

# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ  
ÚSTAV TELEKOMUNIKACÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION  
DEPARTMENT OF TELECOMMUNICATIONS

VYUŽITÍ HILBERT HUANGOVY TRANSFORMACE PRO ANALÝZU  
NESTACIONÁRNÍCH SIGNÁLŮ Z FYZIKÁLNÍCH EXPERIMENTŮ

DIPLOMOVÁ PRÁCE  
MASTER'S THESIS

AUTOR PRÁCE  
AUTHOR

Bc. PETER TULEJA

BRNO 2014



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH  
TECHNOLOGIÍ

ÚSTAV TELEKOMUNIKACÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION  
DEPARTMENT OF TELECOMMUNICATIONS

# VYUŽITÍ HILBERT HUANGOVY TRANSFORMACE PRO ANALÝZU NESTACIONÁRNÍCH SIGNÁLŮ Z FYZIKÁLNÍCH EXPERIMENTŮ

USING HILBERT HUANG TRANSFORMATION FOR ANALYSIS OF NON-STATIONARY SIGNALS  
FROM PHYSICAL EXPERIMENTS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. PETER TULEJA

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. ONDŘEJ RÁŠO, Ph.D.

BRNO 2014



VYSOKÉ UČENÍ  
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

Ústav telekomunikací

# Diplomová práce

magisterský navazující studijní obor  
Telekomunikační a informační technika

**Student:** Bc. Peter Tuleja

**ID:** 115301

**Ročník:** 2

**Akademický rok:** 2013/2014

## NÁZEV TÉMATU:

**Využití Hilbert Huangovy transformace pro analýzu nestacionárních signálů z fyzikálních experimentů**

## POKYNY PRO VYPRACOVÁNÍ:

- 1) Popište principy časově-frekvenční analýzy signálu akustické emise (rázy). Zaměřte se přitom na typy analýz vedoucí k výpočtu okamžité frekvence a amplitudy. Konkrétně pak na HHT a související témata.
- 2) Vytvořte jednoduchý matematický model, který bude simulovat signály akustické emise.
- 3) Navrhněte metodiku srovnání mezi zkoumanými typy analýz pro odhady sledovaných parametrů. Sledovanými parametry budou okamžitá frekvence a amplituda dominantní složky signálu akustické emise. A testovanými typy analýz budou minimálně STFT a HHT.
- 4) Realizujte srovnání testovaných analýz podle bodu č.4. Proveďte diskuzi takto získaných výsledků.

## DOPORUČENÁ LITERATURA:

- [1] Huang, N. E. et al.: The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. Proc. Roy. Soc. Lond., 454, 903-993, 1998
- [2] Liška, J., Janeček, E.: Time-Frequency Representation of Signals Using Kalman Filter. Robotics, Automation and Control, I-Tech Education and Publishing, Wien, Austria, 2008

**Termín zadání:** 10.2.2014

**Termín odevzdání:** 30.5.2014

**Vedoucí práce:** Ing. Ondřej Rášo, Ph.D.

**Konzultanti diplomové práce:**

**prof. Ing. Kamil Vrba, CSc.**

*Předseda oborové rady*

## UPOZORNĚNÍ:

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

## **ABSTRAKT**

Táto práca pojednáva o možnom využití Hilbert-Huangovej transformácie pre analýzu dát získaných z fyzikálnych experimentov. Konkrétne pre analýzu akustickej emisie v podobe akustických rázov. V úvodnej časti je vysvetlený pojem akustická emisia a problematika jej detekcie. Následne sú rozobrané metódy pre analýzu signálu v časovo-frekvenčnej oblasti. Konkrétne krátkodobá Fourierová transformácia, Waveletová transformácia, Hilbertova transformácia a Hilbert-Huangova transformácia. V záverečnej časti je navrhnutá a vykonaná sada testov pre porovnanie výkonnosti a presnosti jednotlivých prístupov.

## **KĽÚČOVÉ SLOVÁ**

Hilbert-Huangová transformácia, Hilbertová transformácia, vlastné modálne funkcie, presná modálna dekompozícia, Waveletová transformácia, krátkodobá Fourierová transformácia, Akustická emisia

## **ABSTRACT**

This paper discusses the possible use of Hilbert-Huang transform to analyze the data obtained from physical experiments. Specifically for the analysis of acoustic emission in the form of acoustic shock. The introductory section explains the concept of acoustic emission and its detection process. Subsequently are discussed methods for signal analysis in time-frequency domain. Specifically, short-term Fourier transform, Wavelet transform, Hilbert transform and Hilbert-Huang transform. The final part contains the series of tests for measuring the performance and accuracy of different approaches.

## **KEYWORDS**

Hilbert-Huang transform, Hilbert transform, intrinsic mode function, empirical mode decomposition, Wavelet transform, short-time Fourier transform, acoustic emission

TULEJA, Peter *Využití Hilbert Huangovy transformace pro analýzu nestacionárních signálů z fyzikálních experimentů*: diplomová práca. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav telekomunikací, 2014. 68 s. Vedúci práce bol Ing. Ondřej Rášo, Ph.D.



## PREHLÁSENIE

Prehlasujem, že som svoju diplomovú prácu na tému „Využití Hilbert Huangovy transformace pro analýzu nestacionárních signálů z fyzikálních experimentů“ vypracoval samostatne pod vedením vedúceho diplomovej práce, využitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autor uvedenej diplomovej práce ďalej prehlasujem, že v súvislosti s vytvorením tejto diplomovej práce som neporušil autorské práva tretích osôb, najmä som nezasiahol nedovoleným spôsobom do cudzích autorských práv osobnostných a som si plne vedomý následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona č. 121/2000 Sb., vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia § 152 trestného zákona č. 140/1961 Sb.

Brno .....

.....

(podpis autora)

## POĎAKOVANIE

Rád by som poďakoval svojmu vedúcemu diplomovej práce, pánovi Ing. Ondřejovi Rášovi Ph.D., za odborné vedenie, konzultácie, trpezlivosť a podnetné návrhy k práci. Ďalšie poďakovanie patrí Ing. Zděnkovi Průšovi Ph.D., za jeho rady v oblasti knižnice LTFAT. V neposlednom rade ďakujem aj Ing. Ivanovi Míčovi Ph.D., za jeho rady a návrhy k tejto práci.

Brno .....

.....

(podpis autora)

Výskum popísaný v tejto diplomovej práci bol realizovaný v laboratóriách podporených z projektu SIX; registračné číslo CZ.1.05/2.1.00/03.0072, operačný program Výskum a vývoj pre inovácie.

# OBSAH

Úvod	12
<b>1 Teoretická časť</b>	<b>13</b>
1.1 Akustická emisia . . . . .	13
1.2 Diagnostické systémy . . . . .	15
1.3 Analýza signálu v časovo-frekvenčnej oblasti . . . . .	15
1.3.1 Krátkodobá Fourierová transformácia . . . . .	16
1.3.2 Hisenberg-Gaborov princíp neurčitosti . . . . .	17
1.3.3 Waveletová transformácia . . . . .	18
1.3.4 Hilbertova transformácia . . . . .	19
1.3.5 Hilbert-Huangová transformácia . . . . .	20
1.3.6 Hilbertové spektrum . . . . .	25
<b>2 Praktická časť</b>	<b>26</b>
2.1 Prostriedky pre realizáciu práce . . . . .	26
2.1.1 Krátkodobá Fourierová transformácia . . . . .	28
2.1.2 Waveletová transformácia . . . . .	28
2.1.3 Hilbert-Huangová transformácia . . . . .	30
2.2 Testy . . . . .	30
2.2.1 Frekvenčný test . . . . .	30
2.2.2 Amplitúdový test . . . . .	33
2.2.3 Lokalizačný test . . . . .	36
2.2.4 Časový test . . . . .	41
<b>3 Záver</b>	<b>42</b>
Literatúra	45
Zoznam symbolov, veličín a skratiek	47
Zoznam príloh	49

<b>A</b>	<b>Zdrojové kódy</b>	<b>50</b>
A.1	Main_test.m . . . . .	50
A.2	Acoustic_emission_signal.m . . . . .	51
A.3	STFT_test.m . . . . .	53
A.4	DWT_test.m . . . . .	55
A.5	HHT_test.m . . . . .	57
A.6	Thresh_pass.m . . . . .	58
A.7	Comparison.m . . . . .	59
A.8	CharFun.m . . . . .	62
A.9	Noise_loc_test.m . . . . .	63
<b>B</b>	<b>Grafy</b>	<b>66</b>

# ZOZNAM OBRÁZKOV

1.1	Popis akustického rázu . . . . .	13
1.2	Spektrogramy signálu simulujúceho akustický ráz. . . . .	17
1.3	Spektrogramy signálu simulujúceho akustický ráz. . . . .	19
1.4	Rozklad signálu pomocou presnej modálnej dekompozície. . . . .	24
2.1	2 kHz signál simulujúci akustický ráz . . . . .	27
2.2	Jedna zložka signálu simulujúceho akustický ráz . . . . .	27
2.3	Banka filtrov použitá pri dekompozícii s hĺbkou $J = 3$ . . . . .	29
2.4	Banka filtrov použitá pri dekompozícii s hĺbkou $J = 5$ . . . . .	29
2.5	Závislosť vypočítanej frekvencie na skutočnej frekvencii. . . . .	31
2.6	Veľkosť relatívnej chyby odhadu frekvencie v závislosti na frekvencii. . . . .	32
2.7	Priebeh amplitúd vypočítaných jednotlivými metódami. . . . .	33
2.8	Korelácia vypočítaných priebehov amplitúd so skutočným priebehom. . . . .	34
2.9	Závislosť MSE odhadu amplitúdy od frekvencii . . . . .	35
2.10	Test polohy 2 kHz signálu simulujúceho akustický ráz v čase (čas v ktorom signál pretne zvolenú hranicu je považovaný za počiatok udalosti). . . . .	36
2.11	Relatívna chyba odhadu času vzniku akustickej udalosti. . . . .	37
2.12	Akustický ráz s frekvenciou 1 kHz zašumený bielym šumom (z hora: SNR = 6 dB, SNR = 0 dB a SNR = -6 dB). . . . .	38
2.13	Priebeh amplitúdy akustického rázu s frekvenciou 1 kHz zašumeného bielym šumom (z hora: SNR = 6 dB, SNR = 0 dB a SNR = -6 dB). . . . .	39
2.14	Čas potrebný pre procesor k výpočtu jednotlivých analýz. . . . .	41
B.1	Závislosť strednej kvadratickej chyby na frekvencii pri výpočte amplitúdy zašumeného signálu metódou STFT s Hammingovým oknom (32) . . . . .	66
B.2	Závislosť strednej kvadratickej chyby na frekvencii pri výpočte amplitúdy zašumeného signálu metódou STFT s Hammingovým oknom (128) . . . . .	67

B.3	Závislosť strednej kvadratickej chyby na frekvencii pri výpočte amplitúdy zašumeného signálu metódou DWT s hĺbkou dekompozície $J = 3$ . . . . .	67
B.4	Závislosť strednej kvadratickej chyby na frekvencii pri výpočte amplitúdy zašumeného signálu metódou DWT s hĺbkou dekompozície $J = 5$ . . . . .	68
B.5	Závislosť strednej kvadratickej chyby na frekvencii pri výpočte amplitúdy zašumeného signálu metódou HHT . . . . .	68

# ÚVOD

Táto práca sa zaoberá problematikou využitia Hilbert-Huangovej transformácie pre analýzu dát získaných z fyzikálnych experimentov. V prvej časti sa nachádza všeobecné a stručné oboznámenie s akustickou emisiou, jej využitím pre testovacie účely a nakoniec aj proces od jej vzniku až po detekciu. Následne sú rozobrané metódy pre analýzu signálu v časovo-frekvenčnej oblasti. Konkrétne krátkodobá Fourierová transformácia, Waveletová transformácia, Hilbertová transformácia a Hilbert-Huangová transformácia. V záverečnej časti je navrhnutá a vykonaná sada testov pre porovnanie výkonnosti a presnosti jednotlivých prístupov.



