



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

SPEKTRÁLNÍ ANALÝZA EEG SIGNÁLU

SPECTRAL ANALYSIS OF THE EEG SIGNAL

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. MICHAL BLATNÝ

VEDOUCÍ PRÁCE
SUPERVISOR

Ing. JAN HROZEK

BRNO 2011



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav biomedicínského inženýrství

Diplomová práce

magisterský navazující studijní obor
Biomedicínské a ekologické inženýrství

Student: Bc. Michal Blatný
Ročník: 2

ID: 73082
Akademický rok: 2010/2011

NÁZEV TĚMATU:

Spektrální analýza EEG signálu

POKYNY PRO VYPRACOVÁNÍ:

Seznamte se s principy snímání a získávání EEG dat. Prostudujte problematiku frekvenční spektrální analýzy a časově-frekvenční spektrální analýzy. Získané poznatky využijte při návrhu uživatelské aplikace pro spektrální analýzu EEG signálu v programovém prostředí Matlab. Pro analýzu budou použita již naměřená data z EEG systému Alien, který je k dispozici na UBMI.

DOPORUČENÁ LITERATURA:

- [1] ROZMAN, J., et al.: Elektronické přístroje v lékařství. 2006. vyd. Praha: Academia, 2006. 408 s. ISBN 80-200-1308-3.
[2] JAN, J. Číslicová filtrace, analýza a restaurace signálů / 2. upr. a rozš. vyd. Brno : VUTIMUM, 2002. 427 s. ISBN 80-214-2911-9

Termín zadání: 15.10.2010

Termín odevzdání: 20.5.2011

Vedoucí práce: Ing. Jan Hrozek

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 dílech 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 částí druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Cílem diplomové práce je seznámit čtenáře se základy měření EEG signálu, jeho vlastnostmi v časové i frekvenční oblasti a popsat princip následující analýzy.

Hlavní částí této práce je terapeutická metoda biofeedback, která je vytvořena pomocí programu LabView pro použití v reálném čase.

Projekt také obsahuje aplikaci vytvořenou v programu Matlab, která vytváří amplitudový brain mapping.

KLÍČOVÁ SLOVA

Elektroencefalografie, EEG, vlnová pásma, spektrální analýza, biologická zpětná vazba, amplitudová mapa, matlab, labview, stacionarita, Biopac,

ABSTRACT

Master's thesis deal about electroencefalography, measurement EEG signals and analysis measuermed signals. Project contains two basis practical parts. Firts part contain two PC's programs that's are used to fundamental analysis to frequence-domain and visual display of brain mapping created with Matlab. Second chapter of practical parts includes two PC's programs created with LabView. First of them is the EEG biofeedback making use for advanced analyses and second program is used to detection segment of stacionarity.

KEYWORDS

Electroencephalography, EEG, EEG wave, spectral analysis, biofeedback, brain mapping, matlab, labview, stacionarity, Biopac.

BLATNÝ,M. Spektrální analýza EEG signálu. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií. Ústav biomedicínského inženýrství, 2011. 66 s., 9 s. příloh. Diplomová práce. Vedoucí práce: ing. Jan Hrozek

PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma Spektrální analýza EEG signálu jsem vypracoval samostatně pod vedením vedoucího semestrální 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 semestrální práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne

.....

(podpis autora)

PODĚKOVÁNÍ

Děkuji vedoucímu semestrální práce ing. Janu Hrozkovi za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne

.....

(podpis autora)

OBSAH

Seznam obrázků	ix
Úvod	11
1 Elektroencefalografie	12
1.1 Elektroencefalogram	12
1.2 EEG vlny	13
1.2.1 Delta vlny	13
1.2.2 Theta vlny	13
1.2.3 Alfa vlny	13
1.2.4 Beta vlny	13
2 Elektroencefalograf	15
2.1 Elektrody	15
2.1.1 Elektrody v EEG	15
2.1.2 Rozhraní elektroda – kůže	15
2.1.3 Elektrodová čepice	16
2.2 Měřic odporu elektrod	17
2.3 Přepínač	18
2.4 Zdroj kalibračního napětí	18
2.5 Zesilovač	18
2.5.1 Diferenční zesilovač	18
2.6 Filtry	19
2.6.1 Filtr HP	19
2.6.2 Filtr DP	20
2.6.3 Filtr ÚPZ	20
2.7 Registrační systém	20
3 Metody Analýzy EEG	20
3.1 Časová oblast	21
3.1.1 Dlouhodobý záznam	21
3.1.2 Videozáznam a signál EEG	21
3.1.3 Neuronové sítě	21
3.2 Spektrální analýza	21

