



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

VLNKOVÁ FILTRACE SIGNÁLŮ EKG

WAVELET FILTERING OF ECG SIGNALS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. MAREK HANDL

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. JIŘÍ KOZUMPLÍK, CSc.

BRNO 2013



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Diplomová práce

magisterský navazující studijní obor
Biomedicínské inženýrství a bioinformatika

Student: Bc. Marek Handl

ID: 119704

Ročník: 2

Akademický rok: 2012/2013

NÁZEV TÉMATU:

Vlnková filtrace signálů EKG

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s problematikou vlnkových transformací s diskretním časem (DTWT). 2) V prostředí Matlab realizujte paketovou redundantní DTWT a seznamte se s možnostmi jejího využití pro filtraci signálů. 3) Navrhněte a realizujte wienerovský filtr daného typu pro potlačení myopotenciálů v signálech EKG. 4) Ověřte funkčnost navrženého filtru na signálech knihovny CSE. 5) Porovnejte výsledky této filtrace s výsledky dosaženými dříve realizovanou filtrací s použitím dyadické DTWT.

DOPORUČENÁ LITERATURA:

- [1] KOZUMPLÍK, J. Multitaktní systémy. Elektronická skripta FEKT VUT v Brně, 2005.
[2] STRANG, G., NGUYEN, T. Wavelets and Filter Banks. Wellesley-Cambridge Press, 1996, ISBN 0-9614088-7-1.

Termín zadání: 11.2.2013

Termín odevzdání: 24.5.2013

Vedoucí práce: doc. Ing. Jiří Kozumplík, CSc.

Konzultanti diplomové práce:

prof. Ing. Ivo Provazník, Ph.D.

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

Práce se zabývá problematikou vlnkových transformací se zaměřením na vlnkové transformace s diskrétním časem (DTWT). Praktická část je zaměřena na realizaci redundantní paketové DTWT a její využití při filtraci signálů EKG. Stěžejní částí práce je návrh wienerovského filtru, využívající redundantní paketovou DTWT, který slouží k odstranění rušení myopotenciálů ze signálů EKG. Samotné řešení je realizováno v programu Matlab. Testování probíhá na knihovně CSE s využitím modelu šumu myopotenciálů, který slouží k zarušení originálních signálů. Pro optimální nastavení parametrů navrženého filtru je využito genetického algoritmu (GA). V práci je realizováno porovnání navrženého filtru s redundantní paketovou DTWT s variantou redundantní dyadické DTWT.

Klíčová slova

EKG signál, vlnková transformace, wienerovský filtr, redundantní paketová DTWT, genetický algoritmus.

Abstract

The work deals with the wavelet transformation, focusing on wavelet transforms with discrete time (DTWT). The practical part is focused on the implementation of redundant packet DTWT and its use in the filtration of ECG signals. The main part of the work is to design wiener filter that uses redundant packet DTWT, designed to eliminate interference myopotentials of ECG signals. The actual solution is implemented in Matlab. Testing is performed on the library CSE using noise model myopotentials used to noising original signals. For optimum parameters designed filter is used the genetic algorithm (GA). The work is carried out comparing the proposed filter redundant packet DTWT a variant of redundant dyadic DTWT.

Key words

ECG signal, wavelet transform, wiener filter, redundant packet DTWT, genetic algorithm.

Bibliografická citace

HANDL, M. *Vlnková filtrace signálů EKG*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2013. 72 s. Vedoucí diplomové práce doc. Ing. Jiří Kozumplík, CSc..

Prohlášení

Prohlašuji, že svoji diplomovou práci na téma Vlnková filtrace signálů EKG jsem vypracoval samostatně pod vedením vedoucího diplomové 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 diplomové práce dále prohlašuji, že v souvislosti s vytvořením této práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si 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. 40/2009Sb.

V Brně dne 14. května 2013

.....
podpis autora

Poděkování

Rád bych poděkoval vedoucímu své diplomové práce, doc. Ing. Jiřímu Kozumplíkovi, CSc., za cenné připomínky a odborné rady, díky nimž mi pomohl k vypracování diplomové práce. A také děkuji za trpělivost a přátelskou atmosféru při konzultacích. Dále bych rád poděkoval Ing. Lukáši Smitalovi za poskytnutí jeho programu k vyhodnocení mého navrženého wienerovského filtru a možnosti objektivního porovnání s jinými metodami filtrace.

V Brně dne 14. května 2013

.....
podpis autora

Obsah

Bibliografická citace.....	4
Obsah.....	6
Seznam obrázků a tabulek	8
Úvod.....	9
1. EKG signál.....	11
1.1 Elektrická činnost srdce	12
1.1.1 Depolarizace.....	13
1.1.2 Repolarizace.....	14
1.2 Rušení signálů EKG.....	14
1.2.1 Kolísání nulové izolínie (drift).....	15
1.2.2 Síťový brum	15
1.2.3 Rušení myopotenciály.....	15
1.3 Tvar EKG křivky	16
2. Vlnková transformace	18
2.1 Vlnková transformace spojitého signálu.....	18
2.2 Diskrétní vlnková transformace DWT	19
2.3 Vlnková transformace s diskrétním časem DTWT.....	19
2.4 Redundantní paketová DTWT	20
2.5 Využití DTWT pro filtraci signálů EKG	22
2.5.1 Tvrdé prahování	23
2.5.2 Měkké prahování	24
2.5.3 Hybridní prahování	24
2.5.4 Nastavení prahu	25
2.5.5 Odhad směrodatné odchylky.....	26
3. Návrh wienerovského filtru	27
3.1 Metoda pilotního odhadu	28
3.2 Realizace bloků WT1 a WT2.....	29
3.2.1 Odvození filtrů	29
3.2.2 Ukázka použitých filtrů.....	30
3.3 Realizace bloků IWT1 a IWT2	32
3.3.1 Odvození parametru stupeň rozkladu	32
3.3.2 Fázové zpoždění filtrů.....	33
3.4 Realizace bloku HW a prahování.....	33

3.4.1	Odhad směrodatné odchyly šumu	33
3.4.2	Výpočet prahu	34
4.	Genetický algoritmus	35
4.1	Realizace GA pro optimalizaci empirické konstanty	35
4.1.1	Navržení úvodní populace	37
4.1.2	Parametry ukončení	38
4.1.3	Nastavení parametrů GA	38
4.2	Realizace GA pro optimalizaci empirické konstanty a stupně rozkladu (GA_2)	38
4.2.1	Úprava GA_2 pro funkci více proměnných	38
4.3	Vyhodnocení výsledků GA a GA_2	39
5.	Realizace wienerovského filtru	42
5.1	Funkce rpDWT	42
5.2	Funkce rpIDWT	43
5.3	Funkce filtrace	44
5.4	Funkce median_pevny	44
5.5	Hlavní funkce wiener_filtr	45
5.6	Skript diplomova_prace	46
5.7	Výsledky a vyhodnocení	47
6.	Statistika a vyhodnocení	50
6.1	Knihovna CSE	50
6.2	Testování pomocí programu <i>statistika</i>	51
6.3	Testování pomocí programu <i>FILTERING_TESTER</i>	52
7.	Závěr	56
8.	Použitá literatura	59
9.	Dodatek: Genetický algoritmus	62
9.1	Základní pojmy	62
9.1.1	Kriteriální funkce	63
9.1.2	Souboj	63
9.1.3	Křížení	63
9.1.4	Mutace	64
9.1.5	Populace	64
	Seznam symbolů a zkratk	65
	Seznam příloh:	67

Seznam obrázků a tabulek

obr. 1. 1 Výkonové spektrum signálu EKG [7].....	11
obr. 1. 2 Elektrická aktivita srdce [9]	12
tab. 1. 1 Rozložení iontů vně a uvnitř buněčné membrány [10]	13
obr. 1. 3 Souvislost akčního potenciálu komorové buňky srdeční a záznamu EKG [9].....	14
obr. 1. 4 Periodogram (čárkovaně) a parametrický AR odhad spektra (plná čára) [12]	16
obr. 1. 5 Fyziologické hodnoty trvání jednotlivých úseků EKG signálu [3].....	17
obr. 2. 1 Realizace rychlé třístupňové dyadické DTWT [2]	20
obr. 2. 2 Realizace stromové dyadické DTWT s podvzorkováním výstupů [2]	20
obr. 2. 3 Přímá a zpětná redundantní paketová DTWT s dvěma stupni rozkladu [23]	21
obr. 2. 4 Škálogram signálu EKG s využitím STFT(a), WT(b)[13]	22
obr. 2. 5 Hybridní prahování pro $\lambda_m = 2$ [6]	25
obr. 3. 1 Schéma wienerovského filtru s pilotním odhadem užitečného signálu[2]	28
obr. 3. 2 Filtry odvozené z výchozích dolních a horních propustí [6]	29
obr. 3. 3 Rozkladová a rekonstrukční vlnka bior4.4	30
obr. 3. 4 Rozkladové a rekonstrukční filtry pro vlnku bior4.4.....	31
obr. 3. 5 Reálné filtry odvozené z dolních a horních propustí	31
obr. 4. 1 Schéma GA [20]	37
tab. 4. 1 Vyhodnocení empirické konstanty nalezené GA	39
obr. 4. 2 Nejlepší jedinec nalezený metodou GA.....	40
obr. 4. 3 Vyhodnocení empirické konstanty metodou brutal force	40
tab. 4. 2 Porovnání doporučených a získaných hodnot pomocí genetického algoritmu GA_2	41
obr. 4. 4 Nejlepší jedinec nalezený metodou GA_2.....	41
obr. 5. 1 Testovací signál obsahující šum myopotenciálů.....	47
obr. 5. 2 Pilotní odhad užitečného signálu	48
obr. 5. 3 Srovnání filtrovaného signálu s originálním signálem	48
obr. 5. 4 Srovnání filtrovaného signálu se zašuměným signálem	49
tab. 6. 1 Parametry pro SWT z [převzato z [16]]	51
tab. 6. 2 Výsledné vypočítané zlepšení $SNR_{výst}$	52
tab. 6. 3 Výsledky testování programem FILTERING_TESTER.....	53
obr. 6. 1 Vyhodnocení nejlepšího výsledku pro redundantní paketovou DTWT	53
obr. 6. 2 Vyhodnocení nejlepšího výsledku pro redundantní dyadickou DTWT	54
tab. 7. 1 Porovnání různých filtračních metod programem FILTERING_TESTER[16].....	57
obr. 9. 1 Křížení dvou jedinců (páru) s různými body křížení [20]	63
obr. 9. 2 Mutace u populace tvořené 4 jedinci [20].....	64

Úvod

V době 21. století dochází neustále k rychlému rozvoji zdravotnictví a s ním roste i důraz, který se klade na možnosti včasné a přesné diagnostiky. V současné době je stále hlavní příčinou úmrtí kardiovaskulární onemocnění. A to nejen v České republice, kde jsou příčinou více než poloviny všech úmrtí, ale i ve světě. Jedním z řešení je bezesporu zdokonalení a zpřesnění diagnostiky kardiovaskulárních nemocí.

Mezi hlavní metody, které slouží k vyšetření lidského srdce, patří zátěžové EKG. Na rozdíl od běžného klidového EKG se u něho setkáváme s výrazným rušením myopotenciálů, které vzniká činností svalů. Běžně používané metody vycházející z lineární filtrace u těchto signálů nejsou vhodné, protože vedou k výraznému zkreslení užitečného signálu. Pro samotnou analýzu a rozměření EKG signálů, která je základem diagnostiky, je nutné minimalizovat zkreslení způsobené filtrací. Řešením může být právě využití vlastností vlnkových transformací. Ty jsou k filtraci takto zarušených signálů šetrnější a mohou být tak velkým přínosem pro proces diagnostiky.

V úvodní části práce nacházíme seznámení se základními vlastnostmi EKG signálů, včetně principu jejich vzniku, a také jejich nejčastějšími druhy rušení. Zejména se zaměřením na rušení myopotenciálů. Následuje obecný rozbor problematiky vlnkových transformací a jejich porovnání s Fourierovou transformací. Práce se zaměřuje na redundantní paketovou vlnkovou transformaci s diskretním časem (redundantní paketová DTWT). Hlavní část práce se zaměřuje na řešení problému odstranění rušení myopotenciálů ze signálů EKG s využitím wienerovského filtru. K tomu je využito právě redundantní paketové DTWT, která je nezbytná jak pro odhad užitečného signálu metodou prahování, tak i pro samotnou činnost wienerovského filtru. Problematika navrženého filtru využívající metodu pilotního odhadu je v práci teoreticky podrobně zpracována od samotné realizace redundantní paketové DTWT, přes způsoby filtrace a metody prahování, až po samotný výpočet a aplikaci korekčních členů. Všechny příslušné funkce jsou realizovány v programu Matlab a detailně v práci popsány.

Vzhledem k výpočetní náročnosti samotné filtrace a nutnosti nalezení vhodné empirické konstanty pro proces prahování je v práci testován genetický algoritmus (GA) jako optimalizační metoda pro nalezení dané empirické konstanty. Dále jsou rozebrány možnosti využití GA pro danou úlohu včetně diskuze nastavení jednotlivých parametrů GA. V neposlední řadě zde najdeme samotné zhodnocení získaných výsledků pomocí GA.

Kapitola 5 je věnována podrobnějšímu popisu použitých funkcí sloužících k realizaci navrženého wienerovského filtru včetně grafických výstupů popisující jednotlivé kroky při samotné filtraci.

V závěrečné části práce nalezneme statistické vyhodnocení navrženého filtru pro různé vstupní parametry, k nimž byly využity dva odlišné programy. První program *statistika*, který vyhodnocuje účinnost filtrace pro konkrétní hodnoty vstupního SNR (poměr signál - šum). Druhým programem je *FILTERING_TESTER*, který poskytl Ing. Lukáš Smital. Ten umožňuje

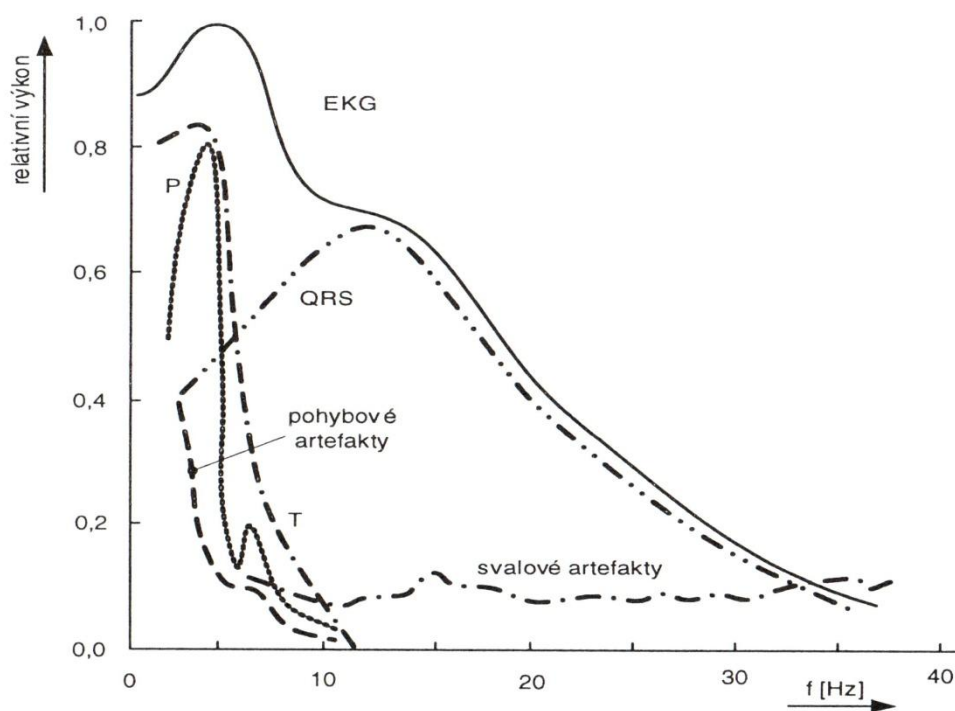
testovat různé navržené filtry sloužící k odstranění šumu myopotenciálů. Hlavním rozdílem je vstupní SNR, které nabývá různých hodnot od -5 dB do 55 dB s krokem 5 dB, což více odpovídá reálnému rušení. Výhodou použitého programu je také možnost objektivního porovnání navrženého filtru s ostatními metodami, které byly tímto programem testovány [16]. Výstupem jsou jak statistické hodnoty, tak grafické výstupy. V neposlední řadě je v práci pro navržený filtr zhodnocen rozdíl mezi využitím varianty redundantní paketové DTWT a redundantní dyadické DTWT.

1. EKG signál

Elektrokardiogram (EKG) je grafický záznam elektrické činnosti srdce získaný pomocí elektrod umístěných na povrchu těla. Přístroj využívaný ke snímání se nazývá elektrokardiograf. Kromě elektrokardiogramu se můžeme setkat se zobrazením jako vektokardiogram (VKG), kde se využívá ortogonální svodový systém [7].

Samotný EKG signál zobrazuje rozdíly potenciálů, které vznikají v důsledku elektrické aktivity srdce. Signál EKG má rozsah 0,05 - 5 mV a používá se nejčastěji kvantovací krok 2,5 μ V, ale můžeme se setkat i s hodnotami 5 až 10 μ V. Užitečná část signálu leží v kmitočtovém pásmu do 125 Hz, u dětí nebo při snímání fetálního EKG až do 150 Hz. Běžně se používá vzorkovací frekvence 500 Hz, aby byl splněn vzorkovací teorém. Pro účely dalších druhů snímání, jako je zátěžové EKG či analýza pozdních potenciálů, se využívá větší vzorkovací frekvence i menší kvantovací krok [1][3][4][7].

Hlavní frekvenční složky signálu EKG však leží v nižších frekvenčních pásmech, asi 90 % délky cyklu EKG tvoří vlny T a P, jejichž hlavní část spektra leží do 10 Hz (obr. 1. 1). Hlavní část výkonu komplexu QRS potom leží v pásmu cca od 3 do 40 Hz, avšak jeho spektrum zasahuje až do 125 Hz [5][6].




obr. 1. 1 Výkonové spektrum signálu EKG [7]

1.1 Elektrická činnost srdce

Srdeční sval (myokard) je tvořen svalovými buňkami. V každé skupině buněk probíhá v danou chvíli depolarizace nebo repolarizace, což představuje různé fáze elektrické aktivity. Tuto aktivitu můžeme snímat pomocí elektrod na povrchu těla tzv. zevní biosignál nebo elektrodami umístěnými v blízkosti srdce jako tzv. přímý biosignál (např. jícnové EKG). V každém časovém okamžiku můžeme tuto aktivitu popsat pomocí vektorové síly. Samotná elektrická činnost srdce je potom dána úhrnem všech okamžitých vektorů [1][8].

Samotný stah srdeční svaloviny (kontrakce) je způsoben elektrickým impulsem. Ten vzniká spontánně v sinoatriálním uzlu (SA). Četnost těchto impulsů se pohybuje mezi 50 až 100 impulsy za minutu a je ovlivněna nejen vegetativním nervstvem, ale i hormonálními a chemickými látkami. Impuls se dále šíří síněmi k atrioventrikulárnímu uzlu (AV), který je jediným vodivým spojením mezi síněmi a komorami. Jeho účelem je zpomalení impulsu, aby došlo k naplnění komor krví po předchozím stahu síní. Po AV elektrický impuls pokračuje přes Hissův svazek, Tawarova raménka a Purkyňova vlákna ke svalovině komor (obr. 1. 2), kde vyvolá depolarizaci myokardu. Ta se projeví kontrakcí komor [1][3][8].



obr. 1. 2 Elektrická aktivita srdce [9]

1.1.1 Depolarizace

Buňky srdečního svalu jsou v klidu polarizovány na hodnotu -90 mV, což je dáno různými koncentracemi iontů v extracelulárním (vně buňky) a intracelulárním (uvnitř buňky) prostoru (tab. 1. 1), činností sodíko - draslíkové pumpy a v neposlední řadě také rozdílnou propustností buněčné membrány pro různé ionty [10].

iont	extracelulární koncentrace (mmol / l)	intracelulární koncentrace (mmol / l)
Na ⁺	145	7
K ⁺	4	145
Ca ²⁺	3	8
Cl ⁻	120	5

tab. 1. 1 Rozložení iontů vně a uvnitř buněčné membrány [10]

V extracelulárním prostředí je vysoká koncentrace sodíku Na⁺ a také chlóru Cl⁻. Naopak v intracelulárním prostředí převládají s největší koncentrací ionty draslíku K⁺. Vlivem difúze může docházet k přesunu iontů dle jejich koncentračního gradientu, to však v klidovém stavu platí pouze pro ionty draslíku K⁺, neboť je membrána oddělující extracelulární a intracelulární prostředí propustná právě jenom pro ionty draslíku. Odliv kladných iontů draslíku K⁺ tak vyvolá v intracelulárním prostředí (uvnitř buňky) vznik záporného potenciálu. Výsledkem je vznik elektrického pole, které působí proti koncentračnímu gradientu a vede tak ke vzniku rovnováhy, kterou můžeme popsat pomocí rovnovážného napětí [3][8][10]. Jeho hodnota je závislá na koncentraci K⁺ a lze jí stanovit pomocí Nerstovy rovnice [10]

$$U_K = \frac{RT}{F} \ln \frac{[K^+]_e}{[K^+]_i}, \quad (1. 1)$$


kde R je plynová konstanta ($8,314 \text{ J mol}^{-1} \text{ K}^{-1}$), T absolutní teplota, F Faradayův náboj ($96\,485 \text{ C mol}^{-1}$) a v neposlední řadě je hodnota rovnovážného napětí závislá také na poměru koncentrace draslíku ve vnějším prostředí $[K^+]_e$ a ve vnitřním prostředí $[K^+]_i$ buňky.

V klidovém stavu proto buňky označujeme jako polarizované. Ke změně dojde při průchodu elektrického impulsu, který krátkodobě změní vodivost membrány pro ionty sodíku Na⁺. Ty začnou proudit do intracelulárního prostředí vlivem koncentračního gradientu, což se projeví rychlou změnou napětí do kladných hodnot mezi 15 až 30 mV a následnou kontrakcí srdeční svaloviny. Na záznamu EKG se depolarizace směřující k elektrodě pozná kladnou výchylkou, naopak depolarizace směřující od elektrody zápornou výchylkou na elektrokardiogramu [3][10].