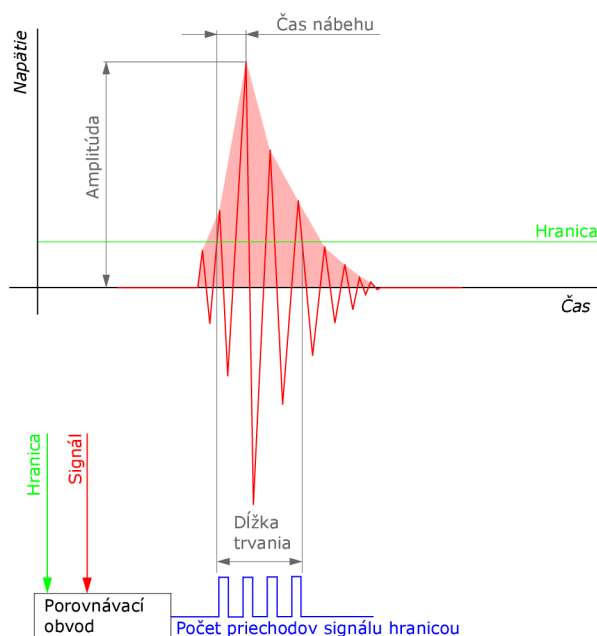
# 1 TEORETICKÁ ČASŤ

## 1.1 Akustická emisia

Už po stáročia je predzvestou štrukturálneho kolapsu zvuk vydaný krátko pred zlyhaním nosného prvku. Napríklad, vetva stromu, pred tým ako sa zlomí, vydá praskajúci zvuk. Podobne, stúpenie na tenký lad vyprodukuje praskajúci zvuk varujúci pred následným kolapsom [9]. Potenciál tohto efektu si po prvýkrát uvedomil J. Kaiser v 50-tych rokoch 20. storočia. Následne v 60-tych rokoch sa analýza zvuku vyprodukovaného pri deštrukcii materiálu stala hotovou vednou disciplínou.

Akustická emisia sa dá charakterizovať ako séria zvukových vln, ktoré vzniknú pri namáhaní materiálu. Využitie akustickej emisie pre testovacie účely si našlo široké uplatnenie vo viacerých vedných disciplínach. Výhodou pri testovaní je, že meranie akustickej emisie môže byť využité vo všetkých testovacích fázach. Či už sú to počiatkové testy spojené, napríklad, s odolnosťou materiálu alebo monitorovanie v reálnom čase či samotná detekcia chýb a porúch.

Typický signál akustickej emisie je podľa [9] popísaný nasledovne:



Obr. 1.1: Popis akustického rázu

**Amplitúda, A**, je najvyššie namerané napätie v signáli. Určuje detekovateľnosť signálu.

**Čas nábehu, R**, (z angl. rise time) je interval medzi hodnotou signálu, ktorý po prvýkrát pretne nastavenú hraničnú hodnotu a maximálnou hodnotou signálu. Tento parameter sa používa pre kvalifikáciu signálu a nastavenie kritérií pre šumové filtre, keďže hovorí o propagácii zvukovej vlny medzi zdrojom akustického rázu a senzorom.

**Dĺžka trvania, D**, (z angl. duration) je čas, ktorý uplynie od prvého prechodu signálu nastavenou hraničnou hodnotou, až po posledný prechod signálu nastavenou hraničnou hodnotou. Dĺžka trvania sa používa na identifikáciu rôznych typov zdrojov a pre filtrovanie šumu.

**MARSE, E**, značí plochu pod obálkou usmerneného lineárneho napätového časového signálu zo snímača. MARSE môže predstavovať relatívnu amplitúdu signálu, pričom je citlivá na dĺžku trvania a amplitúdu signálu. Nepoužíva, naopak, počet priechodov signálu, užívateľsky nastavené hranice, ani frekvenciu signálu.

**Počet prechodov signálu hranicou, N**, (z angl. counts) hovorí o počte pulzov, ktoré vyšlú meracie obvody zakaždým, keď je amplitúda kmitu väčšia ako hraničná hodnota. Aby bolo možné získať kvalitatívne informácie o tvare signálu, je potrebné tento parameter spojiť s amplitúdou a/alebo dĺžkou trvania signálu.

Celý proces testovania pomocou akustickej emisie je v [9] popísaný pomocou nasledujúcich bodov:

- **Akustická emisia** – elastická vlna vygenerovaná náhlym uvoľnením energie zo zdrojov vo vnútri testovaného materiálu.
- **Udalosť** – lokálna materiálová zmena vedúca k akustickej emisii
- **Zdroj** – fyzikálny pôvod jednej alebo viacerých akustických udalostí.
- **Senzor** – zariadenie obsahujúce prvok, ktorý dokáže transformovať mechanickú energiu vyvolanú akustickou emisiou na elektrickú energiu.
- **Signál** – elektrický signál vychádzajúci zo snímacieho prvku prechádzajúci príslušnými obvodmi ako zosilňovače, frekvenčné filtre atď.

- **Detekcia** – rozoznanie prítomnosti signálu. Zvyčajne je detekcia realizovaná porovnávacím obvodom, ktorý detekuje signál nad nastavenou hraničnou hodnotou.
- **Zásah** – proces detekcie a merania akustickej emisie.
- **Signálové komponenty** – merateľné charakteristiky signálu akustickej emisie popísané v 1.1.

## 1.2 Diagnostické systémy

Skoré odhalenie chyby a jej odstránenie v ranom štádiu jej vzniku môže znamenať značnú ekonomickú výhodu pre prevádzkovateľa priemyselného zariadenia, ktorý by inak vynaložil nemalé náklady potrebné na opravu spôsobenú prípadnou poruchou. Na tento účel sú určené práve diagnostické systémy.

V [4] sa priemyselné zariadenia rozdeľujú z pohľadu diagnostiky na:

- zariadenia so zriedkavým monitorovaním
- zariadenia s monitorovaním v dlhších časových intervaloch
- zariadenia s permanentným monitorovaním

Potreba diagnostických systémov je v mnohých prípadoch umocnená potrebou znížiť ekologické a bezpečnostné riziká vznikajúce pri prevádzke priemyselného zariadenia. Zhruba v polovici minulého storočia, [4], zaznamenali metódy a algoritmy používané v diagnostických systémoch svoje počiatky. Vtedy totiž po prvýkrát vznikali potreby monitorovať a diagnostikovať prevádzkové zariadenia. Realizovanie týchto diagnostických metód však bolo obmedzené vtedy dostupným hardvérom.

## 1.3 Analýza signálu v časovo-frekvenčnej oblasti

V nedávnej minulosti bola časovo-frekvenčná analýza príliš výpočtovo náročná na to, aby bola použitá v diagnostických systémoch. Preto takýmto metódam nebola venovaná prílišná pozornosť. Zmenu priniesla potreba zvyšovať rýchlosť, spoľahlivosť, presnosť a efektivitu diagnostiky.

Analyzovať signál priamo v časovej oblasti je niekedy dosť obtiažné a nepresné. Užitočný signál môže byť totiž maskovaný okolitým šumom v časovej alebo frekvenčnej oblasti.

### 1.3.1 Krátkodobá Fourierová transformácia

Táto forma Fourierovej transformácie je veľmi často využívaná na analýzu nestacionárnych signálov. Jej podstata spočíva v tom, že signál je rozdelený na veľmi krátke úseky, v ktorých sa predpokladá stacionarita. Pre potlačenie zložiek signálu, ktoré sú mimo času, o ktorý máme záujem sa používajú funkcie zvané „okná“. Ideálne okno,  $h(t)$  zachová veľkosť signálu v strednom čase  $t$  a zbytok potlačí

$$s_t(\tau) = s(\tau) \text{ pre } \tau \text{ blízke } t. \quad (1.1)$$

Výsledný modifikovaný signál je tak funkciou dvoch časov. Času  $t$ , ktorý je predmetom nášho záujmu a priebežného času  $\tau$  [4].

$$s_t(\tau) = s(\tau) \cdot h(\tau - t). \quad (1.2)$$


S využitím okna sa potom pri Fourierovej transformácii zohľadňuje rozloženie v okolí času  $t$  [4],

$$s_t(\omega) = \frac{1}{\sqrt{2\pi}} \int e^{-j\omega\tau} \cdot s_t(\tau) d\tau = \frac{1}{\sqrt{2\pi}} \int e^{-j\omega\tau} \cdot s(\tau) \cdot h(\tau - t) d\tau. \quad (1.3)$$

V tomto čase sa následne podľa [4] spektrum hustoty energie vypočíta ako

$$P_{SP}(t, \omega) = |S_t(\omega)|^2 = \left| \frac{1}{\sqrt{2\pi}} \int e^{-j\omega\tau} \cdot s(\tau) \cdot h(\tau - t) d\tau \right|^2. \quad (1.4)$$

Pre každý čas  $t$  tak získame spektrum, ktoré v súhrnnom zobrazení nazývame spektrogram. O krátkodobej Fourierovej transformácii hovoríme iba vtedy, keď je použité úzke okno. V prípade použitia širokého okna hovoríme o dlhodobej Fourierovej transformácii.



Obr. 1.2: Spektrogramy signálu simulujúceho akustický ráz.

### 1.3.2 Hisenberg-Gaborov princíp neurčitosti

Tento princíp, priblížený v [4], popisuje fakt, že v prípade zlepšenia rozlíšenia v časovej oblasti, musí zákonite dôjsť k zhoršeniu rozlíšenia vo frekvenčnej oblasti. To isté platí aj pre prípad, kde je zlepšené frekvenčné rozlíšenie, teda dôjde k zhoršeniu rozlíšenia v čase tak, aby v oboch prípadoch platilo

$$\sigma_t \sigma_f(s(at)) = \sigma_t \sigma_f(s(t)), \quad (1.5)$$

kde  $\sigma_t \sigma_f$  predstavuje súčin smerodajných odchýlok stredných hodnôt náhodných veličín  $t$  a  $f$ . Malý súčin  $\sigma_t \sigma_f$  znamená dobrú lokalizáciu v časovo-frekvenčnej oblasti. Samotný Hisenberg-Gaborov princíp je potom v [4] popísaný ako

$$\sigma_t \sigma_f \geq \frac{1}{2}. \quad (1.6)$$

### 1.3.3 Waveletová transformácia


Waveletová transformácia je v [4] popísaná ako transformácia, ktorá – podobne ako Fourierová transformácia – rozkladá signál do frekvenčných zložiek. Hlavný rozdiel je v tom, že pre samotný rozklad nie sú použité komplexné, harmonické signály, ale množina ortonormálnych funkcií. Tieto funkcie sú generované modifikáciou matičného waveletu označovaného ako  $\psi$ . Pod modifikáciou matičného waveletu sa rozumie rozťahnutie  $a$  a posunutie  $b$ , ktoré sú definované ako

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \cdot \psi\left(\frac{t-b}{a}\right) dt. \quad (1.7)$$

Ak sa pri Fourierovej transformácii použije nastaviteľné okno definované v [4] ako

$$W_{a,b;s,\psi}(t) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} s(t) \cdot \psi\left(\frac{t-b}{a}\right) dt, \quad (1.8)$$

vznikne v podstate Waveletová transformácia, kde  $\psi$  predstavuje matičnú Waveletovú funkciu vyhovujúcu nejakým stanoveným všeobecným podmienkam (a rozťahnutie, b posunutie počiatku). Hodnota  $\frac{1}{a}$  teda určuje frekvenčnú mierku a hodnota b umiestnenie udalosti v čase. Waveletová transformácia sa od krátkodobej Fourierovej transformácie líši hlavne tým, že prináša možnosť prispôbovať rozlíšenie požadovanej situácii. Vhodným nastavením rozkladového stromu je tak možné získať, napríklad, presnejšie informácie o zmenách správania sa signálu vo vyšších frekvenciách, za cenu zníženého frekvenčného rozlíšenia.