3.2.1	Brain mapping.....	22
3.3	Časově-frekvenční analýza.....	23
3.3.1	Spektrogram.....	23
3.3.2	Vlnková transformace.....	24
3.4	Dipólová analýza.....	24
3.5	Evokované potenciály.....	24
4	Časová a frekvenční analýza	25
4.1	Fourierova transformace.....	25
4.1.1	Zpětná Fourierova transformace.....	26
4.2	Rychlá Fourierova transformace.....	27
4.2.1	FFT v časové oblasti.....	27
4.2.2	FFT ve frekvenční oblasti.....	28
4.3	Vlnkové transformace.....	28
4.3.1	Spojité vlnkové transformace.....	29
4.3.2	Diskrétní vlnková transformace.....	30
4.4	Stochastické procesy.....	31
4.4.1	Nestacionární stochastický proces.....	31
4.4.2	Stacionární stochastický proces.....	32
4.5	Odhad výkonových spekter stochastických procesů.....	32
4.5.1	Metoda periodogramu.....	32
4.5.2	Metoda pásmové lineární filtrace.....	34
5	Biofeedback	35
5.1	Praktické využití biofeedbacku.....	35
5.2	Biofeedback a hry.....	35
5.3	Biofeedback a epilepsie.....	36
5.4	ADHD.....	36
5.5	Úspěšnost biofeedbacku.....	36
6	Praktická část – analýza v Matlabu	38
6.1	Základní analýza.....	38
6.2	Brain mapping.....	40
7	Praktická část – EEG Biofeedback	41
7.1	Biopac MP35.....	42
7.2	Zvuková karta.....	44

7.3	Terapeutický monitor.....	45
7.3.1	Nastavení filtrů	46
7.3.2	Biofeedback	48
7.3.3	Celkový průběh.....	49
7.3.4	Stacionarita	51
7.3.5	3D, STFT, FFT	52
7.3.6	Databáze (Database)	53
7.3.7	Histogram aktivity	54
7.4	Pacientský monitor	55
7.4.1	Balon.....	55
7.4.2	Plachetnice	56
7.4.3	Box.....	56
7.5	Použitý algoritmus	57
7.6	Diskuze nad dosaženými výsledky	59
8	Závěr	62
	Literatura	64
	Seznam zkratk	65
	Seznam příloh	66

SEZNAM OBRÁZKŮ

Obr. 1.1 – Elektroencefalogram – příklad snímaného EEG signálu.....	12
Obr. 1.2 – Vlnová pásma EEG signálu	14
Obr. 2.1– Blokové schéma EEG přístroje.....	15
Obr. 2.2 – Náhradní elektrické schéma kůže	16
Obr. 2.3 – Znázornění zapojení elektroda-kůže.....	16
Obr. 2.4 – Elektrodotová čepice - rozmístění elektrod	16
Obr. 2.5 – Náhradní schéma měření přechodového odporu elektrod	17
Obr. 2.6 – Princip diferenčních zesilovačů.....	19
Obr. 4.1 – Mateřská vlnka a její modifikace.....	29
Obr. 4.2 – Dyadické vzorkování v prostoru měřítka – čas	30
Obr. 4.3 – Rodina funkcí jako zdroj náhodného signálu	31
Obr. 4.4 – Princip výpočtu periodogramu	33
Obr. 4.5 – Princip výpočtu periodogramu se segmentováním.....	33
Obr. 4.6 – Princip pásmové lineární filtrace	34
Obr. 5.1 – Jednoduchá hra pro biofeedback	36
Obr. 6.1– Matlab - časový průběh EEG signálu	38
Obr. 6.2 – Matlab - spektrum EEG	39
Obr. 6.3 – Matlab - výkonové spektrum	39
Obr. 6.4 – Doba výpočtu interpolace s různým koeficientem	40
Obr. 7.1 – Blokové schéma zapojení EEG biofeedbacku.....	41
Obr. 7.2 - Zapojení EEG elektrod dle manuálu firmy Biopac	41
Obr. 7.3 – Přední panel přístroje Biopac MP35.....	42
Obr. 7.4 – Zadní panel přístroje Biopac MP35	43
Obr. 7.5 – Popis analogového výstupního portu DSUB	43
Obr. 7.6 – Vstupní frekvenční charakteristika zvukové karty AD 1882	44
Obr. 7.7 – Detail vstupní frekvenční charakteristiky zvukové karty AD1882	45
Obr. 7.8 – První záložka - Nastavení filtrů	46
Obr. 7.9 – Druhá záložka - Biofeedback	48
Obr. 7.10 – Třetí záložka - Celkové průběhy	50
Obr. 7.11 – Čtvrtá záložka – Stacionarita	51

