závislá na délce záznamu, mohou ve výpočtech vznikat značné odchylky, z tohoto důvodu se směrodatné odchylky sledují na záznamech normované délky.

Dále se počítá směrodatná odchylka průměrných NN intervalů z 5 minutových úseků za 24 hodin, která se značí **SDANN** (standard deviation of the average NN interval) a nebo SDNN index, který se počítá jako průměr z 5 minutových standardních odchylek intervalů vypočítaných za 24 hodin.[7]

Jako další statistická metoda se využívá **RMSSD**, která počítá odmocninu průměru kvadrátů diferencí sousedících intervalů NN a dále **NN50** – tato metoda nás informuje o počtu párů sousedících intervalů NN lišících se o více než 50ms a **pNN50** nám dává informaci o procentuálním počtu NN intervalů spadajících do NN50.[6]

#### 3.1.2 Geometrické metody

Jako další možnost analýzy v časové oblasti, je zobrazení NN intervalů v geometrickém schématu. Nejčastěji se jedná o zobrazení **histogramu**, který se hodnotí z různých hledisek. Jako první hledisko se určuje šířka histogramu nad daným prahem, jako další kritérium hodnocení se určuje tvar, kterým je možno histogram aproximovat a jako poslední, geometrický tvar, rozdělený do několika tříd, které reprezentují různé typy HRV. Hodnoty intervalů NN bývají v histogramu

diskretizovány s frekvencí 128 Hz, tj 7,8125 ms.

Často využívanou aproximací je právě aproximace pomocí trojúhelníku, u níž je nejdůležitější znát hodnoty  $X$  – nejčastější interval NN,  $Y$  – maximum histogramu,  $N$  a  $M$  – hodnota intervalů při základnách trojúhelníku, z nichž se dají počítat údaje, jako je trojúhelníkový index HRV nebo TINN – triangulární interpolace NN intervalového histogramu.[7]

Jako další často využívanou geometrickou metodou je metoda nelineární a jsou to **Poincarého mapy**, které zobrazují fluktuace  $NN_{i+1}$  proti  $NN_i$ . Na Poincarého mapách se hodnotí směrodatné odchylky ve směrech os na sebe kolmých, přičemž hlavní osa odpovídá hodnotám identickým  $NN_{i+1}=NN_i$ . Právě ze směrodatných odchylek jsme schopni vyčíst sinusovou arytmií, či dlouhodobou variabilitu. Tato metoda se využívá nejčastěji pro studium spánkových stádií.[6]

## 3.2 Analýza ve frekvenční oblasti

Pokud chceme provádět frekvenční analýzu je vhodné intervalovou funkci interpolovat většinou kubickým splajnem se vzorkovací frekvencí 4 Hz. Po interpolaci můžeme provést spektrální analýzu, ve které rozlišujeme 3 pásma: pásmo vysokých kmitočtů HF (high frequency) (0,4 až 0,15 Hz), pásmo nízkých kmitočtů LF (low frequency) (0,15-0,04) a pásmo velmi nízkých kmitočtů VLF (very low frequency) (do 0,04 Hz). V některých případech se určuje pásmo ultranízkých kmitočtů ULF (ultra-low frequency; do 0,003 Hz). [6]

### 3.2.1 Frekvenční oblasti spektra

Oblast HF je důsledkem parasympatické aktivity při dýchání. Frekvence tohoto pásma odpovídá 9-24 cyklům za minutu, což odpovídá běžné dechové frekvenci. Za fyziologických okolností se HF mění jen v závislosti na aktivaci parasympatiku [8]

Jako další je oblast nízkých frekvencí (LF), odpovídající 2,4-9 cyklům za minutu. Většina autorů zastává názor, že pásmo nízkých frekvencí je výsledkem aktivity baroreceptorů, ovlivňovaných sympatikem, parasympatikem a zároveň vazomotorické aktivity, tzv. Mayerových vln. [8]

Oblast VLF je pásmo, odpovídající přibližně 0,2 – 2,4 cyklům za minutu a je ovlivňována vazomotorickým tonusem, který je ovlivněn termoregulačním systémem. [8]

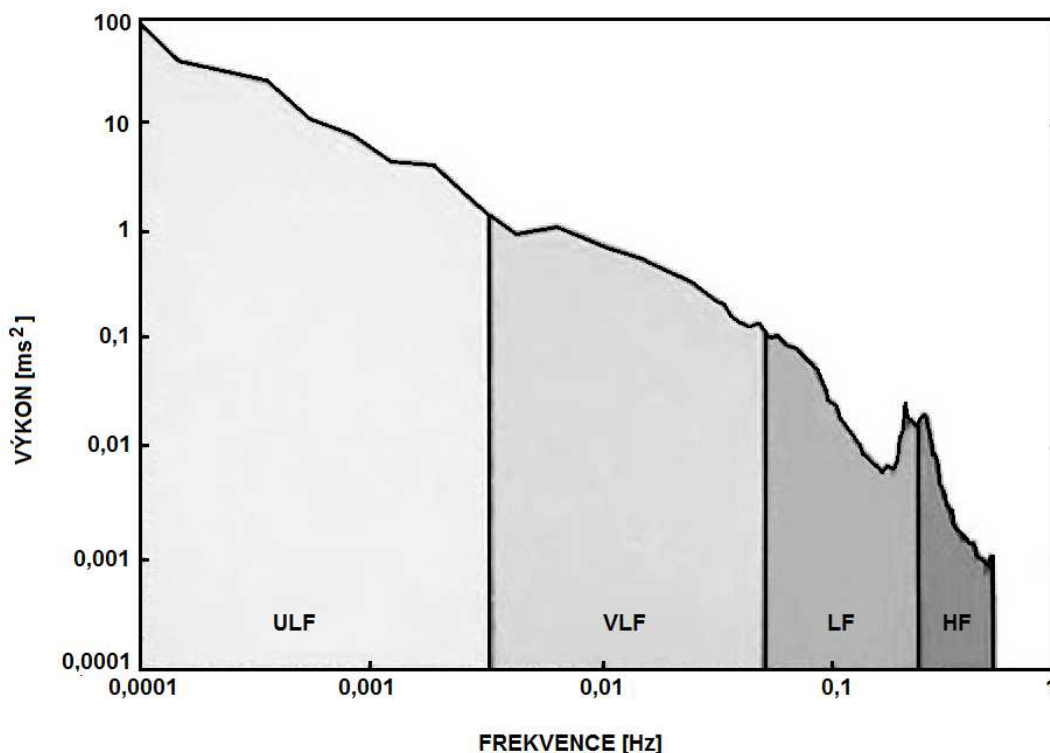
Oblast ULF odpovídá přibližně frekvenci 1 cyklu za 24 hodin, tudíž lze usuzovat, že v sobě odráží cirkadiánní rytmus kolísání autonomního tonusu. Někteří autoři tvrdí, že pásmo ULF a VLF je ovlivněné aktivitou zdravých i nemocných lidí, například s ICHS. Při pravidelném sportování se zvyšuje aktivita VLF i ULF. Omezení pohybu vede k snížení aktivity ULF. [8]

### 3.2.2 Hodnocení spektrální analýzy

Při spektrální analýze hodnotíme aktivity v jednotlivých pásmech. Abychom byli schopni analyzovat spektrum v příslušném pásmu, je nutno přizpůsobit délku snímání právě pásmu, které chceme detekovat. Délka záznamu by měla odpovídat minimálně

desetinásobku periody nejnižší harmonické složky [6]

Při krátkodobém snímání EKG (5-10 minut) a následné analýze HRV jsme schopni detekovat pásma HF a LF, pro které platí, že perioda HF a LF se pohybuje mezi 2,5 s až 25 s, což odpovídá právě 4 minutám snímání, jsme schopni snímat i část pásma VLF, ale toto pásmo již zasahuje do oblastí pro které neplatí výše zmíněné pravidlo. Pokud snímáme Holterovský záznam, který obvykle bývá 24 – 48 hodin, můžeme detekovat i pásma VLF a ULF, jejichž perioda se pohybuje kolem 45 sekund pro VLF a až 24 hodin pro ULF. Pokud chceme v signálu zjišťovat pásma velmi a ultra nízkých frekvencí narážíme na problém stacionarity signálu. Právě nestacionarita signálu je největší překážkou zpracování dlouhodobých záznamů a je nutno podmínku stacionarity zajistit díky kvalitnímu předzpracování. V případě nekvalitního předzpracování může dojít ke zkreslení spektra a následným chybným interpretacím záznamů s chybnou diagnostikou.[6]



Obr. 5 – Výkonové spektrum signálu HRV v logaritmickém měřítku (převzato a upraveno z [6])

Na Obr. 5 je příklad výkonového spektra v logaritmickém měřítku, které je možné získat ze signálu HRV. Hodnoty výkonu v jednotlivých pásmech se udávají v absolutních jednotkách spektrálního výkonu [ms<sup>2</sup>].[6]

### 3.3 Trendy vyskytující se v HRV

Jelikož většina metod zpracování, využívající spektrální analýzu vyžaduje stacionaritu signálu, je nutno tuto podmínku zajistit a to zejména odstraněním takzvaného **trendu**.

Trend je nízkofrekvenční složka spektra, většinou vznikající na základě vnějšího

prostředí, tudíž je nežádoucí složkou. Trendy zasahují do pásma VLF, takže je zřejmé, že chybné odstranění trendu, může vést ke špatnému vyhodnocení spektrální analýzy. Ve většině případů se trend vyskytuje jako složka s velmi pomalou oscilací, či monotónním průběhem. [9]

Jelikož trend je složka, která zasahuje zejména do spektrální oblasti analýzy, či přesněji frekvenční analýzy, je zřejmé, že pokud se trend vyskytuje v signálu, neovlivní nijak výrazně analýzu v časové oblasti.

Po pozorování stovek reálných sérií R-R intervalů v rámci studie [10], se podařilo identifikovat 4 typy trendů, které nazýváme:

**Lineární trend:**

$$Line(i) = a + bi. \quad (1)$$

Lineární trend je tvořen rovnicí (1), Kde  $a$  je průsečík osy  $y$  a  $b$  je směrnice přímky.

**Gaussovský trend:**

$$Gauss(i) = Ae^{-c(i-p)^2}. \quad (2)$$

Gaussovský trend je generován Gaussovským modelem vycházejícím z rovnice (2), s nastavením času výskytu píku  $p$ , ostrosti  $c$  a maximální výchylkou  $A$ .

**Hrotový trend:**

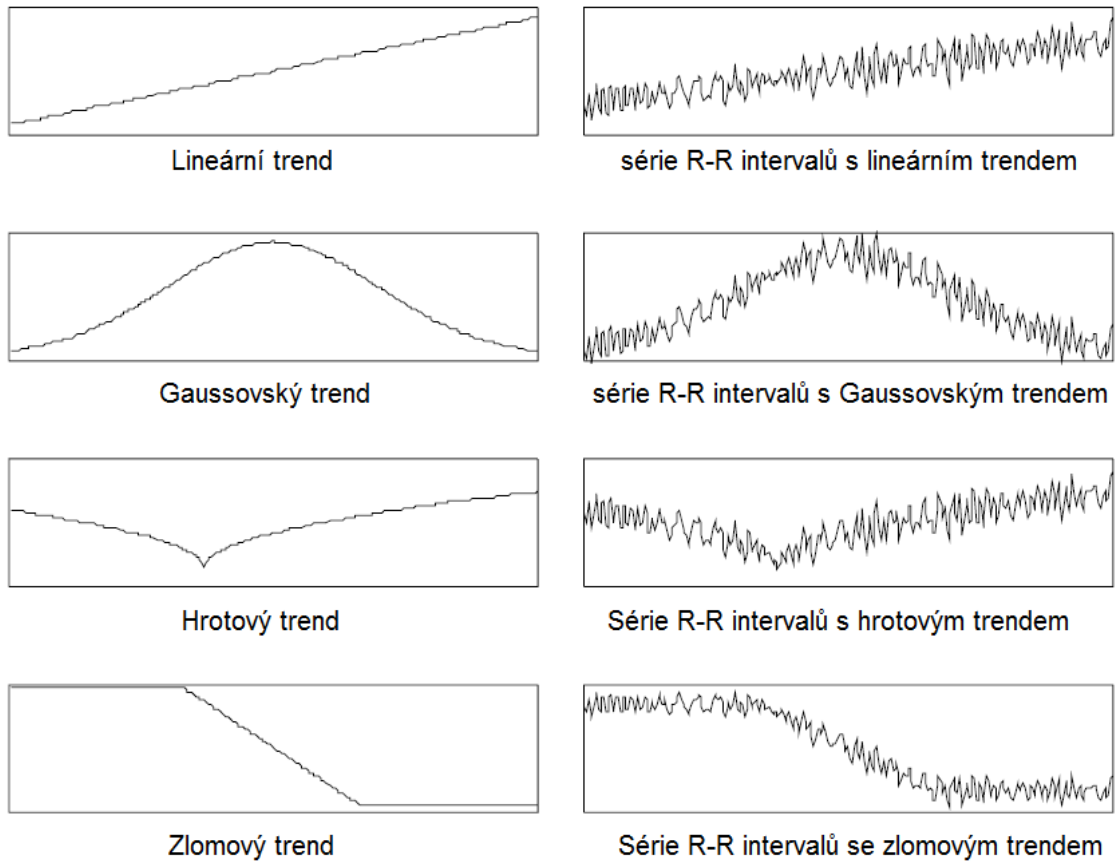
$$Cusp(i) = \sqrt{|i - a|}. \quad (3)$$

Tento trend se skládá z křivky podle rovnice (3), připomínající hrot, kde  $a$  je vrcholem hrotu.

**Zlomový trend:**

$$Break(i) = \begin{cases} A & \text{když } 0 \leq i \leq \frac{L}{2} - \frac{A}{k} \\ k \left( \frac{L}{2} - i \right) & \text{když } \frac{L}{2} - \frac{A}{k} < i < \frac{L}{2} + \frac{A}{k} \\ A & \text{když } \frac{L}{2} + \frac{A}{k} \leq i \leq L \end{cases} \quad (4)$$

Zlomový trend je generován ze vzorce (4), kde  $L$  je délka,  $A$  je rozsah a  $k$  je sklon křivky. [10]



Obr. 6 – Typy jednotlivých trendů [10]

Na Obr. 6 můžeme vidět jednotlivé typy trendů popsané v rovnicích (1) – (4) v generované podobě (vlevo) a následně jejich vliv na sérii R-R intervalů (vpravo).

## 4 METODY DETRENDINGU

Existují různé metody pro odstranění trendu ze signálů HRV. Některé nejpoužívanější metody budou probrány v následující kapitole. Jedná se o metody přiblížení předešlé hladkosti (SPA - smoothness prior approach) , metoda empirického rozkladu (EMD – empirical mode decomposition), a pomocí vlnkové transformace.