Obr. 1.3: Spektrogramy signálu simulujúceho akustický ráz.

### 1.3.4 Hilbertova transformácia

Jeden zo spôsobov, ako presne popísať priebeh frekvencie nestacionárneho signálu, je vypočítať okamžitú frekvenciu podľa [4] ako

$$f_i(t) = \frac{1}{2\pi} \cdot \frac{d\phi(t)}{dt}, \quad (1.9)$$

príčom  $\phi(t)$  predstavuje okamžitú fázu signálu. Signály vyskytujúce sa bežne v prírode majú, v podstate, reálny charakter. Aby bolo možné určiť okamžitú frekvenciu z okamžitej fázy signálu, je potrebné tento reálny signál definovať v komplexnej forme. Reálny signál  $s(t)$  je potrebné doplniť o imaginárnu zložku  $s_i(t)$ . Výsledkom je komplexný signál  $z(t)$ , ktorý musí spĺňať matematický a fyzikálny popis v [1]

$$z(t) = s_r + j \cdot s_i = a(t)e^{j\varphi(t)}. \quad (1.10)$$

Ak je určenie imaginárnej časti signálu možné, amplitúda a fáza sa vypočítajú podľa [1] ako

$$a(t) = \sqrt{s_r^2 + s_i^2}; \quad \varphi(t) = \arctan \frac{s_r}{s_i}, \quad (1.11)$$

takže, okamžitá frekvencia je následne podľa [4] definovaná ako derivácia okamžitej fázy

$$\omega(t) = \varphi'(t) = \frac{s_i' s_r - s_r' s_i}{a^2}. \quad (1.12)$$

K získaniu imaginárnej zložky reálneho signálu slúži práve Hilbertova transformácia. Pre ľubovoľný časový signál  $s(t)$  sa Hilbertova transformácia [4] tohto signálu vypočíta ako

$$H[s(t)] = \hat{s}(t) = \frac{j}{\pi} P \int \frac{s(t')}{t - t'} dt', \quad (1.13)$$

kde  $P$  predstavuje Cauchyho hlavnú hodnotu. Výsledný komplexný signál  $z(t)$  je komplexne konjugovaný pár tvorený signálom  $s(t)$  a transformovaným signálom  $\hat{s}(t)$ . Imaginárnu časť je možné získať niekoľkými spôsobmi. Hilbertova transformácia však zabezpečí, že získaný signál bude analytickým signálom ([4] popisuje analytický signál ako signál, ktorý patrí do triedy komplexných funkcií vyhovujúcich Cauchy-Riemannovej podmienke pre diferencovateľnosť). Okamžitú frekvenciu nie je možné určiť bez obmedzení, tá totiž podľa 1.9 nadobúda práve jednu hodnotu v každom čase  $t$ . Reálne signály sú ale zväčša tvorené nie jednou, ale celým spektrom frekvencií, čo pri pokuse vypočítať okamžitú frekvenciu často vedie k fyzicky neinterpretovateľnému výsledku v podobe zápornej frekvencie. Liška v [4] preto spomína pojem monokomponentný signál, ktorý obsahuje práve jednu frekvenčnú zložku.

### 1.3.5 Hilbert-Huangová transformácia

Samotná Hilbertova transformácia nestačí na to, aby bolo možné z reálneho signálu vypočítať okamžitú frekvenciu. V roku 1999 NASA pomenovala postup, ktorý zverejnil Nordan E. Huang ako Hilbert-Huangovu transformáciu. Celý prístup je detailnejšie popísaný v nasledujúcej časti.



## Vlastné modálne funkcie

Vlastné modálne funkcie sú triedou funkcií, ktoré definujú podmienky nutné k tomu, aby bolo možné určiť okamžitú frekvenciu. Fyzikálne podmienky kladené na komponenty po dekompozícii sú podľa [4] nasledovné:

- funkcie sú symetrické vzhľadom k lokálnej hladine nulovej strednej hodnoty
- funkcie majú počet prechodov nulou zhodný s počtom extrémov

Aby sa dala funkcia považovať za vlastnú modálnu funkciu, musí spĺňať nasledujúce podmienky:

- v celom obore hodnôt sa počet extrémov musí rovnať počtu prechodov nulou (prípadne sa maximálne o jeden líšiť)
- v každom okamihu sa stredná hodnota obálky definovanej lokálnymi maximami a obálky definovanej lokálnymi minimami rovná nule

Následným vypočítaním Hilbertovej transformácie z vlastných modálnych funkcií získame okamžitú frekvenciu signálu. V praxi je však tento spôsob takmer nepoužiteľný, nakoľko, málokteré dáta splňujú vyššie uvedené podmienky kladené na vlastné modálne funkcie.

## Presná modálna dekompozícia

Táto adaptívna metóda je popísaná v [1]. Jej podstata spočíva v tom, že po dekompozícii signálu obsahuje každá zložka práve jeden vlastný oscilačný mód. Samotná dekompozícia je podľa [4] založená na týchto predpokladoch:

- signál, ktorý je dekomponovaný má minimálne dva extrémny (maximum a minimum)
- charakteristická časová mierka je definovaná odstupom medzi jednotlivými extrémami
- v prípade, že dekomponovaný signál neobsahuje žiadne extrémny, no má inflexné body, musí existovať možnosť získať tieto extrémny po derivácii signálu

Presná modálna dekompozícia prebieha v niekoľkých fázach. Prvým krokom presnej modálnej dekompozície je nájdenie lokálnych extrémov. Nájdené lokálne minimum a lokálne maximum sa následne interpolujú krivkou, čím vznikne vrchná obálka  $e_{\max}(t)$  a spodná obálka  $e_{\min}(t)$ . Stredná hodnota obálky  $m$  je v [4] následne definovaná ako

$$m(t) = \frac{e_{\min}(t) + e_{\max}(t)}{2}. \quad (1.14)$$

Prvú zložku presnej modálnej dekompozície získame podľa [1] odčítaním signálu  $s(t)$  a strednej hodnoty signálu  $m(t)$

$$h_1 = s(t) - m_1 \quad (1.15)$$

Ak však  $h_1$  nespĺňa požiadavky kladené na vlastné modálne funkcie, v  $h_1$  sa objavujú nové lokálne extrémumy. Preto je potrebné znovu opakovať predchádzajúce kroky výpočtu obálky spomínané v [1]

$$h_{11} = h_1 - m_{11}. \quad (1.16)$$

Jedná sa o iteratívny proces, ktorý sa opakuje dokiaľ výsledný komponent nevyhovuje podmienkam kladeným na vlastné modálne funkcie. Keďže iteratívny proces je potrebné niekedy zastaviť, aby nedošlo k vytvoreniu nekonečnej slučky alebo k preiterovaniu, vypočíta sa smerodajná odchýlka  $\sigma$  z dvoch po sebe idúcich výsledkov iteratívneho procesu. Hodnota smerodajnej odchýlky použitej ako kritérium pre ukončenie iteratívneho procesu presnej modálnej dekompozície, uvedená v [4], sa pohybuje medzi 0,2 a 0,3. Vypočíta sa pritom ako

$$\sigma = \sum_{t=0}^T \left[ \frac{|h_{1(k-1)}(t) - h_{1k(k-1)}(t)|^2}{h_{1(k-1)}^2(t)} \right]. \quad (1.17)$$

Po zastavení iteratívneho procesu je získaný prvý komponent vlastnej modálnej funkcie. Po odčítaní tohto komponentu od pôvodného signálu je získané takzvané rezíduum obsahujúce zložky s nižšími frekvenciami, ktoré je následne označené ako nový signál  $s(t)$ .

$$s(t) - c_1 = r_1 \quad r_1 \Rightarrow (t). \quad (1.18)$$

Celý proces sa môže opakovať pre tento signál aj pre všetky ďalej vznikajúce rezíduá.

Dekompozícia je ukončená v prípade, že dôjde k jednému z nasledujúcich kritérií spomínaných v [4]

- komponent  $c_n$ , alebo rezíduum  $r_n$  je menšie ako vopred stanovená hranica
- rezíduum  $r_n$  je monotónna funkcia, z ktorej už nemožno extrahovať zložky vlastnej modálnej funkcie

Pôvodný signál je po ukončení dekompozície rozložený do  $n$  vlastných modálnych funkcií. Pôvodný signál je teda možné zapísať podľa [1] ako

$$s(t) = \sum_{j=1}^n c_j + r_n. \quad (1.19)$$

Kontrolu nad samotným iteratívnym procesom je možné zvýšiť zavedením obmedzeného počtu iterácií. Nevhodnou, príliš nízkou, prahovou hodnotou totiž môže ľahko dôjsť k predekomponovaniu signálu. Toto modifikované kritérium je v [4] charakterizované nasledujúcimi hodnotami:

- N - maximálny povolený počet iterácií. Ak dôjde k jeho prekročeniu, iteratívny cyklus sa ukončí pričom práve spracovávaný mód sa označí ako vlastná modálna funkcia a pokračuje sa vo výpočte nasledujúcich módov.
- S - počet po sebe idúcich iteratívnych krokov, v ktorých sa počet extrémov a počet prechodov nulovými bodmi nezmení. Ak je teda pri dekompozícii táto hodnota dosiahnutá, iteratívny proces sa ukončí a podobne ako v predchádzajúcom prípade, sa práve spracovávaný mód označí ako vlastná modálna funkcia a pokračuje sa vo výpočte nasledujúcich módov.


Spôsobov ako ukončiť iteratívny počet existuje niekoľko. V [4] je ešte uvedená metóda prezentovaná trojicou Railling, Flandrin a Gonclaves, kde sa pre ukončenie iterácií presnej modálnej dekompozície požíva podmienka s dvoma prahovými hodnotami  $\theta_1$  a  $\theta_2$ . Táto podmienka má amplitúdu definovanú ako

$$a(t) = \frac{e_{\max}(t) - e_{\min}(t)}{2}, \quad (1.20)$$

príčom funkcia hodnotiaci kolísanie strednej hodnoty je definovaná ako

$$\Delta(t) = \left| \frac{m(t)}{a(t)} \right|. \quad (1.21)$$

Samotný iteratívny proces prebieha pokiaľ  $\Delta(t) < \theta_1$  v časti signálu s dĺžkou  $(1 - \alpha)$  z celkovej dĺžky signálu a  $\Delta(t) < \theta_2$  vo zvyšku signálu. Typické hodnoty uvádzané v [4] sú  $\alpha \approx 0,05$ ;  $\theta_1 \approx 0,05$ ;  $\theta_2 \approx 10 \cdot \theta_1$ .



Obr. 1.4: Rozklad signálu pomocou presnej modálnej dekompozície.

### 1.3.6 Hilbertové spektrum

Po tom, čo sú pomocou presnej modálnej dekompozície vypočítané jednotlivé vlastné modálne funkcie, aplikuje sa na každú z nich Hilbertova transformácia, takže dáta sa dajú podľa [4] popísať ako

$$s(t) = \sum_{j=1}^n a_j(t) \cdot e^{i \int \omega_j(t) dt}. \quad (1.22)$$

Rezíduum  $r_n$  je vynechané zámerné z dôvodu, že sa jedná o monotónnu funkciu alebo konštantu, ktorá nemá vlastnosti vlastnej modálnej funkcie. Pre porovnanie, popísanie tých istých vstupných dát pomocou Fourierovej rady Liška [4] popisuje nasledovne

$$s(t) = \sum_{j=1}^{\infty} a_j \cdot e^{i \omega_j t}. \quad (1.23)$$

Rozdiel medzi týmito dvomi rovnicami 1.22 a 1.23 je markantný. Okamžitá frekvencia a amplitúda závislá na čase predurčujú túto metódu pre použitie na analýzu nestacionárnych dát. Hilbertové amplitúdové spektrum je tak frekvenčno-časové rozloženie amplitúdy. V prípade, že dané frekvenčno-časové zobrazenie obsahuje druhé mocniny amplitúd, jedná sa o Hilbertové energetické spektrum.