Obr. 7.12 – pátá záložka - 3D, STFT, FFT	52
Obr. 7.13 – Záložka šestá - Databáze	53
Obr. 7.14 – Sedmá záložka - Histogram aktivity	55
Obr. 7.15 – Hra Balon.....	55
Obr. 7.16 – Hra Plachetnice.....	56
Obr. 7.17 – Hra Box.....	57
Obr. 7.18 – Detail prosakování spektra	59
Obr. 7.19 – Frekvenční charakteristika filtrů.....	60

ÚVOD

Tato diplomová práce slouží k seznámení se se základními pojmy v metodice snímání EEG signálů a jeho pozdější časové, frekvenční a časově-frekvenční analýze.

Snímání EEG signálů může sloužit jak k diagnostice, tak i k terapii. Příkladem toho jsou právě vytvořené aplikace v programu Matlab a LabView.

Budeme se zabývat technickými vlastnostmi přístrojů pro snímání EEG signálů a vlastního řešení zapojení pomocí systému Biopac MP35 a osobního počítače.

Podrobněji si vysvětlíme princip Fourierovy a rychlé Fourierovy transformace se související zpětnou transformací ve spojení se spektrem signálu. Neopomeneme ani princip vlnkové transformace a spektrogramu, jenž se řadí k nejjednoduššímu typu časově-frekvenčnímu zobrazení. Důležitou součástí práce je vysvětlení pojmu stacionarita, se kterou se u náhodných procesů setkáváme.

Bude následovat popis využití EEG v terapii pomocí pojmu biofeedback, jímž se diplomová práce z převážné části zabývá.

Praktická část je rozdělena do dvou kapitol. První kapitola informuje o vytvoření programů pro spektrální analýzu a brain mapping v programu Matlab. Druhá kapitola popisuje hlavní praktickou část, a sice vytvoření aplikace pro biofeedback v reálném čase v programu LabView. Úkolem vytvořené aplikace je zobrazení měřené EEG aktivity a následného ovládání počítačové hry při překročení nastavených mezí aktivit v různých frekvenčních pásmech. Zde se také setkáme s ověřením stacionarity procesu.

V předposlední části se můžeme pozastavit nad diskuzí o možných výsledcích, které jsou omezeny technickými a teoretickými vlastnostmi zpracování signálu.

Poslední část pojednává o dosažených výsledcích.

1 ELEKTROENCEFALOGRAFIE

Elektroencefalografie (EEG) je diagnostická metoda, při které se analyzují snímané biologické elektropotenciály vznikající v mozku. Elektrické impulsy v mozku vznikají každým okamžikem, stejně tak jak je tomu například u srdce (EKG).

Metody snímání rozdělujeme na invazivní a neinvazivní. Invazivní metody obnáší chirurgický zákrok v lebeční oblasti a přiložení elektrod přímo na mozek. Pro jejich náročnost a životní nebezpečí se proto používají jen zřídka. U neinvazivních metod se používají elektrody povětšinou umístěné ve speciální čepici.


Historie elektroencefalografie sahá do druhé poloviny 19. století, kdy v roce 1875 Richard Calton naměřil elektrickou aktivitu přímo na mozkové tkáni u králíků a opic. V roce 1929 Hans Berger zjistil, že naměřená aktivita se mění v závislosti na stavu uživatele. Tím položil základy pro využívání EEG v lékařské diagnostice a terapii.

V dnešní době se EEG diagnostika využívá například při poškození mozku, poruch spánku, epilepsii či migréně. Při úrazech, mozkových příhodách či nádorech lze s touto metodou lokalizovat místo poškození. Pomocí EEG také dokážeme posoudit hloubku bezvědomí u lidí v kómatu.