### 4.1 Metoda SPA

Na začátku si zapíšeme R-R intervaly časové řady jako

$$z = (R_2 - R_1, R_3 - R_2, \dots, R_N - R_{N-1})^T \in \mathbb{R}^{N-1}, \quad (5)$$

kde  $N$  je počet detekovaných píků R vlny. [10],[11] Série RR intervalů se skládá ze dvou částí

$$z = z_{stat} + z_{trend}. \quad (6)$$

Přičemž  $z_{stat}$  je série RR intervalů, která má největší stacionaritu a  $z_{trend}$  je nízkofrekvenční součást aperiodického trendu. [10] Trendovou složku lze modelovat pomocí lineárního pozorovacího modelu jako

$$z_{trend} = H\theta + v, \quad (7)$$

kde  $H \in \mathbb{R}^{(N-1) \times M}$  je pozorovací matice,  $\theta \in \mathbb{R}^M$  jsou regresní parametry a  $v$  je chyba pozorování. Nyní je nutno vhodně odhadnout parametry, pomocí kterých by se rovnice  $\hat{z}_{trend} = H\hat{\theta}$  dala využít k odhadu trendu. Vlastnosti odhadu jsou silně závislé na vlastnostech základních vektorů (sloupce matice  $H$ ). Široce využívanou metodou je metoda nejmenších čtverců, kterou využijeme v obecnějším přístupu pro odhad  $\hat{\theta}$  [11]. Pro tento případ se využije tzv. regulovaná metoda nejmenších čtverců v podobě

$$\hat{\theta}_\lambda = \arg \min_{\theta} \{ \|H\theta - z\|^2 + \lambda^2 \|D_d(H\theta)\|^2 \}, \quad (8)$$

kde  $\lambda$  je regulační parametr a  $D_d$  značí diskretní aproximaci  $d$ -té derivace operátoru. Jedná se o modifikaci metody nejmenších čtverců, ve které se norma  $\|D_d(H\theta)\|$  zmenšuje. Tímto způsobem můžeme uvést primární informaci, vedoucí k odhadu trendu  $H\theta$ . Vhodnou úpravou rovnice (8) lze získat

$$\hat{\theta}_\lambda = (H^T H + \lambda^2 H^T D_d^T D_d H)^{-1} H^T z, \quad (9)$$

$$\hat{z}_{trend} = H\hat{\theta}_\lambda, \quad (10)$$

kde  $\hat{z}_{trend}$  je odhadovaný trend, který chceme odstranit. [11]

Regulační část z rovnice (8) lze následně pochopit jako řešení vůči nulovému prostoru regulační matice  $D_d$ . Nulový prostor diferenční matice druhého řádu obsahuje všechny prvky křivek prvního řádu. Právě díky diferenční matici  $D_2 = \mathbb{R}^{(N-3) \times (N-1)}$  jsme schopni odhadnout aperiodický trend série RR prvků. S těmito znalostmi je možné zapsat sérii RR intervalů s téměř stacionárním průběhem jako

$$\hat{z}_{stat} = z - H\hat{\theta}_\lambda = (I - (I + \lambda^2 D_2^T D_2)^{-1})z. \quad (11)$$

Přičemž  $I$  je jednotková matice identity. [9]

## 4.2 Metoda EMD

Máme signál  $x(t)$ , který má nalezena všechna lokální maxima a minima. Následně se tyto body propojí pomocí kubického splajnu. Propojením všech lokálních maxim získáme horní obálku  $U(t)$  a propojením všech lokálních minim, získáme dolní obálku  $L(t)$ . Jako další bod se vypočítá průměr z těchto křivek podle vztahu

$$\mu_1(t) = \frac{U(t) + L(t)}{2}, \quad (12)$$

přičemž  $t$  udává vzorek signálu.[12]

Následně se vypočtený průměr odečte ze signálu

$$h_1(t) = x(t) - \mu_1(t). \quad (13)$$

Opakované vyhledávání maxim a minim a následná aplikace vzorců (12) a (13) dokud nezískáme  $h(t)$ , která by splňovala podmínky vlastní modální funkce (dále IMF - intrinsic mode function)[10], se nazývá proces prosívání, jelikož v podstatě prosíváme signál. Podmínky vlastní modální funkce jsou:

1. Průměr mezi obálkou, maxima a minima, musí být téměř nulový
2. Počet extrémů a nulových přechodů je stejný nebo se liší o jeden

V ideálním případě  $h_1(t)$  podmínky IMF splňuje. Ve většině případů ale  $h_1(t)$  tyto podmínky nesplňuje, takže je nutné provést proces prosívání opakovaně, dokud nejsou splněny obě podmínky. Jako zjednodušené kritérium pro ukončení prosívání se používá hodnota standardní odchylky, která se počítá ze dvou po sobě jdoucích  $h(t)$  a počítá se podle vzorce

$$SD = \sum_{t=0}^N \frac{|h_{1(k-1)}(t) - h_{1k}(t)|^2}{[h_{1(k-1)}(t)]^2}, \quad (14)$$

přičemž  $k$  je krok prosévání a  $N$  je počet vzorků z  $x(t)$ . Prosévání ukončujeme pokud je  $SD$  větší než nastavený práh, který se volí většinou kolem 0,25. Pokud máme ukončeno prosévání, můžeme dále pracovat se získanou IMF, kterou značíme  $IMF_1(t)$ . Následně se od původního signálu odečte získaný signál  $IMF_1(t)$  jako v (15) a získáme signál, který bude opět podstupovat proces prosévání.

$$r_1(t) = x(t) - IMF_1(t). \quad (15)$$

Rovnice (15) se dá vyjádřit obecně:

$$r_i(t) = r_{i-1}(t) - IMF_i(t), \quad i = 1, \dots, q, \quad (16)$$

kde  $i$  představuje stupeň EMD z  $q$  průběhů

Celý postup se ukončuje v případě splnění podmínky, že složka  $IMF_q(t)$ , popřípadě vypočtený zbytek  $r_i(t)$  budou malé, nebo se  $r_i(t)$  stane monotónní funkcí.[12] Celý postup rozkladu můžeme vyjádřit vzorcem:

$$x(n) = \sum_{i=1}^q IMF_i(t) + r_q(t). \quad (17)$$

Ve většině případů sumací 4 prvních IMF a následného přičtení střední hodnoty původního signálu dostaneme signál zbavený nerovného průběhu, což je právě trend.[12]

### 4.3 Metoda vlnkové transformace

Základ metody je přepis signálu pomocí vlnkové transformace. Každá základní funkce, tzv. vlnka, je vyjádřena na konečném časovém intervalu, tudíž můžeme říct, že spektrum vytvořené pouze z tohoto úseku vlnky, nese vlastnosti a informace o tomto úseku. Vlnky jsou rozloženy po částech po signálu, z důvodu zachování časové informace signálu.

Tato metoda vychází ze spojité vlnkové transformace (CWT – continuous wavelet transform), definovaná jako:

$$S_{CWT}(a\tau) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{a}} \Psi\left(\frac{t}{a} - \tau\right) dt, \quad a > 0, \tau \in \mathbb{R}. \quad (18)$$

Hodnoty spektra  $S_{CWT}(a, \tau)$ , jsou dvojrozměrnou funkcí a jsou dány korelačním integrálem mezi analyzovaným signálem  $x(t)$  a bázovou funkcí  $\left(\frac{1}{\sqrt{a}}\right)\Psi(\cdot)$ , což je konkrétní vlnka. Základní funkční předpis vlnky je tzv. mateřská vlnka  $\Psi(\cdot)$ , nicméně tvar konkrétní vlnky závisí na obou parametrech  $a$  i  $\tau$ . Parametr  $a$  se označuje jako měřítko, které ovládá časovou dilataci funkce ( $a > 1$  je vlnka natažena  $a$ -krát).  $1/\sqrt{a}$  zajišťuje zachování energie vlnky. Parametr  $\tau$  ovlivňuje časový posun funkce podél časové osy. [13]

Diskrétní vlnková transformace signálu  $x(t)$  je dle [10] definována jako:

$$\begin{aligned} D_{m,n}(t) &= \sum_m \sum_n x(t) \psi_{m,n}(t), \\ A_{m,n}(t) &= \sum_m \sum_n x(t) \phi_{m,n}(t), \end{aligned} \quad (19)$$

kde  $D_{m,n}$  je detail a  $A_{m,n}$  je aproximace.  $\psi_{m,n}$  je dyadická mřížková vlnka a  $\phi_{m,n}$  je váhovací funkce. Trend se nachází v pásmech velmi nízkých frekvencí, avšak přesná hodnota není nikdy známá[10]. Z tohoto důvodu se zavádí prahová hodnota  $Thr$ , které je využito k nastavení koeficientů, u kterých se předpokládá, že budou trendového charakteru, na hodnotu 0 dle vzorce

$$\hat{A}_{m,n} = \begin{cases} A_{m,n} & \text{když } A_{m,n} \geq Thr \\ 0 & \text{když } A_{m,n} < Thr \end{cases} \quad (20)$$

Poté jsou  $D_{m,n}$  a  $\hat{A}_{m,n}$  použity ke zpětné rekonstrukci signálu. Detrendovaný signál získáme inverzní diskretní vlnkovou transformací dle vzorce

$$\hat{x}(t) = \sum_m \sum_n \hat{A}_{m,n} \phi_{m,n}(t) + \sum_m \sum_n D_{m,n} \psi_{m,n}(t). \quad (21)$$

Význam výrazů  $D_{m,n}$ ,  $\phi_{m,n}$  a  $\psi_{m,n}$  je uveden již výše.  $\hat{A}_{m,n}$  je upravený koeficient aproximace. [10]

## 5 FALEŠNÉ DETEKCE A EKTOPICKÉ CYKLY

V datech RR intervalů jsou často přítomny různé typy artefaktů, jako jsou chybějící systoly, extra systoly, chybné rozpoznání R kmitu, přirozený šum, které způsobují, že QRS komplex je složitý, nebo někdy nemožné správně detekovat, a fyziologicky abnormální úder, jako předčasné komorové kontrakce či blokáda sinusového uzlu. Kritický aspekt je většinou určit tyto artefakty přesně. I v případě, že by výskyt těchto artefaktů nebyl příliš velký, dalo by se předpokládat, že pouhé odstranění by mohlo způsobit zkreslení spektra a mohlo by vést až k chybné diagnóze. Z tohoto důvodu se používají různé techniky pro detekci a následnou úpravu signálu. [14]

### 5.1 Vyhledání artefaktů v HRV

Dříve se z důvodu nedostatečného výkonu počítačů využívala hlavně vizuální kontrola, ovšem tato metoda má své nevýhody, jako je časová náročnost, zejména pro dlouhé signály a rozhodnutí, zda se jedná o artefakt, záviselo na subjektivním přesvědčení, které bylo závislé na zkušenostech kontrolora. Z tohoto důvodu se začaly vyvíjet algoritmy pro vyhledání těchto artefaktů pomocí počítačů, u kterých výpočetní výkon rapidně rostl. [14]

Vyhledávání artefaktů je prováděno pomocí algoritmů, které čtou uplynulou dobu od předchozího impulzu, pokud je tato doba delší nebo kratší než vypočítaný práh s určitou plus-mínus tolerancí, označí algoritmus aktuální impulz za artefakt. Všechny algoritmy se liší pouze ve výpočtu a toleranci překročení prahu. Následující algoritmy jsou seřazeny od vývojově nejstaršího po nejnovější:

#### Algoritmus a

Každý RR interval je porovnáván s posledním přijatým RR intervalem. Když je rozdíl větší nebo menší než 20% posledního přijatého RR intervalu, je detekován jako artefakt. [14]

#### Algoritmus b

Každý RR interval je porovnán s posledními dvěma přijatými RR intervaly. Když oba rozdíly jsou větší nebo menší než 20%, je RR interval detekován jako artefakt. [14]

#### Algoritmus c

Tento algoritmus využívá kombinaci dvou kritérií [14]. Pro výpočet prvního kritéria je nutné vypočítat pomocné parametry MAD (minimal artifact difference – minimální rozdíl artefaktů) a MED (maximum expected difference – maximální očekávaný rozdíl). MED je definován dle vzorce

$$MED = \frac{3,32 * IQR(\Delta RR)}{2}. \quad (22)$$

Přičemž IQR je interkvartilní rozsah z  $\Delta RR$ , které je určeno diferencí dvou po sobě jdoucích vzorcích. MAD je definován podle vzorce

$$MAD = \frac{\text{median}(RR) - 2,9 * IQR(\Delta RR)}{2} / 3. \quad (22)$$

A výsledek prvního kritéria je určen vzorcem

$$\text{crit} = \frac{MAD + MED}{2}. \quad (23)$$

Druhé kritérium, které musí aktuální vzorek splnit, je určeno průměrem z 5 okolních RR intervalů. V případě, že interval přesahuje alespoň jedno kritérium o  $\pm 25\%$ , je označen jako artefakt. [14]

#### Algoritmus d

Pro nastavení rozsahu je zde využít medián z 25 RR okolních intervalů. Pokud je rozdíl mezi aktuálním RR intervalem a mediánem větší nebo menší než 30%, je RR označen jako artefakt. Tato metoda je využívána CHIME (Collaborative Home Infant Monitoring Evaluation-„Spolek pro hodnocení dětského domácího monitorování). [14]

#### Algoritmus e

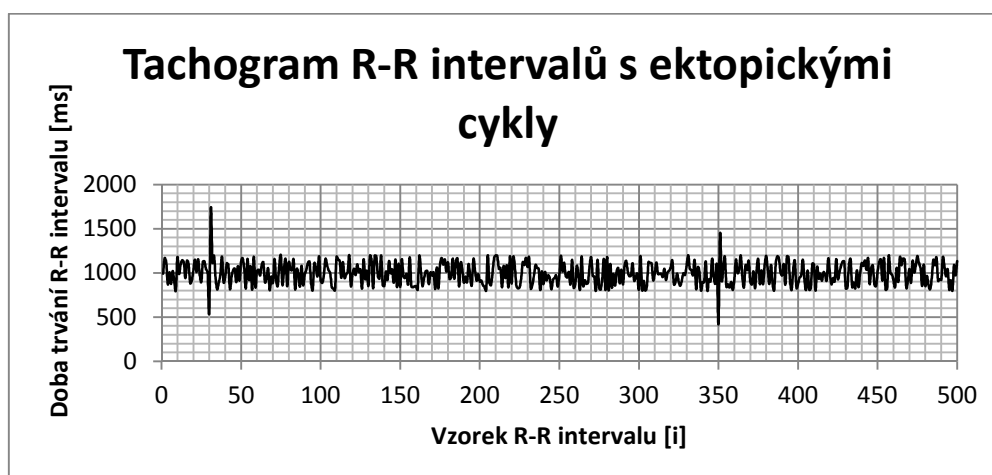
Každý RR interval je porovnán s průměrem předchozích přijatých RR intervalů a s posledním přijatým vzorkem. Pokud je rozdíl obou kritérií větší nebo menší než 20% je RR interval označen jako artefakt. [14]

#### Algoritmus f

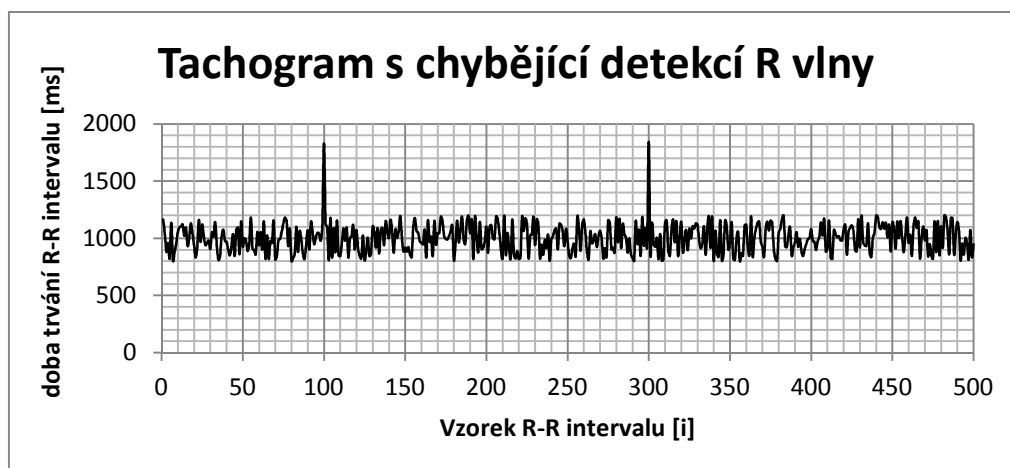
Každý RR interval je porovnán s mediánem 25 okolních RR intervalů a posledním přijatým RR intervalem. Jedině pokud se oba liší o více nebo méně než 20% je interval detekován jako artefakt. [14]

Je nutno poznamenat, že přes poměrně velkou úspěšnost detekce, je zapotřebí nastavit u všech algoritmů vhodné počáteční hodnoty, protože u těchto algoritmů je předpoklad že máme alespoň jeden správný RR interval nalezen. [14]

Příklad náhodně vygenerovaného signálu v programu MS Excel podobného tachogramu s ektopickými cykly na vzorcích 30 a 350 je zobrazen na Obr. 7



Obr. 7 – Vygenerovaný tachogram pomocí MS Excel s ektopickými cykly



Obr. 8 – Vygenerovaný tachogram pomocí MS Excel s chybějící detekcí vlny

Pro porovnání rovněž náhodně vygenerovaný tachogram na Obr. 8 s chybějící detekcí na vzorkách 100 a 300. Je vidět že v případě ektopických cyklů tachogram obsahuje výraznou špičku záporným i kladným směrem a v případě chybějící detekce je špička téměř dvojnásobná. Oba signály jsou pouze náhodná čísla a slouží pouze pro pochopení rozdílu mezi ektopickými cykly a chybnou detekcí.

## 5.2 Náhrada artefaktů v HRV

Vyhledání artefaktů v signálu HRV je pouze jeden ze dvou kroků, který je nutno udělat pro zbavení se ektopických cyklů či jiných artefaktů. Druhým krokem je náhrada části signálu, který obsahuje artefakty.

Existují různé metody náhrady chybných vzorků tachogramu. Starší, zároveň výpočetně jednodušší metodou je metoda **interpolační**. Při aplikaci této metody se využívá poměrně jednoduchého výpočtu pro doplnění hodnoty daného cyklu. V signálech, obsahující velké množství vzorků a málo artefaktů je možné tyto techniky použít při malém zkreslení spektra. Používá se zejména interpolace pomocí lineárního, či kubického splajnu.