Rozlíšenie Hilbertovho spektra popisuje Liška v [4] nasledovne:

- Limit frekvenčného rozlíšenia (najnižšia možná extrahovateľná frekvencia)  $\frac{1}{T}$ , pričom  $T$  je celková dĺžka signálu v sekundách.
- Najvyššia možná extrahovateľná frekvencia  $\frac{1}{n \cdot \Delta t}$ , kde  $\Delta t$  je dĺžka vzorky a  $n$  je minimálny počet vzoriek, ktoré sú potrebné na určenie frekvencie.
- Rozlíšenie vo frekvencii  $N$  je teda


$$N = \frac{\frac{1}{n \cdot \Delta t}}{\frac{1}{T}} = \frac{T}{n \cdot \Delta t}. \quad (1.24)$$

## 2 PRAKTICKÁ ČASŤ

Táto časť je zameraná na overenie funkčnosti a presnosti časovo-frekvenčných analýz spomínaných v predchádzajúcej časti. Nižšie sú popísané experimenty, ktorých účelom je vyhodnotiť, ktorá z rozoberaných časovo-frekvenčných analýz je najpresnejšia pri odhade signálových parametrov. Celkovo sú v praktickej časti prevedené 4 testy pozostávajúce z 35 meraní a jedného experimentu. Prvým testom je frekvenčný test, ktorý meria, s akou presnosťou jednotlivé analýzy odhadujú frekvenciu analyzovaného signálu. Bližšie je rozpísaný v kapitole 2.2.1. Druhým testom je amplitúdový test. Tento test meria, s akou presnosťou sú použité analýzy schopné odhadnúť priebeh amplitúdy analyzovaného signálu. Venuje sa mu kapitola 2.2.2. V poradí tretím testom je lokalizačný test, ktorý má za úlohu odhaliť, ako presne jednotlivé analýzy určujú počiatok vzniku akustickej udalosti. Lokalizačný test je rozobraný v kapitole 2.2.3. Kapitola 2.2.4 popisuje posledný test, ktorý meria časovú náročnosť jednotlivých analýz pre vypočítanie tých istých signálových parametrov.


### 2.1 Prostriedky pre realizáciu práce

Pre účely tejto práce je v programe MATLAB vytvorený jednoduchý signál simulujúci akustický ráz. Amplitúda tohto signálu je normalizovaná na hodnotu 1. Vzorkovacia frekvencia je 44,1 kHz. Návrh signálu je realizovaný kódom (A.2) a vyzerá nasledovne.



Obr. 2.1: 2 kHz signál simulujúci akustický ráz

Pre zvýšenie transparentnosti prvých troch testov, je v kóde A.2 (riadky 40 – 48) extrahovaná iba časť signálu obsahujúca hlavnú amplitúdovú zložku.



Obr. 2.2: Jedna zložka signálu simulujúceho akustický ráz


### 2.1.1 Krátkodobá Fourierová transformácia

Pre výpočet krátkodobej Fourierovej transformácie je použitá funkcia STFT, podľa [11]. Samotná implementácia funkcie prebieha v A.3. Pri testoch sa vyskytuje vždy dvakrát, dôvodom je rôzna dĺžka okna. Skracovaním okna sa zlepšuje rozlíšenie v čase a zhoršuje rozlíšenie vo frekvenčnej oblasti a naopak, predlžovaním okna sa zlepšuje frekvenčné rozlíšenie, pričom sa zhoršuje rozlíšenie v časovej oblasti. V prvom prípade je dĺžka okna  $L = 32$  vzoriek, v druhom prípade je to  $L = 128$  vzoriek. Posun okna je v oboch prípadoch po jednej vzorke a počet FFT bodov pre výpočet DFT je nastavený na štvornásobok dĺžky použitého okna.


### 2.1.2 Waveletová transformácia

Pre výpočet Waveletovej transformácie je použitá knižnica LTFAT [7]. Aj táto transformácia sa pri testoch vyskytuje dvakrát. Parameter, ktorým sa jednotlivé Waveletové transformácie líšia je hĺbka rozkladového stromu, ktorá v prvom prípade predstavuje  $J = 3$  a v druhom prípade  $J = 5$ . Ostatné parametre sú totožné - oba transformácie používajú plný rozkladový strom a wavelet Symlet 8. Rozdielna hĺbka dekompozičného stromu má vplyv na frekvenčné a časové rozlíšenie. Nasledujúce grafy zobrazujú banky filtrov, ktoré sú použité pri dekompozícii s hĺbkou  $J = 3$  a hĺbkou  $J = 5$ .





Obr. 2.3: Banka filtrov použitá pri dekompozícii s hĺbkou  $J = 3$ .



Obr. 2.4: Banka filtrov použitá pri dekompozícii s hĺbkou  $J = 5$ .

### 2.1.3 Hilbert-Huangová transformácia


Pre výpočet Hilbert-Huangovej transformácie sú použité funkcie *plot\_hht.m*, *find-peaks.m* a *emd.m* dostupné z [8]. Samotná implementácia je realizovaná v zdrojovom kóde A.5.

## 2.2 Testy

Umelo vytvorený signál simulujúci akustický ráz je postupne analyzovaný každou časovo-frekvenčnou analýzou spomínanou v časti 2.1. Prvý test má za úlohu vyhodnotiť, ktorá analýza je schopná najpresnejšie určiť frekvenciu analyzovaného signálu. Nasledujúci test určuje náročnosť analýz na čas potrebný pre výpočet. Predposledný test má za úlohu stanoviť presnosť, s akou je tá ktorá analýza schopná odhadnúť priebeh amplitúdy analyzovaného signálu. Posledný test má za úlohu vyhodnotiť presnosť polohy akustického rázu v čase. Všetky spomínané testy sú vykonané päťkrát. Funkciou *Medián* sú vybrané dáta, ktoré sú v ďalších častiach tejto práce prezentované a porovnávané.

### 2.2.1 Frekvenčný test

Cielom tejto časti je vyhodnotiť presnosť odhadu frekvencie. V programe MATLAB je vygenerovaný signál simulujúci akustický ráz s jednou frekvenčnou zložkou (A.2), ktorá sa mení nasledovne: 10 Hz, 20 Hz, 50 Hz, 100 Hz, 200 Hz, 500 Hz, 1 kHz, 2 kHz, 5 kHz, 8 kHz, 10 kHz, 13 kHz, 16 kHz, 19 kHz, 21,5 kHz. Výpočet STFT prebieha v A.3, výpočet pomocou DWT prebieha v A.4 a výpočet HHT je urobený v A.5. Zhrnutie výsledkov je urobené v A.7, odkiaľ sú dáta exportované do .txt súboru a následne importované do programu Excel 2007 z balíka Microsoft Office. Vypočítaný odhad frekvencie je znázornený v nasledujúcom grafe.




Obr. 2.5: Závislosť vypočítanej frekvencie na skutočnej frekvencii.

V tomto grafe je možné vidieť šesť kriviek. Dve sú pre krátkodobú Fourierovú transformáciu s rôznym nastavením dĺžky okna, dve sú pre Waveletovú transformáciu s rôznou hĺbkou dekompozície a jedna je pre Hilbert-Huangovu transformáciu. Krivka  $f$  je pomocná krivka, ktorá naznačuje ideálny priebeh. Na osi  $x$  je vynesená skutočná frekvencia a na osi  $y$  vypočítaná frekvencia. Tento graf ponúka celkom dobrý prehľad o dianí v oblasti nízkych až stredných frekvencií. Jeho výpovedná hodnota ale klesá v oblasti vysokých frekvencií. Aby bola presnosť odhadu lepšie viditeľná aj pre vysoké frekvencie, nasledujúci graf zobrazuje relatívnu chybu odhadu vypočítanú podľa

$$\delta_{\chi} = \frac{\chi_v - \chi_s}{\chi_s} \cdot 100\%, \quad (2.1)$$

kde  $\chi_v$  predstavuje vypočítanú hodnotu frekvencie a  $\chi_s$  skutočnú hodnotu frekvencie.




Obr. 2.6: Veľkosť relatívnej chyby odhadu frekvencie v závislosti na frekvencii.

Ako je viditeľné z tohto grafu, Hilbert-Huangová transformácia pracuje vo väčšine spektra s najmenšou relatívnou chybou. Napoak s najväčšou relatívnou chybou určuje frekvenciu Waveletová transformácia pri plnom dekompozičnom strome s hĺbkou dekompozície  $J = 3$ . Tento výsledok je očakávaný vzhľadom na veľmi hrubé frekvenčné rozlíšenie, ktoré Waveletová transformácia ponúka pri tomto nastavení. Zvýšením hĺbkou dekompozície na  $J = 5$  došlo k značnému zlepšeniu frekvenčného rozlíšenia. Presnosť krátkodobej Fourierovej transformácie bola v oboch prípadoch takmer rovnaká, s miernou prevahou STFT s použitím širokého okna.

## 2.2.2 Amplitúdový test

Amplitúdový test je sústredený na vyhodnotenie presnosti odhadu priebehu amplitúdy analyzovaného signálu. Amplitúdy sú normalizované a ich priebeh je znázornený v nasledujúcom grafe:




Obr. 2.7: Priebeh amplitúd vypočítaných jednotlivými metódami.

Cielom každej metódy je odhadnúť priebeh, ktorý sa čo najviac zhoduje s priebehom originálneho signálu (modrá krivka). Najbližšie sa svojim odhadom priblížili Hilbert-Huangová transformácia a krátkodobá Fourierová transformácia s použitím úzkeho okna. Schodovitost priebehov STFT je daná použitím funkcie okna. Túto schodovitost sa podarilo minimalizovať posúvaním okna po jednej vzorke. Schodovitost priebehov diskretnej Waveletovej transformácie je daná zmenou pomeru strán okna waveletu. Jednotlivé priebehy amplitúd sú naprieč všetkými frekvenciami porovnávané dvoma spôsobmi. Jedným je počítanie vzájomnej korelácie a druhým je výpočet strednej kvadratickej chyby. Nasledujúci graf zobrazuje korelácie jednotlivých odhadov s pôvodným priebehom amplitúdy. Pre výpočet korelácie je použitá funkcia z [10].

Jedná sa o výpočet Pearsonovho korelačného koeficientu  $\rho$  podľa

$$\rho = \frac{\sum_d (S_d - \bar{S}_d)(O_d - \bar{O}_d)}{\sqrt{\sum_d (S_d - \bar{S}_d)^2} \sqrt{\sum_d (O_d - \bar{O}_d)^2}}, \quad (2.2)$$

kde  $S_d$  predstavuje priebeh amplitúdy signálu vypočítaný jednotlivými analýzami,  $O_d$  je priebeh amplitúdy originálneho signálu a  $\bar{S}_d$ ,  $\bar{O}_d$  sú stredné hodnoty týchto priebehov.




Obr. 2.8: Korelácia vypočítaných priebehov amplitúd so skutočným priebehom.

Z grafu je viditeľné, že všetky testované analýzy dosahujú pomerne vysoké hodnoty korelácie odhadu so skutočným priebehom ( $\rho > 0,75$ ). Z tohto testu však nie je úplne jasné, ktorá analýza je pri odhade úspešnejšia. DWT s hĺbkou dekompozície  $J = 3$  dosahuje pomerne vysoké hodnoty korelácie naprieč celým spektrom. Podobne STFT pri oboch nastaveniach. HHT dosahuje jedny z najvyšších hodnôt s výnimkou odhadov v nízkych frekvenciách. Naopak, najhoršie hodnoty korelácie dosahuje DWT s hĺbkou dekompozície  $J = 5$ . To je však dané veľmi hrubým rozlíšením v čase, dobre viditeľnom na obr. 2.7.