1.1 Elektroencefalogram

Elektroencefalogram je záznam elektrické aktivity mozku, který se uživateli představuje jako vizuální obraz. Prakticky jde o graf popisující změnu elektrického potenciálu (osa y) na čase (osa x).

Elektroencefalogram neznázorňuje přímo elektrickou aktivitu jednoho neuronu (nervové buňky), jak je tomu například u vpichových elektrod elektromyografu (záznam svalové aktivity), ale je určen sumací neuronové aktivity na povrchu hlavy. Příklad snímaného signálu lze vidět na Obr. 1.1 [1].



Obr. 1.1 – Elektroencefalogram – příklad snímaného EEG signálu

1.2 EEG vlny

Signál získaný záznamem elektrické aktivity mozku obsahuje určité charakteristické vlny označené písmeny řecké abecedy, jak lze vidět na Obr. 1.2 [3]. Tyto vlny nejsou vidět v časové ose přímo, jako například u snímání elektropotenciálů srdce s typickým QRS komplexem či vlnou P a T. Signál EEG, jakož to jakýkoliv signál, je tvořen sinusovými průběhy s určitou frekvencí a amplitudou. Tohoto se právě využívá v naší aplikaci a EEG signál se rozděluje do několika vlnových pásem v závislosti na frekvenci. V časovém průběhu se mohou ukázat tzv. grafoelementy. Jedná se o zvlnění způsobené artefakty biologickými - mrknutím, kašlem, nebo technickým – elektrody, přístroj či vnější prostředí.

1.2.1 Delta vlny

Od narození do jednoho roku dítěte je v EEG patrná málo pravidelná delta aktivita o frekvenci $1 \div 4$ Hz obvykle vysoké amplitudy. V tomto věku je to fyziologická základní aktivita, která se netlumí otevřením očí. U dospělého člověka se toto pásmo objevuje při bezesném spánku, případně během bezvědomí způsobeného nemocí či úrazem. Ve spánku mají vlny delta amplitudu i 100 mV. [2]

1.2.2 Theta vlny

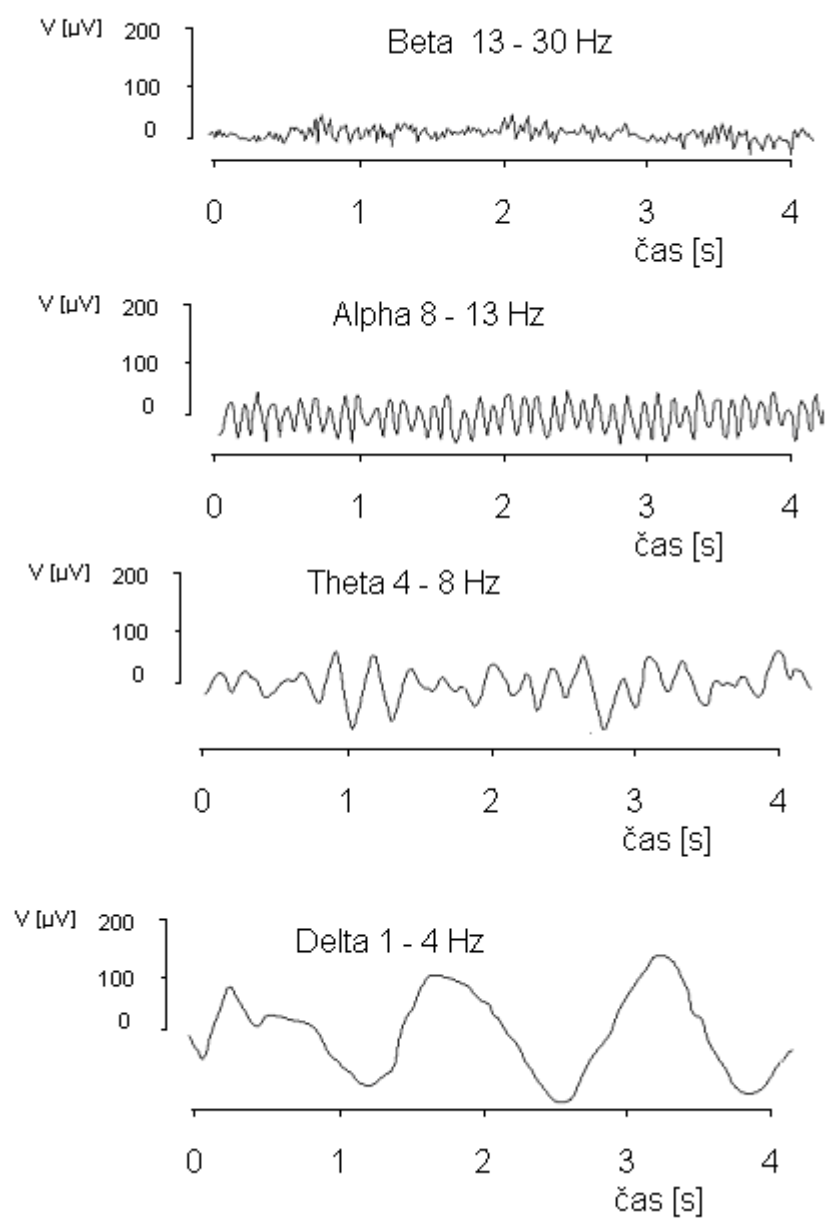
Od jednoho roku věku do tří let je dominantní theta rytmus o frekvenci $4 \div 7$ Hz. U zdravých osob se theta vlny vyskytují v centrální, temporální (spánkové) a parietální (temenní) oblasti. Jestliže je amplituda theta vlny dvakrát vyšší než je vlna alfa, tak tento stav považujeme za patologický. Theta pásmo se vyskytuje i při spánku. Mysl ani tělo nereagují samy o sobě na žádné smyslové podněty. Často dochází k samovolnému uvolnění obrazových informací z podvědomé paměti a jejich selektivní prezentaci v mysli - snů. (Přítomnost snu je vždy provázena slabou radiací vln alfa a beta.) [2]