Lineární splajn, jakožto výpočetně nejjednodušší se počítá pomocí vzorce:

$$S_i(x) = f(x_i) + \frac{f(x_{i+1}) - f(x_i)}{x_{i+1} - x_i} * (x - x_i). \quad (24)$$

Přičemž  $f(x_i)$  je funkční hodnota v bodě  $x_i$  a  $x$  je x-ová souřadnice hodnoty kterou chceme doplnit. [15]

Kubický splajn je výpočetně náročnější, počítá se pomocí soustavy vzorců. V první řadě definujeme rovnici pro výpočet splajnu:

$$S_i(x) = a_i + b_i(x - x_i) + c_i(x - x_i)^2 + d_i(x - x_i)^3. \quad (25)$$

Přičemž  $a_i$  je rovna funkční hodnotě v bodě  $x$ . Dále určíme hodnoty koeficientů ze soustavy rovnic, kterou vytvoříme ze vzorce

$$h_{i-1}c_{i-1} + 2(h_{i-1} + h_i)c_i + h_i c_{i+1} = 3 \left( \frac{\Delta f_i}{h_i} - \frac{\Delta f_{i-1}}{h_{i-1}} \right). \quad (26)$$

Kde  $h_i = x_{i+1} - x_i$  a  $\Delta f_i = f(x_{i+1}) - f(x_i)$  a následně dopočítáme zbývající koeficienty  $b_i$  a  $d_i$  podle vzorců

$$b_i = \frac{f(x_{i+1}) - f(x_i)}{h_i} - \frac{c_{i+1} + 2c_i}{3} h_i, \quad (27)$$

$$d_i = \frac{c_{i+1} - c_i}{3h_i}. \quad (28)$$

Vypočtené koeficienty dosadíme do vzorce (25) a tím získáme rovnici pro splajn na daném intervalu. [15]

Další metoda je velmi jednoduchá, a sice odstranění abnormálního RR intervalu. Při této metodě je detekovaný interval pouze odstraněn a zbytek sekvence je připojen. Výhodou této metody je bezesporu jednoduchost, avšak nevýhodou je, že dostaneme ve výsledku kratší signál, což může způsobit nechtěné zkreslení. [16]


Další možností je náhrada pomocí mediánu z okolních intervalů. Tato metoda je založena na nahrazování chybných RR intervalů pomocí mediánu. Vybereme  $K$  vzorků předcházejících chybě a  $K-1$  vzorku po chybě pro výpočet. Pak  $k$  chybných úderů je nahrazeno  $k'$  úderů hodnoty mediánu  $me$  s přesností  $me/2$ , aby platila podmínka

$$\sum_{j=0}^k RR_{i+j} - \frac{me}{2} < k' \cdot me < \sum_{j=0}^k RR_{i+j} + \frac{me}{2}. \quad (29)$$

Na Obr. 9 je znázorněno, jakým způsobem se mediánové nahrazování provádí, kde  $A$  značí abnormální interval. [16]

Výhody této metody: Nevytváří se nové hodnoty, což by se mohlo stát při výpočtu z průměru okolních intervalů. Náhrada chybných intervalů udržuje časový řád.

Nevýhody této metody: Krátkodobé korelace mohou být ovlivněny. [16]




Obr. 9 – Metoda nahrazování chybných RR intervalů pomocí mediánu (převzato z [16])

Poslední metoda je podobná předchozí metodě, liší se pouze v tom, že nepočítáme medián, ale náhodně vybíráme jednu hodnotu z okolních intervalů. Opět vybereme  $K$  vzorků předcházejících chybě a  $K-1$  vzorků po chybě. Předpokládáme stejnou pravděpodobnost pro všechny hodnoty. Opět platí omezení pro číslo  $k'$ , uvedené ve vzorci

$$\sum_{j=0}^k RR_{i+j} - \frac{m}{2} < \sum_{i=1}^{k'} v_i < \sum_{j=0}^k RR_{i+j} + \frac{m}{2}. \quad (22)$$

Kde  $m$  je průměr náhodných hodnot,  $v_i$  – náhodná  $i$ -tá hodnota vybraná z množiny

2K-1 hodnot z okolních NN intervalů,  $k'$  – počet nahrazených intervalů. Obr. 10 popisuje metodu v případě že  $K=4$ . [16]



Obr. 10 – Metoda nahrazování chybných intervalů pomocí náhodné hodnoty z okolí (převzato z [16])

## 6 VÝBĚR NEJVHODNĚJŠÍHO PŘEDZPRACOVÁNÍ

Výběr nejvhodnější metody pro odstranění trendu je možné na základě zhodnocení ve formě tabulky v článku [10], ve kterém jsou metody popsány. Následující Tabulka 1 je překladem z výše zmíněného článku, přičemž LF je průměrná relativní chyba výkonu pásma mezi 0,08 Hz a 0,12 Hz, HF je průměrná relativní chyba výkonu pásma mezi 0,22 Hz a 0,33 Hz a  $\alpha$  je průměrná relativní chyba výkonu pásma mezi 0,5 Hz a 2 Hz. Výsledky byly vypočítány z 10000 sérií RR intervalů generovaných pomocí McSharry modelu a následně z nich byl trend odstraněn pomocí následujících metod.

Tabulka 1 - Průměrná relativní chyba ve spektrální analýze (převzato a upraveno z [10])

		Lineární	Gaussovský	Hrotový	Zlomový
$\bar{\delta}_{Trend}$ - (%)	LF	11,8±5,63	24,3±6,89	6,97±3,48	50,0±15,6
	HF	4,19±2,65	9,04±5,49	2,72±2,01	19,4±8,62
	$\alpha$	8,20±5,71	15,17±9,60	5,39±3,79	27,1±16,9
$\bar{\delta}_{SPA}$ - (%)	LF	1,78±0,98	1,78±0,97	1,63±1,31	1,68±1,07
	HF	0,17±0,18	0,17±0,18	0,46±0,35	0,18±0,18
	$\alpha$	1,68±0,99	1,67±0,99	1,69±1,36	1,58±1,09
$\bar{\delta}_{VLNKOVA.TR}$ - (%)	LF	0,40±0,54	0,41±0,53	1,47±1,16	0,59±0,55
	HF	0,20±0,24	0,20±0,23	0,48±0,38	0,22±0,24
	$\alpha$	0,47±0,58	0,48±0,57	1,55±1,23	0,66±0,61
$\bar{\delta}_{EMD}$ - (%)	LF	0,25±0,26	0,19±0,3	1,41±2,24	1,98±1,81
	HF	0,11±0,15	0,12±0,20	0,49±1,18	1,16±1,03
	$\alpha$	0,28±0,29	0,24±0,31	1,41±1,21	2,05±1,84

Přičemž  $\bar{\delta}_{Trend}$ , udává průměrnou relativní chybu výkonu bez detrendingu a  $\bar{\delta}_{SPA}$ ,  $\bar{\delta}_{VLNKOVA.TR}$  a  $\bar{\delta}_{EMD}$  udávají průměrnou relativní chybu výkonu po užití metod v indexu. Z tabulky je patrné, že nejlepších výsledků dosahuje metoda empirického rozkladu a vlnková transformace, dále pak záleží, který trend se v signálu objevuje. V případě zlomového trendu se jeví jako výhodnější použití vlnkové transformace, avšak v případě lineárního, Gaussovského a hrotového trendu vychází lépe metoda EMD, z toho důvodu byla pro realizaci a otestování vybrána právě tato metoda.

Co se týká detekce artefaktů a porovnání algoritmů a-f, byla využita Tabulka 2 uvedená v článku [14].

Tabulka 2 - Senzitivita, specificita a přesnost předchozích uvedených algoritmů (převzato a upraveno z [14])

Senzitivita, Specificita a Přesnost algoritmů na náhodně vybraných datech						
Algoritmus	a	b	c	d	e	f
Citlivost na chybějící úder	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000
Citlivost na extra systolu	1,0000	1,0000	0,6500	1,0000	1,0000	1,0000
Celková senzitivita	0,9494	0,9367	0,8608	0,8228	0,8987	0,9367
Specificita	0,9909	0,9928	0,9972	0,9971	0,9922	0,9954
Přesnost	0,9908	0,9926	0,9967	0,9964	0,9918	0,9952
Senzitivita, Specificita a Přesnost algoritmů na zašuměných datech						
Algoritmus	a	b	c	d	e	f
Citlivost na chybějící úder	0,9722	0,9861	0,9444	0,9861	0,9861	1,0000
Citlivost na extra systolu	0,9103	0,9744	0,6026	0,9359	0,9744	0,9744
Celková senzitivita	0,7464	0,7097	0,5592	0,6043	0,6860	0,7156
Specificita	0,8825	0,9088	0,9907	0,9923	0,9757	0,9879
Přesnost	0,8769	0,9006	0,9729	0,9763	0,9638	0,9767
Senzitivita, Specificita a Přesnost algoritmů na celých datech						
Algoritmus	a	b	c	d	e	f
Citlivost na chybějící úder	0,9753	0,9877	0,9506	0,9877	0,9877	1,0000
Citlivost na extra systolu	0,9286	0,9796	0,6122	0,9490	0,9796	0,9796
Celková senzitivita	0,7638	0,7291	0,5850	0,6230	0,7042	0,7346
Specificita	0,9364	0,9506	0,9939	0,9947	0,9839	0,9917
Přesnost	0,9324	0,9455	0,9845	0,9861	0,9776	0,9857

Přičemž bylo vybráno 10 signálů z databáze 388 kojeneckých signálů ze studie CHIME. Z každého z nich byl vybrán 15 minutový náhodný úsek (náhodná data) a 15 minutový zašuměný úsek (zašuměná data). Celá data pak představují oba úseky dohromady. Pro posouzení kvality těchto šesti algoritmu byly v rámci studie [14] použity specificita, senzitivita a přesnost. Specificita vyjadřuje zlomek (po vynásobení 100x dostaneme procenta) počtu správných impulzů, označených za správné. Senzitivita vyjadřuje zlomek (po vynásobení 100x dostaneme procenta) počtu špatných impulzů označených za špatné. Přesnost vyjadřuje zlomek (po vynásobení 100x dostaneme procenta) s jakou přesností byl špatný impuls označen [14]. Při porovnání výsledků, jsou v některých případech viditelné značné rozdíly a z toho důvodu budou všechny tyto algoritmy testovány v následujících kapitolách.

Srovnání metod pro odstranění nebo náhradu detekovaných artefaktů, není v žádném článku uvedeno, z toho důvodu budou v následujících kapitolách metody popsány v podkapitole 5.2 porovnány.

## 7 REALIZACE ALGORITMŮ

V následující kapitole budou rozebrány jednotlivé kroky při vytváření programů pro předzpracování. Všechny algoritmy jsou vytvořeny jako funkce, které jsou volány z hlavního skriptu. Hlavní skript využívá metody, které měly nejlepší výsledky.

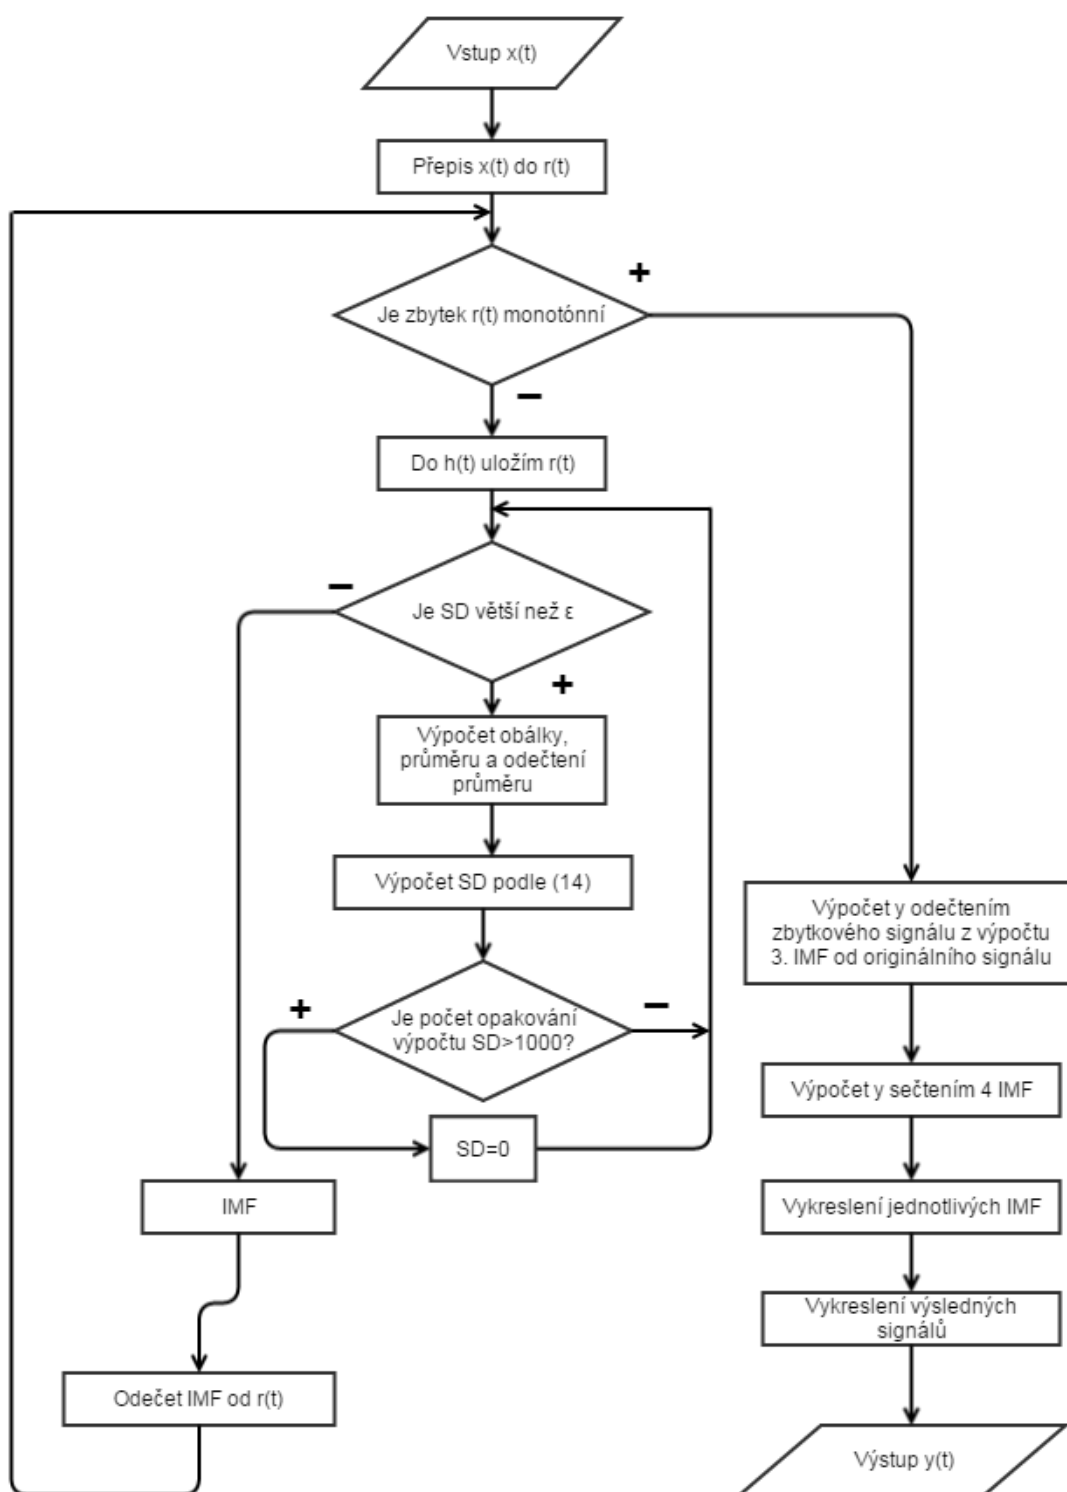
### 7.1 Algoritmus metody empirického rozkladu (EMD)

Princip EMD byl rozebrán v kapitole 4.2, ve které byla popsána teoretická část, podle které byla sepsána funkce s názvem EMD. Funkce se dá rozdělit do tří částí, v první části je prováděno vzorkování vloženého signálu, ve kterém se pomocí cyklu `for` nadefinuje vzorkovací osa a následně se pomocí funkce `interp1` provádí interpolace pomocí kubického splajnu. Tento krok nám zajistí rovnoměrné vzorkování všech bodů s frekvencí  $F_{vz}$ , která je v našem případě 4 Hz.

Další část obsahuje vnější `while` cyklus, ve kterém je prováděno uložení signálu, od kterého je odečtena IMF. Následuje vnitřní `while` cyklus, ve kterém je již prováděno samotné prosívání, tento cyklus běží, dokud hodnota směrodatné odchylky není menší  $\epsilon$ , které bylo nadefinováno na hodnotu 0,25. V cyklu se provádí výpočet horní a dolní obálky, pomocí funkce `obalka()`, která slouží k upravení výsledků (nalezených extrémů) z funkce `extrema()` [17]. Dalším krokem v cyklu je výpočet průměru obálek a jeho následný odečet ze zpracovávaného signálu. Následuje výpočet směrodatné odchylky, která slouží k posouzení, zda výsledný signál dané iterace splňuje podmínky IMF. Následuje podmínka, zda není počet extrému menší než dva, v případě že ano, splňuje zpracovávaná část jednu podmínku IMF a je možné cyklus opustit, což je řešeno nastavením `SD` na hodnotu 0. Z důvodu občasného selhání `SD` jako kontrolního parametru, je zde umístěna podmínka, která omezuje počet iterací na 1000. Důvodem tohoto selhání bývá ve většině případů kolísání hodnoty `SD` místo jejího plynulého poklesu, pokud nastane taková situace, vybere se signál z iterace s nejmenší hodnotou `SD` a vnitřní cyklus se ukončí nastavením `SD` na hodnotu 0. Po vystoupení z cyklu, je provedeno vynulování vektoru obsahujícího hodnoty proměnné `SD` a inicializace jeho prvního prvku s hodnotou větší než  $\epsilon$ , aby bylo v následujícím cyklu možné vstoupit do vnitřního cyklu. Po provedení inicializace se vypočte zbytek po odečtení IMF od vstupního signálu vnitřního cyklu. Pak probíhá kontrola monotónnosti tohoto zbytku. V případě, že výsledný signál splňuje podmínky monotónnosti s určitou tolerancí, nastaví se proměnná `a` do hodnoty `false`, což znamená ukončení vnějšího cyklu. V opačném případě se prosévací proces opakuje s využitím zbytku jako vstupního signálu vnitřního cyklu.