Ako ďalší parameter schopný porovnať výkon testovaných analýz bola na základe [6] zvolená stredná kvadratická chyba, ktorá v poli spracovávania signálov slúži ako kvantitatívna metrika už viac ako 50 rokov. Stredná kvadratická chyba je podľa [3] definovaná ako

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2, \quad (2.3)$$

kde  $N$  predstavuje počet vzoriek signálu a  $x_i, y_i$  sú  $i$ -té vzorky signálov  $x$  a  $y$ . Nasledujúci graf ukazuje závislosť strednej kvadratickej chyby (MSE) od frekvencií.




Obr. 2.9: Závislosť MSE odhadu amplitúdy od frekvencií

Z tohto grafu je zreteľne vidieť, že chyba s akou jednotlivé analýzy určujú priebeh amplitúdy sa odlišuje v rádoch a mení sa s frekvenciou. Najmenšiu priemernú strednú kvadratickú chybu pri odhade priebehu amplitúdy dosahuje krátkodobá Fourierová transformácia s použitím úzkeho Hammingovho okna ( $MSE = 0,045$ ). Nasleduje Hilbert-Huangová transformácia s  $MSE = 0,055$ , krátkodobá Fourierová transformácia s použitím širokého Hammingovho okna ( $MSE = 0,07$ ). Najväčšiu

chybu dosahuje diskrétna Waweletová transformácia s hĺbkou dekompozície  $J = 3$  ( $MSE = 0,37$ ) a s hĺbkou dekompozície  $J = 5$  ( $MSE = 2,2$ ). Tento experiment je zopakovaný ešte trikrát s tým rozdielom, že k pôvodnému signálu je pripočítaný biely šum s odstupom  $SNR = 12$  dB,  $SNR = 6$  dB a  $SNR = 0$  dB. Výsledné grafy sú priložené v prílohe B.

### 2.2.3 Lokalizačný test

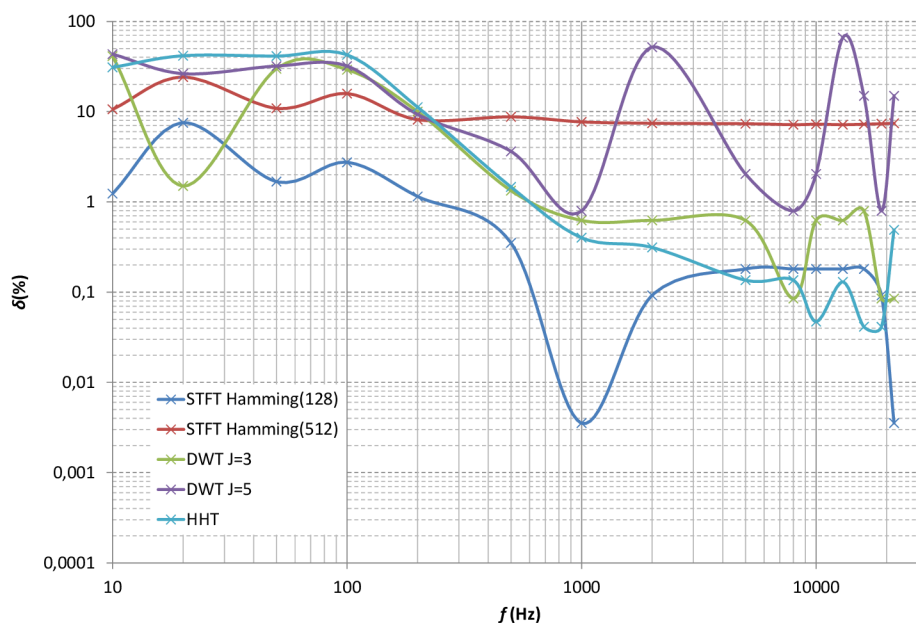
Cieľom lokalizačného testu je určiť, do akej miery sú jednotlivé analýzy schopné určiť čas vzniku akustickej udalosti. Test prebieha tak, že funkcia A.6 sleduje, kedy signál prekročí nastavenú hraničnú úroveň detekcie a vráti čas, v ktorom k tomuto prekročeniu dôjde. Tento čas je považovaný za počiatok simulovanej akustickej udalosti. Použitý referenčný signál 2.1 má počiatok akustickej udalosti v čase  $t = 25,6$  ms.



Obr. 2.10: Test polohy 2 kHz signálu simulujúceho akustický ráz v čase (čas v ktorom signál pretne zvolenú hranicu je považovaný za počiatok udalosti).




Celková dĺžka signálu 2.1 je oproti signálu 2.2 použitému v predchádzajúcich testoch väčšia, preto je potrebné modifikovať nastavenia okna pri STFT tak aby pomer dĺžky signálu a okna približne zodpovedal pomeru z predchádzajúcich testov. Úzke okno má novú dĺžku 128 vzoriek, a široké okno 512 vzoriek. Tieto testy sú vykonané pre všetky frekvencie uvedené v 2.2.1. Následne je vypočítaná relatívna chyba odhadu podľa 2.1 a vynesená do grafu.



Obr. 2.11: Relatívna chyba odhadu času vzniku akustickej udalosti.

Najpresnejší odhad počiatku akustického rázu ponúka krátkodobá Fourierová transformácia s použitím úzkeho Hammingovho okna (priemerná relatívna chyba dosahuje 1,05 %). Nasleduje Waveletová transformácia s hĺbkou dekompozície  $J = 3$ , kde priemerná relatívna chyba dosahuje 7,81 %. Ďalšou v poradí je krátkodobá Fourierová transformácia so širokým oknom, kde priemerná relatívna chyba dosahuje 9,64 %. Hilbert-Huangová transformácia priemerne v realizovaných testoch dosahuje relatívnu chybu 11,4 % a Waveletová transformácia s hĺbkou dekompozície  $J = 5$  dosahuje 20,06 %.

V praxi je však akustický ráz málo kedy tak dobre viditeľný ako v predchádzajúcom teste. Vždy je prítomný nejaký prevádzkový šum. V prípade, že daný šum má vysokú intenzitu, znemožňuje to detekciu akustickej udalosti. V nasledujúcej časti je vytvorený krátky experiment, v ktorom je signál 2.1 s frekvenciou 1 kHz (frekvencia je zvolená na základe výsledkov z predchádzajúceho testu 2.11). Signál je postupne zašumený bielym šumom s odstupom SNR 6 dB, 0 dB a  $-6$  dB.



Obr. 2.12: Akustický ráz s frekvenciou 1 kHz zašumený bielym šumom (z hora: SNR = 6 dB, SNR = 0 dB a SNR =  $-6$  dB).


Spôsob akým je doba začiatku akustického rázu určená v tomto experimente je podrobnejšie opísaný v [4]. Táto metóda využíva fakt, že v momente vzniku akustickej udalosti, vzrastie intenzita signálu, čím sa zvýši aj jeho efektívna hodnota. Táto efektívna hodnota sa určuje z istého časového intervalu s dĺžkou  $T$

$$RMS(t) = \sqrt{\frac{\int_{\tau=t-T}^t s^2(\tau)}{T}}. \quad (2.4)$$

K ohodnoteniu navýšenia intenzity signálu sa v [4] používa podiel medzi krátkodobou a dlhodobou efektívnou hodnotou

$$k(t) = \frac{RMS_K(t)}{RMS_L(t)}, \quad (2.5)$$

ktorý je realizovaný funkciou A.8, kde dlhé okno predstavuje približne 60 ms a krátke približne  $90 \mu s$ . Podobne ako v predchádzajúcom teste, aj tu je pre zistenie času priechodu prahovou hodnotou použitá funkcia A.6. V nasledujúcom grafe je zobrazený prebeh amplitúd jednotlivých signálov.



Obr. 2.13: Pribeh amplitúdy akustického rázu s frekvenciou 1 kHz zašumeného bielym šumom (z hora: SNR = 6 dB, SNR = 0 dB a SNR = -6 dB).

Ako je vidieť, s narastajúcou intenzitou šumu je potrebné posunúť aj hraničnú úroveň detekcie. Keďže časový úsek v ktorom došlo k detekcii samotného akustického rázu je pomerne krátky a z grafu neprehľadný, nasledujúca tabuľka obsahuje absolútne chyby odhadu v milisekundách, vypočítané podľa

$$\Delta x = x_n - x_s, \quad (2.6)$$

kde  $x_n$  je nameraná hodnota a  $x_s$  je skutočná hodnota.


Tab. 2.1: Absolútne chyby odhadu doby vzniku akustickej udalosti v ms

	STFT 512	STFT 128	DWT J3	DWT J5	HHT
SNR = 6 dB	-1,85	0,42	0,97	0,24	0,43
SNR = 0 dB	-2,28	$-9,9 \cdot 10^{-3}$	0,53	-0,19	0,36
SNR = -6 dB	-1,82	0,26	0,26	-0,46	0,73

Pri porovnaní výsledkov s predchádzajúcim lokalizačným testom 2.11 je možné vidieť podobnosť v dosiahnutej presnosti. Krátkodobá Fourierová transformácia vplyvom posúvania širokého okna registruje zmenu amplitúdy skôr ako k nej v skutočnosti dôjde. Tendenciu túto zmenu detekovať predčasne má aj Waveletová transformácia pri dekompozičnom strome s hĺbkou  $J = 5$ . Samotné časové rozlíšenie doby vzniku akustickej udalosti je do značnej miery ovplyvnené práve nastavením dĺžky okien pri 2.5. Pre výpočet tohto testu je použitý skript A.9.

## 2.2.4 Časový test

V tejto časti je vygenerovaný signál 2.2 spracovávaný jednotlivými metódami, pričom sa meria čas, ktorý procesor potrebuje pre výpočet každej metódy. Čas je stanovený pre procesor Intel® Core™ 2 DUO T9400 s frekvenciou 2,53 GHz počas bežnej prevádzky. Výsledné časy sú znázornené v nasledujúcom grafe.



Obr. 2.14: Čas potrebný pre procesor k výpočtu jednotlivých analýz.

Najkratší čas je potrebný pre krátkodobú Fourierovú transformáciu, ktorá je nasledovaná Hilbert-Huangovou transformáciou. Časovo najnáročnejšia je Waveletová transformácia, ktorá pre rovnaký výpočet spotrebovala takmer 10-krát viac času ako Hilbert-Huangová transformácia a takmer 100-krát viac času ako krátkodobá Fourierová transformácia. Na rýchlosť výpočtu má značný vplyv efektívnosť a náročnosť použitých algoritmov. Pre výpočet STFT v A.3 je použitá funkcia *stft.m* dostupná z [11]. Výpočet Waveletovej transformácie v A.4 je realizovaný funkciami z knižnice LTFAT dostupnej z [7]. Skript A.5 využíva pre výpočet HHT funkcie dostupné z [8].

### 3 ZÁVER

Táto diplomová práca zhŕňa v prvej časti základnú teóriu týkajúcu sa akustickej emisie a metód používaných pre analýzu signálov akustickej emisie. Menovite, krátkodobá Fourierová transformácia, diskretná Waveletová transformácia a Hilbert-Huangová transformácia, kde je bližšie rozpisovaný spôsob výpočtu vlastných modálnych funkcií pomocou presnej modálnej dekompozície.

V druhej časti práce je navrhnutý signál simulujúci akustický ráz A.2. V tejto časti sú taktiež navrhnuté 4 testy, ktorých úlohou je objektívne porovnať menované typy časovo-frekvenčných analýz. Časť práce venovaná samotným testom sa skladá z frekvenčného testu 2.2.1, amplitúdového testu 2.2.2, lokalizačného testu 2.2.3 a časového testu 2.2.4. Všetky testy sú vždy vykonané päťkrát a prezentovaný je medián nameraných hodnôt. Medián je zvolený kvôli vyššej robustnosti – odolnosti voči výkyvom v dátach (žiadne markantné výkyvy však počas meraní nenastali).

Frekvenčný test ukázal ľahkú superioritu HHT v presnosti odhadu frekvencie oproti ostatným skúmaným metódam. Tento výsledok je do istej miery skreslený faktom, že analyzovaný signál obsahoval vždy iba jednu frekvenčnú zložku. Vo frekvenciách do približne 3 kHz je odhad veľmi presný. Vo vysokých frekvenciách dochádza k veľkému rozptylu odhadnutých okamžitých frekvencií v snahe obsiahnuť celé spektrum. Tento rozptyl sa na nepresnosti odhadu neprejavil, pretože ako výsledok je v teste uvažovaný priemer odhadnutých okamžitých frekvencií.