1.1.2 Repolarizace

Po depolarizaci následuje repolarizace, při které dochází k obnově elektrické aktivity na původní hodnotu -90 mV. Pro tuto činnost je nejdůležitější činnost sodíko - draslíkové pumpy, která zajišťuje přesun iontů Na^+ vně do extracelulárního prostředí a naopak iontů K^+ dovnitř buňky, což trvá cca 100 ms. Během této fáze nejsou buňky schopné reagovat na další stimul (podnět) a označujeme to jako období refrakterity. Sodíko - draslíková pumpa přečerpává ionty proti koncentračnímu gradientu a její činnost tak vyžaduje energii, kterou získává hydrolýzou ATP (adenosintrifosfát) [3][8][10].

Děje repolarizace a depolarizace, na které mají největší vliv propustnost membrány pro ionty Na^+ a K^+ , se podílejí na vzniku akčního potenciálu. Právě změna propustnosti membrány pro ionty Na^+ vede ke vzniku proudu směřující do buňky, který vyvolá rychlou depolarizaci, která vede ke vzniku akčního potenciálu (obr. 1. 3, fáze 0). Po prudkém zvýšení vodivosti Na^+ dochází i k její inaktivaci a současně ke zvýšení vodivosti (aktivaci) K^+ (obr. 1. 3, fáze 1,2). Vlivem změn vodivosti a činností sodíko - draslíkové pumpy dochází k postupné repolarizaci (obr. 1. 3, fáze 3) a to až do fáze stabilního klidového potenciálu (obr. 1. 3, fáze 4) [3][8].



obr. 1. 3 Souvislost akčního potenciálu komorové buňky srdeční a záznamu EKG [9]

1.2 Rušení signálů EKG

Snímané signály EKG bývají znehodnoceny různými druhy rušení. Ať už se jedná o rušení z rozvodných sítí či rušení původu biologického, vznikající činností svalů či dýcháním. Jednou z možností, jak odstranit část rušení a zlepšit tak poměr signál – šum (tzv. SNR), je využívání invazivních elektrod tzv. jícnové svody. Jejich zavádění je však časově náročné a samotné měření je pro pacienta nekomfortní. Proto není pro běžné snímání EKG příliš

vhodné. Při snímání se nejčastěji setkáváme se třemi druhy rušení a to driftem, brumem a rušení myopotenciály [2][7].

1.2.1 Kolísání nulové izolácie (drift)

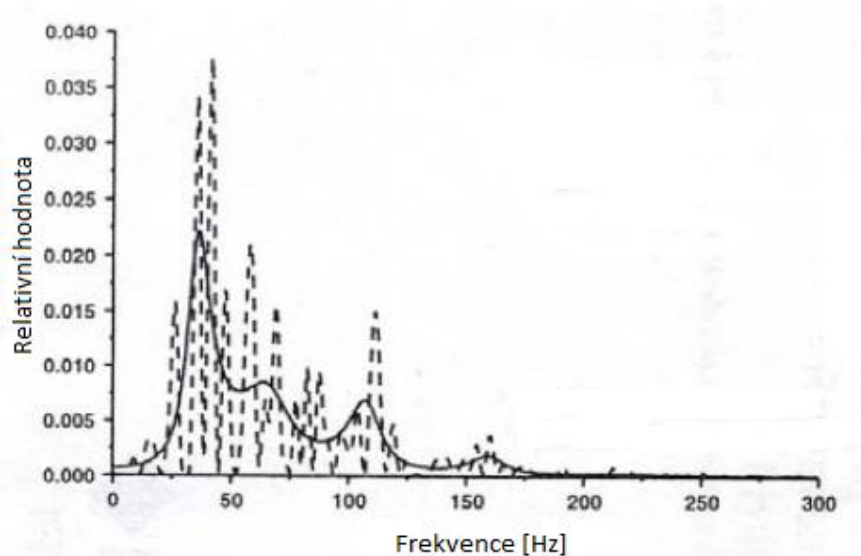
Tzv. drift je nejčastěji způsoben dýcháním, jehož vlivem dochází k pohybu elektrod vzhledem k srdci, dále pomalými elektrochemickými ději na rozhraní elektroda - pokožka a pohyby pacienta. Jedná se o nízkofrekvenční rušení zasahující do 2 Hz, které se projevuje kolísáním nulové izolácie. K odstranění driftu se nejčastěji používá filtrace horní propusti s velmi nízkou mezní frekvencí pro analogové filtry cca 0.05 Hz a to z důvodu nelinearity fázové charakteristiky, která způsobuje nežádoucí zkreslení signálu. Druhou možností je použití FIR filtru (filtr s konečnou impulsní charakteristikou) vycházející z DP (dolní propust) Lynnova typu. Možností je také metoda nulování spektrálních čar, avšak ta nezle provádět v reálném čase [2][7].

1.2.2 Síťový brum

Dalším druhem rušení je síťový brum od okolních přístrojů a elektrických rozvodů. Vlastnosti brumu vychází z parametrů rozvodných sítí. V České republice je tvořen 50 Hz složkou s danou přesností a jejími vyššími harmonickými kmitočty, ale například v USA se setkáváme s rušením 60 Hz. K ochraně před brumem se využívají speciální stíněné kabely pro elektrody, aby došlo k minimalizaci průniku elektromagnetického rušení do přívodních kabelů. Pro filtraci se používají úzkopásmové filtry typu IIR (filtr s nekonečnou impulsní charakteristikou). Tyto IIR filtry sice nemají kolem 50 Hz lineární fázovou charakteristiku, avšak v blízkosti frekvence 50 Hz se nenachází žádná významná složka EKG signálu. Hlavní výkon signálu EKG se nachází do 40 Hz (obr. 1. 1). FIR filtry jsou obecně pro úzkopásmové propusti nevhodné kvůli dlouhé impulsní charakteristice [2][7].

1.2.3 Rušení myopotenciály

Jedná se o širokopásmové rušení, které je způsobené činností svalů. Pro klidové EKG má spektrum nad 100 Hz a hlavní prevencí je uvolnění pacienta při snímání tak, aby nedocházelo ke stahům kosterní svaloviny. Nejčastěji se využívá snímání pacienta v leže. Problém nastává pro zátěžové EKG, kde toto rušení najdeme již od 10 až 20 Hz výše (obr. 1. 4). Potlačení myopotenciálů u zátěžového EKG je velký problém, protože dochází k výraznému překrytí užitečného signálu a spektra rušení. Výjimečně se používá filtrace DP (dolní propust) s mezní frekvencí 35 - 45 Hz. Zde ale dochází k výraznému zkreslení signálu, hlavně ořezání komplexů QRS a také k jejich rozšíření. I přesto se s touto variantou můžeme setkat u mnoha komerčních přístrojů. V dnešní době se k řešení používá hlavně vlnková filtrace nebo kumulační metody, které ale lze využít jen k získání reprezentativního cyklu, nikoli však pro snímání signálu v reálném čase [2][7][11][18].




obr. 1. 4 Periodogram (čárkovaně) a parametrický AR odhad spektra (plná čára) [12]

Na obrázku vidíme záznam povrchového EMG signálu nasnímaného nad pažním bicipsem. Hlavní část spektra leží od 20 Hz výše a výrazně se tak překrývá s užitečným signálem EKG viz. obr. 1. 1.

1.3 Tvar EKG křivky

V signálu EKG se nachází několik významných vln, kmitů a intervalů, které tvoří charakteristický tvar křivky EKG. Tyto vlny a kmity jsou odezvou elektrické aktivity především myokardiálních buněk. Samotné vedení vzruchů převodním systémem v záznamu EKG většinou není patrné, protože nevytváří dostatečně silnou voltáž. Pro analýzu a vyhodnocení je nejprve nutné stanovit začátek a konec P vlny, začátek a konec komplexu QRS a konec T vlny (obr. 1. 5) [1][8].



obr. 1. 5 Fyziologické hodnoty trvání jednotlivých úseků EKG signálu [3]

Vlna P

Velikost síňového myokardu (svalu) je ve srovnání menší než velikost srdečních komor, čemuž odpovídá i menší elektrická změna způsobená slabší kontrakcí. Proto je vlna P výrazně menší než kmit QRS [3][8].

Komplex QRS

Nejvýraznější částí EKG signálu je kmit QRS, který odpovídá kontrakci komor. Jeho spektrum zasahuje poměrně vysoko až do 125 Hz, ale hlavní část leží do 40 Hz. Výrazně se tak překrývá s rušením myopotenciálů [2][3].

Vlna T

Vlna T odráží návrat myokardu komor do klidového stavu (repolarizace) [3].

2. Vlnková transformace

Vlnková transformace je druhem lineární transformace signálů, kdy se jedná o časově-frekvenční rozklad. Hlavní rozdíl od běžně používané Fourierovy transformace je v tom, že Fourierova transformace vlivem svého nekonečného rozsahu Fourierova integrálu pracuje s globálně zprůměrovanými informacemi, což vede k dobré frekvenční analýze, ale znemožňuje analýzu přechodných dějů a místně specifických úseků ve spektru. Částečně lze tuto nevýhodu odstranit s využitím krátkodobé Fourierovy transformace (STFT), která využívá posuvné okno. Pro danou délku okna tak můžeme docílit určitého časového a frekvenčního rozlišení, které je konstantní. Při zvětšení velikosti okna dochází ke zlepšení frekvenčního rozlišení, ale ke zmenšení časového rozlišení. Avšak vlnková transformace vytváří časově-frekvenční rozklad signálu, který nám umožňuje dobré rozlišení i krátkodobých vysokofrekvenčních úseků ve spektru, což STFT dostatečně neumožňuje. Proto se vlnková transformace stala populárním nástrojem pro analýzu problematických signálů, zejména pro přechodové, aperiodické či jiné nestacionární signály [2][13].

2.1 Vlnková transformace spojitého signálu

V případě vlnkové transformace se spojitým časem jí můžeme definovat jako korelaci spojitého signálu $x(t)$ s bázovými funkcemi tzv. vlnkami. Tyto vlnky musí mít nulovou střední hodnotu a musí být nenulové jen na konečném časovém intervalu nebo se zanedbatelnými hodnotami mimo tento interval [2][13]. Matematicky můžeme vyjádřit spojitou vlnkovou transformaci [14]

$$y(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi * \left(\frac{t-b}{a} \right) dt, \quad (2.1)$$

kde výraz $x(t)$ je vstupní signál, symbol $*$ značí komplexně sdruženou funkci a výraz

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \cdot \psi * \left(\frac{t-b}{a} \right) \quad (2.2)$$

definuje bázovou funkci, nebo-li vlnku. Ta je popsána dvěma spojitými parametry a to časovým posunem b a dilatací a . Parametr a nám definuje šířku pásma příslušné vlnky, resp. její spektrum. S rostoucím parametrem dilatace a dochází k posunu spektra k nižším kmitočtům a k zúžení spektra a při rostoucím parametru a je tomu naopak. Dochází k rozšíření spektra a k posunutí k vyšším kmitočtům. Posun b potom určuje časovou polohu vlnky a umožňuje nám vlnkami pokrýt celý časový rozsah signálu $x(t)$. Pomocí parametrů a, b získáváme odvozené vlnky od obecně komplexní mateřské vlnky $\psi(t)$. Pro práci s výpočetní

technikou je však nutné si nadefinovat diskretní vlnkovou transformaci (DWT) a vlnkovou transformaci s diskretním časem (DTWT) [2][13].

2.2 Diskretní vlnková transformace DWT

Pro práci se signálem se spojitým časem má předešlá WT některé nevýhody, které lze částečně vyřešit využitím DWT. Je to zejména nadbytečnost dat, která je dána konvolučním integrálem a vede ke vzniku nekonečného množství koeficientů. Pro DWT se provádí diskretizace (vzorkování) parametrů vlnky a to časového posunu a dilatace. Nejčastěji se využívá varianta s dyadickým vzorkováním kmitočtového měřítka a časová osa je dělena rovnoměrně [2][13][22]. Výsledná transformace je potom definována vztahem [2]

$$y(m, k) = \int_{-\infty}^{\infty} x(t)\psi * (2^{-m}t - kT) dt, \quad (2.3)$$

kde m je kmitočtové měřítko a k je časové měřítko.

Lze ji realizovat rozkladem signálu bankou lineárních spojitých oktávních filtrů. Výsledkem je nerovnoměrně rozložená množina koeficientů $y(m, k)$, kde s každou další hodnotou m se spektrum zmenšuje na polovinu.

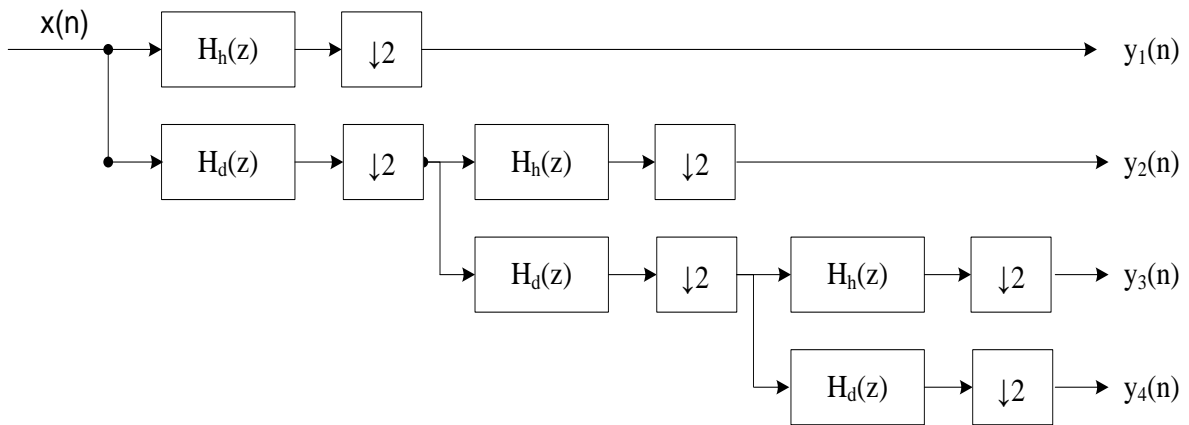
2.3 Vlnková transformace s diskretním časem DTWT

Nejpoužívanější varianta dyadická vlnková transformace s diskretním časem diskretního signálu $x(n)$ je definována diskretní konvolucí [2]

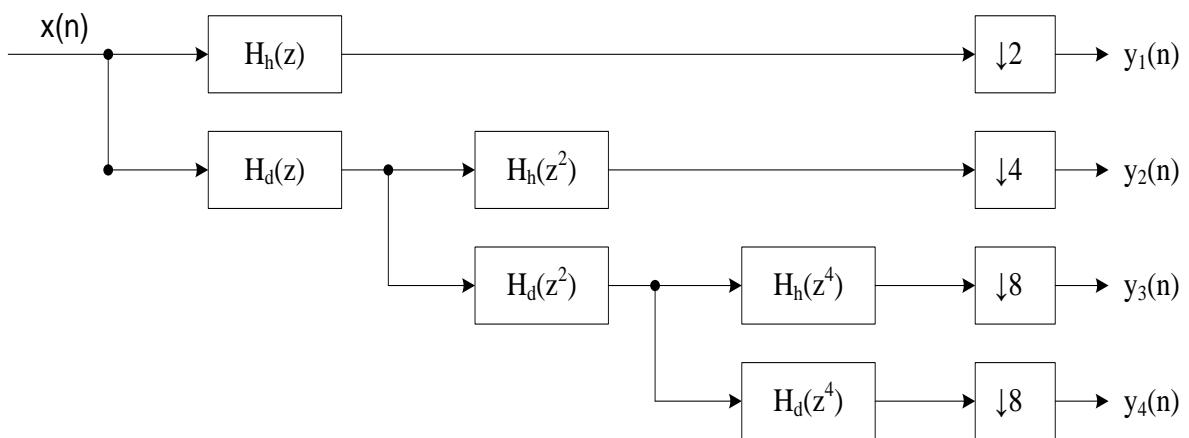
$$y_m(n) = \sum_{i=-\infty}^{\infty} x(i)h_m(2^m n - i) = \sum_{i=-\infty}^{\infty} h_m(i)x(2^m n - i), \quad (2.4)$$

kde m je kmitočtové měřítko.

Prakticky tak můžeme dyadickou vlnkovou transformaci s diskretním časem realizovat rozkladem signálu bankou diskretních oktávních filtrů s impulsními charakteristikami $h_m(n)$. Výstupní vzorky banky filtrů jsou potom přímo koeficienty dyadické DTWT a vzorkovací frekvence signálu $y_m(n)$ na výstupu m -tého filtru je potom 2^m -krát nižší než vzorkovací frekvence (f_{vz}) vstupního signálu $x(n)$. To je způsobeno podvzorkováním výstupů filtrů, které může probíhat dvěma způsoby. V případě rychlé dyadické DTWT dochází k podvzorkování výstupu každého filtru s faktorem $D = 2$ (obr. 2. 1) a v případě realizace stromové struktury (obr. 2. 2) jsou podvzorkovány až samotné finální výstupy z banky filtrů s příslušným decimálním faktorem, který je dán mocninou dvou [2][6].



obr. 2. 1 Realizace rychlé třístupňové dyadické DTWT [2]



obr. 2. 2 Realizace stromové dyadické DTWT s podvzorkováním výstupů [2]

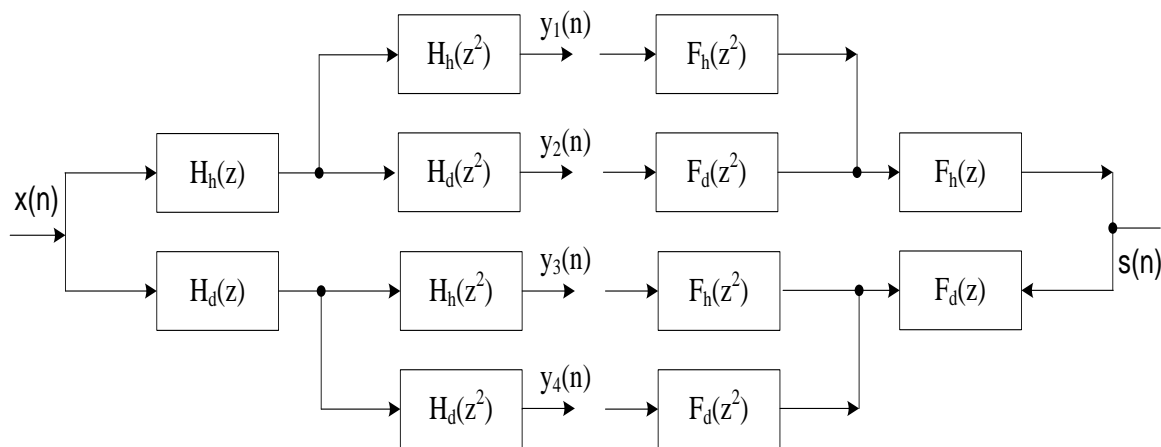
Z (obr. 2. 1 a obr. 2. 2) můžeme odvodit několik charakteristických vlastností běžné dyadické DTWT s podvzorkováním. Realizujeme rozklad pouze výstupů dolních propustí a vlivem podvzorkování dochází k nerovnoměrnému rozložení koeficientů $y(n)$ v časově - frekvenční rovině.

2.4 Redundantní paketová DTWT

Pro samotnou realizaci DTWT v programu matlab však využijeme její specifickou variantu jako redundantní paketovou DTWT. Redundantní varianta transformace nemá podvzorkované výstupy filtrů na rozdíl od častější varianty DTWT s podvzorkováním (decimací). Počet koeficientů tudíž narůstá úměrně s počtem pásem. Samotný počet koeficientů je v každém pásmu totožný a odpovídá počtu vzorkům vstupního signálu. Někdy se můžeme setkat s označením jako stacionární vlnková transformace (SWT). Výhodou této realizace je, že koeficienty redundantní DTWT nejsou závislé na posunutí vstupního signálu a tudíž na volbě počátku samotné filtrace. Proto je vhodná pro filtraci EKG signálů a setkáváme se s ní v mnoha pracích [11][15][16]. Další odlišností od předešlé DTWT s decimací je

přenosová hodnota filtrů, která je rovna 1. V neposlední řadě také při zpětné redundantní IDTWT (inverzní DTWT) nedochází k interpolaci, což vede k lepším výsledkům a menší citlivosti na výběr banky filtrů. Naopak nevýhodou realizace redundantní DTWT může být velký objem dat ke zpracování, který roste úměrně s počtem pásem, avšak pro jednorozměrné signály tento problém můžeme opomenout [2][6][16].

Varianta paketové DTWT je realizována rozkladem tzv. úplným stromem. To znamená, že dochází k rozkladu nejen výstupů z dolních propustí, ale i z horních propustí. Výsledkem je rozklad na stejně široká pásma. Není však nutné vždy striktně realizovat úplný strom, záleží na volbě uživatele. S touto variantou se v literatuře příliš nesetkáváme. Většinou se využívá pro práci v 2D prostoru, teda pro práci s obrazy [23]. Jedním z důvodů je zřejmě to, že hlavní charakter a podstata signálu je dána nižšími frekvencemi. Častější varianta, při které dochází k rozkladu pouze výstupů dolních propustí, se označuje jako dyadická DTWT. Schéma redundantní paketové DTWT s dvěma stupni rozkladu je uvedeno na (obr. 2. 3) [2][13].



obr. 2. 3 Přímá a zpětná redundantní paketová DTWT s dvěma stupni rozkladu [23]

Pro samotné využití redundantní paketové DTWT pro filtraci je nutné si nadefinovat i inverzní operaci, tedy redundantní paketovou IDTWT, abychom byli schopni získat výstupní signál. Při realizaci je nutné vyřešit dva základní problémy. Jedná se o vytvoření tzv. rekonstrukčních filtrů dle vztahu [2]

$$Y(z) = [F_d(z)H_d(z) + F_h(z)H_z(z)]X(z), \quad (2.5)$$


kde $F_d(z)$ a $F_h(z)$ jsou rekonstrukční filtry a $H_d(z)$ a $H_h(z)$ jsou rozkladové filtry. Druhým problémem je stanovení fázového zpoždění, které banky filtrů do procesu zavádějí [2][11]

$$F_d(z)H_d(z) + F_h(z)H_z(z) = z^{-\tau}. \quad (2.6)$$

Na pravé straně vztahu (2. 6), pro věrnou rekonstrukci vstupního signálu, vidíme rozdíl v koeficientu 1 od varianty pro DTWT s decimací. Z toho vyplývá přenos jak dolních, tak i horních propustí 1, jak již bylo uvedeno výše [2][6].