Následuje poslední část funkce, která má za úkol vykreslení výsledků do subplotů. V prvním `figure` se do jednoho subplotu vykreslují signály vytvořené složením 4 IMF a do druhého subplotu odečtením zbytku signálu z výpočtu 3. IMF od originálního signálu a vedle nich jejich spektra. Ve druhém `figure` jsou zobrazeny jednotlivé IMF.

Algoritmus počítající EMD, je možné shrnout v poměrně jednoduchém diagramu, zobrazeném na Obr. 11.

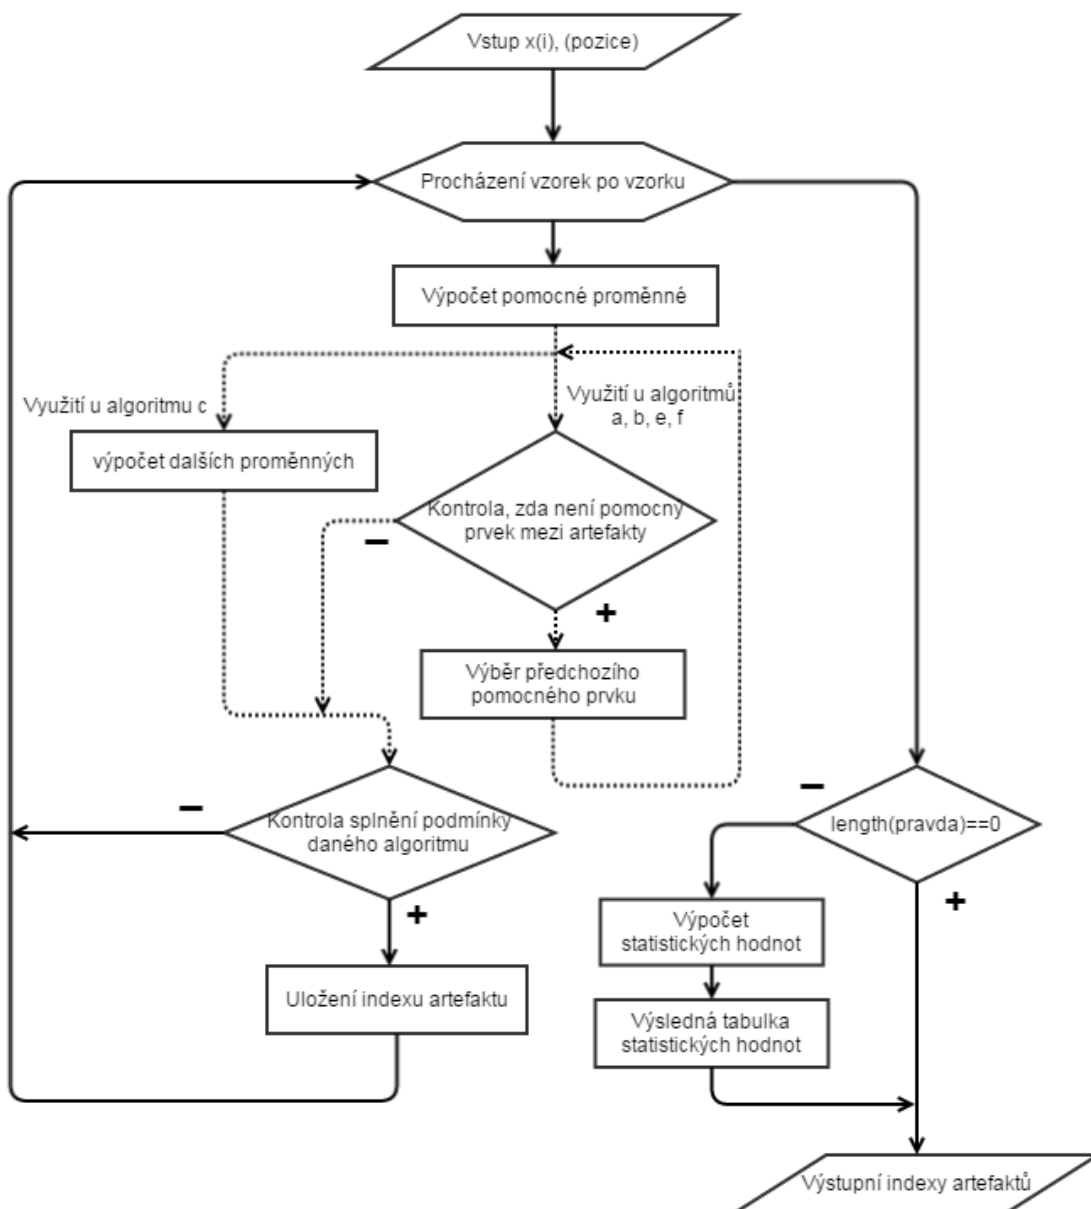


Obr. 11 – Vývojový diagram metody EMD

## 7.2 Popis algoritmů pro vyhledání artefaktů HRV

Všechny algoritmy a-f jsou vytvořeny ve formě funkce detekce s výstupem

všech jednotlivých algoritmů a vstupem neinterpolovaného signálu HRV a v případě, že máme k dispozici přesné pozice artefaktů, je možné je zadat jako další vstup funkce (proměnná *pravda*), v opačném případě se místo druhého vstupu zadá prázdný vektor []. Všechny algoritmy mají přibližně stejný postup, který je znázorněn na diagramu na Obr. 12. Obsahuje větve znázorněné čárkovaně, což znamená, že tohoto postupu je využito pouze v některých případech. Větve kreslené plnou čarou znamenají, že tento postup je společný pro všechny algoritmy (*a-f*).



Obr. 12 – Vývojový diagram pro detekci artefaktů

### 7.2.1 Algoritmus a

Algoritmus začíná inicializací vektoru *a*, a pokračuje do cyklu `for`, ve kterém je

vnořen cyklus `while`, který zabraňuje tomu, aby program použil pro kontrolu objevený artefakt. Dále vytvoříme pomocnou proměnnou `pom`, se kterou následně porovnáme aktuální zpracovávaný vzorek signálu. V případě, že je splněna podmínka, že jejich rozdíl je mimo  $\pm 20\%$ , uloží se index zpracovávaného vzorku do proměnné `a`, která je výstupem funkce.

### 7.2.2 Algoritmus b

Algoritmus začíná inicializací vektoru `b`, a následně pokračuje do cyklu `for`, ve kterém jsou vnořeny dva `while` cykly za sebou, opět aby zabránily použití artefaktů pro srovnání. Dále je zde umístěna podmínka, která kontroluje dva předchozí přijaté `RR` s aktuálním, v případě, že jejich rozdíl je mimo  $\pm 20\%$ , do proměnné `b` se uloží index aktuálního vzorku. Algoritmus *b* se liší od algoritmu *a* pouze tím, že obsahuje kontrolu dvou prvků.

### 7.2.3 Algoritmus c

Algoritmus opět začíná inicializací vektoru `c`, do kterého se následně budou ukládat indexy artefaktů. Následuje krátký cyklus `for`, který pouze počítá hodnoty vektor `deltaR` ( $\Delta RR$ ). Poté se vzestupně seřadí vytvořená proměnná v předchozím cyklu a uloží se do pomocné proměnné `pomc` a následuje výpočet interkvartilního rozsahu (`IQR`), minimálního rozdílu artefaktů (`MAD`), maximálního očekávaného rozdílu (`MED`) a z nich srovnávacího kritéria (`crit`). Dále je zde další cyklus `for`, který slouží k výpočtu průměru z okna délky 5 intervalů, a následnému porovnání aktuálního vzorku s oběma podmínkami. V případě, že jsou podmínky splněny a vzorek je mimo  $\pm 25\%$  obou kritérií, je do proměnné `c` uložen index aktuálního vzorku.

### 7.2.4 Algoritmus d

Na začátku algoritmu je inicializace vektoru `d` a pomocného vektoru `pomd`, ze kterého se později bude počítat medián. Následuje cyklus `for`, ve kterém se plní pomocný vektor `pomd`. Cyklus obsahuje rovněž podmínku, která kontroluje, zda aktuální zpracovávaný vzorek nemá index menší nebo roven 25, v případě že ano, proběhne naplnění pomocného vektoru prvními 50 vzorky signálu, kromě zpracovávaného. Další podpodmínkou umístěnou v cyklu se kontroluje, zda není index zpracovávaného vzorku větší než délka vektoru - 25, v případě že ano, postupuje obdobně jako v prvním případě, a sice naplní pomocný vektor posledními 50 vzorky signálu kromě aktuálně zpracovávaného. V případě, že není splněna ani jedna podmínka, naplní se pomocný vektor 25 hodnotami před artefaktem a 25 hodnotami po artefaktu. Jako poslední část cyklu je kontrola splnění podmínky *algoritmu d* a v případě, že je podmínka splněna, která zní, že velikost kontrolovaného `RR` intervalu je mimo  $\pm 30\%$  mediánu vypočteného z aktuálního vektoru `pomd`, uloží se aktuálně zpracovávaný index do vektoru `d`.

### 7.2.5 Algoritmus e

Ze začátku je opět nutné provést inicializaci vektoru `e` a pomocného vektoru `pome`, který bude obsahovat index přijatých `RR` vzorků, ze kterých se bude počítat průměr.

Následuje vstup do cyklu, který počítá až od druhého prvku, jelikož do pomocného vektoru v prvním kroku cyklu vkládáme index snížený o 1, protože první RR bereme automaticky za první přijatý vzorek. Pomocný vektor bude v následujícím kroku použit pro indexaci. Následuje vnořený cyklus `for`, ve kterém je porovnán pomocný vektor a vektor obsahující indexy artefaktů `e`. V případě shody těchto vektorů, je v `pome` tato hodnota odstraněna. Po ukončení vnitřního cyklu, následuje výpočet průměrné hodnoty všech hodnot, které do aktuálního kroku nebyly označeny jako artefakt. Následuje závěrečná podmínka, která kontroluje, zda se aktuální zpracovávaná hodnota neliší o více než 20% od vypočteného průměru a zároveň od posledního akceptovaného RR. V případě, že je závěrečná podmínka splněna, uloží se index do vektoru `e`.

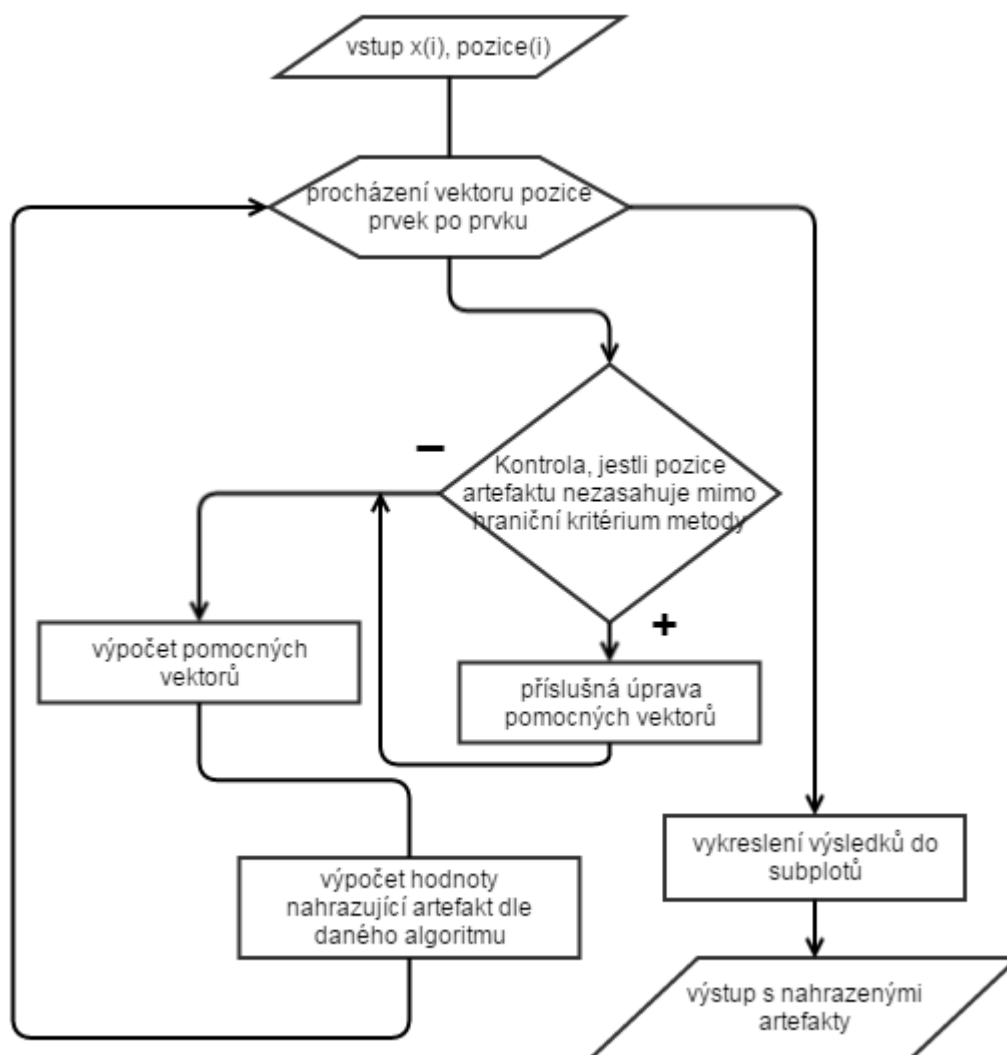
### 7.2.6 Algoritmus f

Poslední algoritmus začíná opět inicializací proměnných `f` a `pomf` pro uložení indexů artefaktů, respektive pomocné proměnné. Následuje stejný výpočet pomocné proměnné, jako v případě *algoritmu d*, poté stejně jako v *algoritmu a* následuje cyklus `while`, který zabrání tomu, aby algoritmus použil pro srovnání intervalů právě RR interval, který byl označen jako artefakt. Po ukončení vnitřního cyklu následuje podmínka, která ověřuje podmínky *algoritmu f*, v případě, že aktuální interval splňuje obě podmínky, tedy jeho hodnota se liší o více než  $\pm 20\%$  od mediánu vektoru `pomf` a zároveň od poslední akceptované RR, uloží se index do proměnné `f`.

Na konci funkce *detekce* je zobrazení do 6 subplotů, na kterých je možné snadno pozorovat rozdíly mezi jednotlivými výsledky algoritmů. V případě, že byly zadány hodnoty přesných pozic artefaktů, je použito zobrazení do 7 subplotů a rovněž proběhne výpočet statistických hodnot, jako je senzitivita, specificita a přesnost.

## 7.3 Algoritmy pro náhradu detekovaného artefaktu

Všechny metody uvedené v následujících podkapitolách jsou uloženy ve funkci *nahrada*, která má 2 vstupy – `x` a `pozice`, přičemž `x` je originální signál a `pozice` jsou výstupem funkce *detekce*, která určuje artefakty. Výstupem funkce je 5 vektorů, které obsahují signál s opravenými artefakty, jsou jimi: `lin`, `kub`, `vyn`, `med` a `nah`. Celá funkce začíná inicializací všech výstupních proměnných a to tak, že do všech se uloží vstupní vektor `x`, následuje vstup do cyklu `for`, ve kterém se jednotlivé metody zpracovávají. Jelikož všechny algoritmy mají přibližně stejný postup, lze je shrnout do jednoho vývojového diagramu na Obr. 13. Pouze v případě vynechání prvku, je postup mírně odlišný, a sice neobsahuje `for` cyklus, pouze vymazání prvků.



Obr. 13 – Vývojový diagram pro náhradu artefaktů

### 7.3.1 Nahrazení pomocí lineárního splajnu

Algoritmus začíná kontrolou, zda není zpracovávaným prvkem, uloženým v proměnné *pozice* číslo 1, jelikož při dalším zpracování se využívá právě prvku z proměnné *x* s indexem o 1 nižším než je v proměnné *pozice*. V případě že je podmínka splněna, do pomocné proměnné  $f_{xi}$  se uloží průměrná hodnota ze vstupu *x*. V opačném případě se do zmíněné pomocné proměnné uloží hodnota vektoru *x* s indexem o 1 nižším než je v aktuálně zpracovávaném prvku vektoru *pozice*. Následuje další podmínka, která kontroluje opačný případ, než je rozebírán výše, takže pokud zpracovávaná hodnota proměnné *pozice* obsahuje hodnotu, která je stejná jako délka vstupního vektoru, uloží se do pomocné proměnné  $f_{xii}$  průměrná hodnota vstupního vektoru *x*. V případě opačném, se do zmiňované pomocné proměnné uloží hodnota vstupního vektoru s indexem o 1 vyšším, než je uložen v aktuálně zpracovávaném prvku proměnné *pozice*. Z důvodu přehlednosti výpočtu vzorce, jsou zde ještě další 3 pomocné proměnné. Posledním krokem je výpočet hodnoty podle

vzorce (24), která bude nahrazovat artefakt.