Amplitúdový test ako prvú metriku používa koreláciu odhadnutého priebehu amplitúdy s pôvodným priebehom (2.8). Napriek dosiahnutiu pomerne vysokých korelácií sa tento test ukázal ako nedostatočne výpovedehodný. Preto je v ďalšej časti testu používaná iba stredná kvadratická chyba, ktorej výpovedná hodnota je oproti korelácii viditeľne vyššia (2.9). V tomto teste dosiahla HHT taktiež veľmi dobré výsledky, keď skončila druhá v poradí, s najmenšou kvadratickou chybou. V prílohe B je možné vidieť, ako vplýva aditívny šum na jednotlivé typy analýz pri odhade priebehu amplitúdy. Kým u Hilbert-Huangovej transformácie sa s rastúcim šumom zväčšovala chyba odhadu vo vysokých frekvenciách, o ostatných analýz tomu bolo naopak. Chyba vo vysokých frekvenciách ostáva približne rovnaká, no mení sa

chyba v nízkych frekvenciách.

Lokalizačný test má jednoduchú úlohu. Zistiť, či je daná analýza schopná presne odhadnúť dobu vzniku akustickej udalosti. Za tým účelom bola navrhnutá jednoduchá funkcia A.6, ktorá detekuje signál nad zvolenú hraničnú úroveň, pričom vráti čas, v ktorom k priechodu došlo. Závislosť 2.11 zobrazuje relatívnu chybu odhadu doby vzniku akustickej udalosti oproti skutočnej hodnote 25,6 ms. Okrem tohto merania je v podkapitole 2.2.3 navrhnutý experiment, ktorý bližšie naznačuje problematiku detekcie akustickej emisie. Výsledky experimentu sú prezentované v tabuľke 2.1.

Časový test pozostáva z merania času, ktorý spotrebuje procesor pri výpočte jednotlivých analýz. Toto meranie prebehlo päťkrát v slede rýchlo za sebou. Úmyslom pri tomto teste bolo minimalizovať rozdiely v časoch spôsobené rôznym vyťažením procesora. V kapitole 2.2.4 je zobrazený graf reprezentujúci medián vykonaných meraní. Táto sekcia sa taktiež odkazuje na zdroje, z ktorých boli všetky kritické funkcie prevzaté. Kritickými funkciami sú myslené tie časti programu, ktoré sú priamo predmetom časového merania.

Po preštudovaní výsledkov vykonaných testov nie je možné jednoznačne určiť, ktorá časovo-frekvenčná analýza je najlepšia. Každá má svoje pre a proti. Hilbert-Huangová transformácia však prináša odlišný prístup k časovo-frekvenčnej analýze, za čo si rozhodne zaslúži pozornosť.

Pozornosť si taktiež zaslúžia oblasti, ktoré v tejto práci nie sú zohľadnené, nakoľko ich zohľadnenie by značne pridalo práci na komplexnosti. Pri krátkodobej Fourierovej transformácii je použité Hammingovo okno. Vplyv tvaru iných okien nebol zohľadnený. Pri waveletovej transformácii by bolo možné použiť dekompozíciu pomocou dekompozičného stromu DWT, čím by došlo k značnému zrýchleniu výpočtu danej metódy – frekvenčné rozlíšenie by ale muselo byť prispôbené podľa oblasti záujmu. Pri Hilbert-Huangovej transformácii sa podľa ?? dá dosiahnuť oveľa lepších výsledkov použitím Kalmanovho filtra. Pri frekvenčnom teste by bolo vhodnejšie namiesto signálu so statickou frekvenciou použiť signál s meniacou sa frekvenciou. Pri amplitúdovom teste bola efektívna hodnota počítaná z okien bez prekryvu. Detektor priechodu signálu by mohol byť vybavený funkciou, ktorá zohľadní „falošný poplach“ pri priechode signálu hraničnou hodnotou. Zohľadnením týchto oblastí by

však mohlo dôjsť k značnému vylepšeniu výkonu jednotlivých analýz aj celkového systému porovnávania.



# LITERATÚRA

- [1] HUANG, Norden E. *Introduciton to the Hilbert Huang transform and its related mathematical problems*. Goddard Institute for Data Analysis, Code 614.2, NASA/Goddard Space Flight Center, Greenbelt, MD 20771, USA, 2004, 26 s.
- [2] HUANG, Norden E. et al.: *The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis*. Proc. Roy. Soc. Lond., 454, 903-993, 1998.
- [3] *IEEE Signal Processing Magazine: Mean Squared Error: Love It or Leave It?* [online]. IEEE, 2009. ISSN 1053-5888/09. Dostupné z URL: <[http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=4775883&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs\\_all.jsp%3Farnumber%3D4775883](http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=4775883&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D4775883)>.
- [4] LIŠKA, Jindřich. *Zpracování signálů pro diagnostiku a jeho aplikace*. Ústav automatizace a měřicí techniky, VUT v Brně, 2010, 60 s.
- [5] LIŠKA, J., JANEČEK, E.: *Time-Frequency Representation of Signals Using Kalman Filter. Robotics, Automation and Control*, I-Tech Education and Publishing, Wien, Austria, 2008
- [6] *Performance Comparison of STFT, WT, LMS and RLS Adaptive Algorithms in Denoising of Speech Signal* [online]. 2011. ISSN 1053-5888/09. Dostupné z URL: <<http://www.ijetch.org/papers/230-JT338.pdf>>.
- [7] SØNDERGAARD, Peter L. et al.: *The Large Time-Frequency Analysis Toolbox*, Dostupné z URL:<<http://ltfat.sourceforge.net/>>.
- [8] TAN, Alan. *Hilbert-Huang Transform*, In: [Http://www.mathworks.com/](http://www.mathworks.com/) [online]. 2008. Dostupné z URL:<<http://www.mathworks.com/matlabcentral/fileexchange/19681-hilbert-huang-transform>>.
- [9] THE MCGRAW HILL COMPANIES, Inc. *Acoustic emission testing*. 2003, 39 s. Dostupné z URL: <<http://mech.vub.ac.be/teaching/>>

info/Damage\_testing\_prevention\_and\_detection\_in\_aeronautics/  
PDF/acoustic-emission.pdf>.

- [10] *TULEJA, P. Vyhodnocování kvality řečového signálu.* Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2011. 56 s. Vedoucí bakalářské práce Ing. Ivan Míča.
- [11] *ZHIVOMIROV, Hristo. Short-Time Fourier Transform with MATLAB Implementation.* In: [Http://www.mathworks.com/](http://www.mathworks.com/) [online]. 2014. Dostupné z URL:<<http://www.mathworks.com/matlabcentral/fileexchange/45197-short-time-fourier-transformation-with-matlab-implementation>>.

# ZOZNAM SYMBOLOV, VELIČÍN A SKRATIEK

$a$	roztiahnutie matičného waveletu
$b$	posunutie matičného waveletu
$c_n$	komponent rozkladu pomocou presnej modálnej dekompozície
DWT	Klasický rozkladový strom, kde je dekomponovaný iba výstup dolnej priepusti
$\delta_x$	relatívna chyba
$\Delta x$	absolútna chyba
$e_{\max}$	vrchná obálka
$e_{\min}$	spodná obálka
$f_{vz}$	vzorkovací kmitočet
FULL	Úplný dekompozičný strom pre waveletovú transformáciu. Každý výstup je dekomponovaný až po J-tú úroveň
$h$	funkcia – ideálne okno
$H[s(t)]$	Hilbertova transformácia signálu $s(t)$
$m$	stredná hodnota obálky
MSE	stredná kvadratická chyba
$\omega$	okamžitá frekvencia signálu
P	Cauchyho hlavná hodnota
$\phi$	okamžitá fáza signálu
$\psi$	matičný wavelet
$P_{SP}$	spektrum hustoty energie

$r_n$	rezíduum presnej modálnej dekompozície
$\rho$	Pearsonov korelačný koeficient
$s$	pôvodný signál
$s_i$	imaginárna časť signálu $s$
$s_t$	modifikovaný signál
$\sigma_f$	smerodajná odchýlka náhodnej veličiny $f$
$\sigma_t$	smerodajná odchýlka náhodnej veličiny $t$
STFT	krátkodobá Fourierová transformácia
$t$	čas, ktorý je predmetom záujmu
$\theta$	prahová hodnota pre ukončenie iteratívneho procesu presnej modálnej dekompozície
$\tau$	priebežný čas
$W$	nastaviteľné okno Waveletovej transformácie
$z$	komplexný signál pozostávajúci zo signálov $s$ a $s_i$

# ZOZNAM PRÍLOH

<b>A</b>	<b>Zdrojové kódy</b>	<b>50</b>
A.1	Main_test.m . . . . .	50
A.2	Acoustic_emission_signal.m . . . . .	51
A.3	STFT_test.m . . . . .	53
A.4	DWT_test.m . . . . .	55
A.5	HHT_test.m . . . . .	57
A.6	Thresh_pass.m . . . . .	58
A.7	Comparison.m . . . . .	59
A.8	CharFun.m . . . . .	62
A.9	Noise_loc_test.m . . . . .	63
<b>B</b>	<b>Grafy</b>	<b>66</b>

# A ZDROJOVÉ KÓDY

## A.1 Main\_test.m

```
close all; clear all; clc;
%% ----- Setting Parameters ----- %%
% Signal Parameters
fs=44100;           % Sampling frequency in Hz
A= 1;              % Amplitude
F=[10 20 50 100 200 500 1000 2000 5000 8000 10000 13000 16000 19000 21500]; %
    Frequency in Hz
SNR=96;            % Signal to Noise Ratio
threshold = 0.05; % threshold for signal detection

%DFT parameters
win_shift = 1;          % window shift in STFT
win_length = 128;      % length of narrow window for STFT
narrow_win = win_length;
wide_win = narrow_win*4; % length of wide window for STFT
nfft = win_length*4;   % n points FFT

%% ----- Computing ----- %%
% Function designs signal according to Signal Parameters
[Harm, At1, tsn] = Acoustic_emission_signal(A,F,SNR,fs);
% STFT computation
run STFT_test.m
%initialization of LTFAT toolbox
run C:\Users\Peter\Documents\MATLAB\MA\lftfat_1.4.5\lftfatstart.m % change the path
    to reflect library location!
% DWT computation
run DWT_test.m
% HHT computation
run HHT_test.m
% Script will compare results from STFT, DWT and HHT. Results are stored in
    structures
run Comparison.m

% End of Script
```