2.5 Využití DTWT pro filtraci signálů EKG

Využití vlnkové transformace s diskretním časem se neomezuje pouze pro samotnou filtraci signálů, ale i k detekci charakteristických kmitů a vln, jak je popsáno v [13]. V [17] se uvádí až 99.8 % úspěšnost při detekci vln a kmitů v EKG. Signál EKG je charakteristický změnou frekvenčního obsahu v čase, což nedokáže zachytit FT a dostatečně ani STFT. Zatímco vlnková transformace umožňuje pomocí výběru vlnek a jejich parametrů nastavit jak vlastní dobu jejich trvání, tak i umístění v čase a frekvenční pásmo. Hlavní rozdíl mezi využitím DTWT a STFT vidíme na obr. 2. 4 [13][17].



obr. 2. 4 Škálogram signálu EKG s využitím STFT(a), WT(b)[13]

Nedostatky tradiční STFT jsou zobrazeny na (obr. 2. 4 a), kde vidíme rozmazání mezi jednotlivými realizacemi STFT a s ní spojenou ztrátu lokálních informací v porovnání s WT (obr. 2. 4 b). Škálogram je obdobou spektrogramu, ale s obrácenou orientací osy a (dilatace)

resp. f (frekvence). V případě signálů EKG nám vlnková transformace umožňuje zachytit detaily s dobrým časově-frekvenčním rozlišením [13][17].

Samotná filtrace obecně spočívá ve vhodné úpravě koeficientů DTWT a vyžaduje ireverzibilitu transformace, která je dle vztahu (2. 5) splněna. Možnosti vlnkové transformace se využívají zejména pro nestacionární signály, mezi které můžeme zařadit i signál EKG. Výhodou filtrace pomocí DTWT nacházíme hlavně při vyhlazování signálů, kde se spektrum užitečného signálu výrazně překrývá se spektrem šumu. To je právě příklad rušení myopotenciály v EKG signálu, kde dochází k výraznému překrytí spekter, zejména pro zátěžové EKG [2][6].

Klasickou Fourierovou filtrací dochází ke stejné míře potlačení jak složky šumové, tak ale i užitečné frekvenční složky signálu. Samotný princip filtrace, využívající vlnkovou transformaci, je založen na rozkladu signálu do jednotlivých frekvenčních pásem a vzniklé koeficienty DTWT jsou v jednotlivých pásmech vhodně upravovány, nejčastěji tzv. prahováním. Následně je využito zpětné transformace pomocí IDTWT. Ačkoliv jak DTWT, tak i IDTWT jsou lineární, tak samotné prahování je operace nelineární. Proto se proces celé filtrace označuje jako nelineární [2][6].

Pro návrh konkrétního filtru je nutné zvolit vhodný typ DTWT. V práci se zaměříme na redundantní paketovou DTWT a na výběr vhodného druhu prahování, které obecně vychází z předpokladů, že šum je rovnoměrně rozložený mezi všemi koeficienty v celém pásmu. Druhým důležitým předpokladem je, že velikost šumu není příliš vysoká a můžeme tak rozpoznat koeficienty užitečného signálu od šumových, které jsou menší [21]. Dalším problémem je vhodné nastavení samotného prahu. Pro malé hodnoty prahu mohou v signálu zůstat zbytky šumu, naopak při velké hodnotě prahu dochází k nárůstu nulovaných koeficientů. To se projeví hladkostí či plynulostí signálu. U obrazových dat to může vést až k rozmazání [21].

Nejčastěji se setkáme s prahováním tvrdým, měkkým nebo hybridním (v anglické literatuře se setkáváme s označením *garotte*). Každé má určité klady a zápory. Nejjednodušším druhem prahování je nulování všech koeficientů daného pásma. To je vhodné použít pouze v případě, kdy se v daném pásmu nenachází výrazné úseky užitečného signálu. To lze s rezervou použít třeba pro nejvyšší pásmo EKG signálu, neboť se v něm většinou nenachází výrazné úseky užitečného signálu [2][6][11].

Při prahování je nutné nejprve stanovit práh T_m , nejčastěji pro každé pásmo zvlášť a v daném pásmu se následně prahují všechny koeficienty $y_m(n)$, kde m označuje m -té pásmo. Práh označujeme jako λ_m , výstupní hodnoty jako $\hat{y}_m(n)$.

2.5.1 Tvrdé prahování

Jedná se o velmi jednoduchý způsob prahování, kdy je každá hodnota koeficientu $y_m(n)$ porovnávána s příslušným prahem. Jestli je daná hodnota koeficientu menší než práh,

nahradí se nulou, jinak zůstává hodnota původní. Tento práh je definován na základě vztahu [2][11]

$$\lambda_{y_m} = \begin{cases} y_m(n) & \text{pro } |y_m(n)| > T_m \\ 0 & \text{pro } |y_m(n)| \leq T_m \end{cases} \quad (2.7)$$

Výhodou tvrdého prahování je, že nedochází v případě signálů EKG ke zkreslení vysokých kmitů QRS a dosahuje se i velmi vysokého poměru signál-šum tzv. SNR. Nevýhodou je, že jakákoliv šumová hodnota jen o trochu větší než práh se přeneseme beze změny. To vede ke vzniku náhodných šumových impulsů ve filtrovaném výstupním signálu, které se často označují jako "blips". Tvrdé prahování proto také s mnoha algoritmy sloužící k filtraci nefunguje [6][11][21].

2.5.2 Měkké prahování

Měkké prahování se pro podprahové hodnoty chová stejně jako tvrdé prahování, tudíž tyto koeficienty se také nulují. Nadprahové hodnoty koeficientů se potom posouvají směrem k nule o prahovou hodnotu λ_m [2][11].


$$\lambda_{y_m} = \begin{cases} \text{sign}(y_m(n))(|y_m(n)| - T_m) & \text{pro } |y_m(n)| > T_m \\ 0 & \text{pro } |y_m(n)| \leq T_m \end{cases} \quad (2.8)$$

Výhodou měkkého prahování je, že dosáhneme lepšího vyhlazení signálu bez výrazných rušivých impulsů, což je způsobeno útlumem i šumových složek, které jsou větší než práh. Nevýhodou je, že dochází i k útlumu užitečných složek signálu, což se projeví v případě signálů EKG hlavně oříznutím QRS komplexů. Využití měkkého prahování můžeme najít např. v práci [19][22]. Vhodným řešením je spojení obou druhů prahování, tzv. hybridní prahování [2][11].

2.5.3 Hybridní prahování

Jedná se o kombinaci obou předešlých metod prahování, které se pro malé hodnoty nad prahem chová jako měkké prahování a naopak pro výrazně větší hodnoty jako tvrdé prahování (obr. 2. 5). Setkáváme se s ním ve většině prací např. [11][15][16]. Výsledná realizace je dána vztahem [15]

$$\lambda_{y_m}(n) = \begin{cases} y_m(n) - \lambda_m^2/y_m(n) & \text{pro } |y_m(n)| > \lambda_m \\ 0 & \text{pro } |y_m(n)| \leq \lambda_m \end{cases} \quad (2.9)$$



obr. 2. 5 Hybridní prahování pro $\lambda_m = 2$ [6]

2.5.4 Nastavení prahu

Pro správnou činnost metody prahování je nutné správně stanovit hodnotu samotného prahu. To je možné buď pouhým odhadem, nebo intuitivně z úrovně šumu. V druhém případě se nejčastěji provádí odhad směrodatné odchylky šumu (σ_w), ideálně pro každé pásmo zvlášť [2][6][19]. Samotný práh T potom můžeme stanovit dle vztahu pro empirický práh [6]

$$T = k\sigma_w, \quad (2.10)$$

kde k je zvolená empirická hodnota nebo ze vztahu (2. 11) pro univerzální práh [6]

$$T = \sigma_w \sqrt{2 \ln(N)}, \quad (2.11)$$

kde N je počet vzorků signálu.

Hodnota univerzálního prahu někdy může být příliš vysoká. Proto se často setkáváme s modifikací, kdy se stanovuje práh zvlášť pro každé pásmo, neboť původně je tento práh globální (stejný pro všechny pásma). Samotná velikost prahu se nastavuje v závislosti na velikosti šumu, přesněji na velikosti směrodatné odchylky šumu [2][11].

Výpočet pro univerzální práh (2. 11) je odvozen pro bílý šum s gaussovým rozložením. Jeho velikost je ovlivněna délkou signálu, ačkoliv jen minimálně vzhledem k vlivu přirozeného logaritmu. Velikost prahu s délkou signálu pomalu roste a původně byl

odvozen pro variantu dyadické DTWT s decimací. Univerzální práh věnuje větší pozornost vyhlazení signálu tzv. hladkost, zatímco většina ostatních prahů se zaměřuje na minimalizaci střední kvadratické chyby [19][21][22].

Kromě již zmíněných metod pro výpočet prahu se můžeme setkat i s jinými metodami jako je např. BayesShrink, který byl odvozen ze statistického modelu pro rozložení koeficientů DTWT v jednotlivých pásmech. Přehled dalších metod prahů a jejich odvození je podrobně zpracováno v [21].

2.5.5 Odhad směrodatné odchylky

Jedna z používaných možností odhadu směrodatné odchylky se realizuje dle vztahu

$$\sigma_w = \frac{\text{median}|x_1(n)|}{0,6745}, \quad (2.12)$$

kde $x_1(n)$ jsou koeficienty v příslušném pásmu. Označuje se jako robustní odhad a dosahuje zpravidla dobrých výsledků. Je používán ve velké části prací zabývajících se filtrací signálů EKG [2][15][16][22].

3. Návrh wienerovského filtru

Využití wienerovské filtrace je vhodné pro potlačení šumu $w(n)$, jehož spektrum se výrazně překrývá se spektrem užitečného signálu $s(n)$. Předpokladem využití tohoto filtru je, že obě složky, jak užitečný signál, tak šum, jsou aditivní směsí nekorelovaných složek. Wienerovskou filtraci lze realizovat ve frekvenční oblasti, kde hledáme optimální korekční faktor $H_{opt}(\omega)$, který vede ke korekci spektra vstupu $X(\omega)$ tak, aby výstupní spektrum signálu $Y(\omega)$ bylo co nejlepší aproximací spektra užitečného signálu $S(\omega)$. Obecně se teda snažíme minimalizovat střední kvadratickou odchylku výstupu $y(n)$ od užitečného signálu $s(n)$.

Druhou možností je analogie k předchozí realizaci, kde se hledají vhodné korekční faktory pro koeficienty DTWT. Těmi potom jednoduše vynásobíme jednotlivé koeficienty DTWT, avšak je nutné stanovit korekční členy zvlášť pro každé pásmo m [2][15][16]. Samotné korekční členy stanovíme dle vztahu [15]

$$g_m(n) = \frac{u_m^2(n)}{u_m^2(n) + \sigma_{v_m}^2}, \quad (3.1)$$

kde $u_m(n)$ jsou koeficienty užitečného signálu v m -tém pásmu a $\sigma_{v_m}^2$ je odhad rozptylu šumu v m -tém pásmu. Pro využití korekčních členů pro DTWT platí analogie s předchozí variantou, tedy snaha minimalizovat střední kvadratickou odchylku tak, aby upravené koeficienty DTWT ${}^\lambda y_m(n)$ byly optimální aproximací koeficientů užitečného signálu $u_m(n)$ [15].

$$e_m^2(n) = ({}^\lambda y_m(n) - u_m(n))^2 \rightarrow \min, \quad (3.2)$$

kde ${}^\lambda y_m(n)$ je koeficienty DTWT výstupního filtrovaného signálu a $u_m(n)$ jsou koeficienty užitečného signálu pro m -té pásmo.

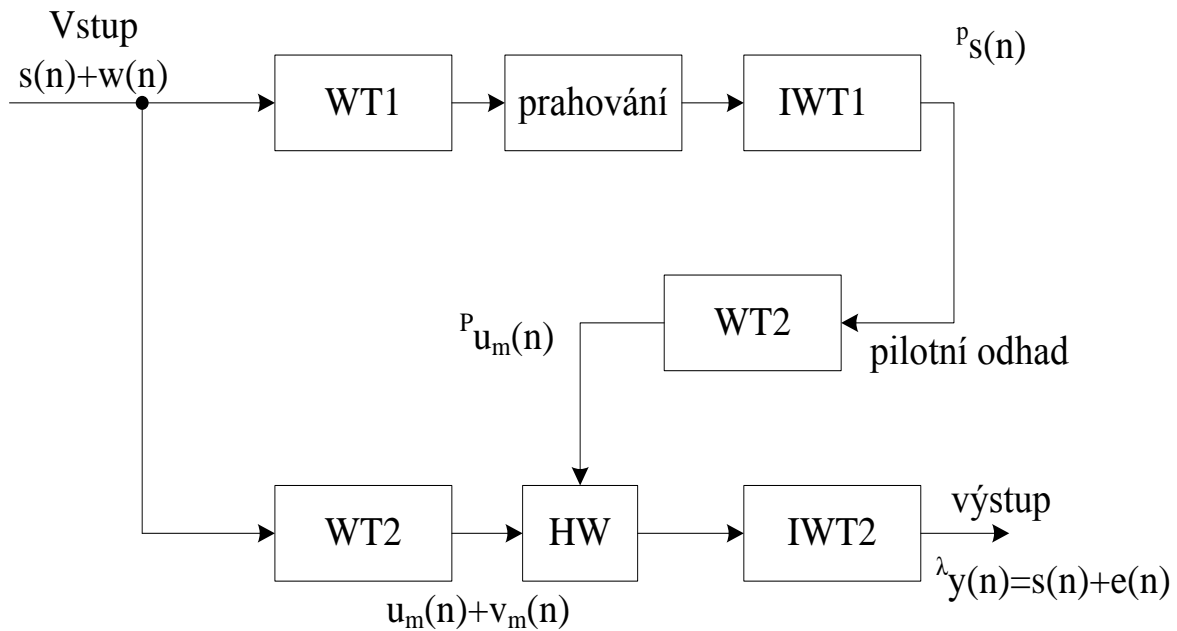
Samotná aplikace korekčních členů je jen jednoduchá matematická operace popsaná vztahem [2][15]

$${}^\lambda y_m(n) = y_m(n) \cdot g_m(n), \quad (3.3)$$

kde $y_m(n)$ jsou koeficienty DTWT vstupního signálu pro m -té pásmo a $g_m(n)$ jsou korekční členy pro m -té pásmo. Druhem wienerovské filtrace využívající korekční členy pro koeficienty DTWT je metoda pilotního odhadu užitečného signálu [2][15].

3.1 Metoda pilotního odhadu

Při metodě pilotního odhadu vycházíme ze schématu na obr. 3. 1. Pomocí bloku WT1 realizujeme vlnkovou transformaci a následně provádíme filtraci metodou prahování koeficientů v jednotlivých pásmech, kromě pásma nejnižšího. Následně pomocí IWT1 (inverzní vlnková transformace) získáme tzv. pilotní odhad užitečného signálu $^p s(n)$, který je potřeba ke stanovení korekčních členů [2][16].



obr. 3. 1 Schéma wienerovského filtru s pilotním odhadem užitečného signálu[2]


Originální signál je podroben v druhé větvi vlnkové transformaci WT2 a v každém pásmu stanovíme hodnotu rozptylu, která je následně využita v bloku HW, představující samotný výpočet a aplikaci korekčních členů dle vztahu 3. 1 výše. Ve vztahu 3. 1 ještě vystupují koeficienty užitečného signálu $u_m(n)$, které však neznáme. Místo nich použijeme koeficienty pilotního odhadu užitečného signálu $^p u_m(n)$, které získáme pomocí WT2 (vlnkové transformace) pilotního odhadu signálu $^p s(n)$. Korekční členy pro každé pásmo se aplikují na koeficienty DTWT, které jsme získali vlnkovou transformací WT2 originálního signálu. Následně blokem IWT2 (inverzní vlnková transformace) získáme výsledný filtrovaný signál $^{\lambda} y(n)$. Tento signál je tvořen dvěma složkami, kde složka $s(n)$ je námi požadovaný originální signál bez šumu a druhou složkou je chybový signál $e(n)$, který se pomocí správného nastavení korekčních členů snažíme minimalizovat. Výše uvedené schéma je obecné a v následujících kapitolách jsou jednotlivé bloky přesněji popsány a vysvětleny [2][15][16].

3. 2 Realizace bloků WT1 a WT2

Pro realizaci vlnkové transformace v obou blocích WT1 a WT2 je využito varianty redundantní paketové DTWT, která je popsána v kapitole 2. Jediným rozdílem mezi bloky WT1 a WT2 je možnost nastavení různých parametrů zvláště pro každý blok a to parametrů stupeň rozkladu a typ vlnky. Při volbě vlnky můžeme vycházet z vlnek jak z řad ortogonálních, tak biortogonálních. Pro volbu stupně rozkladu se nejčastěji setkáváme s hodnotami 3 a 4 [15][16]. Vyšší stupeň rozkladu se moc nepoužívá a vede k výraznému nárůstu výpočetních nároků, zejména pro realizovanou variantu redundantní paketové DTWT. Zde každý další stupeň rozkladu generuje dvojnásobek dat ke zpracování. Prvním z faktorů, ovlivňující zvolený stupeň rozkladu, je vzorkovací frekvence signálu. Ta nám pro zadaný stupeň rozkladu stanovuje frekvenční šířku jednotlivých pásem. Druhým faktorem je charakter šumu, který chceme odstranit. Nejnižší pásmo neprahujeme a ani na něj neuplatňujeme korekční členy, protože dle předpokladů by se v tomto pásmu měl nacházet pouze užitečný signál. V případě zvolení malého stupně rozkladu, kdy se šum myopotenciálů objeví i v nejnižším pásmu, již toto rušení nelze pomocí wienerovského filtru odstranit. K realizaci redundantní paketové DTWT je využito metody postupné filtrace pro jednotlivé stupně rozkladu a příslušné impulsní charakteristiky filtrů jsou odvozeny metodou ředění impulsní charakteristiky. Realizace je provedena v programu Matlabu pomocí funkce *rpDWT*.

3.2.1 Odvození filtrů

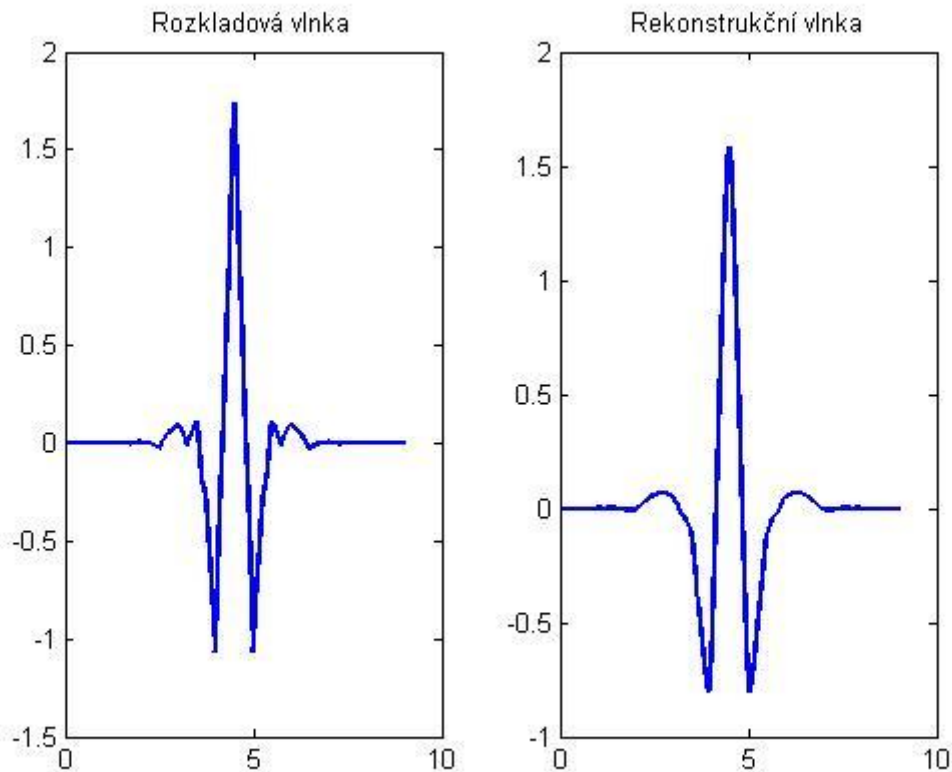
Pro odvození filtrů pro jednotlivé stupně rozkladu je využito metody ředění impulsní charakteristiky, která spočívá ve vložení $k - 1$ nulových vzorků mezi jednotlivé vzorky impulsní charakteristiky výchozího filtru. Jedná se v podstatě o substituci v přenosové funkci $H(z)$, kde $z \rightarrow z^k$ (obr. 3. 2). Výchozí dva rekonstrukční a rozkladové filtry získáme pomocí příkazu v Matlabu (*wfilters*), avšak je nutné upravit jejich hodnoty. Jsou odvozeny pro variantu dyadické DTWT s decimací, kde je jiný přenos než pro redundantní DTWT [2][6].



obr. 3. 2 Filtry odvozené z výchozích dolních a horních propustí [6]

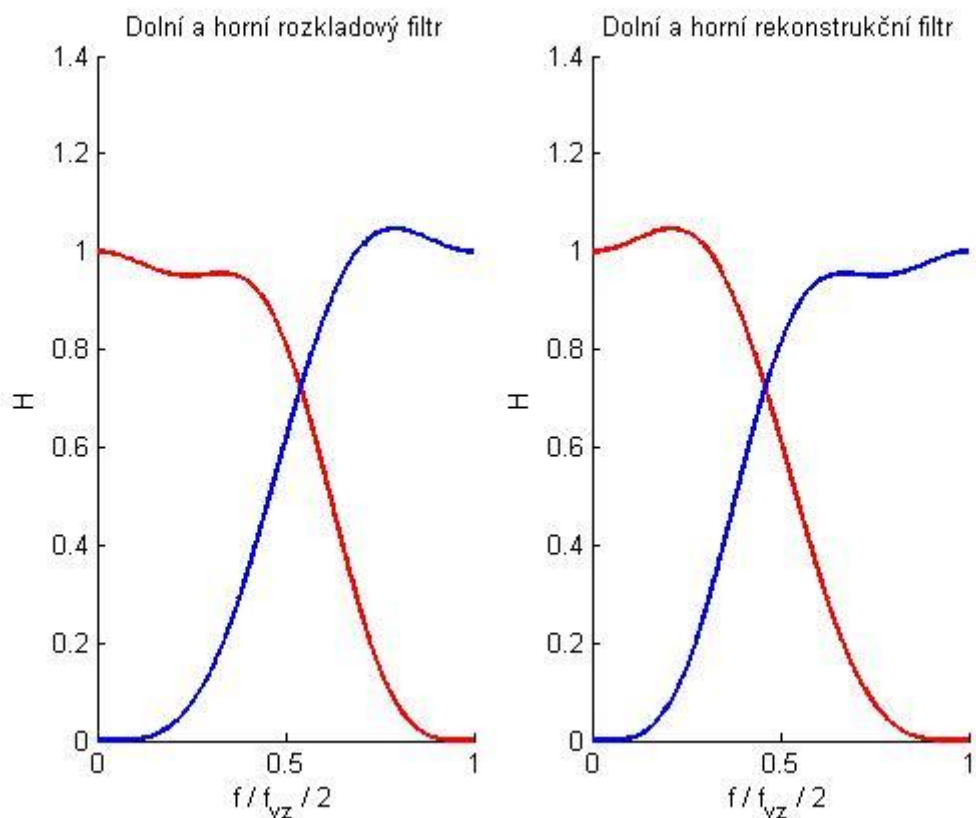
3.2.2 Ukázka použitých filtrů

Nejlepších výsledků při testování navrženého filtru bylo docíleno pro kombinaci vlnek 'bior4.4' a 'sym4'. Ukázku rozkladové a rekonstrukční vlnky 'bior4.4' vidíme na obr. 3. 3.