### 7.3.2 Nahrazení pomocí kubického splajnu

Náhrada pomocí kubického splajnu probíhá pomocí funkce integrované v MATLABu, s názvem `interp1`, takže podstatou celého algoritmu je jen vhodně nachystat data, aby bylo možné je vložit do zmíněné funkce. Na začátku algoritmu jsou opět podmínky, které kontrolují obsah proměnné `pozice` z důvodu zmiňovaných v předchozí kapitole. V případě že není splněna žádná z těchto podmínek a není nutné do pomocné proměnné dopočítávat žádný vzorek, uloží se do ní vektor 4 hodnot, z okolí nahrazovaného vzorku. Dále se ukládá do pomocné proměnné `t` vektor 4 indexů z okolí nahrazovaného vzorku a do pomocné proměnné `pomku` vektor 5 indexů z okolí včetně nahrazovaného vzorku.

### 7.3.3 Nahrazení pomocí mediánu

Algoritmus opět obsahuje podmínku, která zajišťuje, abychom nečetli nulové, nebo záporné indexy vzorku. V případě, že by zmíněná podmínka byla splněna, nevkládají se do pomocné proměnné vzorky okolní, ale pouze následující a jejich počet závisí na předdefinované hodnotě  $K$ . Může nastat opačný případ, ve kterém by vzorky proměnné `pozice` obsahovaly takovou hodnotu, že při vyplnění pomocné proměnné bychom zasahovali mimo vstupní vektor, v takovém případě se do zmiňované proměnné uloží hodnoty předchozí. V případě že ani jedna podmínka není splněna, ukládá se do pomocné proměnné  $K$  prvků před artefaktem a  $K$  prvků po artefaktu. Následuje výpočet mediánu z pomocné proměnné a ten se pak dosadí za artefakt.

### 7.3.4 Nahrazení pomocí náhodného prvku z okolí

Algoritmus využívá vypočteného okolí z předchozího algoritmu, jelikož proměnná  $K$ , která určuje velikost okolí, je stejná jak pro nahrazení pomocí mediánu, tak pro nahrazení pomocí náhodného prvku z okolí. Jedná se tedy o jeden řádek kódu, který vybere náhodný index v rozmezí  $1-K$  a právě prvek v pomocném vektoru `pom` s náhodně vybraným indexem, má v sobě uloženou hodnotu indexu `RR`, který za artefakt dosadíme.

### 7.3.5 Vynechání vzorku s artefaktem

Algoritmus vynechání vzorku s artefaktem patří mezi nejjednodušší, a to jak z hlediska výpočetního, tak programátorského. Obsahuje pouze jeden řádek, ve kterém jsou indexovány vzorky s artefaktem a následně jsou odstraněny.

V závěru funkce je vykreslení jednotlivých výsledků do příslušných subplotů, včetně originálního signálu.

## 8 TESTOVÁNÍ ALGORITMŮ

V následujících kapitolách budou algoritmy zpracovávat generovaná data pomocí McSharry modelu. Pro posouzení budou sloužit v případě EMD a náhrady artefaktů vypočtená spektra a v případě algoritmů pro detekci artefaktů, statistické hodnoty v podobě senzitivity, specificity a celkové přesnosti. Pro názornost budou ukázány výsledky metod i na reálných datech.

K testování jednotlivých algoritmů sloužily R-R tachogramy, generované pomocí algoritmu, který byl poskytnut od vedoucí práce. Generátor pracuje na principu McSharry modelu, do kterého je následně přidán trend a artefakty v podobě náhodných impulzů.

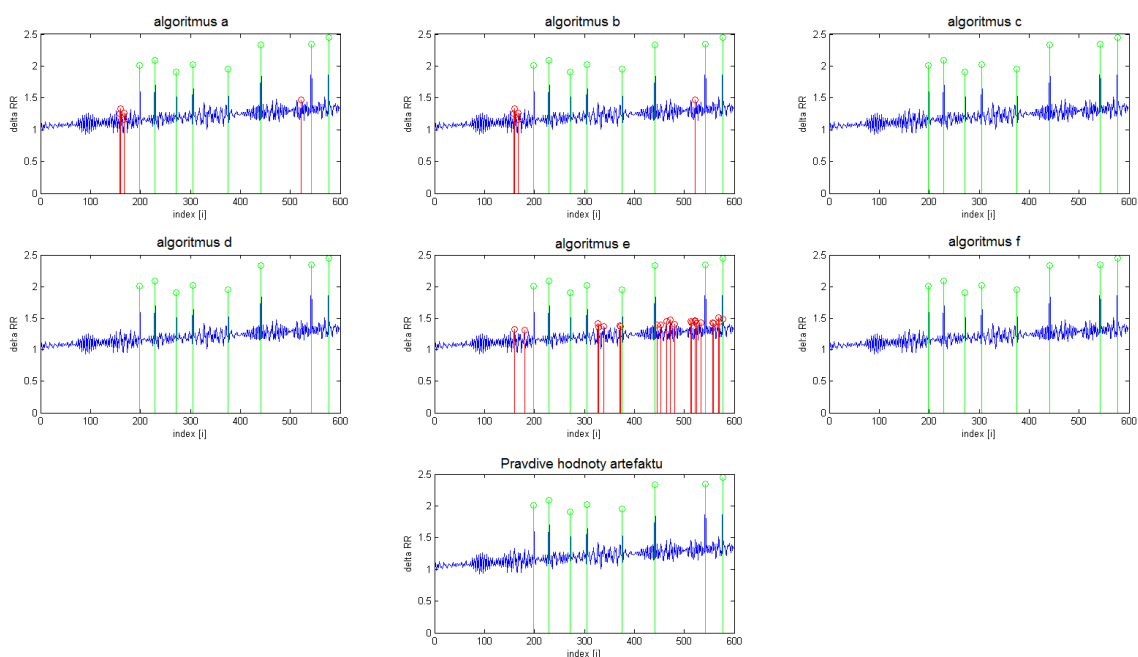
Následující kapitoly obsahují vždy zpracování pomocí jedné funkce. Pro názornost je každá podkapitola rozdělena do 4 dalších podle jednotlivých trendů, s výjimkou náhrady artefaktů, jelikož bylo pozorováno, že i například na algoritmus vyhledávání artefaktů má trend v některých případech výrazný vliv.

### 8.1 Detekce artefaktů v tachogramu

V každém případě byl algoritmus spuštěn desetkrát, a výsledné statistické hodnoty byly zprůměrovány. V případě generovaných dat, kde byly známy i přesné hodnoty artefaktů, jsou v grafu odlišeny správně detekované pozice (zelená) a špatně detekované pozice (červená).

#### 8.1.1 Detekce artefaktů v signálu s lineárním trendem

Jak můžeme vidět na Obr. 14, v případě lineárního trendu střední hodnota pomalu roste.



Obr. 14 – Detekce artefaktů na signálu s lineárním trendem (zeleně – správná, červeně – špatná)

Při bližším pohledu a porovnání jednotlivých algoritmů z vizuálního hlediska se jeví jako nejhorší algoritmus *e*. Vysoká chybovost algoritmu *e* je dána výpočtem kritéria pro porovnávání, jelikož porovnává střední hodnotu všech předchozích přijatých R-R intervalů a posledního přijatého prvku. Je logické, že v případě lineárního trendu ke konci signálu dojde k překročení prahu *i* u intervalů, které artefakty neobsahují. K přesnému porovnání slouží Tabulka 3, ta jen potvrzuje zmíněný výrok, že algoritmus *e* má největší chybovost.

Tabulka 3 – Statistické hodnoty při detekci artefaktů při lineárním trendu

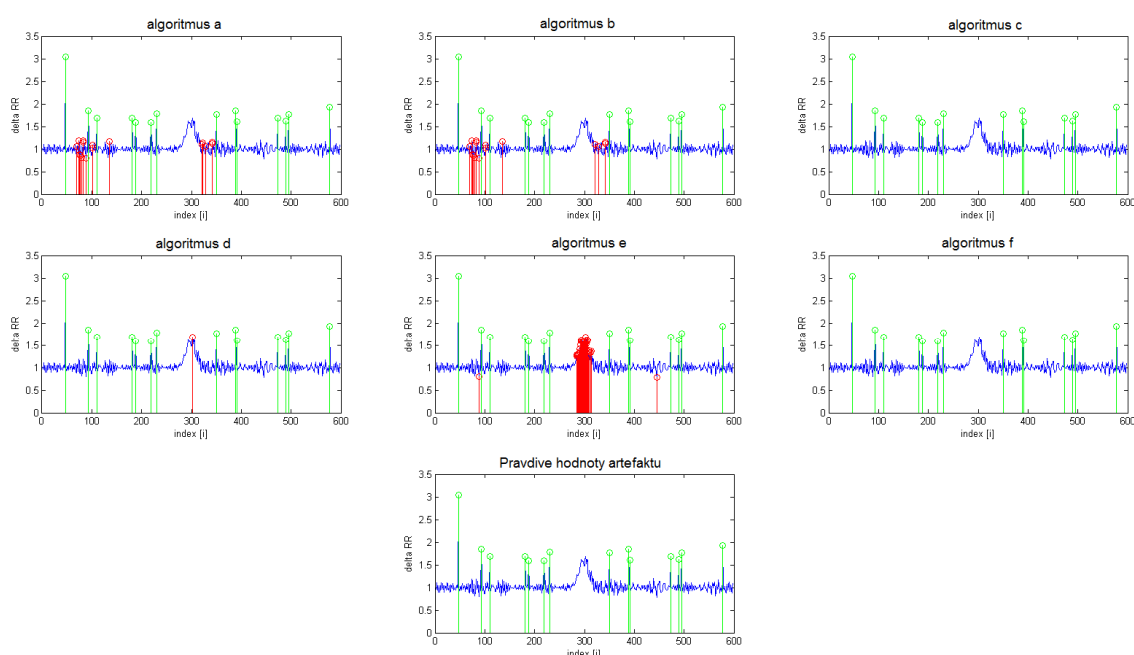
	a	b	c	d	e	f
Senzitivita	0.9960	0.9904	0.9960	0.9960	0.9960	0.9960
Specifická	0.9875	0.9877	0.9998	1	0.9706	1
Přesnost	0.9876	0.9876	0.9997	0.9998	0.9711	0.9998

Jelikož se jedná o průměrné hodnoty z deseti opakování, nemůžeme výsledky přesně ztotožnit se zmiňovanými grafy, což je vidět například u algoritmu *f*, který podle Obr. 14, neprovedl ani jednu chybnou detekci, avšak v Tabulka 3 je snižená senzitivita.

Za předpokladu, že se v tachogramu objevuje pouze lineární trend, můžeme vyhodnotit na základě statistických dat, že nejpřesnějšími metodami jsou algoritmy *d* a *f*, které měli stejné hodnocení přesnosti, senzitivity i specifit. Druhou nejvhodnější metodou je algoritmus *c*, který podle specifity obsahoval i falešně pozitivní detekce. Dále pak jsou algoritmy *a* a *b* podle přesnosti rovnocenné, avšak liší se senzitivitou, či specifitou.

### 8.1.2 Detekce artefaktů v signálu s Gaussovským trendem

Signál s Gaussovským trendem má dobře známý průběh, ve kterém je poměrně prudký nárůst, tudíž lze předpokládat, že některé algoritmy pro detekci artefaktů by s ním mohli mít problém.



Obr. 15 – Detekce artefaktů na signálu s Gaussovským trendem (zeleně – správné, červeně – špatné)

Jak lze vidět na Obr. 15, potvrdil se předpoklad, že by s prudkým nárůstem Gaussova trendu mohl mít některý algoritmus problém. Největší chybovost je v oblasti prudkého nárůstu a poklesu v případě algoritmu *e*. Chyba způsobená algoritmem *e* byla vysvětlena v předchozí kapitole. Poměrně výrazná chybovost se projevila i u algoritmů *a* a *b*, avšak tyto chyby nebyly způsobeny prudkým nárůstem, ale zřejmě poměrně velkými rozdíly mezi výchylkou po sobě jdoucích vzorků.

Tabulka 4 - Statistické hodnoty při detekci artefaktů při Gaussovském trendu

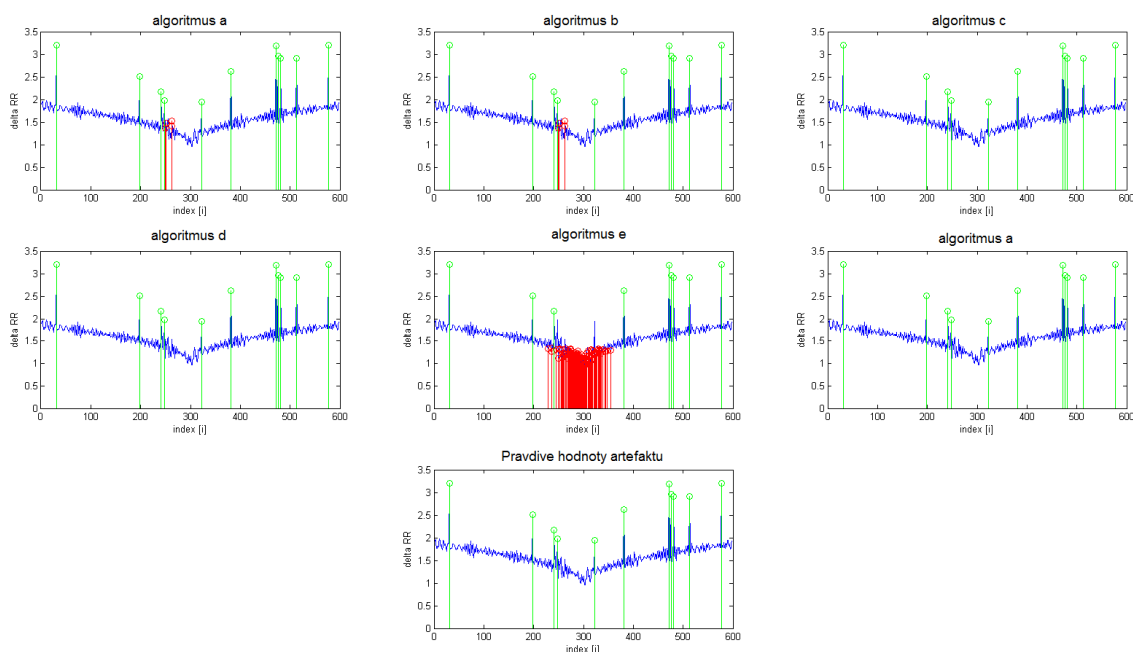
	a	b	c	d	e	f
Senzitivita	0.9864	0.9864	0.9520	0.9864	0.9864	0.9864
Specifická	0.9644	0.9694	0.9984	0.9974	0.9455	1
Presnost	0.9647	0.9696	0.9973	0.9970	0.9462	0.9995

Z Tabulka 4 vyplývá, že opět nejpresnější metodou je algoritmus *f*. Snížená senzitivita byla důkladněji zkoumána, se závěrem, že ve většině případů u algoritmu *f* byla způsobena nedokonalostí programu při generování signálu, konkrétně při generování náhodných pozic. V případě, že se některá pozice opakovala, algoritmus ji detekoval pouze jednou a to způsobilo sníženou senzitivitu.

Poměrně přesná detekce byla i v případě algoritmu *c* a *d*, avšak senzitivita v případě algoritmu *c* byla nejhorší. Dále algoritmy *a* a *b* byly přibližně na stejné úrovni, avšak algoritmus *b* měl mírně vyšší specificku.

### 8.1.3 Detekce artefaktů v signálu s hrotovým trendem

Z tvaru trendu je opět patrné, že některé algoritmy, zejména algoritmus *e*, budou mít s detekcí artefaktů problémy. Při pohledu na Obr. 16 jsou výsledky zřejmé.



Obr. 16 – Detekce artefaktů na signálu s hrotovým trendem (zeleně – správně, červeně – špatně)

Algoritmus *e* opět selhal v částech signálu, kde se nejvíce projevuje hrotový trend, avšak při pohledu na konkrétní příklad z Obr. 16, se jeví všechny ostatní metody jako poměrně spolehlivé.