## A.2 Acoustic\_emission\_signal.m

```

% =====
%> @brief Brief description of the Acoustic_emission_signal function
%>
%> Author: Peter Tuleja
%>
%> This function designs signal which simulates acoustic emission
%> @param A Contains amplitude of signal.
%> @param F Contains vector of frequencies.
%> @param SNR Contains value of Signal-to-Noise Ratio in dB
%> @param fs Contains sampling frequency.
%> @retval Harm Returns matrix where columns represent designed signals
%> @retval At1 Returns vector that represents amplitude course
%> @retval tsn Returns time vector in mili seconds
% =====
function [Harm, At1, tsn]=Acoustic_emission_signal(A,F,SNR,fs)

% ----- Acoustic emission signal design ----- %

N1=round(0.01*fs);
Nh=round(N1*1/4);
Nd=round(N1*3/4);

% upwards course of amplitude
nh=linspace(-3,0,Nh);
An=exp(nh)-0.05;

% downwards course of amplitude
nd=linspace(0,3,Nd);
Ad=exp((-1).*nd)-0.05;

At1=A/0.95*[An Ad]; % combining upword and downward courses

hit=round(2.5*N1-1); % setting number of samples that put before signal
                    % current setting corespondes to 25.6 ms
for i=1:length(F)
pHarm(i,:)=At1.*cos(2*pi*F(i)/fs*(0:N1-1)+2*pi*rand(1,1)); % creating signal
sHarm=10*log10(sum(pHarm(i,:).^2)/length(pHarm(i,:)));
%1.box - signal with space added before and behind signal
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
out(i,:)=[zeros(1,hit) pHarm(i,:) zeros(1,hit)]; % \
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% % \
% adding noise to output signal choose only one box
out_wn(i,:)=out(i,:)+wgn(1,length(out(i,:)),sHarm-SNR); % /
%2.box - only signal /
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

%out_wn(i,:)=pHarm(i,:)+wgn(1,length(pHarm(i,:)),sHarm-SNR);%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
out_wn(i,:)=out_wn(i,:)./max(out_wn(i,:)); % normalizing signal
end
% matching length of amplitude plot
At1=[zeros(1,hit) At1 zeros(1,hit)]; % comment this line when box 2 is enabled

Harm=out_wn';
ts=size(Harm(:,1));
tsn=linspace(0,(ts(1)/fs)*1000,ts(1)); % setting time vector to milliseconds

%% ----- Plotting of signals and amplitudes courses ----- %%

figure(1);
for i=1:length(F)
subplot(length(F),1,i);
plot(tsn,Harm(:,i),...
      'LineWidth',1,...
      'Color',[0 0 1]);
h=title(['\bf', num2str(F(i)), ' Hz']);
set(h,'FontName','MS Sans Serif')
xlabel('\itt (ms) \rightarrow')
ylabel('\ita (-) \rightarrow')
legend('\its ( {\itt} )')
set(gca,'ylim',[-1 1])
grid on
end

for i=1:length(F)
figure(i+1);
plot(tsn,At1,...
      'LineWidth',2,...
      'Color',[0 0 1]);
h=title(['\bf', num2str(F(i)), ' Hz signal amplitude']);
set(h,'FontName','MS Sans Serif')
xlabel('\itt (ms) \rightarrow')
ylabel('\ita (-) \rightarrow')
set(gca,'ylim',[0 1])
grid on
hold on
end
% Uncomment to print active figure to .pdf in landscape orientation
% h=gcf;
% set(h,'PaperOrientation','landscape');
% set(h,'PaperUnits','normalized');
% set(h,'PaperPosition',[0 0 1 1]);
% print(gcf, '-dpdf', 'Akusticky_raz.pdf');

```



## A.3 STFT\_test.m

```
%% ----- Plotting of spectrograms ----- %%
figure;
for i=1:length(F)
subplot(length(F),1,i);

CPU_start = tic;    % start of STFT CPU time measurement

[Sw{i},Fw{i},Tw{i}] = stft(Harm(:,i),wide_win,win_shift,nfft,fs); % STFT
    computation using wide window

CPU_time_STFTtw = toc(CPU_start); % end of STFT CPU time measurement

K = sum(hamming(wide_win, 'periodic'))/wide_win;
Sw{i} = abs(Sw{i})/wide_win/K;
Sw_tmp{i}=Sw{i};
Sw{i} =(Sw{i} + 1e-6);
imagesc(Tw{i}, Fw{i}, Sw{i});

set(gca,'YDir','normal')
h=title('\bfSpektrogram signálu simulujúceho akustický ráz (široké okno)');
set(h,'FontName','MS Sans Serif')
xlabel('\itt (s) \rightarrow');
ylabel('\itf (Hz) \rightarrow')
h = colorbar;
set(h,'FontName','MS Sans Serif')
ylabel(h,'\itL (dB)')

end

% amplitude course plotting for wide window STFT
for i=1:length(F)
figure(i+1);
en=size(Sw{i});
    for j=1:en
        maxValue(j)= max(Sw{i}(j,:));
    end
    [mx SWind]=max(maxValue);
    stairs(Tw{i}.*1000,Sw{i}(SWind,1:length(Tw{i})) ./max(Sw{i}(SWind,1:length(Tw{i}
        )))),...
        'LineWidth',2,...
        'Color',[0 1 0])
hold on
end

figure;
```

```

for i=1:length(F)
subplot(length(F),1,i);

CPU_start = tic;    % start of STFT CPU time measurement

[Sn{i},Fn{i},Tn{i}] = stft(Harm(:,i),narrow_win,win_shift,nfft,fs); % STFT
    computation using narrow window

CPU_time_STFTnw = toc(CPU_start);    % end of STFT CPU time measurement

K = sum(hamming(narrow_win, 'periodic'))/narrow_win;
Sn{i} = abs(Sn{i})/narrow_win/K;
Sn_tmp{i}=Sn{i};
Sn{i} = (Sn{i} + 1e-6);
imagesc(Tn{i}, Fn{i}, Sn{i});
set(gca, 'YDir', 'normal')
h=title('\bfSpektrogram signálu simulujúceho akustický ráz (úzke okno)');
set(h, 'FontName', 'MS Sans Serif')
xlabel('\itt (s) \rightarrow');
ylabel('\itf (Hz) \rightarrow')
h = colorbar;
set(h, 'FontName', 'MS Sans Serif')
ylabel(h, '\itL (dB)')
end

% amplitude course plotting for narrow window STFT
for i=1:length(F)
figure(i+1);
en=size(Sn{i});
for j=1:en(1)
    maxValue(j)= max(Sn{i}(j,:));
end
[mx SNind]=max(maxValue);
stairs(Tn{i}.*1000, Sn{i}(SNind,1:length(Tn{i}))./max(Sn{i}(SNind,1:length(Tn{i}))))
    ,...
    'LineWidth',2,...
    'Color',[1 0 0])
hold on
end

% Uncomment to print active figure to .pdf in landscape orientation
% h=gcf;
% set(h, 'PaperOrientation', 'landscape');
% set(h, 'PaperUnits', 'normalized');
% set(h, 'PaperPosition', [0 0 1 1]);
% print(gcf, '-dpdf', 'Akusticky_raz_spektrogramy.pdf');

```

## A.4 DWT\_test.m

```
%% ----- Plotting of spectrograms ----- %%

for i=1:length(F)
figure(length(F)+2);
subplot(length(F),1,i);

CPU_start = tic; % start of DWT CPU time measurement
% inputs parameters: wavelet type, depth of decomposition, decomposition tree
[c1, info] = wfbt(Harm(:,i),{'sym8',3,'full'});

CPU_time_WT = toc(CPU_start); % end of DWT CPU time measurement

plotwavelets(c1,info,fs,'dynrange',90);
h=title('\bfSpektrogram signálu simulujícíeho akustický ráz (FULL J=3)');
set(h,'FontName','MS Sans Serif')
xlabel('\itt} (s) \rightarrow')
ylabel('Kanál (-) \rightarrow')
grid on

D=get(gca,'children');
t_WT{i}=get(D,'XData');
mx = cellfun(@(x) max(x(:)), c1);
[maxValue, Wind(i)]= max(mx);

% amplitude course plotting for DWT J=3
figure(i+1);
WTenv{i}=abs(hilbert(c1{Wind(i),:}));
stairs(t_WT{i}.*1000, WTenv{i}./max(WTenv{i}),'-',...
'LineWidth',2,...
'Color',[1 1 0]);
end

%Plotting bank of filters used in decomposition
figure;
[g,a] =wfbt2filterbank({'sym8',3,'full'});
filterbankfreqz(g,a,2048,'plot','linabs','posfreq','fs',fs);
% middle frequencies of filterbank tree
freqz = [2756 4135 6891 9649 12405 15260 17915 19290];

for i=1:length(F)
figure(length(F)+3);
subplot(length(F),1,i);

CPU_start = tic; % start of DWT CPU time measurement
% inputs parameters: wavelet type, depth of decomposition, decomposition tree
[c2, info2] = wfbt(Harm(:,i),{'sym8',5,'full'});
```

```

CPU_time_WT_2 = toc(CPU_start); % end of DWT CPU time measurement

plotwavelets(c2,info2,fs,'dynrange',90);
h=title('\bfSpektrogram signálu simulujícíeho akustický ráz (FULL J=5)');
set(h,'FontName','MS Sans Serif')
xlabel('\itt} (s) \rightarrow')
ylabel('Kanál (-) \rightarrow')
grid on

D=get(gca,'children');
t_WT2{i}=get(D,'XData');

mx = cellfun(@(x) max(x(:)), c2);
[maxValue, Wind2(i)] = max(mx);

% amplitude course plotting for DWT J=5
figure(i+1);
WTenv2{i}=abs(hilbert(c2{Wind2(i),:}));
stairs(t_WT2{i}.*1000, WTenv2{i}./max(WTenv2{i}),'-',...
    'LineWidth',2,...
    'Color',[1 0 1]);

end

%Plotting bank of filters used in decomposition
figure;
[g,a] =wfbt2filterbank({'sym8',5,'full'});
filterbankfreqz(g,a,2048,'plot','linabs','posfreq','fs',fs);
% middle frequencies of filterbank tree
freqz2 = [689 1034 1723 2412 3101 3790 4478 5168 5858 6547 7236 7925 8614 9303 9994
    10685 11370 12055 12745 13435 14125 14815 15505 16195 16885 17575 18260 18945
    19635 20325 21015 21136];

% Uncomment to print active figure to .pdf in landscape orientation
% h=gcf;
% set(h,'PaperOrientation','landscape');
% set(h,'PaperUnits','normalized');
% set(h,'PaperPosition',[0 0 1 1]);
% print(gcf, '-dpdf', 'Akusticky_raz_spec_DWT.pdf');

```

## A.5 HHT\_test.m

```
% HHT computation
for i=1:length(F)
subplot(length(F),1,i);

CPU_start = tic; % start of HHT CPU time measurement

[imf{i},d{i}]= plot_hht(Harm(:,i),1/fs);

CPU_time_HHT = toc(CPU_start); % end of HHT CPU time measurement
end

% plotting of HHT amplitude
Env=zeros(length(F),length(Harm));
for i=1:length(F)
figure(i+1);
mx = cellfun(@(x) max(x(:)), imf{i});
[maxValue, Hind(i)]= max(mx);
Env(i,:) = abs(hilbert(imf{i}{Hind(i)}));
Env(i,:) = Env(i,:)./max(Env(i,:));
plot(tsn,Env(i,:), '--', ...
      'LineWidth',2,...
      'Color',[0 0 0]);
%plotting threshold for signal detection
plot(tsn,0.05,...
      'LineWidth',2,...
      'Color',[0 1 1]);
legend('Original signal','STFT 128','STFT 32','DWT J3','DWT J5','HHT','Threshold')
end

% Uncomment to print active figure to .pdf in landscape orientation
% h=gcf;
% set(h,'PaperOrientation','landscape');
% set(h,'PaperUnits','normalized');
% set(h,'PaperPosition',[0 0 1 1]);
% print(gcf, '-dpdf', 'Amplituda_2k.pdf');
```

## A.6 Thresh\_pass.m

```
% =====
%> @brief Brief description of the Thresh_pass function
%>
%> Author: Peter Tuleja
%>
%> This function compute time when input signal rises above set threshold
%> @param Amp Contains input signal.
%> @param threshold Contains threshold for amplitude detection.
%> @param tv Contains time vector of input signal.
%> @retval pass_time Returns time (unit is similar as one used in tv), when input
%> signal rises above threshold set.
% =====

function [ pass_time ] = Thresh_pass( Amp, threshold, tv)

for tp=1:length(Amp)
    if Amp(tp)>=threshold
        break
    end
end

pass_time = tv(tp);
```