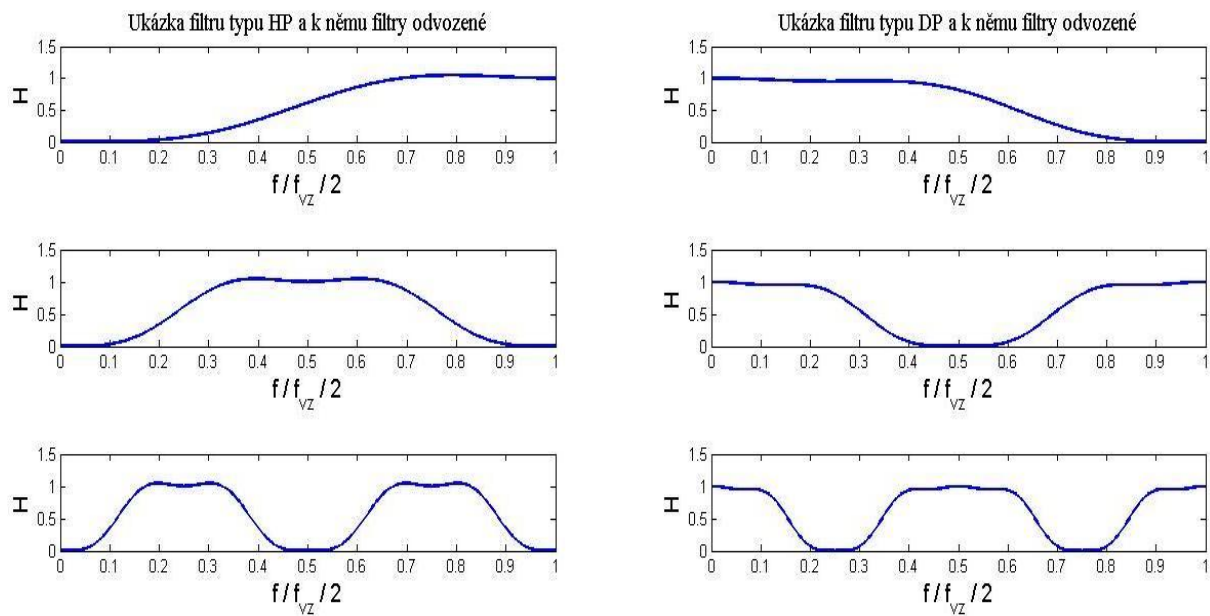


obr. 3. 3 Rozkladová a rekonstrukční vlnka bior4.4

Jak rozkladové, tak rekonstrukční vlnce 'bior4.4' přísluší vždy dva druhy filtrů a to typu horní a dolní propust. Ty mají ideálně přenos 1 v propustné části a nulový přenos v části nepropustné. Avšak pro samotnou realizaci pracujeme s reálnými filtry, jejichž frekvenční charakteristiky pro vlnku 'bior4.4' jsou uvedeny na obr. 3. 4. Na obr. 3. 2 vidíme ukázkou ideálních filtrů a k nim filtrů odvozených metodou ředění impulsní charakteristiky. Pro srovnání je můžeme porovnat s reálnými filtry a filtry odvozenými vycházející z vlnky 'bior4.4' použité při filtrování (obr. 3. 5).



obr. 3. 4 Rozkladové a rekonstrukční filtry pro vlnku bior4.4



obr. 3. 5 Reálné filtry odvozené z dolních a horních propustí

3.3 Realizace bloků IWT1 a IWT2

Pro správnou činnost wienerovské filtru je nutné správně rekonstruovat signál z koeficientů v jednotlivých pásmech. K tomu slouží inverzní redundantní paketová DTWT (IDTWT). Zde využíváme stejného principu pro odvození jednotlivých filtrů, jak je popsáno v předešlé kapitole 3.2.1. Nyní však pracujeme s filtry rekonstrukčními a to typu horní a dolní propust. V rámci práce je realizována i možnost porovnání navrženého wienerovského filtru využívajícího redundantní paketovou DTWT s variantou redundantní dyadické DTWT. Pro možnost co nejobektivnějšího porovnání obou metod je nezbytné, aby se obě metody skutečně lišily pouze ve způsobu rozkladu (paketová DTWT – rozklad výstupů horních i dolních propustí; dyadická DTWT – rozklad jen výstupů dolních propustí). Tudíž samotný princip filtru, včetně prahování, výpočtu a aplikací korekčních členů musí být pro obě varianty totožný. Toho bylo docíleno strukturou navržených funkcí *rpDWT* (redundantní paketová DTWT) a *rpIDWT* (inverzní redundantní paketová DTWT), které mají totožný formát (mají stejné vstupy a výstupy) jako defaultní funkce v Matlabu pro variantu redundantní dyadické DTWT (funkce *swt* a *iswt*). Pro porovnání wienerovského filtru využívající varianty paketové DTWT s variantou využívající dyadickou DTWT lze tak využít pouze jednoduché záměny těchto funkcí (*swt* → *rpDWT* a *iswt* → *rpIDWT*). Vstupní a výstupní parametry funkcí zůstanou totožné, stejně jako celý princip wienerovského filtru. Tím je umožněno porovnání obou variant (paketové x dyadické) pro stejné nastavení parametrů transformace a i pro stejné nastavení a princip samotného wienerovského filtru. V případě defaultní funkce *iswt* (realizující dyadickou IDTWT) se však nezadáva stupeň rozkladu a proto pro moji navrženou funkci *rpIDWT* musel být tento parametr odvozen.

3.3.1 Odvození parametru stupeň rozkladu

K odvození vztahu pro stanovení stupně rozkladu vycházíme ze znalosti struktury paketové DTWT, kde v každém pásmu vzniká dvojnásobek pásem, což lze popsat vztahem $m = 2^s$, kde s je stupeň rozkladu. Následně pomocí matematické aritmetiky a vzorců pro práci s logaritmy můžeme odvodit vztah pro stupeň rozkladu

$$\begin{aligned}m &= 2^s \quad \therefore \ln \\ \ln(m) &= \ln(2^s) \\ \ln(m) &= s \cdot \ln(2) \\ s &= \ln(m)/\ln(2) \\ s &= \log_2(m)\end{aligned}$$

Výsledný vztah (3. 4) slouží ke stanovení stupně rozkladu s , kde je potřeba znát pouze počet pásem rozkladu m

$$s = \log_2(m). \tag{3.4}$$

S využitím tohoto vztahu má navržená funkce $rpIDWT$ stejné vstupní parametry jako $iswt$ a lze je pro potřeby testování snadno zaměnit.

3.3.2 Fázové zpoždění filtrů

Při realizaci rozkladu pomocí funkcí $rpDWT$ a $rpIDWT$ dochází ke zpoždění. Výhodou paketové varianty DTWT je, že dochází k rozkladu vždy všech výstupů (předchozího stupně rozkladu). Současně vlivem stejné délky impulsních charakteristik rozkladových, resp. rekonstrukčních filtrů, získáme stejné zpoždění ve všech pásmech. To nám umožňuje nejdříve rekonstruovat výsledný signál a teprve poté ho posunout o dané zpoždění. Pro výpočet zpoždění vycházíme ze znalosti, že zpoždění je dáno polovinou délky impulsní charakteristiky.

Vlivem zpoždění je nutné signál posunout o dané zpoždění, což vede k oříznutí signálu. V literatuře najdeme různé metody, jak tuto problematiku lze vyřešit bez nutnosti signál oříznout. Avšak zkrácení signálu je minimální většinou do 1% celkové délky, proto bylo použito tohoto jednoduchého řešení.

3.4 Realizace bloku HW a prahování

Blok HW je základem wienerovského filtru a dochází v něm k výpočtu korekčních členů (3. 1) a jejich aplikaci na koeficienty DTWT vstupního signálu (3. 3). Korekční členy počítáme pro všechny koeficienty v každém pásmu kromě pásma nejspodnějšího, kde se nachází pouze užitečný signál.

Prahování slouží k filtraci vstupního signálu a získání odhadu užitečného signálu tzv. pilotního odhadu. Ten dále slouží k odhadu koeficientů DTWT užitečného signálu $^p u_m(n)$, které vystupují ve vztahu (3. 1) pro výpočet korekčních členů. Pro správnou činnost filtrace metodou prahování je nutné správně stanovit hodnotu směrodatné odchylky šumu a následně samotnou hodnotu prahu včetně výběru typu prahování. Z různých prací [11][15][16], ale i z praktického testování se ukázala jako nejlepší volba prahování hybridní, ale je možné využít i prahování tvrdé nebo měkké, které je použito například v práci [19].

3.4.1 Odhad směrodatné odchylky šumu

Pro odhad směrodatné odchylky vycházíme ze vztahu pro robustní odhad (2. 12). Ten je využíván ve většině prací [15][16]. Ovšem uplatnění tohoto vztahu na celý úsek signálu resp. na dané pásmo koeficientů DTWT není vhodné kvůli vlivu komplexů QRS. Proto bylo využito jednoduché modifikace vycházející z práce [16], kde je použito posuvného okna k odhadu směrodatné odchylky. Tím získáme časovou závislost směrodatné odchylky. Ta je následně použita s empirickou konstantou k výpočtu prahu. Je však nutné zaručit, že se v okně vždy nachází pouze jeden komplex QRS, což vzhledem k variabilitě tepové frekvence resp. RR intervalů vede k nutnosti velikost okna měnit. Ovšem pro samotnou realizaci této metody je potřeba mít k dispozici detektor R vln, který k dispozici ale nemáme. Proto je použito

jednodušší varianty s pevnou délkou okna, která je zvolena vzhledem k průměrnému srdečnímu rytmu 60 tepů za minutu.

V našem případě pro vzorkovací frekvenci $f = 500$ Hz je délka okna 500 vzorků, což nám v ideálním případě zajistí, že se v okně vždy nachází pouze jeden QRS komplex. Dalším parametrem je posun okna. Pro hodnotu 1 (plynulý posun okna) dochází k neúměrnému nárůstu výpočetní náročnosti a zvyšuje se pravděpodobnost, že by se v okně mohly vyskytnout i dva QRS komplexy. Během testování se ukázala vhodná hodnota posunu okna 100 vzorků. Výsledná směrodatná odchylka je určena pomocí vztahu (2. 12), kde se za hodnoty x_l dosadí vektor obsahující mediány z jednotlivých oken. Výpočet probíhá zvlášť pro každé m -té pásmo.

3.4.2 Výpočet prahu

V kapitole 2.4 je uveden přehled různých způsobů výpočtu prahu, avšak většina je navržena pro dyadickou DTWT s decimací a vychází z bílého gaussovského šumu, což v případě aplikace pro redundantní paketovou DTWT, sloužící k odstranění šumu myopotenciálů, není vhodné. Proto je dána přednost empirickému prahu [16]

$$\lambda_m = TM \cdot \sigma_{vm}, \quad (3.5)$$

kde TM je empirická konstanta a σ_{vm} je směrodatná odchylka šumu v m -tém pásmu. Hodnota konstanty se nastavuje na základě testovacích dat, avšak pro velkou výpočetní náročnost je k jejímu výpočtu využito optimalizace pomocí genetického algoritmu. Problematika a samotné řešení je podrobně popsáno v následující kapitole 4.

4. Genetický algoritmus

Základní pojmy související s genetickými algoritmy a jejich principy jsou podrobně popsány v kapitole 9 Dodatek: Genetické algoritmy. Tato kapitola je zaměřena už na praktické využití GA a to nalezení vhodných parametrů wienerovského filtru. Samotné spojení genetického algoritmu a vlnkové transformace pro filtraci signálů EKG je využito v práci [24]. Pro získání maximální výtěžnosti vlnkové transformace pro filtraci je vždy nutné nalezení optimálních parametrů. Jedná se zejména o parametry: výběr vlnky, stupeň rozkladu, typ prahování a samotná hodnota prahu [24]. Při nastavení parametrů navrženého filtru se vychází z aktuálního článku [16], odkud jsou převzaty doporučené typy vlnek, stupně rozkladu a typ prahování. Avšak pro nastavení samotné hodnoty prahu je nutné vycházet z principu navržené metody. Nelze převzít hodnoty z jiných prací, protože je použito jiného druhu transformace (redundantní paketová DTWT) a i jiný způsob odhadu směrodatné odchylky.

GA mají velký potenciál pro hledání vhodného řešení, zejména pro funkce více proměnných a rozsáhlé definiční obory. Cílem této kapitoly je zjistit, do jaké míry je možné GA využít pro nalezení vhodných parametrů wienerovského filtru. Kapitola 4.1 je zaměřena na vhodné nalezení empirické konstanty. Ovšem tento problém je možné řešit i metodou úplného vyhledávání (brutal force) vzhledem k jednorozměrné funkci a poměrně malému definičnímu oboru hodnot. Z toho důvodu je kapitola 4.2 zaměřena na využití GA pro hledání nejen vhodné empirické konstanty, ale současně i stupně rozkladu, který patří mezi jedny ze základních parametrů ovlivňující účinnost navrženého wienerovského filtru. Jedná se tak o funkci dvou proměnných, kde již metodu brutal force, vzhledem k velké výpočetní náročnosti, nelze použít.

4.1 Realizace GA pro optimalizaci empirické konstanty

Pro správnou činnost wienerovského filtru je nutné při odhadu užitečného signálu správně stanovit hodnotu prahu. Ve většině článků se setkáváme s variantou tzv. empirického prahu, jejíž hodnota je dána směrodatnou odchylkou šumu a empirické konstanty [16]

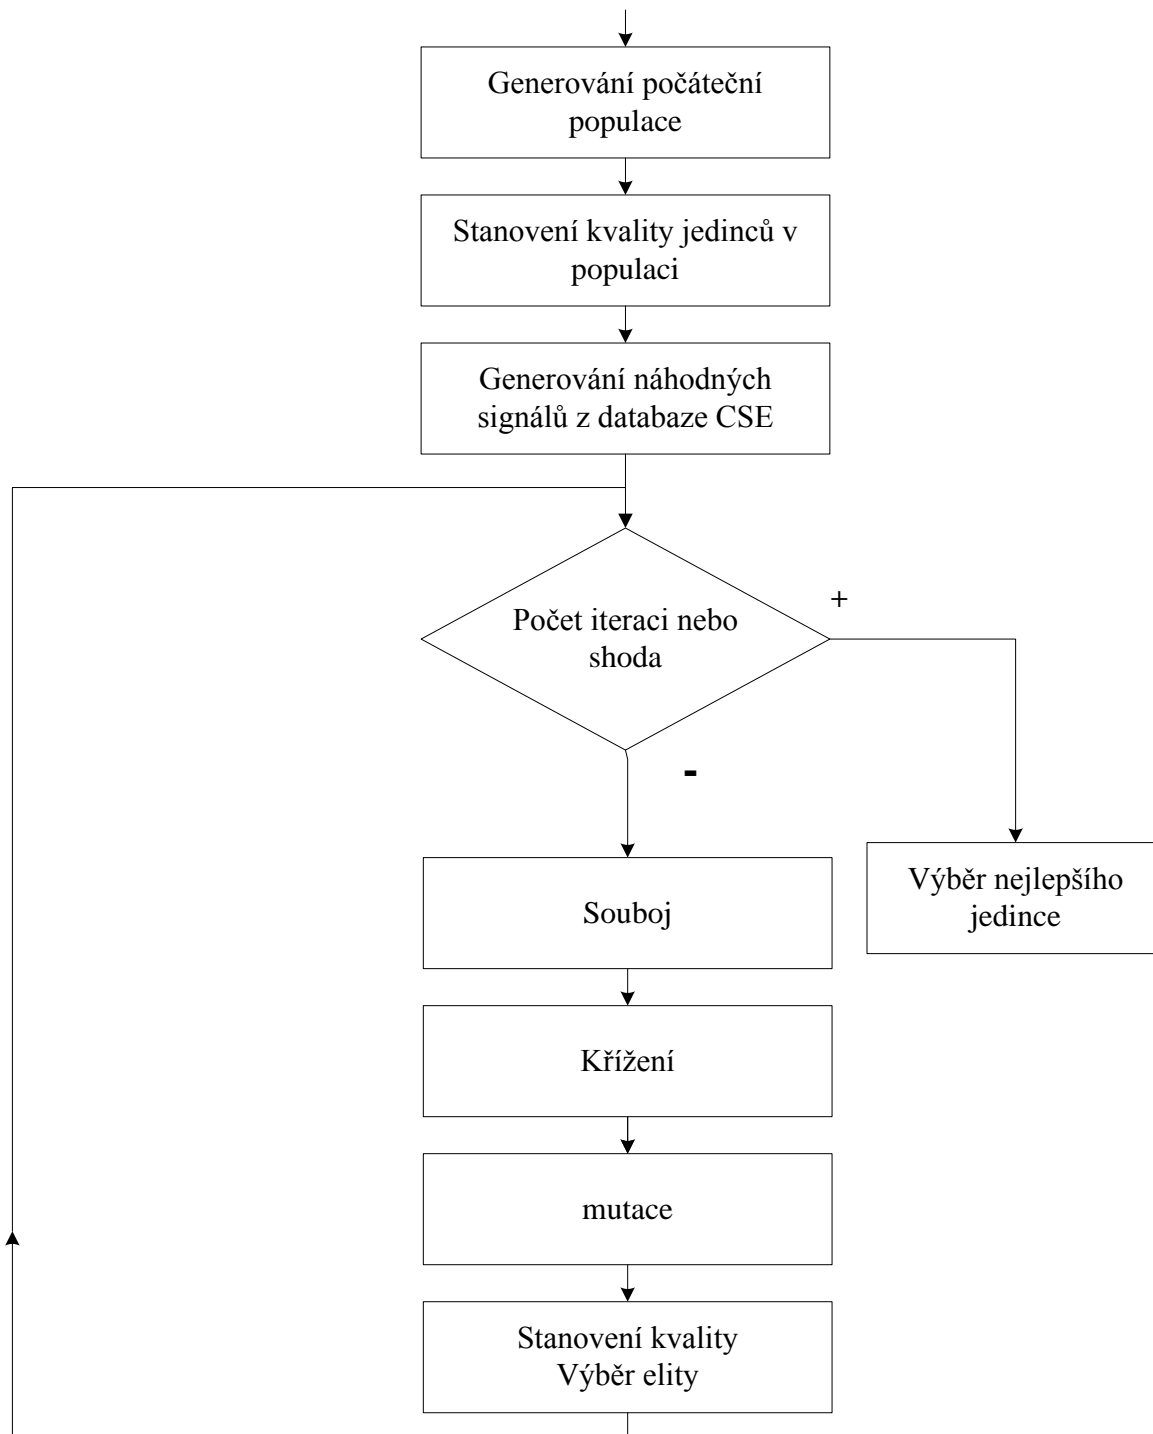
$$\delta_m = TM \cdot \sigma_m, \quad (4.1)$$

kde σ_m je směrodatná odchylka šumu a TM je empirická konstanta.

Samotné stanovení hodnoty empirické konstanty je závislé na použitém druhu transformace, způsobu výpočtu směrodatné odchylky šumu a v neposlední řadě také na testovací množině. Avšak nalezení empirické konstanty, prohledáváním celého prostoru (vhodného rozmezí pro empirickou konstantu), metodou úplného prohledávání tzv. brutal force není vhodný pro redundantní paketovou DTWT. Hlavním důvodem je velké množství

dat, které získáme touto transformací a s ní spojená vysoká výpočetní náročnost. Při redundantní paketové DTWT rozkládáme všechny výstupy (realizace úplným stromem), které nejsou podvzorkovány. Pro srovnání při rozkladu signálu o délce 5000 vzorků (10 sekund záznamu s $f_{vz} = 500$ Hz) a stupně rozkladu 4 získáme pro redundantní paketovou 16 pásem, kde každé pásmo je tvořeno 5000 koeficienty. Každé pásmo, vyjma posledního, musíme dále prahovat a vypočítat z nich korekční členy včetně jejich aplikace. Pro redundantní dyadickou vlnkovou transformaci tzv. SWT získáme pásem jenom 5 o stejném počtu koeficientů. To je více než 3x méně dat. V případě, že využijeme variantu dyadické DTWT s podvzorkováním, tak získáme také pět pásem, ale dohromady jsou tvořeny cca. 5000 koeficienty.