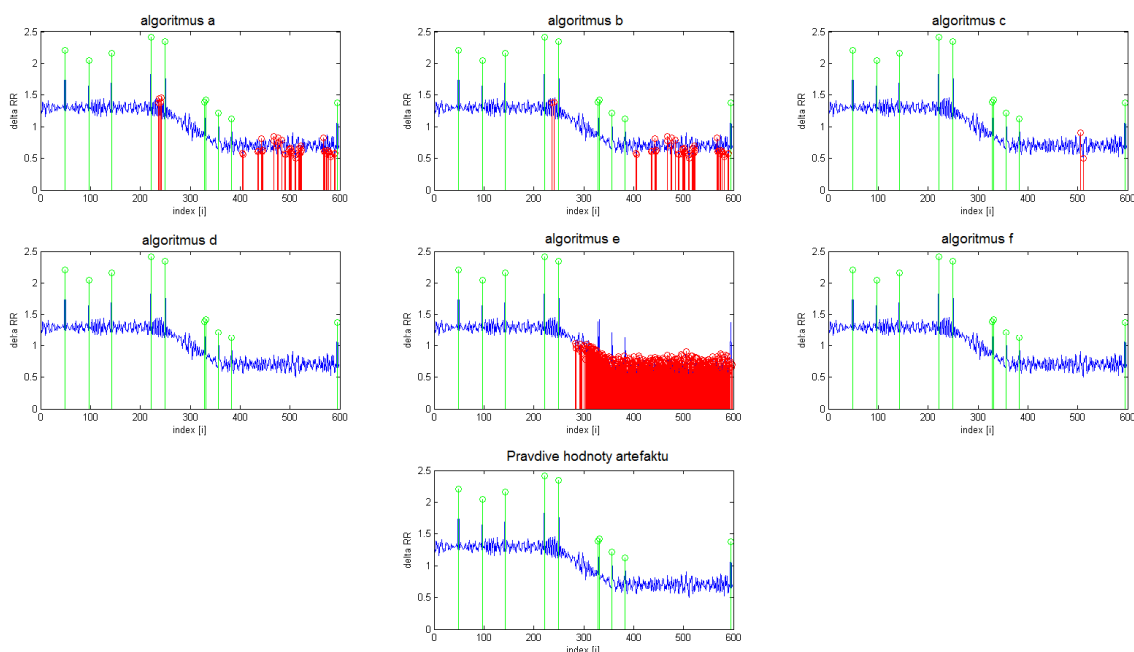
Tabulka 5 - Statistické hodnoty při detekci artefaktů při hrotovém trendu

	a	b	c	d	e	f
Senzitivita	0.9628	0.9628	0.9628	0.9628	0.9248	0.9628
Specifická	0.9979	0.9981	0.9998	1	0.8542	1
Presnost	0.9975	0.9977	0.9993	0.9995	0.8559	0.9995

Podle Tabulka 5 můžeme soudit, že všechny metody, kromě algoritmu *e* byly poměrně úspěšné. Nejúspěšnější byl opět algoritmus *f* a stejných výsledků dosáhl i algoritmus *d*, avšak velmi slušných výsledků dosáhl i algoritmus *c*. Při porovnání senzitivit všech algoritmů, je patrné, že u všech, s výjimkou algoritmu *e*, se opět projevila nepřesnost části programu pro generování artefaktů.

### 8.1.4 Detekce artefaktů v signálu se zlomovým trendem

Podle tvaru trendu je možné předpovídat, že algoritmus *e* bude mít problémy, jelikož se objevuje opět poměrně prudký pokles střední hodnoty, což zmíněný algoritmus většinou detekuje již jako artefakt.



Obr. 17 - Detekce artefaktů na signálu se zlomovým trendem (zeleně – správné, červeně – špatné)

Na Obr. 17 je vidět, že algoritmus *e* v případě zlomového trendu vyhodnotil téměř polovinu signálu jako artefakt, tudíž opět výrazně selhal. V případě algoritmů *a* a *b* je rovněž vidět že při poklesu průměrné hodnoty za zlomem se projevují nedostatky algoritmů, ovšem v tomto případě se zřejmě jedná o shodu náhod, jelikož zmiňované algoritmy nevyužívají žádným způsobem hodnoty z počátku tachogramu.

Tabulka 6 - Statistické hodnoty při detekci artefaktů při zlomovém trendu

	a	b	c	d	e	f
Senzitivita	0.9628	0.9628	0.9184	0.9628	0.5874	0.9628
Specifická	0.9305	0.9353	0.9973	0.9993	0.4907	0.9998
Přesnost	0.9314	0.9361	0.9960	0.9988	0.4928	0.9993

Z Tabulka 6 jsou nejlépe vidět rozdíly mezi jednotlivými algoritmy. Opět nejlepší detekci prováděl algoritmus *f* a poměrně přesné jsou i algoritmy *d* a *c*. Ovšem přesnost, senzitivita i specifická algoritmu *e* je nevyhovující.

### 8.1.5 Závěrečné hodnocení algoritmů pro detekci artefaktů

K závěrečnému hodnocení nejlépe poslouží opět statistické hodnoty na Tabulka 7, v tomto případě se jedná o průměrné hodnoty pro všechny typy trendů, které byly měřeny desetkrát.

Tabulka 7 – Statistické hodnoty při detekci artefaktů po zprůměrování

	a	b	c	d	e	f
Senzitivita	0.9849	0.9821	0.9645	0.9857	0.6479	0.9857
Specifická	0.9315	0.9265	0.9952	0.9984	0.4885	0.9989
Presnost	0.9325	0.9278	0.9942	0.9980	0.4909	0.9985

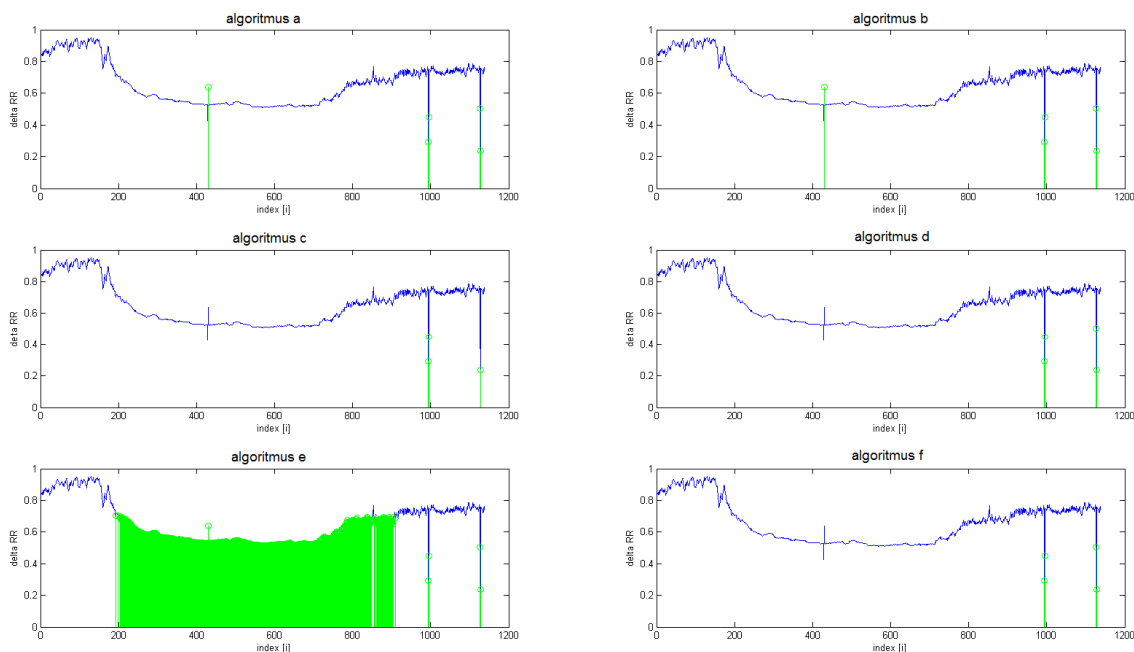
Nabízí se zde tedy otázka, z jakého důvodu byl algoritmus *e* navrhnut, z tohoto důvodu bylo provedeno ještě jedno měření, a sice na tachogramu bez trendu. Výsledky v Tabulka 8 na zmiňovanou otázku odpovídají.

Tabulka 8 – Statistické hodnoty při detekci artefaktů bez trendu

	a	b	c	d	e	f
Senzitivita	0.9927	0.9794	0.9808	0.9927	0.9927	0.9927
Specifická	0.9716	0.9720	0.9984	1	0.9954	1
Presnost	0.9719	0.9717	0.9977	0.9997	0.9952	0.9997

Algoritmus *e* byl zřejmě vyvinut pro detekci artefaktů na signálech, které trend neobsahují nebo obsahují jen velmi malý trend, nicméně stále je nejúspěšnější a nejpresnější algoritmus *f*, který je zároveň vývojově nejnovější.

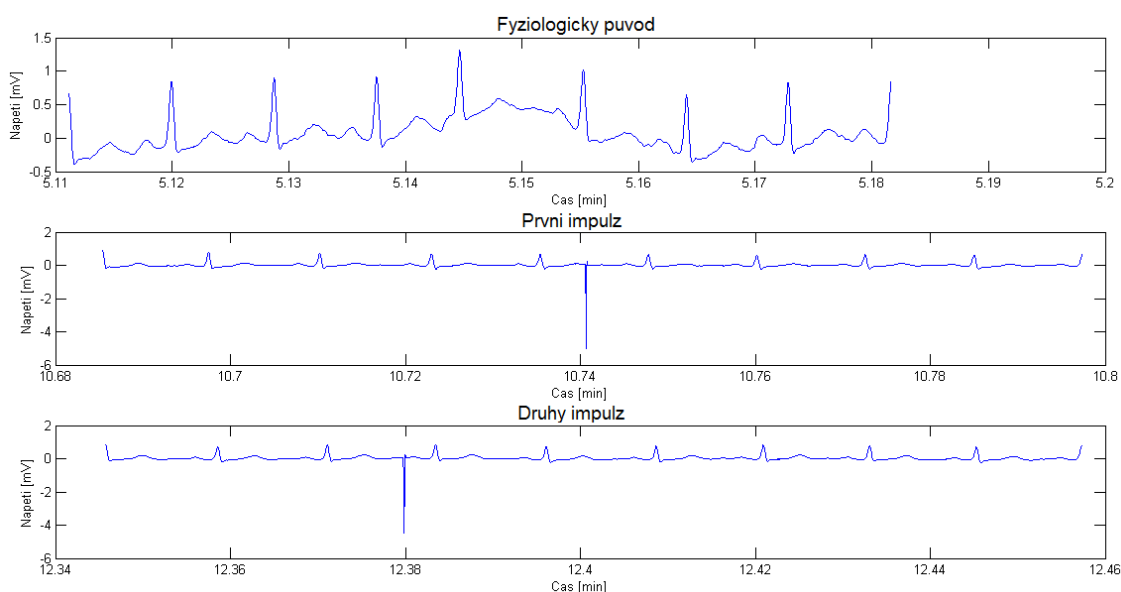
Pro úplné porovnání teorie s praxí jsou na Obr. 18 uvedeny výsledky detekce artefaktů na reálných datech, u kterých byl předpoklad vyšší chybovosti.



Obr. 18 – Aplikované algoritmy na reálných datech

Data byla zpracována pomocí QRS detektoru [18]. Jedná se o zátěžový test pacienta s metabolickým syndromem. Test probíhal tak, že pacient byl 2,5 vleže v klidu a následně 5 minut šlapal na horizontálním rotopedu, tento přechod je viditelný poměrně strmým poklesem délky RR intervalu, následovalo 5 minut odpočinku. Na

záznamu můžeme vidět celkem tři poměrně výrazné kmity, první kmit na vzorku přibližně 450 je po zkontrolování záznamu EKG fyziologického původu, tento kmit nebyl zaznamenán algoritmy *c*, *d* a *f*, což je zřejmě způsobeno tolerancí k překročení prahu v algoritmu. Ve zmíněných případech je totiž procentuální tolerance větší než 20%, v případě detekce pomocí algoritmů *a*, *b* a *e* tento ektopický cyklus byl detekován, nutno podotknout, že v případě algoritmu *e* této detekci nemůžeme dávat žádnou váhu, jelikož celý interval, ve kterém byla doba trvání RR intervalu výrazně nižší, byl označen jako artefakt. Následovaly dva velmi výrazné kmity na vzorkách přibližně 1000 a 1150, které soudě dle EKG záznamu byly způsobeny zřejmě odlepením elektrody. Tyto dva impulzy byly správně detekovány všemi algoritmy. Na Obr. 19 jsou vidět detaily EKG záznamu ve zmiňovaných úsecích.

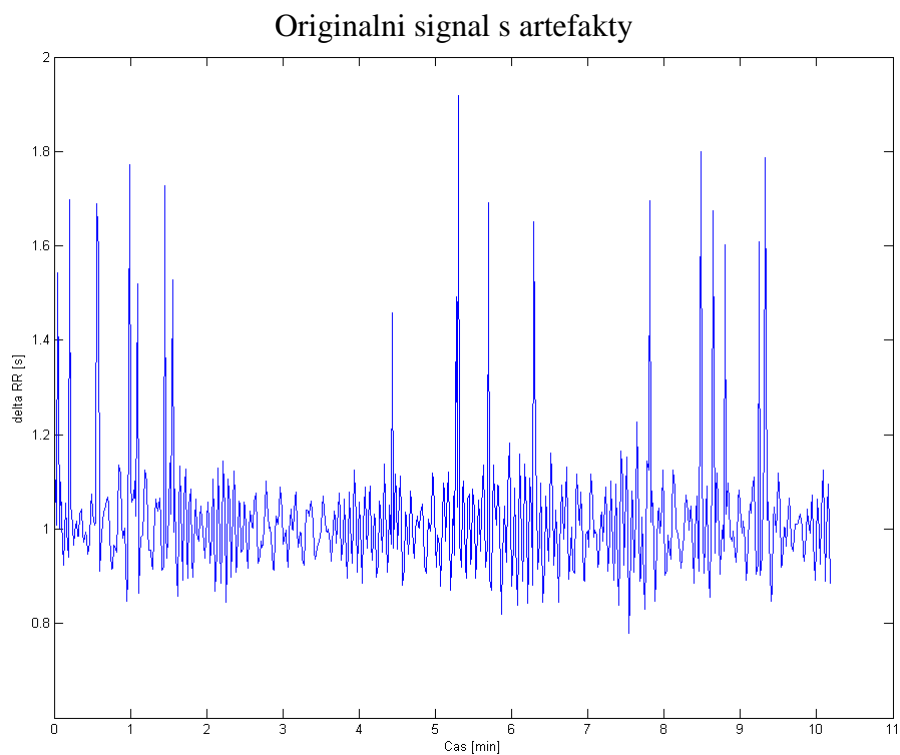


Obr. 19 – EKG signál v pozicích artefaktů

Jako nejvhodnější algoritmus pro vyhledávání artefaktů, byl zvolen algoritmus *f*, který je dle výsledků nejlepší, s ohledem na senzitivitu, specifitu i přesnost, alternativou algoritmu *f* by mohl být algoritmus *d*, který podobně jako v Tabulka 2 dosahoval uspokojivých výsledků.


## 8.2 Náhrada artefaktů v tachogramu

Následující podkapitola obsahuje výsledky náhrady artefaktů, jejichž pozice byly přečteny přímo z generátoru signálu. Grafy jsou zpracovány tak, že zobrazují rozdíl spektra daného algoritmu a originálního signálu bez trendu a artefaktů, v případě algoritmu pro vynechání vzorku, budou pouze spektra porovnána z vizuálního hlediska. Všechny metody byly testovány na generovaném signálu, zobrazeném na Obr. 20.



Obr. 20 – Originální signál s artefakty

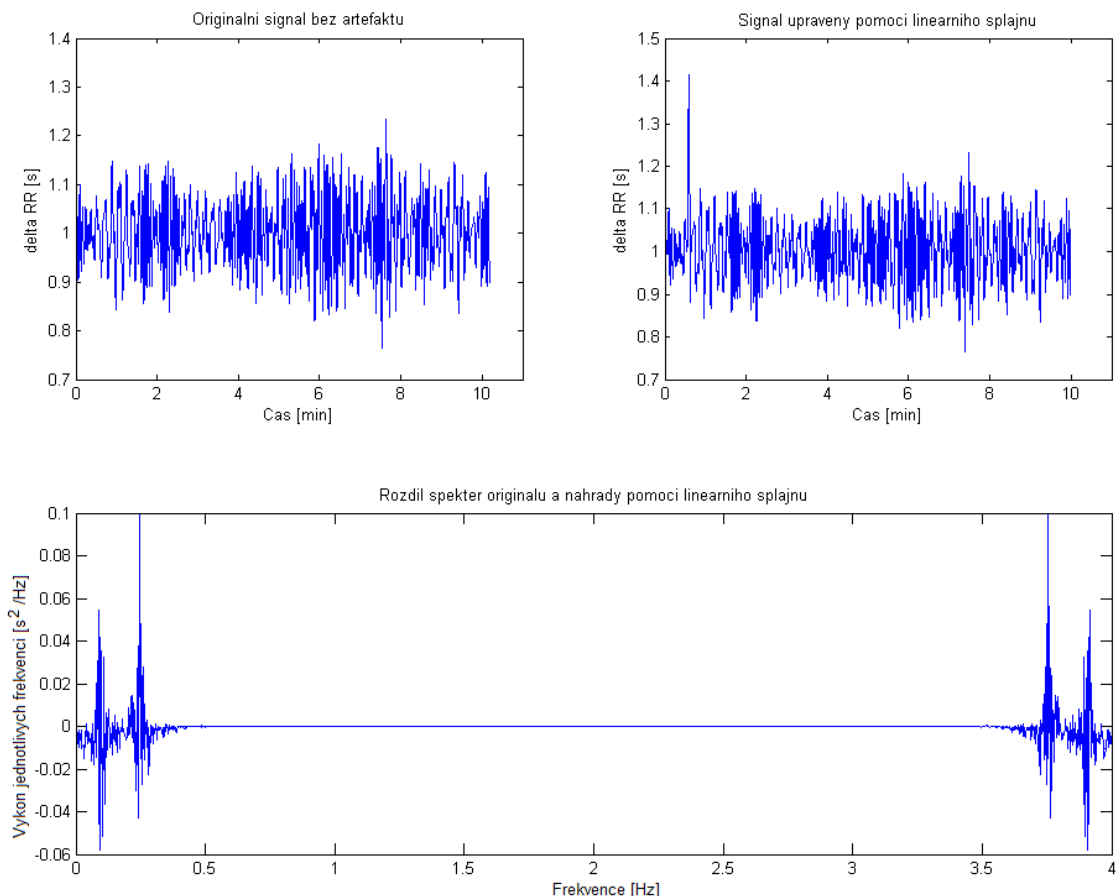
Na Obr. 21 je zobrazeno výkonové spektrum originálního signálu bez artefaktů. Jsou zde patrné píky na frekvencích přibližně 0,1 Hz a 0,25 Hz, z čehož lze předpokládat, že chyby, které se projeví u následujících algoritmů, budou obsaženy v okolí těchto frekvencí.