## A.7 Comparison.m

```

%% ===== Correlation ===== %%

for i=1:length(F)
    en=size(Sn{i});
    for j=1:en(1)
        maxValue(j)= max(Sn{i}(j,:));
    end
    [mx, SNind]=max(maxValue);
    en=size(Sw{i});
    for j=1:en
        maxValue(j)= max(Sw{i}(j,:));
    end
    [mx, SWind]=max(maxValue);
    cor.STFTnw(i) = Correlation(Sn{i}(SNind(1),:),At1(win_length/2:end-win_length
        /2));
    cor.STFTtw(i) = Correlation(Sw{i}(SWind(1),:),At1(wide_win/2:end-wide_win/2));
    cor.DWT(i)= Correlation(At1(1:round(info.Ls/info.Lc(1)):end),WTenv{i}./max(
        WTenv{i}));
    cor.DWT2(i)= Correlation(At1(1:round(info2.Ls/info2.Lc(1)):end),WTenv2{i}./max(
        WTenv2{i}));
    cor.HHT(i) = Correlation(Env(i,:),At1);
end

%% ===== Mean Squared Error ===== %%

for i=1:length(F)
    en=size(Sn{i});
    for j=1:en(1)
        maxValue(j)= max(Sn{i}(j,:));
    end
    [mx, SNind]=max(maxValue);
    en=size(Sw{i});
    for j=1:en
        maxValue(j)= max(Sw{i}(j,:));
    end
    [mx, SWind]=max(maxValue);
    mse.STFTnw(i)=sum((Sn{i}(SNind(1),:)-At1(win_length/2:end-win_length/2)).^2)/
        length(Sn{i}(SNind(1),:));
    mse.STFTtw(i)=sum((Sw{i}(SWind(1),:)-At1(wide_win/2:end-wide_win/2)).^2)/length
        (Sw{i}(SWind(1),:));
    mse.DWT(i)=sum((WTenv{i}-At1(1:round(info.Ls/info.Lc(1)):end)').^2)/length(
        WTenv{i});
    mse.DWT2(i)=sum((WTenv2{i}-At1(1:round(info2.Ls/info2.Lc(1)):end)').^2)/length(
        WTenv2{i});
    mse.HHT(i)=sum((Env(i,)-At1).^2)/length(Env(i,:));
end

```

```

end

%% ===== Frequency ===== %%

for i=1:length(F)
    en=size(Sn{i});
    for j=1:en(1)
        maxValue(j)= max(Sn{i}(j,:));
    end
    [mx, SNind]=max(maxValue);
    en=size(Sw{i});
    for j=1:en
        maxValue(j)= max(Sw{i}(j,:));
    end
    [mx, SWind]=max(maxValue);
    fsn = size(Sn{i});
    fsw = size(Sw{i});
    freq.STFTnw(i)= (fs/2/fsn(1)*SNind(1))-fs/2/fsn(1)/2;
    freq.STFTtw(i)= (fs/2/fsw(1)*SWind(1))-fs/2/fsw(1)/2;
    freq.DWT(i) =freqz(Wind(i));
    freq.DWT2(i) =freqz2(Wind2(i));
    freq.HHT(i)= median(d{i}{1});
end

%% ===== Time ===== %%

for i=1:length(F)
    en=size(Sn{i});
    for j=1:en(1)
        maxValue(j)= max(Sn{i}(j,:));
    end
    [mx, SNind]=max(maxValue);
    en=size(Sw{i});
    for j=1:en
        maxValue(j)= max(Sw{i}(j,:));
    end
    [mx, SWind]=max(maxValue);
    time.STFTnw(i)= Thresh_pass( Sn{i}(SNind(1),:), threshold, Tn{i}.*1000);
    time.STFTtw(i)= Thresh_pass( Sw{i}(SWind(1),:), threshold, Tw{i}.*1000);
    time.DWT(i) = Thresh_pass( WTenv{i}./max(WTenv{i}), threshold, t_WT{i}.*1000);
    time.DWT2(i) = Thresh_pass( WTenv2{i}./max(WTenv2{i}), threshold, t_WT2{i}
        }.*1000);
    time.HHT(i)= Thresh_pass(Env(i,:), threshold, tsn);
end

%% ===== Writing results into txt ===== %%

fid = fopen('freq.txt', 'w+');

```



```
fseek(fid,0,'eof');
fprintf(fid, '\n%f ', freq.STFTnw, freq.STFTww,freq.DWT,freq.DWT2, freq.HHT);
fclose(fid);

fid = fopen('mse.txt', 'w+');
fseek(fid,0,'eof');
fprintf(fid, '\n%f ', mse.STFTnw, mse.STFTww,mse.DWT,mse.DWT2, mse.HHT);
fclose(fid);

fid = fopen('cor.txt', 'w+');
fseek(fid,0,'eof');
fprintf(fid, '\n%f ', cor.STFTnw, cor.STFTww,cor.DWT,cor.DWT2, cor.HHT);
fclose(fid);

fid = fopen('time.txt', 'w+');
fseek(fid,0,'eof');
fprintf(fid, '\n%f ', time.STFTnw, time.STFTww,time.DWT,time.DWT2, time.HHT);
fclose(fid);
```

## A.8 CharFun.m

```
% =====
%> @brief Brief description of the CharFun function
%>
%> Author: Peter Tuleja
%>
%> This function compute characteristic function k(t) given by
%> \latexonly
%> \begin{equation}\label{CharFun}
%> \mathrm{k}(t)=\frac{\mathrm{RMS}_{\mathrm{K}}(t)}{\mathrm{RMS}_{\mathrm{L}}(t)},
%> \end{equation}
%> \endlatexonly
%>
%> @param Pow_env Contains input signal.
%> @param n Contains lenght of window for K_RMS.
%> @retval kt Returns characteristic function.
% =====

function [ kt, tvec ] = CharFun( Pow_env, n )

    L_RMS = rms( Pow_env );
    step=1:n:length( Pow_env );
    for i=1:length( Pow_env )/n;
        K_RMS(i)=rms( Pow_env( step(i) : step(i+1) ) );
    end
    kt=K_RMS./L_RMS;
    kt=kt./max(kt);
    tvec=(1:n:length( Pow_env ));

end
```

## A.9 Noise\_loc\_test.m

```

% This script is designed for single test only.

% Hilbert-Huang spectrum
freq_vect= [1:100:22050];
fv=[1:220];
time=length(d{1}{1});
freq_mat= repmat(round(freq_vect./100)',1,time);
for j=1:length(imf{1})
    for i=1:time
        mask(:,i)=freq_mat(:,i)==round((d{1}{j}(i))./100);
    end
    Envelope=abs(hilbert(imf{1}{j}(1:end-1))).^2;
    Amp=repmat(Envelope,length(freq_vect),1);
    C{j}=Amp.*mask;
end

figure;
Hspec=C{Hind-1} + C{Hind}+ C{Hind+1};
imagesc(Hspec)
set(gca,'FontSize',8,'YLim',[0 length(fv)/2]); xlabel('Time'), ylabel('
    Frequency')

%plotting od amplitude courses
figure(20);
n=4; % length of RMS_K (in samples)
[kt_At, tvec_At]=CharFun(At1.^2,n);
t=tsn(1:n:end);
plot(tsn,At1,...
    'LineWidth',2,...
    'Color',[0 0 1]);
h=xlabel('\itt (ms) \rightarrow');set(h,'FontSize',20);
h=ylabel('\ita (-) \rightarrow');set(h,'FontSize',20);
set(gca,'ylim',[0 1],'FontSize',20);
grid on
hold on
en=size(Sw{1});
for j=1:en
    maxValue(j)= max(Sw{1}(j,:));
end
[mx SWind]=max(maxValue);
[kt_STFTtw, tvec_STFTtw]=CharFun((Sw{1}(SWind,1:length(Tw{1}))).^2,n);
t=Tw{1}(1:n:end).*1000;
stairs(t(1:end-1),kt_STFTtw,...
    'LineWidth',2,...
    'Color',[0 1 0])

```

```

en=size(Sn{1});
for j=1:en(1)
    maxValue(j)= max(Sn{1}(j,:));
end
[mx SNind]=max(maxValue);

[kt_STFTnw, tvec_STFTnw]=CharFun((Sn{1}(SNind,1:length(Tn{1}))).^2,n);

t=Tn{1}(1:n:end).*1000;
stairs(t(1:end-1),kt_STFTnw,...
    'LineWidth',2,...
    'Color',[1 0 0])
WTenv{1}=abs(hilbert(c1{Wind(1),:}));
[kt_DWT3, tvec_DWT3]=CharFun(WTenv{1}.^2,n);
t=t_WT{1}(1:n:end).*1000;
stairs(t(1:end-1),kt_DWT3,'-',...
    'LineWidth',2,...
    'Color',[1 1 0]);
WTenv2{1}=abs(hilbert(c2{Wind2(1),:}));
[kt_DWT5, tvec_DWT5]=CharFun(WTenv2{1}.^2,n);
t=t_WT2{1}(1:n:end).*1000;
stairs(t(1:end-1),kt_DWT5,'-',...
    'LineWidth',2,...
    'Color',[1 0 1]);
Pow_env_HHT=abs(hilbert(imf{1}{Hind})).^2;
[kt_HHT, tvec_HHT]=CharFun(Pow_env_HHT,n);
t=tsn(1:n:end);
stairs(t(1:end-1),kt_HHT,'--',...
    'LineWidth',2,...
    'Color',[0 0 0]);
plot(t(1:end-1),threshold,...
    'LineWidth',3,...
    'Color',[0 1 1]);
legend('Original signal','STFT 512','STFT 128','DWT J3','DWT J5','HHT','Threshold')

%----- localization of acoustic emission signal (time estimation -----
for i=1:length(F)
    en=size(Sn{i});
    for j=1:en(1)
        maxValue(j)= max(Sn{i}(j,:));
    end
    [mx, SNind]=max(maxValue);
    en=size(Sw{i});
    for j=1:en
        maxValue(j)= max(Sw{i}(j,:));
    end
    [mx, SWind]=max(maxValue);

```

```


time.STFTnw(i)= Thresh_pass( kt_STFTnw, threshold, tvec_STFTnw);
time.STFTtw(i)= Thresh_pass( kt_STFTtw, threshold, tvec_STFTtw);
time.DWT(i) = Thresh_pass( kt_DWT3, threshold, tvec_DWT3);
time.DWT2(i) = Thresh_pass( kt_DWT5, threshold, tvec_DWT5);
time.HHT(i)= Thresh_pass(kt_HHT, threshold, tvec_HHT);
time.At(i)=Thresh_pass(kt_At, threshold, tvec_At);
time.At_norm(i)=Thresh_pass(At1, threshold, tsn);
end

time.STFTnw = Tn{1}(time.STFTnw).*1000
time.STFTtw = Tw{1}(time.STFTtw).*1000
time.DWT = t_WT{1}(time.DWT).*1000
time.DWT2 = t_WT2{1}(time.DWT2).*1000
time.HHT = tsn(time.HHT)
time.At = tsn(time.At)


plot(time.At_norm,threshold,'+r','MarkerSize',10,'linewidth',2);
plot(time.STFTnw,threshold,'+r','MarkerSize',10,'linewidth',2);
plot(time.STFTtw,threshold,'+r','MarkerSize',10,'linewidth',2);
plot(time.DWT,threshold,'+r','MarkerSize',10,'linewidth',2);
plot(time.DWT2,threshold,'+r','MarkerSize',10,'linewidth',2);
plot(time.HHT,threshold,'+r','MarkerSize',10,'linewidth',2);

```


## B GRAFY




Obr. B.1: Závislosť strednej kvadratickej chyby na frekvencii pri výpočte amplitúdy zašumeného signálu metódou STFT s Hammingovým oknom (32)




Obr. B.2: Závislosť strednej kvadratickej chyby na frekvencii pri výpočte amplitúdy zašumeného signálu metódou STFT s Hammingovým oknom (128)



Obr. B.3: Závislosť strednej kvadratickej chyby na frekvencii pri výpočte amplitúdy zašumeného signálu metódou DWT s hĺbkou dekompozície  $J = 3$



Obr. B.4: Závislosť strednej kvadratickej chyby na frekvencii pri výpočte amplitúdy zašumeného signálu metódou DWT s hĺbkou dekompozície  $J = 5$



Obr. B.5: Závislosť strednej kvadratickej chyby na frekvencii pri výpočte amplitúdy zašumeného signálu metódou HHT