Jako vhodné optimalizační řešení pro hledání empirické konstanty je zvoleno využití genetického algoritmu, který pracuje se základními prvky a to populací, kriteriální funkcí a operátory: křížení, souboj a mutace. Kriteriální funkce má vstupní parametr již zmíněnou empirickou konstantu a pro ni vyhodnocuje kvalitu pomocí poměru signál - šum (SNR), který chceme maximalizovat. Při vyhodnocení SNR, pro zadanou hodnotu empirického prahu, využíváme pouze 10% databáze CSE, která je generována náhodně. Vzhledem k principu evolučního algoritmu a možné variabilitě výsledků je zbytečné využívat celou databázi, jak by tomu bylo v případě metody brutal force. GA totiž nerealizuje optimalizaci čistě z matematického hlediska. Umožňujeme nám pouze nalezení vhodného řešení v relativně krátkém čase, nemůže nám však zaručit nalezení nejlepšího řešení. V našem případě je na základě literatury a praktických zkušeností navrženo schéma GA na obr. 4. 1. Při realizaci samotného programu se vycházelo z programu realizovaného v rámci cvičení předmětu FEAL (evoluční algoritmy).



obr. 4. 1 Schéma GA [20]

4.1.1 Navržení úvodní populace

Pro nastavení velikosti populace je využito menšího počtu jedinců 10, které se běžně používá. Vyhodnocení 10 jedinců tvořící populaci na 10% databáze CSE (375 signálů) klade v podstatě stejné výpočetní nároky jako vyhodnocení SNR pro jednu hodnotu empirické konstanty při metodě brutal force. Při praktickém testování se ukázalo, že je nutné generovat

stejnou skupinu signálů z databáze pro všechny jedince v dané populaci. Při generování náhodných signálů, zvláště pro každého jedince, může být horší jedinec ohodnocen lépe než jiný z důvodu vygenerování “lepších“ signálů. To vedlo k oscilacím a pomalé konvergenci.

Pro práci s populací je využít jejího binárního zápisu, který je vhodnější pro genetické operátory. Pro kódování bylo využito délky binárního slova osm, které umožňuje prohledávaný prostor rozdělit na 256 stejných dílů (2^8). Rozsah empirické konstanty na základě literatury byl omezen na prostor od 2 do 5, to nám dává přesnost $3 / 256$ (rozsah/počet dílů). Po zaokrouhlení můžeme mluvit o přesnosti na setiny.

4.1.2 Parametry ukončení

Při praktickém testování se ukázalo, že metoda velmi rychle konverguje k globálnímu maximu, a to během několika iteračních cyklů. Pro praktické použití byl stanoven maximální počet iterací 10 a jako druhá ukončovací podmínka pro zkrácení výpočetní náročnosti byla nastavena hodnota *shoda*. Jestli je po třech iteracích stále stejný nejlepší jedinec, hledání je ukončeno.

4.1.3 Nastavení parametrů GA

Používané operace křížení a souboj jsou nastaveny dle doporučení, pro křížení je stanovena pravděpodobnost 80 %. Pro nastavení mutace musela být použita maximální doporučená hodnota 10 %. Důvodem je charakter prostoru a počet jedinců. Pro hodnotu mutace 1%, kdy dochází pouze přibližně k jedné mutaci alely u jednoho jedince z celé populace a vzhledem k menšímu počtu jedinců, metoda měla tendence uváznout v lokálních extrémech, což bylo nežádoucí. Pro hodnotu mutace 10 % však tento problém vymizel. Poslední vhodnou úpravou bylo zavedení pojmu elity, kdy nejlepší jedinec z populace je automaticky vybrán i do další populace. To opět zabránilo zbytečným oscilacím a zpomalení konvergence.

4.2 Realizace GA pro optimalizaci empirické konstanty a stupně rozkladu (GA_2)

V případě hledání dvou parametrů se jedná pouze o samotné rozšíření předešlé metody. Samotné použití operátorů, včetně jejich parametrů, zůstává neměnné (obr. 4. 1). Jediná úprava spočívá v úpravě populace. V případě zápisu více proměnných se využívá zápis na řádek za sebe bez jakéhokoliv oddělení. Opět platí, že počet vzorků (alel), kódující danou proměnou, je dáno požadovanou přesností a oborem hodnot proměnné.

4.2.1 Úprava GA_2 pro funkci více proměnných

Pro zrychlení GA_2 je využito pro kódování empirické konstanty pouze 6 alel, což vede k rozdělení prohledávaného prostoru $\langle 1-4 \rangle$ na $2^6 = 64$ dílů. Dosažený krok se tak pohybuje okolo 0,05, což je dostačující a na druhou stranu nám to umožňuje zvýšit konvergenci GA_2. Změna rozsahu prohledávaného prostoru empirické konstanty (z $\langle 2,5 \rangle$ na $\langle 1,4 \rangle$) je zvolena z důvodu volby různých stupňů rozkladu, pro které by velikost vhodného

prahu nemusela být nutně větší než 2. Pro kódování stupně rozkladu je použito pouze 2 alel, což nám umožní testovat čtyři stupně rozkladu (2^2). V našem případě se jedná o stupeň rozkladu 2 až 5. Použitím 3 alel je sice možné testovat až do stupně rozkladu 9, avšak takto vysoký rozklad vede spíše k poškození signálu a v případě DTWT i prudkému nárůstu výpočetní náročnosti. Proto kódování třemi alelami je zcela zbytečné.

Nutnou úpravou prošla samotná kritériální funkce, která je rozšířena o nový parametr *stupeň rozkladu*. Druhou změnou je ukončovací kritérium vycházející z maximálního počtu iterací. Zde je nutné, vzhledem k velikosti prohledávaného prostoru, navýšit maximální počet iterací (pro testování maxiter = 15), avšak druhá ukončovací podmínka zůstává stejná. Možnou změnou je velikost populace resp. počet jedinců, který se stanovuje právě i na základě počtu proměnných. Pro testování bylo využito velikosti populace 20.

4.3 Vyhodnocení výsledků GA a GA_2

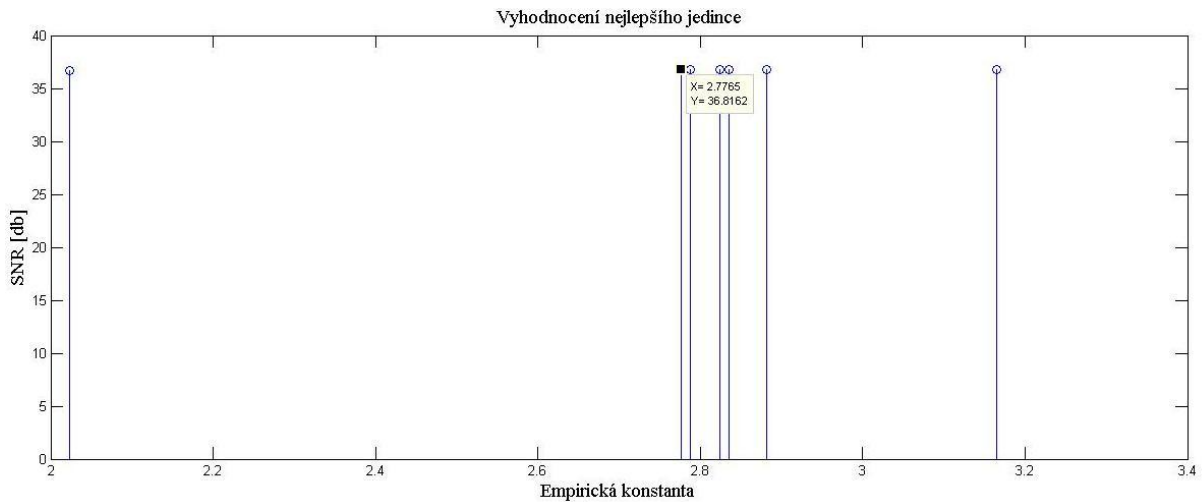
Při praktickém testování se ukázalo, že metoda v případě jednorozměrné varianty pro empirickou konstantu rychle konverguje a to během několika iteračních cyklů. Pro praktické použití byl stanoven maximální počet iterací deset. Při testování a porovnání s metodou brutal force (s krokem jedné desetiny) genetický algoritmus po zaokrouhlení na desetiny našel stejné maximum jako metoda brutal force. Zajímavostí je, že při zaokrouhlení nalezeného empirického prahu, pomocí GA na setiny, jsme získali lepší SNR než při zaokrouhlení na desetiny. Ukázku můžeme vidět na obr. 4. 2, kde genetický algoritmus našel dva nejlepší jedince a to pro hodnoty empirické konstanty 2.78 a 2.79. Pro oba jedince GA stanovil hodnotu SNR = 36.8162. Při porovnání s metodou brutal force (obr. 4. 3) vidíme, že metoda správně konverguje ke globálnímu maximu, které v tomto případě je 2,8 s přesností na desetiny. Ovšem při testování nalezených empirických prahů na celé databázi CSE (tab. 4. 1) nalezený empirický práh pomocí GA s přesností na setiny dosahuje lepšího SNR než se zaokrouhlením na desetiny. Takže metodu můžeme považovat za přesnější než metodu brutal force s krokem jedné desetiny. Tyto konkrétní hodnoty jsou získány pro vlnku1 = bior4.4, vlnku2 = sym4, stupně rozkladu = 3 a vstupní SNR = 30.

Naměřené hodnoty SNR	
empirický práh	SNR
2,8	36,7698
2,78	36,7698
2,79	36,7699

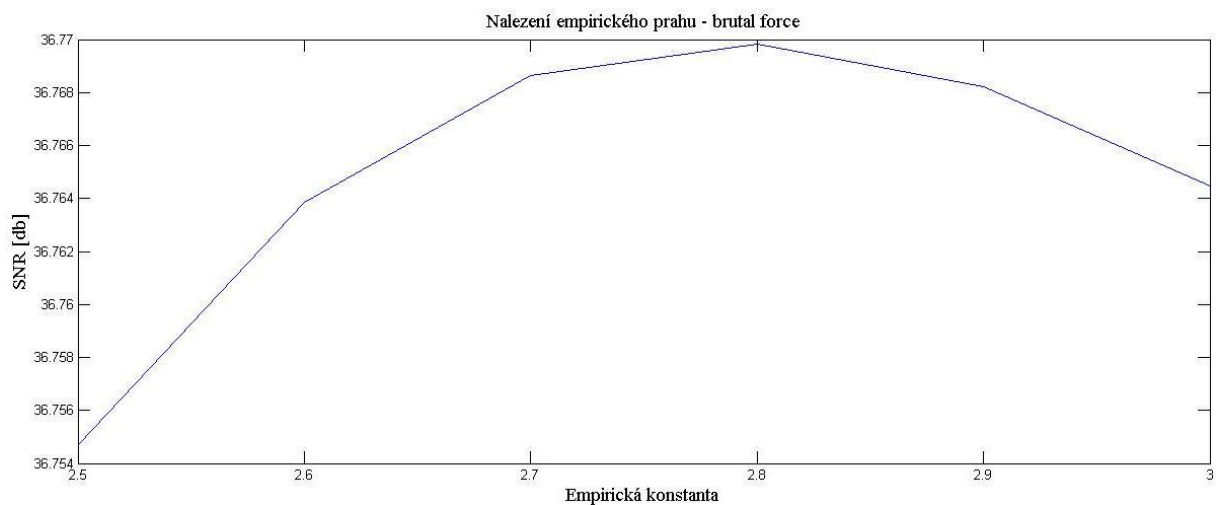
tab. 4. 1 Vyhodnocení empirické konstanty nalezené GA

Pro vyhodnocení druhého nejdůležitějšího parametru výpočetní náročnosti si genetický algoritmus vedl dobře. Vyhodnocení maximálního počtu deseti populací je náročností srovnatelný jako vyhodnocení metody brutal force pro 10 hodnot empirické konstanty. Avšak v případě metody brutal force pro vyhodnocení celého zadaného prostoru

(obor hodnot pro empirickou konstantu), s přesností na desetiny, potřebujeme otestovat hodnot 30 (interval 2 až 5 s krokem 0.1). Pro předchozí ukázkou GA program proběhl v 7 iteracích. Z podmínky ukončení tak vyplývá, že už v 5 iteraci byl nalezen nejvhodnější výsledek (nejlepšího jedince).



obr. 4. 2 Nejlepší jedinec nalezený metodou GA



obr. 4. 3 Vyhodnocení empirické konstanty metodou brutal force

Závěrem tak můžeme říct, že genetický algoritmus dokáže najít hodnotu empirické konstanty minimálně 3krát rychleji. Avšak pořád zůstává faktem, že nám tato metoda nemůže zaručit nalezení nejlepšího řešení. Druhým problémem GA je, že pracuje pouze s 10% databáze. Vzhledem k velmi malému vlivu empirické konstanty na SNR, který můžeme vidět na obr. 4. 3 (jedná se o setiny), může výběr "špatného" vzorku z databáze (nereprezentativní) ovlivnit nalezení výsledné hodnoty empirické konstanty. Nutno dodat, že vyhodnocení SNR pro nejlepší empirickou konstantu stanovenou genetickým algoritmem je následně testováno vždy na celé databázi CSE.

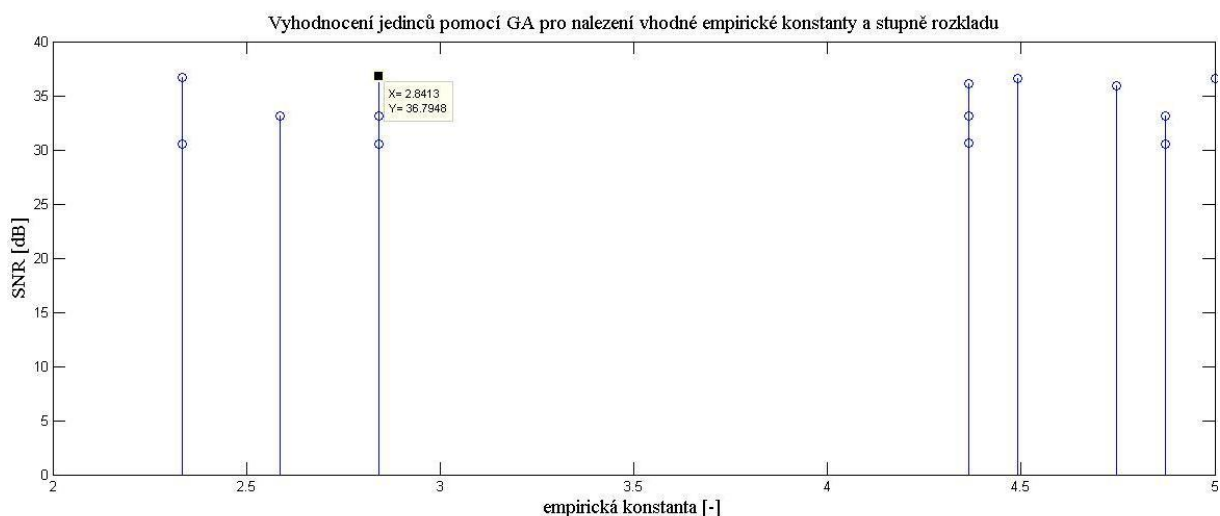
V případě varianty pro GA_2, hledající vhodnou empirickou konstantu a stupeň rozkladu, je tento algoritmus testovaný pro tři případy a to z důvodu velké výpočetní náročnosti. Testování proběhlo pro $SNR_{vst} = 20, 30$ a 40 dB a k nim příslušnými typy vlnek (tab. 4. 2), které byly převzaty z [16]. Výsledné hodnoty empirické konstanty a stupně rozkladu, získané pomocí GA_2, byli porovnány s doporučenými hodnotami stupně rozkladu z článku [16] a k nim příslušnými hodnotami empirické konstanty získanými pomocí GA pro empirickou konstantu (v tabulce jsou tyto hodnoty uvedeny v závorce).

Výsledné hodnoty parametrů získané pomocí GA_2					
SNR	WT1	WT2	empirický práh GA_2	stupeň rozkladu GA_2	SNR
20 dB	db4	sym4	2,5 (2,5)	4 (4)	29,93 (29,93)
30 dB	bior4.4	sym4	2,8 (2,8)	3(3)	36,77(36,77)
40 dB	bior3.9	sym4	2,6 (2,4)	3 (3)	45,40 (45,41)
()- parametry získané GA pro empirický práh, hodnoty stupeň rozkladu z [16]					

tab. 4. 2 Porovnání doporučených a získaných hodnot pomocí genetického algoritmu GA_2

Ze získaných hodnot vidíme, že GA_2 dokázal najít stejné kombinace stupně rozkladu i velikosti empirické konstanty. Výjimku pozorujeme pro vstupní hodnotu SNR 40 dB, kdy GA_2 našel jako ideální empirickou konstantu 2,6. Avšak při testování na celé databázi CSE bylo výsledné zlepšení pouze o jednu setinu horší než pro hodnotu empirické konstanty 2,4. Genetický algoritmus tak lze využít pro vhodné nalezení parametrů wienerovského filtru. V práci [24] je genetický algoritmus využit i pro nalezení vhodných typů vlnek. Na obr. 4. 4 vidíme zobrazení poslední populace včetně označení nejlepšího jedince. V grafu chybí informace o počtu stupňů rozkladu, avšak program sám provede výpis nejlepší hodnoty empirické konstanty a příslušného stupně rozkladu:

"Nejvhodnější hodnota empirické konstanty je 2.8413 a hodnota stupně rozkladu je 3."



obr. 4. 4 Nejlepší jedinec nalezen metodou GA_2

5. Realizace wienerovského filtru

Samotná realizace wienerovského filtru je realizována v programovacím prostředí programu Matlab a vychází ze schématu na obr. 3. 1 pro pilotní odhad signálu. Pro lepší možnost zhodnocení účinnosti navrženého filtru je využito signálu EKG *test_original.mat*, který byl šetrně zbaven šumu. K testování je však možno použít libovolný signál z knihovny CSE a lze nastavit i míru zarušení, přesněji vstupní SNR. K těmto signálům se přičte uměle vytvořený model šumu, jehož spektrum a frekvenční rozsah modeluje rušení myopotenciálů. Navržený filtr využívá redundantní paketová DTWT a k ní inverzní DTWT (IDTWT). Kromě samotné funkce pro wienerovský filtr *wiener_filtr*, jsou používány další čtyři funkce, které jsou nezbytné pro fungování hlavní funkce. Jedná se o funkci *rpDWT*, která realizuje redundantní paketovou DTWT a k ní funkci *rpIDWT*, která realizuje inverzní transformaci. Funkce *filtrace*, jež realizuje filtraci metodou prahování a poslední funkce *median_pevny*, která je určena k výpočtu směrodatné odchylky pomocí mediánového plovoucího okna.

5.1 Funkce rpDWT

Program *Matlab* obsahuje funkci pro realizaci nejčastěji používané DTWT s decimací pomocí funkce *wavedec*, avšak pro variantu redundantní paketové DTWT nikoliv.

Syntaxe

```
rpDWT(signal, stupen_R, vlnka)
```

Popis

Vstupními parametry funkce jsou:

- *signal* – je vstupní signál, který chceme rozložit
- *stupen_R* – požadovaný stupeň rozkladu
- *vlnka* – a volbu použité vlnky jak z řad ortogonálních, tak i biortogonálních vlnek.

Funkce pomocí příkazu *wfilters(vlnka)* získá impulsní charakteristiky pro rozkladovou horní a dolní propust. Tyto impulsní charakteristiky je však nutné podělit odmocninou 2, abychom získali filtry s přenosem 1 určené pro redundantní paketovou DTWT. Samotná filtrace probíhá ve *for* cyklu pro jednotlivé stupně rozkladu. Příslušné impulsní charakteristiky pro daný stupeň rozkladu získáváme metodou ředění impulsní charakteristiky, ukázkou vidíme níže:

```
I = 2^(i-1);  
Lo = zeros(1, I*length(Lo_D) - (I-1));  
Lo(1:I:end) = Lo_D;  
% interpolační faktor  
% nulový vektor výsledné délky  
% nahrazení každé I-té nuly vzorkem  
% impulsní charakteristiky
```

Výstupem je matice y , kde každému řádku matice připadají koeficienty jednoho pásma. Výhodou této funkce je její univerzálnost, kdy je možné zadat libovolný stupeň rozkladu, stejně jako druh použité vlnky. Vývojový diagram je uveden v příloze C.

5.2 Funkce `rpIDWT`

Jedná se o inverzní transformaci k `rpDWT`, kdy po její aplikaci získáme původní signál bez zkreslení.

Syntaxe

```
rpIDWT(y, vlnka)
```

Popis

Vstupními parametry funkce jsou:

- y – je matice obsahující koeficienty vlnkové transformace pro jednotlivá pásma
- `vlnka` – volba použité vlnky, jak z řad ortogonálních, tak i biortogonálních vlnek.

Funkce realizuje inverzní redundantní paketovou DTWT. Na rozdíl od předešlé funkce zde není nutno zadávat stupeň rozkladu, ačkoliv je pro transformaci nezbytný. Stupeň rozkladu je vypočítán automaticky na základě znalosti počtu pásem a informací, že paketová DTWT je realizována úplným stromem. Níže je uvedena příslušná část zdrojového kódu:

```
[m,n] = size(y); % parametr m udává počet řádků matice/pásem  
stupen_R = log2(m); % vzorec odvozen pro výpočet stupně rozkladu
```

Funkce následně, stejně jako `rpDWT`, získá impulsní charakteristiky, pro rekonstrukční horní a dolní propust, pomocí funkce `wfilters(vlnka)`. A stejně tak i pro jednotlivá pásma využívá ředění těchto dvou základních impulsních charakteristik. Rozdílem je, že probíhá celý proces opačně (od největšího faktoru k pro ředění impulsní charakteristiky k menšímu) a po filtraci v každém stupni rozkladu je nutné sečíst koeficienty dvojice pásem příslušných k dané dvojici rekonstrukčních filtrů (horní a dolní propust) dle obr. 2.3.

Ukázku hlavní části této funkce, realizující celou filtraci a rekonstrukci signálu, vidíme níže:

```
for i = 1:stupen_R  
    rozklad = stupen_R+1-i; % Nutno postupovat opačně  
    .  
    .  
    .  
    for j=1:2^(rozklad-1)  
        me(j,:) = filter(Hi,1,y(k,:)) + filter(Lo,1,y(k+1,:));  
        k = k+2;  
    end  
    y = 0;          y = me;          me = [];  
end
```

Výstupem funkce je zrekonstruovaný signál y . Pro správnou činnost wienerovského filtru je nutné správné stanovení zpoždění, neboť by mohlo dojít ke stanovení špatných korekčních členů, resp. jejich aplikace na špatné pozice koeficientů vlnkové transformace originálního signálu. Vlivem zpoždění bylo nutné oříznout signál.