Obr. 21 – Výkonové spektrum originálního signálu bez artefaktů

## 8.2.1 Náhrada pomocí lineárního splajnu

Nahrazení pomocí lineárního splajnu, je jedna z jednodušších metod, takže je pravděpodobné, že při větší hustotě artefaktů se mohou projevit její nedokonalosti.




Obr. 22 – Náhrada artefaktů pomocí lineárního splajnu

Na Obr. 22 jsou vidět výsledky aplikace lineárního splajnu. Je vidět, že v čase kolem 0,5 minuty je chybná náhrada, která byla způsobena zmiňovanou zvýšenou hustotou artefaktů. Při pohledu na rozdíl spekter signálu bez artefaktů a signálu s nahrazenými artefakty pomocí lineárního splajnu, je patrné, že impuls, způsobený nedokonalostí algoritmu, byl na vyšších frekvencích. Pokud bychom porovnali nejvíce zasažená pásma tak se jedná o pásmo HF a pásmo LF. Pásmo VLF a ULF bylo při nahrazení pomocí lineárního splajnu zasaženo minimálně.

## 8.2.2 Náhrada pomocí kubického splajnu

Kubický splajn je ve srovnání s lineárním splajnem výpočetně náročnější a jeho schopnost nahrazení artefaktů je v našem případě dána hlavně okolím artefaktu. Při nahrazování pomocí zmíněné metody, byly vybírány dva body v okolí artefaktu, což zmírňuje chybu, kterou s sebou nesl lineární splajn.




Obr. 23 – Náhrada artefaktů pomocí kubického splajnu

Při srovnání originálního a upraveného signálu na Obr. 23 je opět patrný impulz v oblasti přibližně 0,5 minut. Je opět způsoben zmiňovanou vyšší hustotou artefaktů v této oblasti. Rozdíl spekter ukazuje, že v oblasti LF došlo k přibližně stejnému zkruslení jako u splajnu lineárního, avšak v oblasti HF má pík nižší hodnotu. Pásma VLF a ULF opět zůstala téměř stejná.

### 8.2.3 Náhrada pomocí mediánu z okolí

Metoda nahrazování artefaktů pomocí mediánu z okolí se poměrně liší od metod s výpočtem splajnu, takže lze očekávat, že výsledky budou odlišné. V našem případě se počítal medián z 8 hodnot z okolí artefaktu opět z důvodu menší možnosti zasažení chybou, způsobenou vysokou hustotou artefaktů. Při pohledu na Obr. 24 je vidět, že pík, který se objevoval v algoritmech, které využívaly výpočtu splajnu, již není zřetelný.




Obr. 24 – Náhrada artefaktů pomocí mediánu z okolí

Avšak při pohledu na rozdíl spekter signálů je jistý rozdíl mezi signály viditelný. Při srovnání s předchozími metodami, se jedná o výrazné zvětšení přesnosti, jelikož odchylka spekter v pásmech HF a LF se snížila přibližně na polovinu.

### 8.2.4 Náhrada pomocí náhodného prvku z okolí artefaktu

Tato metoda se svým předzpracováním nijak výrazně neliší od náhrady pomocí mediánu, jelikož ze stejného okna, v našem případě délky 4 před artefaktem a 4 za artefaktem, se vybírá náhodný prvek. Tato metoda nepočítá žádné nové hodnoty, tudíž lze předpokládat zlepšení oproti mediánu, avšak nevýhodou této metody je fakt, že náhodně vybraný prvek může obsahovat artefakt, který se vyskytuje v těsné blízkosti artefaktu právě zpracovávaného. Tato chyba se může vyskytovat opět u signálů, s větší hustotou artefaktů.

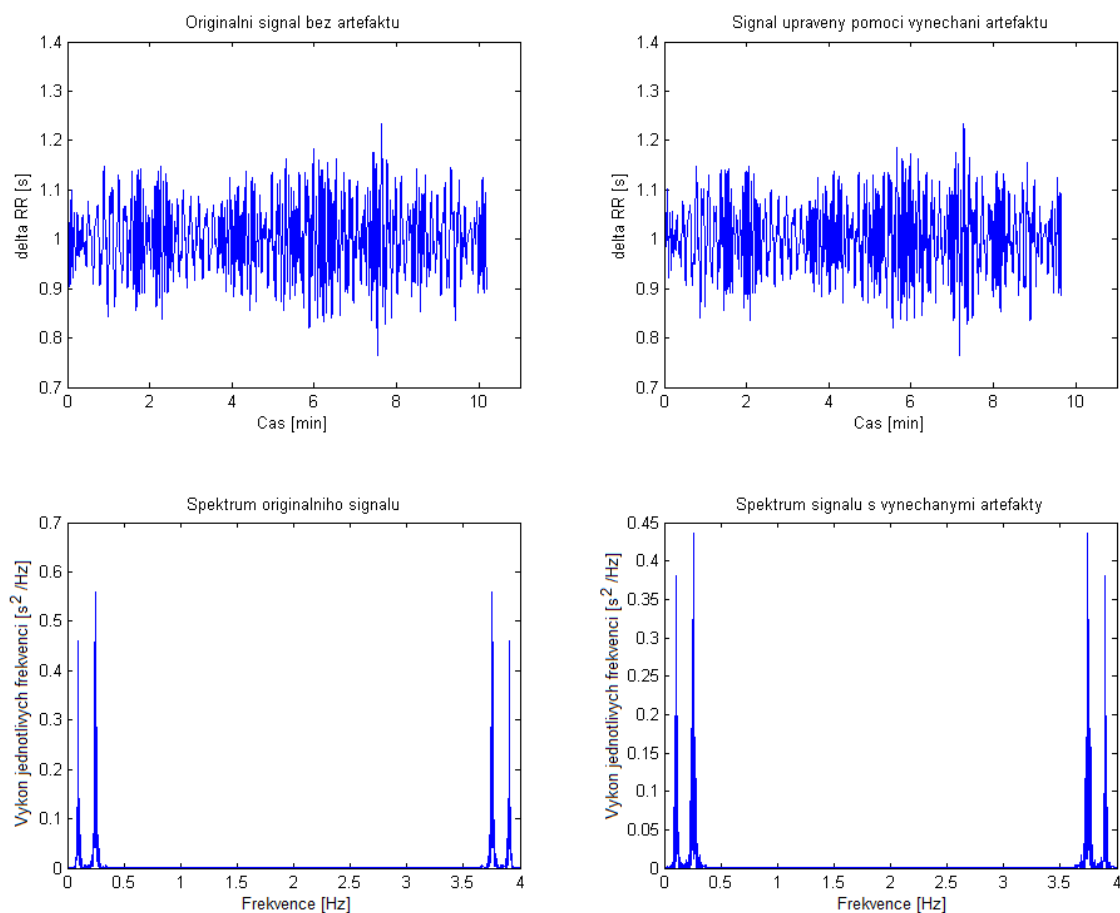


Obr. 25 – Náhrada artefaktů pomocí náhodného prvku z okolí.

Jelikož byl záměrně vybrán signál, u kterého se v jednom místě vyskytuje větší hustota artefaktů, zmiňovaná chyba se projevila. Na Obr. 25 je vidět porovnání originálního a upraveného signálu, přičemž výrazný pík v oblasti přibližně 0,5 minut způsobuje i výraznou výchylku v rozdílu spekter signálů. Tato chyba je v porovnání s předchozími metodami největší a to zejména v oblasti HF.

### 8.2.5 Úprava signálu pomocí vynechání prvku s artefaktem

V případě, že se využívá této metody, musí být brán ohled na to, že je zde jistá ztráta informace ze signálu. Jelikož se jedná výpočetně o nejjednodušší metodu, lze brát v úvahu jisté nepřesnosti. K posouzení kvality této metody nebyl využit rozdíl spekter, jelikož se jedná o různě dlouhé signály a v případě programového porovnání by bylo nutné provést úpravy v podobě splajnu, což je jiná metoda. Na Obr. 26 je názorně vidět, že jsme přišli o jistou část signálu, jelikož délka originálu a upraveného signálu se výrazně liší.



Obr. 26 – Úprava signálu vynecháním artefaktů

Při vizuálním porovnání originálního a upraveného signálu na Obr. 26 nejsou vidět žádné rozdíly. Při porovnání spekter, je patrné, že spektrum upraveného signálu má menší výchylku v oblasti píky, tudíž lze s přibližným výpočtem říci, že zkreslení v oblasti LF dosahuje asi 0,08 a v oblasti HF 0,12, což lze zařadit přibližně k přesnosti algoritmu náhrady pomocí lineárního splajnu.

### 8.2.6 Závěrečné zhodnocení algoritmů pro odstranění artefaktů

Představu o přesnosti lze vyjádřit výpočtem přibližných procentuelních odchylek dvou nejvýraznějších píků, které se vyskytují v HF a LF. Tyto hodnoty jsou uvedeny Tabulka 9 na následující straně. Jedná se o přibližné hodnoty těchto chyb, sloužící k porovnání jednotlivých algoritmů. Je patrné, že metodou nejvhodnější pro odstranění artefaktů je odstranění pomocí mediánu okolních prvků. Naopak nejméně vhodnou v našem případě se jeví metoda, využívající principu náhodného výběru a metoda, která artefakt vynechává.

Tabulka 9 – Relativní chyby odstranění artefaktů v pásmech HF a LF

Algoritmus	Relativní chyba [%]	
	LF	HF
Náhrada artefaktu lineárním splajnem	11,96	17,86
Náhrada artefaktu kubickým splajnem	15,22	16,07
Náhrada artefaktu mediánem z okolí	6,74	7,23
Náhrada artefaktu náhodným prvkem z okolí	13,04	28,57
Vynechání artefaktu	17,39	21,43

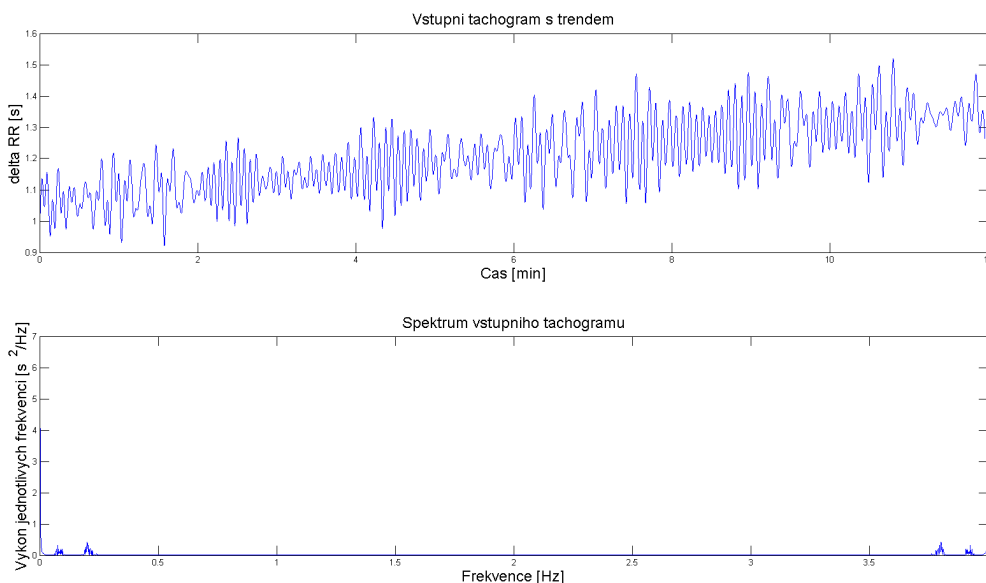
Tabulka 9 obsahuje 5 řádků, přičemž každý představuje jednu metodu.

### 8.3 Odstranění trendu pomocí metody EMD

V této podkapitole bude posouzena funkčnost programu na signály s jednotlivými druhy trendů. Posuzování bude na základě porovnání spektra originálního signálu bez trendu a signálu, který byl vytvořen pomocí funkce EMD. Zároveň zde bude posouzena experimentální metoda, která byla vypořizována během testování. Jelikož bylo zjištěno, že trend se většinou vyskytuje ve zbytkovém signálu z výpočtu 3. IMF, po jeho odečtení od originálního signálu vzniká signál bez trendu.


#### 8.3.1 Odstranění lineárního trendu

Lineární trend má sestupný nebo vzestupný charakter, v našem případě je tento trend vzestupný.



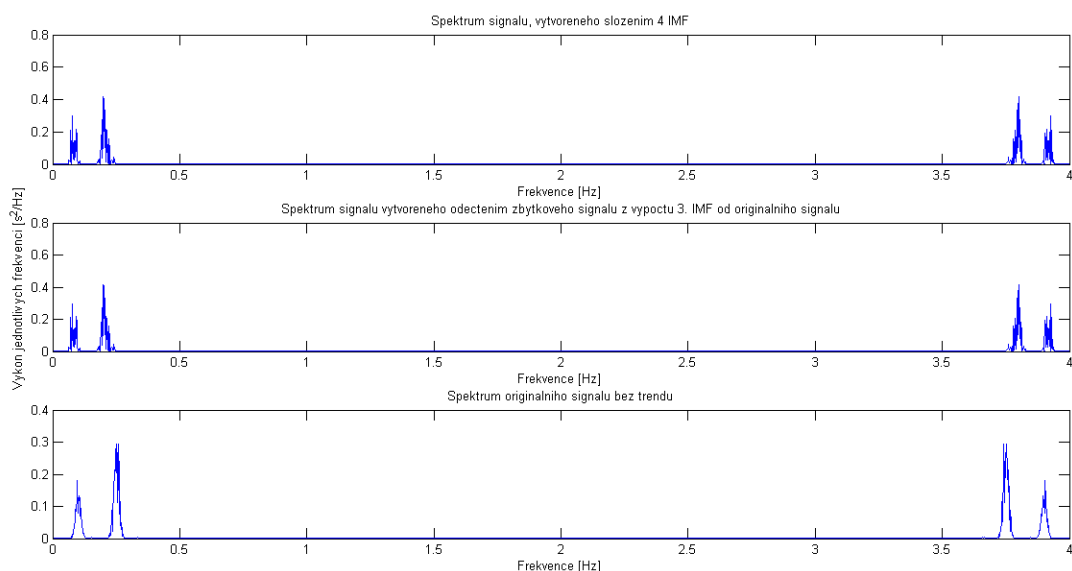
Obr. 27 – Spektrum a průběh tachogramu s lineárním trendem

Jak je vidět na Obr. 27, trend, vyskytující se ve velmi nízkých frekvencích má na spektrum výrazný vliv.