5.3 Funkce `filtrace`

Samotná filtrace se provádí metodou prahování koeficientů v jednotlivých pásmech, kromě pásma nejnižšího, neboť v něm leží užitečný signál. Avšak při dostatečně velkém stupni rozkladu (3 a více) do nejnižšího pásma šum myopotenciálu nezasahuje nebo jen minimálně. Prahování bylo zvoleno hybridní, neboť tvrdé prahování zavádí impulsní rušení. To je způsobeno šumem myopotenciálů, jehož intenzita je nad hladinou prahu a prohází prahováním beze změny. Měkké prahování zase vede ke zkreslení užitečného signálu, ale pro samotný wienerovský filtr je vhodnější než tvrdé prahování.

Syntaxe

```
filtrace(y)
```

Popis

Vstupními parametry funkce jsou:

- y – je matice obsahující koeficienty vlnkové transformace pro jednotlivá pásma.

Funkce si pomocí příkazu `size` zjistí počet pásem a potom provede prahování ve všech pásmech kromě posledního. V každém pásmu se spočítá nejprve směrodatná odchylka σ_w dle vztahu 2. 10 a následně samotná hodnota prahu T pomocí vztahu 2. 9. Samotné prahování se provádí pomocí příkazu `wthresh` (pro variantu měkkého nebo tvrdého prahování) nebo blokem příkazů pro hybridní prahování. Výstupem je opět matice koeficientů vlnkové transformace po prahování y .

5.4 Funkce `median_pevny`

Správné stanovení směrodatné odchylky šumu je pro činnost wienerovského filtru zásadní. Pro její výpočet je využito funkce `median_pevny`, kde je využito plovoucího okna a vzorce pro výpočet směrodatné odchylky. Problematika je rozebrána v předchozích kapitolách.

Syntaxe

```
median_pevny(y)
```

Popis

Vstupními parametry funkce jsou:

- y – je matice obsahující koeficienty vlnkové transformace pro jednotlivá pásma.

Funkce provede výpočet směrodatné odchylky a tato hodnota je odeslána na výstup funkce.

5.5 Hlavní funkce `wiener_filtr`

Hlavní funkce realizuje samotný wienerovský filtr. Volá si k tomu pomocné funkce pro realizaci vlnkové transformace a filtrace. Pro samotné testování je však využito varianty hlavní funkce jako skriptu *diplomova_prace*, který nám umožňuje jednoduše měnit jednotlivé vstupní parametry. Skript také slouží k vizuální kontrole, protože umožňuje vykreslení signálu v jednotlivých krocích úpravy (jednotlivá pásma v první větvi před a po prahování, pilotní odhad signálu, zarušený signál i výsledný signál po aplikaci korekčních členů) a porovnání s originálním signálem bez šumu.

Syntaxe

```
wiener_filtr(signal, vlnka1, stupen_R1, vlnka2, stupen_R2)
```

Popis

Vstupními parametry funkce jsou:

- `signal` – je vstupní EKG signál, který chceme filtrovat od šumu myopotenciálů
- `vlnka1` – volba použité vlnky pro vlnkovou transformaci ve větvi pro pilotní odhad užitečného signálu
- `stupen_R1` – požadovaný stupeň rozkladu pro vlnkovou transformaci v první větvi pro pilotní odhad užitečného signálu
- `vlnka2` – volba vlnky pro vlnkovou transformaci v druhé větvi pro aplikaci korekčních členů
- `stupen_R2` – požadovaný stupeň rozkladu pro vlnkovou transformaci v druhé větvi pro aplikaci korekčních členů.

Hlavní funkce v úvodní části nejprve vykreslí zadaný signál a umožní uživateli provést vizuální kontrolu, zda je signál správně načten. Po stisknutí libovolné klávesy následně proběhne zbylá část programu a vykreslení výsledného signálu po filtraci wienerovským filtrem. Část programu realizující první větev, pro odhad pilotního signálu, je realizována voláním pomocných funkcí níže:

```
y = rpDWT(signal, stupen_R1, vlnka1); % Realizace rozkladu
y = filtrace(y); % Filtrace metodou prahování pásem
y = rpIDWT(y, vlnka1); % Rekonstrukce WT-vznik pilotního
% odhadu užitečného signálu
y_p = rpDWT(y, stupen_R2, vlnka2); % Rozklad pro stanovení koeficientů
% užitečného signálu pro výpočet korekčních členů
```

Výpočet korekčních členů je realizován pomocí cyklu *for* a korekční členy jsou uloženy do matice *g*. Ukázka zdrojového kódu je uvedena níže:

```
for i=1:m % Výpočet korekčních členů pro m pásem
    smer_odch = median_pevny(y_w(i,:)) % Směrodatná odchylka
    rozptyl = smer_odch^2; % Rozptyl
    g(i,:) = (y_p(i,:).^2)./(y_p(i,:).^2 + rozptyl); % Korekční členy
end
```

Pro správnou činnost navrženého filtru bylo nutné zahrnout do zdrojového kódu několik úprav. Vlivem vlnkové transformace WT1 a k ní inverzní IWT1 dochází k zavedení zpoždění do pilotního odhadu užitečného signálu. Vlivem zpoždění by vypočítané korekční členy byly použity na špatné pozice originálního signálu. Proto je nutné pilotní odhad užitečného signálu posunout a to metodou oříznutí signálu o velikost zpoždění. Následkem toho je však délka pilotního odhadu užitečného signálu, resp. i korekčních členů kratší než délka originálního signálu. Jako vhodné řešení je využito oříznutí originálního signálu na stejnou délku, jako je pilotní odhad užitečného signálu.

```
[m,n] = size(y_p); % rozměr „n“ nám udává délku pilotního odhadu
                    užitečného signálu
signal = signal(1:n); % zkrácení originálního signálu
```

Druhou nutnou úpravou je změna korekčních členů pro nejspodnější pásmo. Pro snadnou aplikaci korekčních členů (násobení matic prvek po prvku) je nutné, aby rozměr matice korekčních členů byl stejný jako je rozměr matice obsahující koeficienty WT2 originálního signálu. Avšak matice korekčních členů má vždy o jeden řádek méně, protože se nepočítají korekční členy pro nejspodnější pásmo. Proto je matice korekčních členů doplněna o nový řádek, obsahující samé jedničky, který je umístěn jako poslední řádek matice. Umožní to násobit korekční matici s maticí koeficientů vstupního signálu a současně tento řádek nemá vliv na nejspodnější pásmo (násobení jedničkou nemění hodnoty koeficientů).

```
a = ones(1,n); % Vytvoření vektoru jedniček
g(m,:) = a; % Uložení na poslední řádek matice
vysledek = y_w.*g; % Snadná aplikace korekčních členů
```

5.6 Skript diplomova_prace

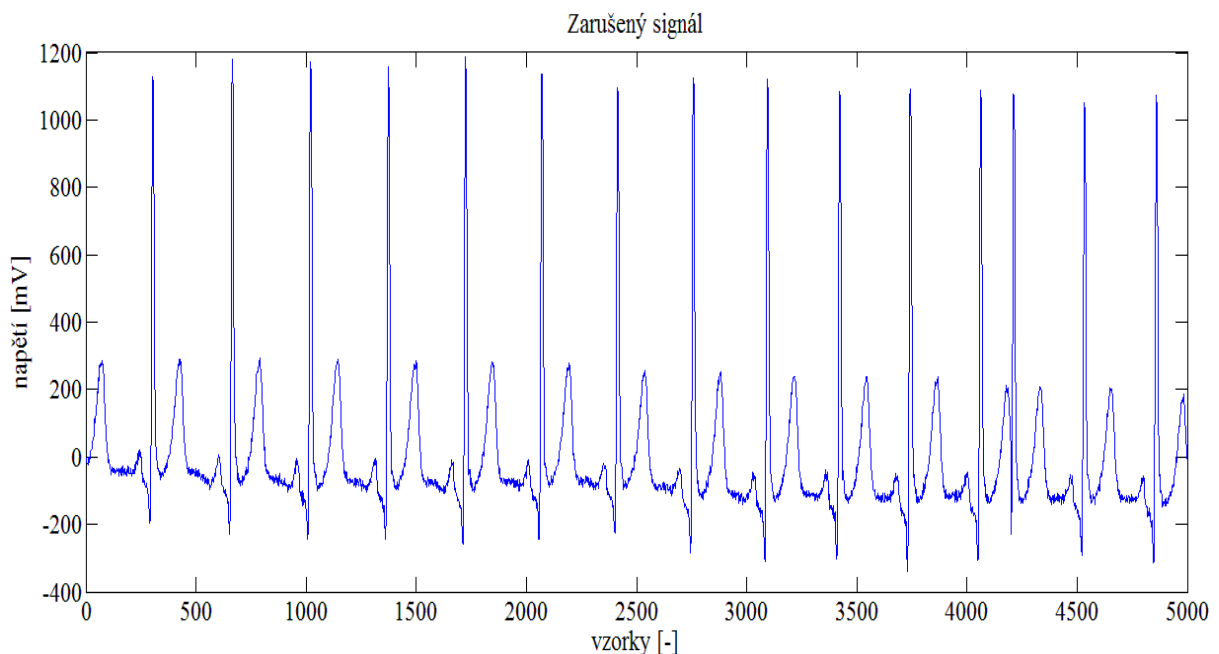
Pro snadnější práci s navrženým filtrem je vytvořena jeho varianta jako skriptu. V úvodní části (inicializační) lze nastavit základní parametry pro daný filtr včetně vstupního SNR a zvolit libovolný signál z knihovny CSE. Základní parametry k nastavení jsou: typ vlnky a stupeň rozkladu, které se nastavují zvlášť pro pilotní odhad užitečného signálu a pro výpočet korekčních členů, dále již zmíněný požadovaný vstupní SNR a v neposlední řadě výběr konkrétního signálu z databáze CSE (eventuálně lze načíst testovací signál –

test_original.mat). Hodnota empirické konstanty je nastavena na hodnotu 2,8, která byla stanovena spolu s hybridním prahováním při samotném statistickém vyhodnocení jako optimální. Po nastavení inicializačních podmínek a spuštění programu dojde k vykreslení zarušeného signálu, následně pilotního odhadu užitečného signálu a na závěr se vykreslí již signál filtrovaný spolu s chybovým signálem. Ten slouží hlavně k určení míry zkreslení a k lokalizaci úseků, kde k tomuto zkreslení dochází. Program také umožňuje pro srovnání v jednotlivých krocích (pilotní odhad užitečného signálu, filtrovaný signál) vykreslit do stejného grafu signál originální (nezarušený). Poslední výhodou skriptu je vyčíslení výstupní hodnoty SNR.

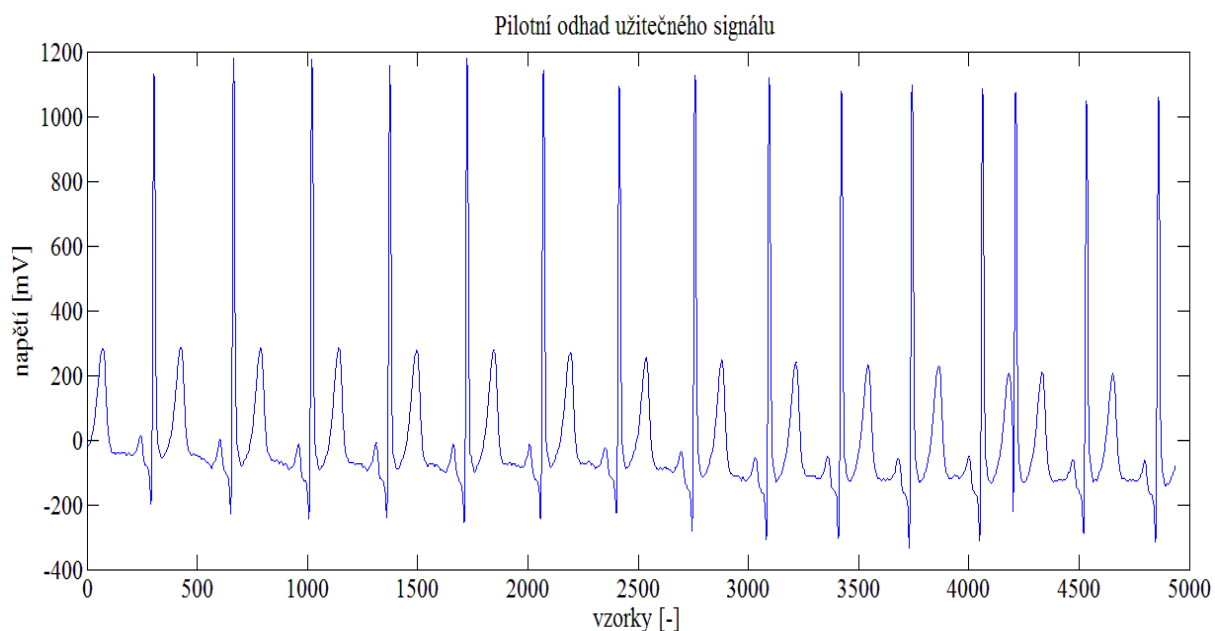
5.7 Výsledky a vyhodnocení

K ověření funkčnosti realizovaného wienerovského filtru s pilotním odhadem signálu je využito testovacího signálu *test_original.mat*, který je následně zarušen modelem šumu, jehož spektrum a frekvenční rozsah modeluje rušení myopotenciálů. K samotnému hodnocení funkčnosti realizovaného filtru je využito jak vizuální kontroly v jednotlivých krocích (porovnání s originálním signálem), tak výpočet výstupního SNR.

Na obr. 5. 1 je ukázka testovacího signálu, který je zarušený dle vstupní SNR = 30 dB. Tento signál EKG má délku trvání 10 sekund a vzorkovací frekvenci $f_{vz} = 500$ Hz. V první větvi je podroben filtraci metodou prahování s využitím redundantní paketové DTWT. Po aplikaci redundantní paketové IDTWT v bloku IWT1 získáváme pilotní odhad užitečného signálu (obr. 5. 2). Parametry jsou stupně rozkladu 3, vlnka 'bior4.4' pro pilotní odhad a vlnka 'sym4' pro výpočet korekčních členů.

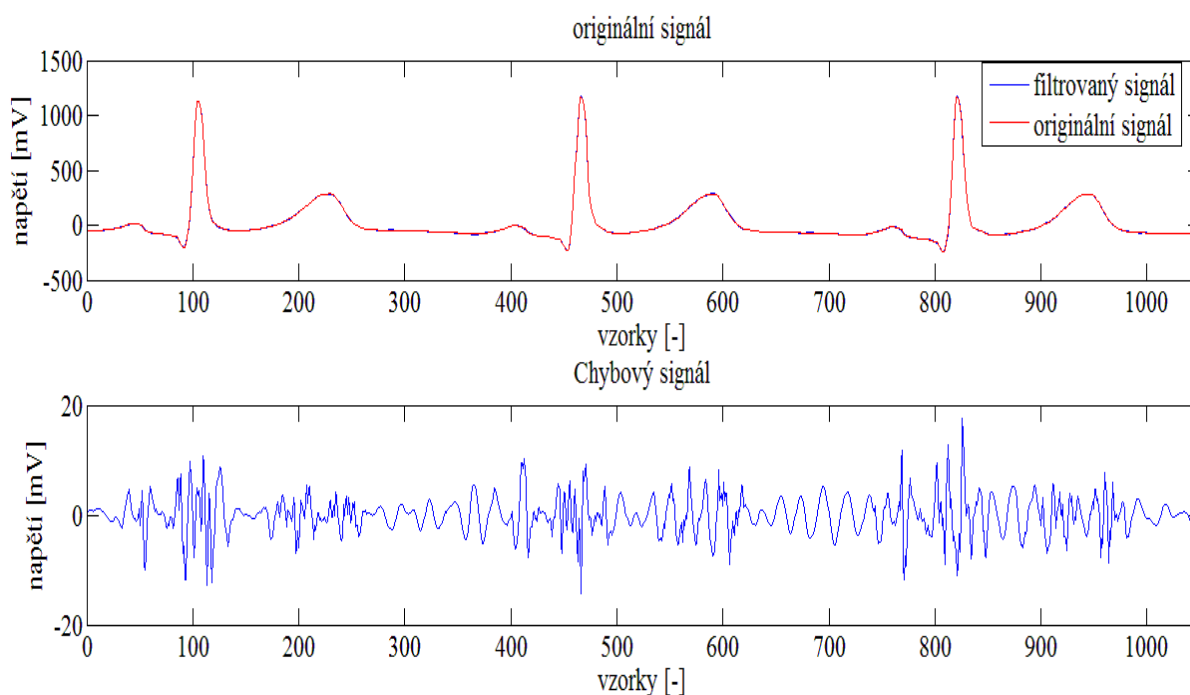


obr. 5. 1 Testovací signál obsahující šum myopotenciálů




obr. 5. 2 Pilotní odhad užitečného signálu

Pro správný odhad užitečného signálu je vhodné zvolit stupeň rozkladu alespoň 3, protože pro menší stupeň rozkladu je spodní pásmo příliš frekvenčně široké a může do něj zasahovat rušení myopotenciálů. V závěrečném kroku s využitím pilotního odhadu stanovíme korekční členy, které aplikujeme na testovací signál. Výsledný úsek signálu je uveden na obr. 5. 3. Pro větší názornost jsou zobrazeny pouze první tři QRS komplexy a k nim chybový signál. Z něho lze usoudit, že k největšímu zkreslení dochází ve vzestupných a sestupných částech QRS komplexu, P vlny a T vlny.



obr. 5. 3 Srovnání filtrovaného signálu s originálním signálem

Z obrázku je patrné, že wienerovský filtr funguje a korekční členy jsou počítány správně. Pro lepší názorné vyhodnocení účinnosti filtru je uvedeno srovnání zarušeného signálu s filtrovaným signálem (obr. 5. 4), který je označen modře.



obr. 5. 4 Srovnání filtrovaného signálu se zašuměným signálem

6. Statistika a vyhodnocení

Pro samotné vyhodnocení účinnosti navrženého wienerovského filtru s metodou pilotního odhadu užitečného signálu, který využívá redundantní paketovou DTWT, je využito dvou odlišných způsobů. V obou případech je však zvolena stejná testovací databáze knihovna CSE. K vyhodnocení se využívá parametr SNR (poměr signál šum) výstupního signálu (6. 1), který je jedním z nejlepších ukazatelů účinnosti navrženého filtru. Snahou je docílit co nejlepšího zlepšení SNR, ale také je žádoucí dosáhnout co nejmenší směrodatné odchylky. Ta je ukazatelem univerzálnosti navrženého řešení pro různé signály a variabilitu šumu. Ideálně by nemělo v žádném případě dojít ke zhoršení SNR. To lze interpretovat jako poškození signálu [11].

$$SNR_{výst} = 10 \cdot \log_{10} \frac{\sum_{n=1}^{N-1} [s(n)]^2}{\sum_{n=1}^{N-1} [y(n) - s(n)]^2} [dB], \quad (6.1)$$

kde $y(n)$ je signál po filtraci a $s(n)$ je užitečný signál. Výsledné výstupní SNR je porovnáno s hodnotou vstupního SNR a na základě jejich rozdílu můžeme vyhodnotit účinnost navrženého wienerovského filtru. Kromě samotné hodnoty zlepšení SNR je taky důležitá informace, jak navržený filtr zkresluje významné vlny a kmity v signálu EKG. To si můžeme ověřit pro jednotlivé signály z knihovny pomocí již zmíněného skriptu *diplomova_prace*, který je podrobně popsán v předešlé kapitole.

6.1 Knihovna CSE

Použitá knihovna CSE obsahuje 3750 jednotlivých signálů uložených v matici. Ve skutečnosti se jedná o 250 různých EKG signálů, které jsou nasnímány ve dvanácti svodech (dvanácti svodový systém) a další tři svody z ortogonálního snímání. Všechny signály mají stejnou délku 5000 vzorků, což při jejich vzorkovací frekvenci $f_{vz} = 500$ Hz odpovídá záznamu o délce 10 sekund. Signály byly předem šetrně zbaveny šumu. Pro testování navrženého filtru, k odstranění rušení myopotenciálů, je využito umělého zašumění signálu knihovny CSE a to pomocí šumového signálu *sumik.mat*, který byl poskytnut vedoucím práce. Tento signál je modelem rušení, jehož spektrální vlastnosti reprezentují skutečné rušení myopotenciálů. Knihovna CSE je uložena pod názvem *signaly_f_ADP9_2.mat*.

6.2 Testování pomocí programu *statistika*

Pro testování účinnosti navrženého filtru je vytvořen program *statistika*. Je realizovaný pro jednoduchost jako skript a v úvodní části lze nastavit základní vstupní parametry (inicializace). Lze zvolit zvlášť typ vlnky (vlnka1) a stupeň rozkladu (stupeň_R1) pro větev pilotního odhadu užitečného signálu a zvlášť typ vlnky (vlnka2) a stupeň rozkladu (stupeň_R2) pro samotný wienerovský filtr (výpočet a aplikaci korekčních členů). Dalšími důležitými inicializačními parametry jsou hodnota empirické konstanty pro výpočet prahu, volba vstupního SNR a v neposlední řadě také možnost zvolit mezi metodami redundantní dyadická DTWT a redundantní paketová DTWT. Testování probíhalo ve všech případech na celé databázi CSE. Pro nastavení parametrů, typy vlnek a stupně rozkladu, je využito nejnovějšího článku související s danou problematikou z roku 2013 "Adaptive Wavelet Wiener Filtering of ECG Signals" [16] (tab. 6. 1).

SNR _{vstup} [dB]	Parametry				
	Stupeň rozkladu	Prahování	TM	SWT3	SWT4
-5	4	Hybridní	3,6	rbio3.3	rbio4.4
0, 5, 10	4	Hybridní	3,4	rbio1.3	rbio4.4
15, 20	4	Hybridní	3,1	db4	sym4
25, 30, 35	3	Hybridní	2,8	bior4.4	sym4
40, 45	3	Hybridní	2,5	bior3.9	sym4
50, 55	2	Hybridní	2,3	sym6	bior3.3
TM - empirická konstanta					

tab. 6. 1 Parametry pro SWT z [převzato z [16]]

Vzhledem k velkému počtu typů vlnek, stupňů rozkladu a vysoké výpočetní náročnosti samotné filtrace, jsou použity doporučené hodnoty z předešlé tabulky. Ovšem vzhledem k odlišnosti způsobu odhadu směrodatné odchylky a použité metody v práci [16] jsou hodnoty empirické konstanty stanoveny pomocí genetického algoritmu, který je popsán v kapitole Genetický algoritmus. Empirická konstanta se pomocí GA nenastavovala zvlášť jen pro různé vstupní parametry (typ vlnky, stupeň rozkladu a SNR_{vstup}), ale také pro obě metody (redundantní paketová DTWT x redundantní dyadická DTWT). Důvodem je objektivita při porovnávání těchto dvou variant, kdy se snažíme docílit maxima efektivity u obou metod. V případě, kdy byla původně použita odvozená empirická konstanta pro paketovou DTWT automaticky i pro variantu dyadické DTWT, došlo k chybnému závěru, že je paketová DTWT lepší variantou. Obě metody se liší jenom ve způsobu rozkladu (dyadická x paketová), zbylé části programu jsou naprosto totožné. Výsledné zlepšení SNR_{vyst} můžeme pro různé parametry a metody vidět v tab. 6. 2 získané programem *statistika*.

Vypočítané hodnoty SNR - empirický práh, hybridní prahování							
Parametry/Typ transformace				Redundantní paketová DTWT		Redundantní dyadickou DTWT	
SNR _{vst} [dB]	Stupeň rozkladu	WT1	WT2	Emp. práh	SNR _{vyst} [dB]	Emp. práh	SNR _{vyst} [dB]
10	4	rbio1.3	rbio4.4	2,9	23,36	3,4(3,3)	23,40(23,40)
20	4	db4	sym4	2,5	29,93	2,9	30,32
30	3	bior4.4	sym4	2,8	36,77	2,8(3,0)	36,81(36,805)
40	3	bior3.9	sym4	2,4	45,41	2,6	45,53
50	2	sym6	bor3.3	2,8	52,88	2,8	52,87

tab. 6. 2 Výsledné vypočítané zlepšení SNR_{vyst}

Z výsledků uvedených v tabulce je patrné, že redundantní paketová DTWT dosahuje nepatrně horších výsledků, řádově se jedná pouze o setiny. Avšak současně vyžaduje větší výpočetní náročnost, protože pracujeme s více pásmy. Nejedná se pouze o výpočetně náročnější rozklad a inverzní transformaci, ale je nutné každé pásmo navíc také prahovat, stanovit v něm směrodatnou odchylku a v neposlední řadě vypočítat korekční členy a provést jejich aplikaci.

6.3 Testování pomocí programu *FILTERING_TESTER*


Předchozí testování proběhlo pro konkrétně zadané hodnoty SNR_{vstup}, ale reálně snímané signály EKG obsahují obecně různé rušení myopotenciálů a to jak do velikosti intenzity (velikost SNR_{vstup}), tak co do charakteru frekvenčního spektra. Program *FILTERING_TESTER* byl vytvořen a poskytnut Ing. Lukášem Smitalem. Jedná se o testovací funkci, která umožňuje testovat různé navržené filtry sloužící k odstranění rušení myopotenciálů. Provádí nejen zarušení signálů, ale také statistické a grafické vyhodnocení. Výhodou je nejen testování na zarušených signálech více odpovídající reálným, ale také možnost objektivního porovnání s dalšími metodami uvedenými v článku [16]. Pro testování byly použity stejné kombinace parametrů jako při předchozím testování včetně vypočítaných hodnot empirické konstanty (tab. 6. 2). V tabulce tab. 6. 2 jsme našli vhodné kombinace typů vlnek, stupně rozkladu a příslušné hodnoty empirické konstanty pro konkrétní hodnoty vstupního SNR (SNR_{vstup}). V případě testování programem *FILTERING_TESTER* jsou signály zarušeny různou intenzitou šumu. Abychom zjistili, která kombinace parametrů je vhodná pro různě zarušené signály, testujeme všech pět kombinací (pro SNR_{vstup} = 10, 20, 30, 40, 50 dB) pro paketovou DTWT i pro dyadickou DTWT. Výsledky jsou zaznamenány v tab. 6. 3 níže.

Vypočítané hodnoty SNR - empirický práh, hybridní prahování								
Parametry/Typ transformace			Redundantní paketová DTWT			Redundantní dyadická DTWT		
Stupeň rozkladu	WT1	WT2	Emp. práh	SNR- μ [dB]	SNR- σ [dB]	Emp. práh	SNR- μ [dB]	SNR- σ [dB]
4	rbio1.3	rbio4.4	2,9	8,13	3,70	3,3(3,4)	8,18(8,17)	3,89(3,91)
4	db4	sym4	2,5	7,95	3,48	2,9	8,22	3,78
3	bior4.4	sym4	2,8	9,91	2,00	2,8(3,0)	9,81(9,87)	1,94(1,97)
3	bior3.9	sym4	2,4	9,64	1,92	2,6	9,59	1,92
2	sym6	bior3.3	2,8	5,31	0,66	2,8	5,25	0,65

tab. 6. 3 Výsledky testování programem *FILTERING_TESTER*

Z výsledků uvedených v tabulce je patrné, že obě metody vychází podobně. Nejlepších výsledků dosahujeme pro redundantní paketovou DTWT při volbě stupně rozkladu 3, vlnky WT1 'bior4.4', WT2 'sym4' a empirickém prahu 2,8 a to průměrného zlepšení 9,91 dB a směrodatné odchylce 2 dB (obr. 6. 1).

Redundantní dyadická DTWT vychází nejlépe se stejným nastavením vlnek a stupňů rozkladu, ale s hodnotou empirického prahu 3. Výsledné průměrné zlepšení je 9,87 dB a směrodatná odchylka 1,97 dB (obr. 6. 2). Rozdíly mezi nejlepšími dosaženými hodnotami SNR jsou tak minimální, stejně jako jejich směrodatná odchylka. Metody tak na základě testování programem *statistika* a *FILTERING_TESTER* můžeme považovat za adekvátní.



obr. 6. 1 Vyhodnocení nejlepšího výsledku pro redundantní paketovou DTWT

Testováno na 3750 signálech (100% databáze)

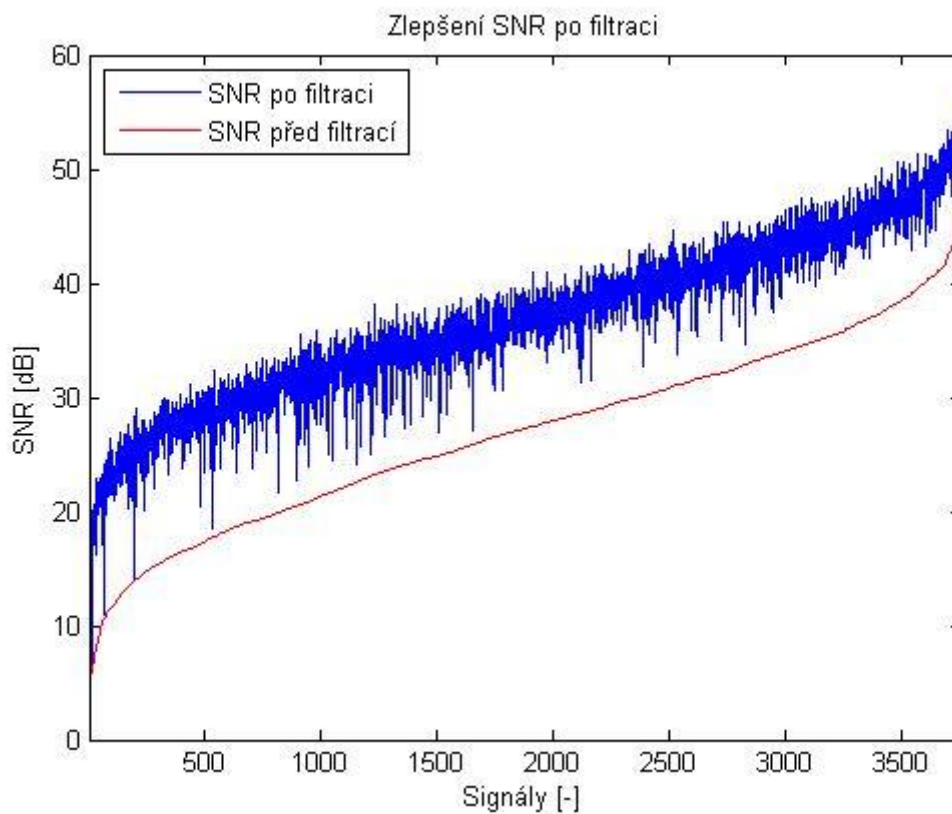
Průměrné zlepšení SNR = 9.91 [dB]

Směrodatná odchylka zlepšení SNR = 2.00 [dB]

Maximální zlepšení SNR = 15.03 [dB]

Minimální zlepšení SNR = 0.60 [dB]

Velkým kladem navrženého filtru je, že v žádném případě nedošlo ke zhoršení SNR a stanovená směrodatná odchylka ukazuje na poměrně malý rozptyl účinnosti navrženého filtru pro jednotlivé signály.



obr. 6. 2 Vyhodnocení nejlepšího výsledku pro redundantní dyadickou DTWT

Testováno na 3750 signálech (100% databáze)

Průměrné zlepšení SNR = 9.87 [dB]

Směrodatná odchylka zlepšení SNR = 1.97 [dB]

Maximální zlepšení SNR = 15.12 [dB]

Minimální zlepšení SNR = 0.21 [dB]

V případě varianty redundantní dyadické DTWT vidíme téměř stejné výsledky jako je průměrné zlepšení a směrodatná odchylka.

7. Závěr

Na základě zpracovaných teoretických poznatků se podařilo realizovat wienerovský filtr v prostředí programu Matlab, který využívá redundantní paketovou DTWT. Zadaný filtr umí pracovat s libovolným počtem stupňů rozkladu a typem vlnek, jak z řad biortogonálních, tak ortogonálních. Pro vlnkovou transformaci WT1, sloužící k realizaci filtrace metodou prahování a ke zjištění pilotního odhadu užitečného signálu, lze použít odlišné nastavení transformace, než pro vlnkovou transformaci WT2, která slouží k výpočtu korekčních členů (samotný wienerovský filtr).

Pro samotnou filtraci ve větvi pilotního odhadu užitečného signálu je použito hybridního prahování, které kombinuje výhody tvrdého a měkkého prahování. Program umožňuje ale využít i měkké a tvrdé prahování. Jejich nevýhody jsou v práci podrobně okomentovány. Pro stanovení hodnoty prahu existuje velké množství vzorců, avšak většina z nich vychází z bílého gaussovského šumu, což neodpovídá rušení myopotenciálů a k tomu bývají odvozeny pro variantu DTWT s podvzorkováním (decimací). Proto je využito vztahu pro empirický práh.

Vzhledem k náročnosti filtrace s využitím redundantní paketové DTWT a nutnosti nalezení vhodné hodnoty empirické konstanty pro metodu prahování je, jako optimalizační metoda, testován genetický algoritmus (GA). Na základě teoretických poznatků a praktického testování byly nalezeny vhodné parametry GA a naprogramovány jednotlivé podfunkce jako je: *mutace*, *křížení*, *souboj* či *kriteriální funkce*. Výsledný GA dokázal nalézt vhodnou hodnotu empirické konstanty rychleji než metoda brutal force (úplné prohledávání). Pro možnost ověření účinnosti navrženého GA je v práci realizována i metoda úplného vyhledávání (brutal force). Samotný potenciál navrženého algoritmu v případě hledání pouze jedné proměnné (empirické konstanty) není tak výrazný, daný prostor by šel prohledat i jinými optimalizačními metodami. Proto bylo na základě článku [24] testováno rozšíření GA pro dvě proměnné, kdy se hledala vhodná kombinace empirické konstanty a stupně rozkladu, který má zásadní vliv na účinnost wienerovského filtru. Z výsledků je patrné, že GA_2 (pro dvě proměnné) dokázal najít vhodnou kombinaci empirické konstanty a stupně rozkladu a to výrazně rychleji než metodou úplného vyhledávání. Genetické algoritmy tak lze využít jako optimalizační metodu pro hledání vhodných parametrů wienerovského filtru.

Samotné vyhodnocení správnosti a účinnosti navrženého filtru je realizováno nejprve vizuálně s využitím originálního nezarušeného signálu a stejného signálu zarušeného šumem myopotenciálů. Vizuální kontrola probíhala v jednotlivých krocích wienerovského filtru a je podrobně zdokumentovaná a okomentována v textu. Samotné dílčí funkce jako je redundantní paketová DTWT a k ní inverzní transformace byly testovány samostatně s využitím jednotkového impulsu a s různými parametry (stupeň rozkladu a typ vlnky). Vždy bylo získáno totožného výsledku bez zkreslení. Ověření funkce filtrace realizující prahování včetně vhodné velikosti prahu je zdokumentováno v příloze.

Pro statistické zhodnocení navrženého filtru pro různé vstupní parametry je využito dvou odlišných programů. Hlavním hodnotícím kritériem je výstupní SNR, které nám reprezentuje účinnost navrženého filtru. Testování proběhlo vždy na celé databázi knihovny CSE. První program *statistika* vyhodnocuje účinnost filtrace pro konkrétní hodnoty vstupního SNR (poměr signál - šum). Nastavení parametrů jako je typ použitých vlnek a stupeň rozkladu v závislosti na vstupním SNR bylo provedeno dle aktuálního článku [16], který se zabývá podobnou problematikou. Druhý program k testování navrženého filtru byl *FILTERING_TESTER*, který poskytl Ing. Lukáš Smital.

Pomocí tohoto programu bylo možné otestovat navržený filtr na uměle zarušených signálech o různém vstupním SNR a charakteru spektra rušení, což lépe reprezentuje reálnou situaci. Druhou výhodou je možnost objektivního porovnání nejen obou navržených metod, redundantní paketové DTWT s redundantní dyadickou DTWT, ale také s ostatními metodami uveřejněnými v článku [16]. Výsledky můžeme vidět v tab. 7. 1 (převzato z [16]).

Nejlépeších výsledků dosahujeme pro redundantní paketovou DTWT při volbě stupně rozkladu 3, vlnky WT1 'bior4.4', WT2 'sym4' a empirickém prahu 2,8 a to průměrného zlepšení 9,91 dB a směrodatné odchylce 2 dB (obr. 6. 1).

Redundantní dyadická DTWT vychází nejlépe se stejným nastavením vlnek a stupňů rozkladu, ale s hodnotou empirického prahu 3. Výsledné průměrné zlepšení je 9,87 dB a směrodatná odchylka 1,97 dB (obr. 6. 2). Rozdíly mezi nejlepšími výsledky jsou tak minimální. A na základě testování jak programem *statistika*, tak *FILTERING_TESTER* můžeme říct, že metody jsou srovnatelné. Ovšem pořád zůstává faktem, že s variantou paketové DTWT je spojena výrazně větší výpočetní náročnost a to nejen rozkladem do více pásem, ale také nutností každé pásmo prahovat, stanovit v něm směrodatnou odchylku šumu a pro každé pásmo také vypočítat a aplikovat korekční členy. Stejná účinnost a současně větší výpočetní náročnost jsou tak zřejmě hlavními důvody, proč se s variantou redundantní paketové DTWT v praxi setkáváme minimálně.

Výsledky pro různé testovací metody					
Metoda	LF	WF	WWF	AWWF	WWF_RP
Průměrné zlepšení [dB]	-4,5	6,4	6,6	10,6	9,9
Směrodatná odchylka zlepšení [dB]	8,2	3,6	3,8	2,2	2

tab. 7. 1 Porovnání různých filtračních metod programem *FILTERING_TESTER*[16]

Z tabulky výše vidíme, že navržený wienerovský filtr (využívající redundantní paketovou DTWT) s označením WWF_RP (Wavelet Wiener Filtering Method) dopadl velmi dobře vzhledem k ostatním metodám. Nejhůře dopadl LF (lineární filtr s mezní frekvencí 40 Hz). Metody WF (dyadická WT s decimací) a WWF (stacionární dyadická WT) vyšli obdobně. Zlepšení je pořád výrazně menší a obě metody dosahují velkého rozptylu zlepšení. Nejlépe dopadla metoda AWWF Ing. Lukáše Smitala. Tato metoda vychází také z

wienerské filtru a využívá redundantní dyadickou DTWT stejně jako jedna z mnou navržených metod. Avšak v případě metody AWWF se jedná o mnohem propracovanější (optimalizovanou) metodu, která tak dosahuje většího průměrného zlepšení. Kromě toho si můžeme všimnout, že tato metoda má i výrazně lepší jak minimální zlepšení 3,5 dB, tak maximální zlepšení 19 dB v porovnání s mnou navrženou metodou (obr. 6. 2), kde minimální zlepšení je 0,6 dB a maximální zlepšení je 15 dB. Podrobnější informace o daných metodách včetně použitých parametrů můžeme najít v článku [16]. Závěrem tak navržený wienerovský filtr dosahuje velmi dobrých výsledků vzhledem k ostatním metodám a také velmi malého rozptylu zlepšení, což lze interpretovat jako univerzálnost navrženého filtru pro různá rušení myopotenciálů. Druhým velmi pozitivním výsledkem je, že ani v jednom z 3750 signálů nedošlo ke zhoršení SNR.

8. Použitá literatura

- [1] HAMPTON, J. R. *EKG stručně, jasně, přehledně*. 2. vydání. Praha : Grada Publishing, a. s., 2005. 152 s. ISBN 80-247-0960-0.
- [2] KOZUMPLÍK, J. *Multitaktní systémy*. Elektronická skripta FEKT VUT v Brně, 2005
- [3] KHAN, M. G. *EKG a jeho hodnocení*. 1. vydání. Praha : Grada Publishing, a. s., 2005. 348 s. ISBN 80-247-0910-4.
- [4] HAMPTON, J. R. *EKG v praxi*. 1. vydání. Překlad Pravoslav Hykeš. Praha: Grada Publishing a. s., 1997, 318 s. ISBN 80-716-9426-6.
- [5] THAKOR, N. V. - WEBSTER, J. G. - TOMPKINS, W. J. Estimation of QRS complex power spectra for design of a QRS filter. *IEEE Trans Biomed Eng.* 1984 Nov;31(11):702-706. PubMed PMID: 6500590.
- [6] KOZUMPLÍK, J. *Vlnkové transformace a jejich využití pro filtraci signálů EKG*: habilitační práce. Brno, VUT FEKT. 2004. 81 s.
- [7] ROZMAN, J. *Elektronické přístroje v lékařství*. 1. vydání. Praha: ACADEMIA, 2006. ISBN 80-200-1308-3.
- [8] MALCOLM, S. T. *EKG a jeho klinické využití*. Překlad Jiří Kolář. Praha: Grada publishing, a. s., 2013, 213 s. ISBN 978-80-247-4193-2
- [9] TROJAN, S. *Lékařská fyziologie*. 4. vydání. Praha : Grada Publishing, a.s., 2003. 772 s. ISBN 80-247-0512-5.
- [10] ROSINA, J. - KOLÁŘOVÁ, H. - STANEK, J. *Biofyzika pro studenty zdravotnických oborů*. Praha: Grada publishing, a. s., 2006. 232 s. ISBN 80-247-1383-7.
- [11] SMITAL, L. - KOZUMPLÍK, J. Filtrace signálů EKG s využitím vlnkové transformace. *Elektrorevue*, 2009, 54.ročník, 6 s.. ISSN: 1213-1539.
- [12] FARINA, D. - MERLETTI, R. Comparison of Algorithms for Estimation of EMG Variables during Voluntary Isometric Contractions. *J. Electromyogr. Kinesiol*, Vol. 10, 2000, pp.337-350.

- [13] ADDISON, P. S. Wavelet transforms and the ECG: A review. *Physiological Measurement*, vol. 26, no. 5, pp. 155–199, 2005.
- [14] DAUBECHIES, I. Ten Lectures on Wavelets. *Society for Industrial and Applied Mathematics* (SIAM), CBMS Series, April 1992.
- [15] CHMELKA, L. - KOZUMPLÍK, J. Wavelet-Based Wiener Filter for Electrocardiogram Signal Denoising. *Computers in Cardiology*, pp. 771–774, 2005.
- [16] SMITAL, L - VÍTEK, M. - KOZUMPLÍK J. - PROVAZNÍK, I. Adaptive wavelet Wiener filtering of ECG signals. *IEEE transactions on bio-medical engineering*. February 2013, roč. 60, č. 2, s. 437–445. doi 10.1109/TBME.2012.2228482.
- [17] SARITHA, C. - SUKANYA, V. - MURTHY, Y. N. ECG Signal Analysis Using Wavelet Transforms. *Bulg. J. Phys.* 2008, s. 68–77.
- [18] BAILEY, J.J. - BERSON, A. S. - GARSON, A. J. - HORAN, L. G. - MACFARLANE, P. W. - MORTARA, D. W. - ZYWIETZ, C. Recommendations for standardization and specifications in automated electrocardiography: bandwidth and digital signal processing. (*A report for health professionals by an ad hoc writing group of the Committee on Electrocardiography and Cardiac Electrophysiology of the Council on Clinical Cardiology, American Heart Association*). *Circulation*. 1990 Feb;81(2):730-9. PubMed PMID: 2297875.
- [19] ALFAOURI, M. - DAQROUQ, K. ECG signal denoising by wavelet transform thresholding. *American Journal of Applied Sciences*. 2008, roč. 5, č. 3, s. 276–281..
- [20] HYNEK, J. *Genetické algoritmy a genetické programování*. 1. vydání. Praha: Grada Publishing a. s., 2008. 200 s. ISBN 9788024726953.
- [21] ASSCHE, W. V. - BEIRLANT, J. - BULTHEEL, A. - GOVAERTS, R. - ROOSE D. - UNSER, M. - VANDERMEULEN, D. *Wavelet thresholding and noise*. Katholieke Universiteit Leuven—Faculteit Toegepaste Wetenschappen Arenbergkasteel, Heverlee, Belgium, 2000. ISBN 9056822357.
- [22] SINGH, B. N. - TIWARI, A. K. Optimal selection of wavelet basis function applied to ECG signal denoising. *Digital Signal Processing: A Review Journal*. 2006, roč. 16, č. 3, s. 275–287.

- [23] ERGEN, B. Signal and Image Denoising Using Wavelet Transform. *Advances in Wavelet Theory and Their Applications in Engineering, Physics and Technology*. 2012, Intech. 634 s. ISBN: 978-953-51- 0494-0
- [24] DAHSHAN, E. L. - SAYED, E. L. Genetic algorithm and wavelet hybrid scheme for ECG signal denoising. *Telecommunication Systems*. 2011, roč. 46, č. 3, s. 209–215.