Obr. 28 – Signály s odstraněným lineárním trendem

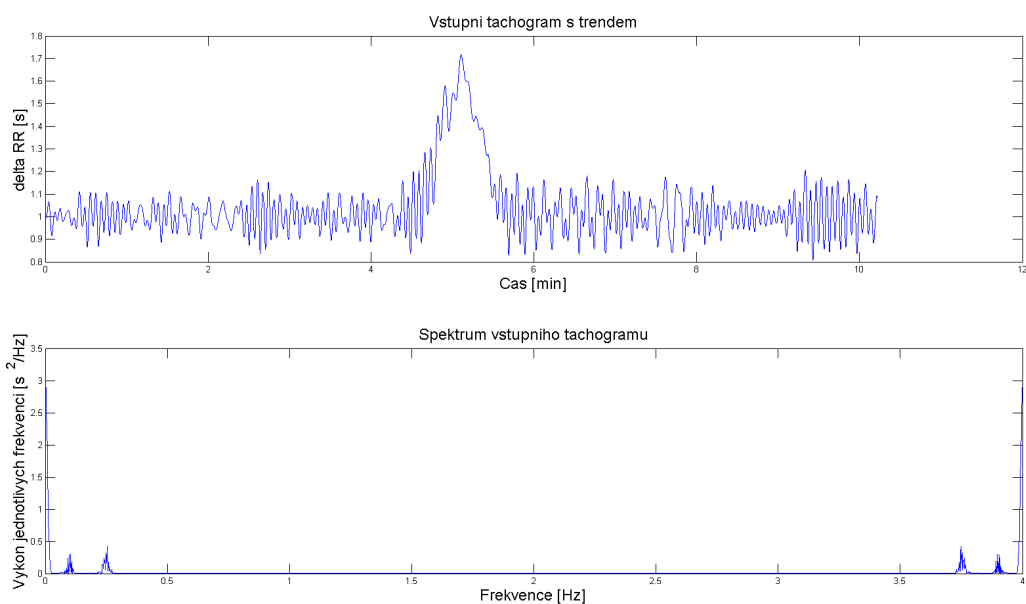
Výsledné signály, které byly vypočítány pomocí EMD jsou zobrazeny na Obr. 28. Při vizuální kontrole, nejsou patrné téměř žádné rozdíly mezi výslednými signály, avšak signál, vzniklý sumací 4 IMF má vyšší průměrnou hodnotu. Pro přesnější porovnání výsledných signálů, slouží výkonové spektrum, zobrazené na Obr. 29. Z těchto obrázků je patrné, jak vysokou úspěšnost metoda EMD při odstraňování lineárního trendu měla. Oba způsoby zpracování způsobily mírný nárůst amplitudy, nicméně tvar spektra se v podstatě nezměnil. Zmiňovaný nárůst střední hodnoty není ve spektru patrný, jelikož by i u originálního signálu bez trendu způsobil velkou výchylku na 0 frekvenci, čímž by se spektrum stalo téměř nečitelné. Trend, který se vyskytoval v oblastech VLF a ULF byl úspěšně odstraněn.



Obr. 29 – Výkonová spektra signálů s odstraněným lineárním trendem

### 8.3.2 Odstranění Gaussovského trendu


Tvar a spektrum signálu, který bude zpracováván, je zobrazen na Obr. 30.



Obr. 30 – Spektrum a průběh tachogramu s Gaussovským trendem


Na spektru je vidět, že Gaussovský trend zasahuje do vyšších frekvencí než trend lineární, avšak jedná se stále o velmi nízké frekvence.

Výsledné signály, které byly výstupem funkce EMD jsou na Obr. 31.



Obr. 31 – Signály s odstraněným Gaussovským trendem


Jak je vidět, opět při vizuální kontrole byl trend dokonale odstraněn, v případě výkonového spektra, které je zobrazeno na Obr. 32 na následující straně, je již patrné mírné zkreslení v oblastech přibližně kolem 0,1 Hz.



Obr. 32 – Výkonová spektra signálu s odstraněným Gaussovským trendem

### 8.3.3 Odstranění hrotového trendu

Průběh i spektrum zpracovávaného signálu, který obsahuje hrotový trend, je možné vidět na Obr. 33.




Obr. 33 – Spektrum a průběh tachogramu s hrotovým trendem

Ze spektra průběhu vyplývá, že trend je obsažen na nejnižších frekvencích, avšak s velkým výkonem, tudíž velmi výrazným způsobem ovlivňuje zpracovávaný tachogram.


Výsledné signály jsou zobrazeny na Obr. 34. Co se týká tvarových změn signálu,

nebyly téměř žádné, avšak střední hodnota, v případě sumace 4 IMF byla o 0,6 sekundy vyšší, což se dá považovat za poměrně velkou chybu, výpočet pomocí druhé metody byl podstatně úspěšnější, a je téměř srovnatelný s originálem.



Obr. 34 – Signály s odstraněným hrotovým trendem.


V případě vizuální kontroly spekter zobrazených na Obr. 35 jsou změny poměrně výrazné. Došlo k posunu píků, v pásmech HF i LF.



Obr. 35 – Výkonová spektra signálu s odstraněným hrotovým trendem


### 8.3.4 Odstranění Zlomového trendu

Zpracovávaný signál se zlomovým trendem je na Obr. 36, z něhož je díky spektru opět patrné jak velkým způsobem trend zasahuje do signálu.




Obr. 36 – Spektrum a průběh tachogramu se zlomovým trendem

Na výsledných signálech na Obr. 37 je vidět poměrně výrazné zkreslení i bez spektrální analýzy. Signály zpracované oběma způsoby mají přibližně stejný tvar, avšak signál, který vznikl sumací má opět vyšší střední hodnotu.



Obr. 37 – Signály s odstraněným zlomovým trendem

Podrobnější výsledky udává spektrální analýza zobrazená na Obr. 38 na následující straně. Z této analýzy je patrné, že metoda EMD není příliš vhodná pro zlomový trend, jelikož výrazně ovlivňuje signál.



Obr. 38 – Výkonová spektra s odstraněným zlomovým trendem

### 8.3.5 Závěrečné zhodnocení odstranění trendu pomocí EMD

Metoda EMD je poměrně úspěšnou metodou pro odstranění trendu, avšak při odstraňování zlomového trendu se objevují poměrně výrazné změny tachogramu, což je nežádoucí jev, avšak výsledky odpovídají teoretickým předpokladům z Tabulka 1.


## 8.4 Testování vybraného postupu

Z předchozích kapitol lze určit způsob, jakým nejúčinněji provést předzpracování tachogramů RR intervalů, který je nutno provádět v následujícím pořadí:

1. Vyhledávání artefaktů pomocí algoritmu  $f$
2. Náhrada nalezených artefaktů mediánem z okolních prvků
3. Odstranění trendu pomocí EMD s využitím metody sumace 4 IMF

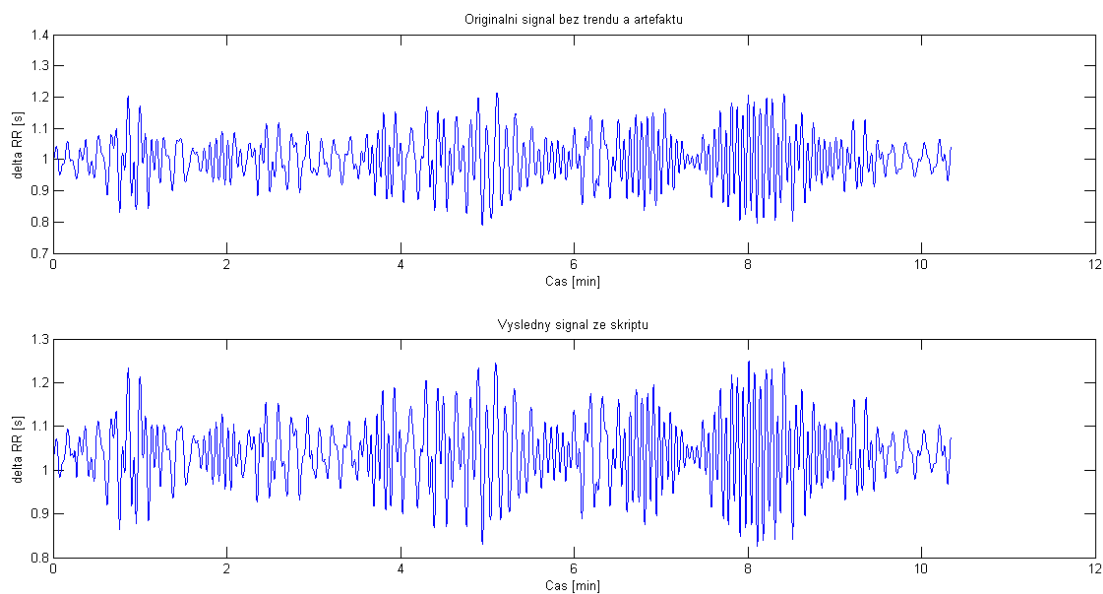
Tento postup je zahrnut ve skriptu `komplet`, pomocí kterého se volají zmíněné funkce. Skript se spouští v případě, že máme ve `workspace` uložen tachogram jako proměnnou `HRV`, případně pozice QRS komplexů jako `QRS`.

Výsledkem spuštěného skriptu je jeden `figure` se zobrazeným originálním vstupem a vypočteným výstupem. Příklad výstupu ze skriptu, je pro generovaný signál na Obr. 39.




Obr. 39 – Výstup z řídicího skriptu pro generovaný signál

Jelikož se jedná o generovaný signál, je na Obr. 40 zobrazen porovnání originálního signálu bez trendu a artefaktů a výsledného signálu po zpracování



Obr. 40 – Srovnání signálu bez trendu a artefaktů a výsledného signálu ze skriptu

Dále pro srovnání generovaného a reálného signálu, je na Obr. 41 zobrazen výstup zmiňovaného skriptu pro náhodně vybraný reálný signál.



Obr. 41 – Výsledek skriptu pro náhodně vybraný reálný signál

## 9 ZÁVĚR

V této bakalářské práci, bylo stručně popsáno EKG, a zpracování HRV z různých hledisek. Dále zde bylo vysvětleno co je trend, který se vyskytuje v signálech HRV, jaké rozlišujeme druhy trendů a jakým způsobem je možné tyto trendy odstranit. Byly uvedeny 3 nejpoužívanější metody, které jsou: SPA - smoothness prior approach („přiblížení předešlé hladkosti“), EMD – empirical mode decomposition („metoda empirického rozkladu“) a odstranění pomocí vlnkové transformace. Dále zde byly popsány metody pro detekci artefaktů podle [14]. Následoval popis 5 metod, kterými se detekované artefakty odstraňují.

Práci lze dle kapitoly 8 rozdělit do 4 dílčích částí, přičemž první část, ve které se testovaly jednotlivé algoritmy pro detekci artefaktů, byla rozdělena podle typu trendů. Z výsledků měření vyplývalo, že některé algoritmy jsou poměrně náchylné na trend, jedná se především o algoritmus  $e$ , který využíval pro detekci artefaktů průměrné hodnoty ze všech předchozích přijatých intervalů a předchozí přijatý interval. Jak bylo následně prokázáno, za předpokladu, že není v signálu obsažen trend, algoritmy podle toho jak jsou vývojově staré, tak jsou kvalitní ( $a$  - nejméně kvalitní,  $f$  – nejkvalitnější). Avšak za předpokladu, který je u reálných signálů pravděpodobnější, že je trend obsažen, algoritmus  $e$  naprosto selhává, naopak algoritmus  $f$  byl nejvhodnější pro signály s trendem i bez něj, z tohoto důvodu byl i algoritmus  $f$  vybrán pro využití pomocí řídicího skriptu. V poslední části testování algoritmů pro detekci artefaktů byl použit reálný signál, obsahující dva výrazné píky, nefyziologického původu, a jeden menší pík fyziologického původu. V případě reálných signálů z důvodu poměrně malé výchylky fyziologického píku, nebyl zaznamenán vybraným algoritmem  $f$ , takže ani vybraný algoritmus není úplně bezchybný.

V další části byla věnována pozornost náhradě detekovaných artefaktů. Testování probíhalo opět na generovaných datech z důvodu možnosti porovnání přesnosti náhrady. Algoritmy byly spouštěny všechny na stejném signálu a pro posouzení přesnosti daného algoritmu sloužil rozdíl spekter. Z výsledků uvedených v Tabulka 9 vyplývá, že nejvhodnější metodou pro odstranění artefaktů ze signálu je algoritmus, který využívá pro náhradu medián okolních prvků, konkrétně 4 před artefaktem a 4 po artefaktu. Naopak nejméně vhodná metoda není jednoznačná, jelikož metoda, která využívá náhodně vybraného prvku z okolí, může být v některých případech zatížena velkou chybou, ale v některých případech má chybu minimální. Druhá možnost nejhoršího algoritmu je metoda vynechání prvku, která nehledě na to, že zkracuje signál, má i největší chybu v pásmu LF.

Ve třetí části byla testována metoda EMD, která slouží k odstranění zmiňovaného trendu. Testování probíhalo opět na generovaných signálech, aby bylo možné posoudit zkreslení pro různé druhy trendů. Zároveň s klasickou metodou EMD byla testována metoda, která pracovala na principu odečtení zbytku signálu po výpočtu 3. IMF od originálního signálu. Tato metoda se jevila jako poměrně přesná, v některých případech i přesnější než klasické EMD, nicméně pro následující zpracování signálu byl vybrán postup klasického EMD.

Poslední část bakalářské práce se věnovala testování vybraného postupu, na generovaném signálu, který bylo možné posoudit i se správným výsledkem. Dále byl testován i náhodně vybraný reálný signál, u něhož byl vidět trend i artefakty.

Výsledkem, této kapitoly může být verdikt, že vybraný postup s ohledem na typ trendu může být použit jako nástroj pro předzpracování signálu HRV.

# LITERATURA

- [1] VÍTEK, M. *Automatické rozměření signálů EKG*. Brno: VUT 2010. Disertační práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií
- [2] Medicína, nemoci, studium na 1.LF UK [online]. Jiří Šafránek. 2011. [cit. 22.12.2014]. Dostupné z: <http://www.stefajir.cz/?q=ekg-obecne>
- [3] TARVAINEN, M. *Kubios HRV User's Guide* [online]. Department of Applied Physics University of Eastern Finland, Kuopio, June 2014. [cit. 22.12. 2014]. Dostupné z: [http://kubios.uef.fi/media/Kubios\\_HRV\\_2.2\\_Users\\_Guide.pdf](http://kubios.uef.fi/media/Kubios_HRV_2.2_Users_Guide.pdf)
- [4] Životní energie [online]. Popis srdce a srdeční činnosti. [cit. 14.3.2015]. Dostupné z: <http://zivotni-energie.cz/popis-srdce-a-srdecni-cinnosti.html>
- [5] Ischemická choroba srdeční [online]. IKEM. [cit. 22.12.2014]. Dostupné z: <http://www.ikem.cz/www?docid=1004151>
- [6] KOZUMPLÍK J. Analýza biologických signálů. Elektronická skripta FEKT VUT v Brně, 2012
- [7] TASK FORCE OF THE EUROPEAN SOCIETY OF CARDIOLOGY AND THE NORTH AMERICAN SOCIETY OF PACING AND ELECTROPHYSIOLOGY, Heart rate variability: standards of measurement, physiological interpretation, and clinical use. *European Heart Journal*. 1996 roč. 17,č 1, s. 354-381
- [8] JAVORKA, K. a kol., Variabilita frekvencie srdca: mechanizmy, hodnotenie, klinické využitie. Martin: Osveta, 2008, 204 s. ISBN 978-80-8063-269-4.
- [9] YOO, C. S. a S. H. YI. Effects of Detrending for Analysis of Heart Rate Variability and Applications to the Estimation of Depth of Anesthesia. *Journal of the Korean Physical Society*,. 2004, roč. 44, č. 3, s. 561-568. [vid 23.12.2014]. Dostupné z: <http://www.kps.or.kr/home/kor/journal/library/downloadPdf.asp?articleuid=%7BAB84ED5B-FBFC-4C07-A1AC-E3FAEFE260F5%7D>
- [10] LI Liping., LI Ke. , LIU Changchun and LIU Chengyu. Comparison of Detrending Methods in Spectral Analysis of Heart Rate Variability. *Journal of Applied Sciences, Engineering and Technology 3* [online]. 2011. S 1014-1021, ISSN: 2040-7467, [vid 23.12.2014]. Dostupné z: <http://maxwellsci.com/print/rjaset/v3-1014-1021.pdf>
- [11] TARVAINEN, M. P., P. O. RANTA-AHO a P. A. KARJALAINEN. An advanced detrending method with application to HRV analysis. *Biomedical Engineering: IEEE Transactions*. 2002, roč. 49, č. 2, s. 172-175.
- [12] BOUDRAA, Abdel-Ouahab. EMD-Based Signal Filtering. *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT*, VOL. 56, NO. 6, DECEMBER 2007, s 2196-2202.

- [13] JAN, Jiří. Číslíková filtrace, analýza a restaurace signálů. Vyd. 2. Brno: VUTIUM, 2002, 427 s. ISBN 80-214-1558-4
- [14] XU, X., MSE, SCHUCKERS, S. and the CHIME Study Group. Automatic Detection of Artifacts in Heart Period Data. Journal of Electrocardiology Vol. 34. 2001, s 205-210
- [15] FAJMON, B., RŮŽIČKOVÁ I. Matematika 3. Elektronická skripta FEKT VUT v Brně, 2013
- [16] WEJER, D., MAKOWIEC, D., STRUZIĆ, Z. R., ZARCZYŃSKA-BUCHOWIECKA, M. Impact of the editing of patterns with abnormal rr-intervals on the assessment of heart rate variability. Acta physica polonica B Vol. 45. 2014, s. 2103-2121
- [17] AGUILERA, C.A.V. Extrema.m. (software) THE MATHWORKS, INC., Matlab Central [online]. 2007 [cit. 2015-05-25]. Dostupné z: <http://www.mathworks.com/matlabcentral/fileexchange/12275-extrema-m--extrema2-m>.
- [18] VÍTEK, M.; KOZUMPLÍK, J.: QRS SEEKER; Software pro detekci komplexů QRS. Ústav biomedicínského inženýrství, Vysoké učení technické v Brně, Kolejní 2906/ 4, 612 00 Brno, Česká republika. [online software]. 2010 [cit. 2015-02-19]. Dostupné z: <http://www.dbme.feec.vutbr.cz/vyzkum-a-vyvoj/produkty>