9. Dodatek: Genetický algoritmus

Genetické algoritmy vychází z myšlenky darwinovského principu evoluce, kdy hledání optimálního řešení (maximalizace či minimalizace) je dána formou soutěže mezi jedinci dané populace. Aby bylo možné porovnávat jednotlivé jedince (individa), je nutné je kvantifikovat. V této souvislosti se setkáváme s pojmem ohodnocení, míra kvality, vhodnost či kritériální funkce. Ať už zvolíme jakékoliv označení, vždy musí platit, že jedinci s větším ohodnocením mají větší šanci přežít a tím se podílet na utváření další generace. Nová generace je vždy utvářena s využitím předchozí generace a genetických operátorů jako je křížení, mutace či souboj. Po určitém počtu opakování, které je závislé na typu dané úlohy, parametrech, požadované přesnosti atd. získáme generaci jedinců s vysokým ohodnocením. Ty představují dostatečné (tzv. optimální) řešení [20].

Je ale nutné si uvědomit, že genetické algoritmy, na rozdíl od jiných matematických optimalizačních metod, pracují odlišně se značným dílem náhody. Každé vyhodnocení generace může proběhnout zcela odlišně a stejně tak jak může metoda velmi rychle konvergovat, může dojít i k degeneraci. Nejlepší jedinec může potom reprezentovat pouze lokální optimum velmi vzdálené od globálního. V literatuře můžeme najít velké množství variací schémat pro genetické algoritmy, které se liší např. ve způsobu vytváření nové populace a samozřejmě také zcela rozdílném nastavení ostatních parametrů jako je pravděpodobnost mutace, křížení, souboj či vážená ruleta nebo využívání elitářství. Pro vytvoření vhodného schématu a parametrů je využito jak teoretických předpokladů, tak i praktických zkušeností z předmětu FEAL, kde byla problematika podrobně probírána a testována [20].

9.1 Základní pojmy

Pro práci s genetickými algoritmy je nutné si nejdříve nadefinovat základní pojmy se kterými budeme pracovat. Hlavním prvkem je populace, která je tvořena jednotlivými jedinci. Každý jedinec je tvořen chromozomem, který se dále dělí na jednotlivé geny. A konečně každý gen je tvořen alelami, které nabývají hodnot 0 a 1. Samotné genetické algoritmy jsou však zjednodušením skutečného principu evoluce. Jedinec tvořený chromozomem obsahuje pouze tolik genů, kolik máme proměnných (1 proměnná = 1 gen). Informace o dané proměnné je v genu kódována pomocí binárního zápisu (alel). Jejich počet závisí na velikosti použitého rozsahu definičního oboru dané proměnné a požadované přesnosti. GA pracují vždy s populací, která je tvořena skupinou jedinců. Pro zápis populace se využívá matice, kde každý řádek matice odpovídá jednomu jedinci, jednotlivé geny se zapisují na řádek za sebou bez oddělovače a každá hodnota na řádku odpovídá alele (může nabývat hodnot 0 a 1). Dalším důležitým prvkem je kritériální funkce, často označována jako fitness [20].

9.1.1 Kriteriaální funkce

Při hodnocení kvality každého jedince v dané populaci se využívá kriteriaální funkce. Stanovení kvality pro populaci v dané generaci je základním prvním krokem. Na základě kvality jedinců jsou dále prováděny příslušné operace, které nazýváme jako genetické operátory popsané níže. V případě, že hledáme minimum zadané funkce, je nutné kriteriaální funkci modifikovat tak, aby jedinec s menší hodnotou zadané funkce než druhý, měl kriteriaální funkci větší [20].

9.1.2 Souboj

Pro vytváření nových populací resp. generací se využívá několik genetických operací, které mají postupně vést k výběru nejlepších jedinců. Velmi používanou operací je vážená ruleta. Jedincům v dané populaci je přiřazena procentuální část prostoru v závislosti na jejich kvalitě, kde jedinci s větší kvalitou (fitness, kriteriaální funkce) budou mít větší procentuální část prostoru než jedinci s kvalitou menší. Tento prostor je převeden na distribuční funkci v rozsahu $\langle 0,1 \rangle$. Lepší jedinci tak i v distribuční funkci zahrnují větší část rozsahu a mají větší pravděpodobnost, že budou vybráni. Výběr je realizován velmi jednoduše generováním náhodného čísla v rozsahu distribuční funkce a vybraný jedinec postupuje do další populace.

Druhou možností je využít metodu soutěže, označovanou také jako souboj. Jsou při ní náhodně vybráni dva jedinci z populace, kdy do další generace postoupí ten s lepším ohodnocením [20].

9.1.3 Křížení

Křížení je další nezbytnou operací, se kterou se u genetických algoritmů setkáváme. Je také jedním z důvodů, proč je lepší pracovat s binárním zápisem jedinců, neboť křížení v této podobě je jednodušší. Ale existuje i varianta pro práci s reálnými čísly. Při křížení jsou náhodně vybráni dva jedinci a tzv. bod křížení. Bod křížení se volí z intervalu $\langle 1, L-1 \rangle$, kde L je délka chromozomu (jedince). Křížení pro L bylo zbytečné, nedošlo by k žádné změně. Samotné křížení je potom realizováno prohozením dané části chromozomu mezi jedinci (obr. 9. 1). V některých případech však může být vhodné, aby měli někteří jedinci možnost přežít beze změny a uchovat tak svoji informaci pro další generace. Proto je v literatuře doporučeno nastavit pravděpodobnost křížení v intervalu pravděpodobnosti $\langle 0.75-0.95 \rangle$ [20].

	<i>Chromozom</i>		<i>Nový chromozom</i>
1. pár	(0, 1, 1, 1, 1, 0, 1, 1)	→	(0, 1, 0, 0, 1, 1, 0, 0)
	(1, 1, 0, 0, 1, 1, 0, 0)	→	(1, 1, 1, 1, 1, 0, 1, 1)
2. pár	(0, 0, 0, 1, 0, 0, 0, 1)	→	(0, 0, 0, 1, 1, 0, 1, 1)
	(0, 1, 1, 1, 1, 0, 1, 1)	→	(0, 1, 1, 1, 0, 0, 0, 1)

obr. 9. 1 Křížení dvou jedinců (páru) s různými body křížení [20]

9.1.4 Mutace

Jednou z velmi důležitých genetických operací je mutace. Opět vychází z evoluční teorie a nejlépe se prakticky realizuje pro binární zápis jedinců. S určitou pravděpodobností může dojít k mutaci libovolné alely daného jedince (obr. 9. 2). Mutace se nastavuje v rozsahu obvykle od 0.1 % až do 5 % alel, někdy až do 10%. Mutace dané alely je dána inverzí její hodnoty (0→1 nebo 1→0). Hlavní význam mutace je možnost vytvářet zcela nové jedince a tak zabraňuje uvíznutí pouze v lokálním extrému. Někdy je nutné její hodnota nastavit na dost vysokou hodnotu, to ale záleží na konkrétním problému a jeho okolnostech [20].

<i>Chromozom před mutací</i>		<i>Chromozom po mutaci</i>
(0, 1, 0, <u>0</u> , 1, 1, 0, 0)	→	(0, 1, 0, <u>1</u> , 1, 1, 0, 0)
(1, 1, 1, 1, 1, 0, 1, 1)	→	(1, 1, 1, 1, 1, 0, 1, 1)
(0, 0, 0, 1, 1, 0, 1, 1)	→	(0, 0, 0, 1, 1, 0, 1, 1)
(0, 1, 1, 1, 0, 0, 0, <u>1</u>)	→	(0, 1, 1, 1, 0, 0, 0, <u>0</u>)

obr. 9. 2 Mutace u populace tvořené 4 jedinci [20]

9.1.5 Populace

V neposlední řadě je nutné zmínit samotnou populaci. Pro její zápis se nejčastěji používá právě binární zápis a to do podoby matice. Umožňuje to snadnější práci s genetickými operátory a populací. Zápis je tak velice jasný a přehledný. Úvodní populace je generována vždy náhodně a používá se od 10 jedinců výše. To v závislosti na charakteru úlohy. Ke kódování lze využít jak klasické binární kódování, tak někdy i tzv. Grayův kód. Hlavním rozdílem je Hammingova vzdálenost jedinců při kódování. Pro klasický binární kód je jedinec kódován náhodně, takže dva jedinci, kteří spolu sousedí (představují dvě po sobě následující hodnoty proměnné) mohou mít i maximální vzdálenost rovnou délce binárního slova. Zatímco u Grayova kódu jsou dva sousední body prohledávaného prostoru kódovány tak, aby jejich vzdálenost byla 1 [20].

Seznam symbolů a zkratek

EKG	- elektrokardiogram
VKG	- vektokardiogram
EMG	- elektromyogram
SNR	- Signal to Noise Ratio (poměr signálu vůči šumu)
WT	- vlnková transformace se spojitým časem
DWT	- diskrétní vlnková transformace
SWT	- stacionární vlnková transformace
DTWT	- vlnková transformace s diskrétním časem
IDTWT	- inverzní vlnková transformace s diskrétním časem
GA	- genetické algoritmy
SNR_{vst}	- poměr signál/šum vstupního signálu
$SNR_{\text{výst}}$	- poměr signál/šum výstupního (filtrovaného) signálu
FT	- Fourierova transformace
STFT	- krátkodobá Fourierova transformace
WT1	- zkrácené označení DTWT pro pilotní odhad
WT2	- zkrácené označení DTWT pro wienerovskou filtraci
$x(n)$	- vstupní diskrétní signál
$x(t)$	- vstupní spojitý signál
b	- časový posun vlnky
$e(n)$	- chybový signál, $e(n)=y(n)-s(n)$
$g_m(n)$	- korekční členy pro úpravu $y_m(n)$
$h(n)$	- impulsní charakteristika
$H_d(z)$	- přenosová funkce dolní propusti
$H_h(z)$	- přenosová funkce horní propusti
m	- index pásma DTWT
M	- počet stupňů rozkladu
n	- index vzorku diskrétního signálu
N	- délka posloupnosti (signálu)
$s(n)$	- užitečný diskrétní signál na vstupu
t	- spojitě proměnný čas
$u_m(n)$	- koeficienty DTWT užitečného signálu $s(n)$ v m -tém pásmu
$v_m(n)$	- koeficienty DTWT šumu $w(n)$ v m -tém pásmu

$w(n)$	- diskrétní šum na vstupu
$y(a,b)$	- výstup WT $\{x(t)\}$
$y(m,k)$	- výstup DWT $\{x(t)\}$ (m je kmitočtové měřítko, k je časové měřítko)
$y_m(n)$	- koeficienty DTWT $\{x(n)\}$ v m -tém pásmu
$y(n)$	- výstupní diskrétní signál
$y(n)$	- výstup IDTWT po úpravě koeficientů DTWT
$y_m(n)$	- upravené koeficienty $y_m(n)$ (pomocí $g_m(n)$)
z	- komplexní proměnná
λ	- prahová hodnota
λ_m	- prahová hodnota v m -tém pásmu DTWT
τ	- fázové zpoždění filtru
$\Psi(t)$	- mateřská vlnka
$\Psi_{a,b}(t)$	- časově posunutá a dilatovaná vlnka

Seznam příloh:

- A. Obsah přiloženého CD**
- B. Uživatelský manuál k programům**
- C. Ukázka vývojového diagramu funkce „rpDWT“**
- D. Ukázka metody tvrdého prahování**

Příloha A: Obsah přiloženého CD.

- Složka se zdrojovými kódy (podsložky: Statistika, Wienerův filtr, Genetický algoritmus)
- Elektronická verze diplomové práce (Marek_Handl_DP.pdf)
- Knihovna CSE, šumový signál (sumik.mat) a testovací signál (test_original.mat), které jsou uloženy spolu s programy ve složkách

Příloha B: Uživatelský manuál k programům

Pro práci s programy je nutné nejprve v programu matlab nastavit cestu do příslušné složky:

- 1) CD → Zdrojové kódy → Statistika (pro statistické testování navrženého filtru na databázi CSE).
- 2) CD → Zdrojové kódy → Wienerův filtr (pro testování filtru pro konkrétní signály a jejich vykreslení v jednotlivých částech úpravy).
- 3) CD → Zdrojové kódy → Genetický algoritmus (pro testování genetického algoritmu pro nalezení buď jen empirické konstanty, nebo i pro nalezení stupně rozkladu).

Po nastavení adresáře už všechny potřebné funkce a podfunkce včetně knihoven se signály jsou připraveny. Pro spuštění hlavních funkcí postupujte dle návodu níže:

- 1) Pro testování wienerovského filtru jsou dvě možnosti. Jednou variantou je volání funkce `wiener_filtr` jejím zapsáním okna Command Window dle syntaxe:

```
wiener_filtr(signal, vlnka1, stupen_R1, vlnka2, stupen_R2)
```

Vstupními parametry funkce jsou:

- `signal` – je vstupní EKG signál, který chceme filtrovat od šumu myopotenciálů
- `vlnka1` – volba použité vlnky pro vlnkovou transformaci ve větvi pro pilotní odhad užitečného signálu
- `stupen_R1` – požadovaný stupeň rozkladu pro vlnkovou transformaci v první větvi pro pilotní odhad užitečného signálu
- `vlnka2` – volba vlnky pro vlnkovou transformaci v druhé větvi pro aplikaci korekčních členů
- `stupen_R2` – požadovaný stupeň rozkladu pro vlnkovou transformaci v druhé větvi pro aplikaci korekčních členů

Příklad volání: `load test_signal.mat`
 `wiener_filtr(signal, 'bior4.4', 3, 'sym4', 3)`

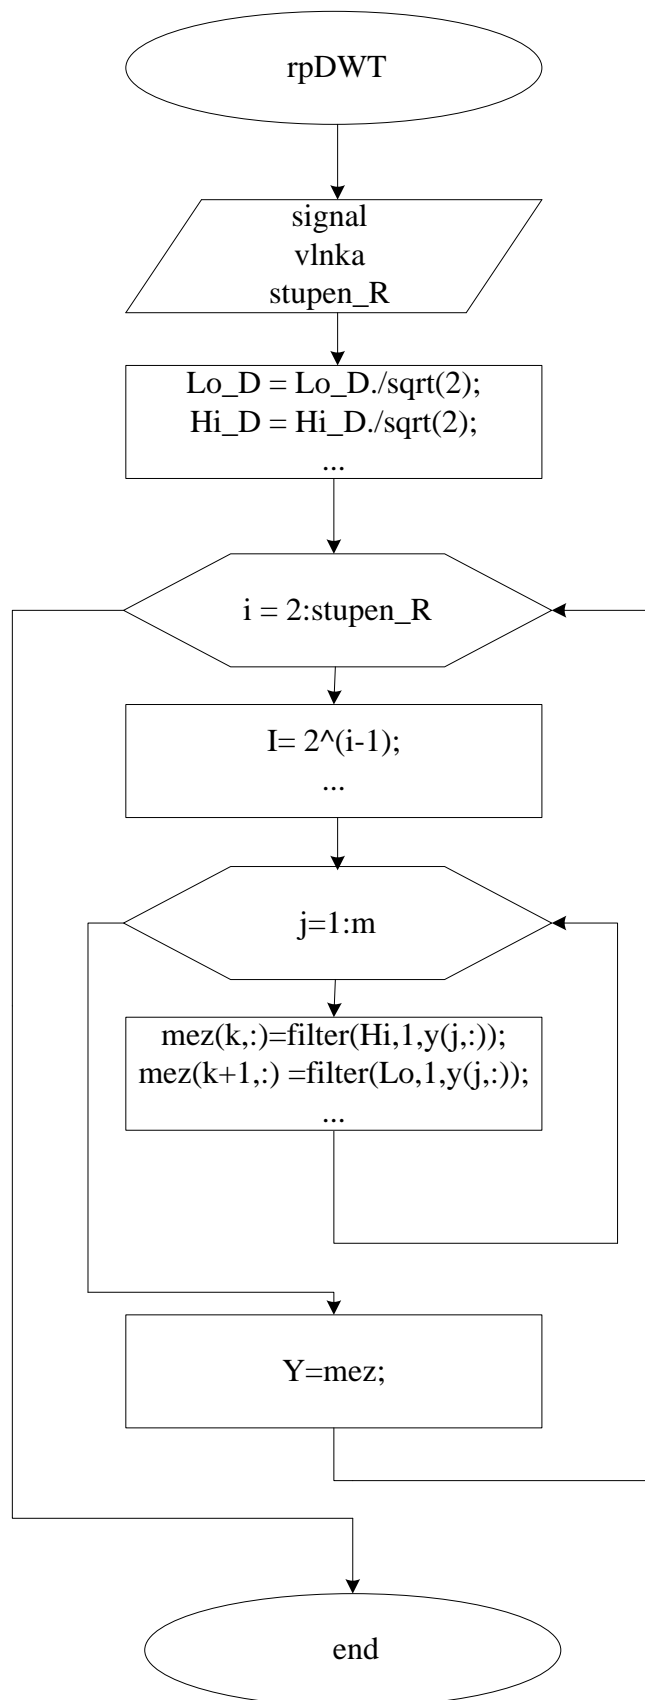
Druhou možností je využití skriptu *diplomova_prace*, kde uživatel v úvodní části zdrojového kódu může nastavit inicializační podmínky: typ vlnky (`vlnka1`, `vlnka2`), stupeň rozkladu (`stupen_R1`, `stupen_R2`), vstupní SNR (`SNR_dB`) a číslo signálu z databáze CSE (1 až 3750). Výstupem je postupné vykreslení zarušeného signálu,

pilotního odhadu užitečného signálu, filtrovaného signálu v porovnání s originálem před zašuměním a chybový signál. Vypíše se také hodnota výstupního SNR.

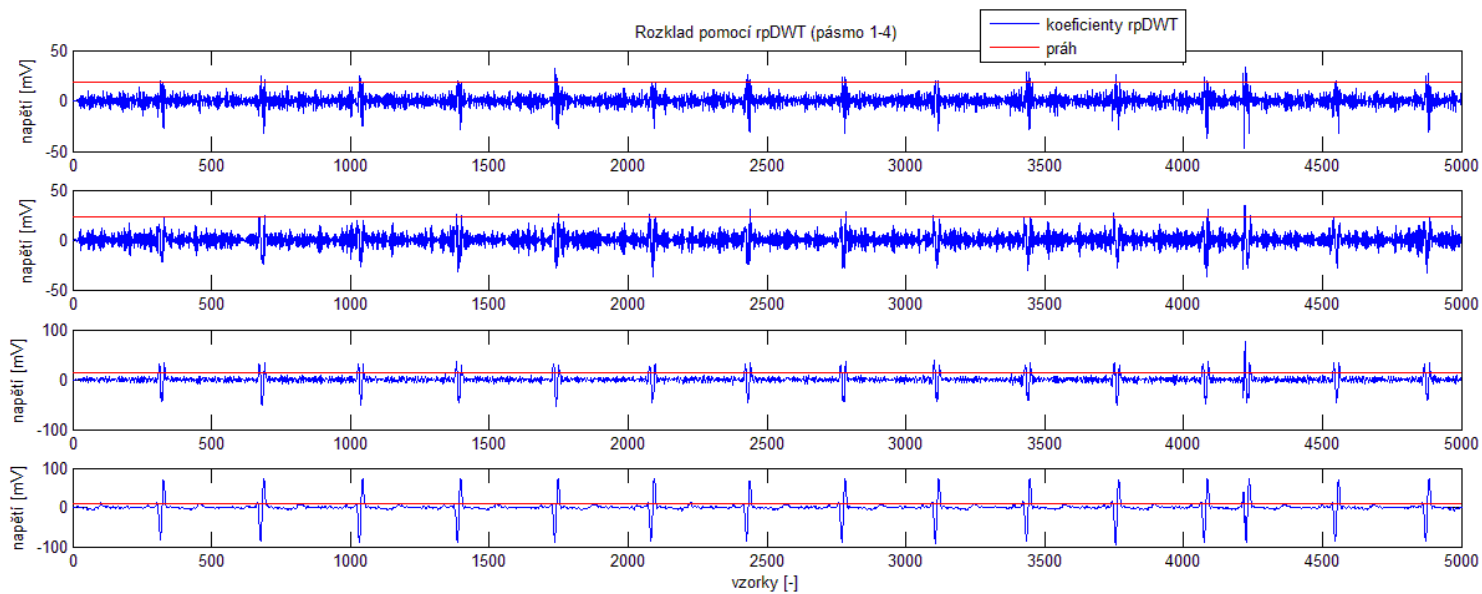
- 2) Pro statistické testování na knihovně CSE je opět pro jednoduchost využito skriptu *statistika*, kde uživatel nastaví vstupní parametry: typ vlnky (vlnka1, vlnka2), stupeň rozkladu (stupen_R1, stupen_R2), vstupní SNR (SNR_dB), empirickou konstantu a vybere variantu použité DTWT (1 = paketová; 0 = dyadická). Výstupem je opět výstupní SNR po vyhodnocení celé databáze CSE. V případě testování pomocí programu *FILTERING_TESTER* je nutné na řádku 85 nastavit hodnotu empirické konstanty a v případě testování varianty paketové DTWT odkomentovat řádek 86, v případě varianty dyadické DTWT odkomentovat řádek 87 a 88.

- 3) Pro testování genetického algoritmu je využito skriptu *GA_optimalizace* (pro hledání empirické konstanty) a *GA_2_optimalizace* (pro hledání empirické konstanty a stupně rozkladu). V úvodní části zdrojového kódu lze nastavit několik parametrů GA a to: počet bitů, počet jedinců v populaci, pravděpodobnost mutace či křížení, zapnutí či vypnutí elitářství, maximální počet iterací a rozsah, ve kterém hledáme empirickou konstantu. Poté stačí spustit skript a doporučené hodnoty se vypíší do Command Window. Proces je ale časově velmi náročný cca. hodina i více. Pro nastavení ostatních parametrů jako je: typ vlnky, stupně rozkladu, zvolená metoda (paketová x dyadická) a vstupní SNR lze využít kritériální funkcí (*GA_kriterialni_fc* a *GA_2_kriterialni_fc*).

Příloha C: Vývojový diagram funkce "rpDWT".



Příloha D: Ukázka prahování. Stupeň rozkladu 3, vlnka 'bior1.3', tvrdé prahování.



Ke srovnání jsou zde uvedeny první čtyři stupně rozkladu před a po prahování. Na další straně jsou zobrazena zbylá pásma 5 až 8.