1.2.3 Alfa vlny

Alfa pásmo je charakterizováno frekvencí v rozmezí $8 \div 13$ Hz a střední amplitudou, která je $30 \div 60$ μ V. V bdělém stavu je maximum nad zadními oblastmi mozkových hemisfér. Reaktivita této aktivity je velmi dobrá, tlumí se především otevřením očí, ale i spontánně zvýšenou pozorností. Alfa aktivita je také charakteristická pro stadium těsně před usnutím. Alfa aktivita se začíná objevovat v období pátého až sedmého roku života dítěte. [2]

1.2.4 Beta vlny

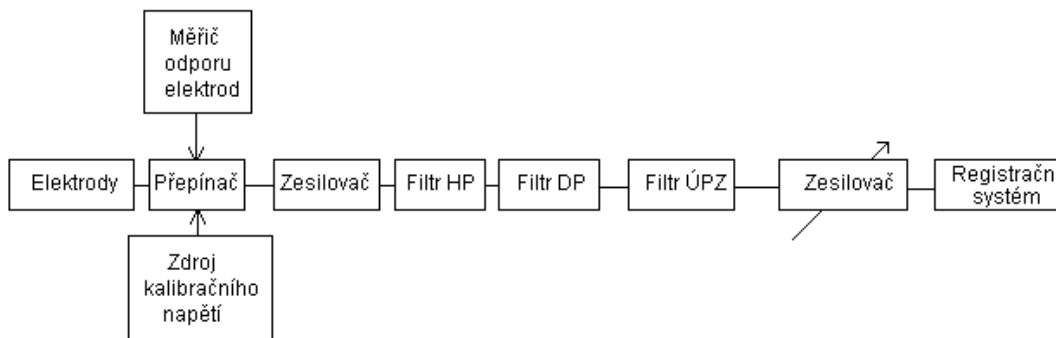
Pásmo beta se objevuje současně s alfa aktivitou. Frekvence beta vlny je $14 \div 30$ Hz. A její amplituda je nízká $20 \div 30$ μ V. Pásmo beta charakterizuje vědomé smyslové soustředění na naše okolí, připravenost reagovat, akceschopnost. Pásma vyšší (kolem 30 Hz) se pak objevují při podráždění, trémě, úzkosti, nebo vysoce náročných životních situacích. [2]



Obr. 1.2 – Vlnová pásma EEG signálu

2 ELEKTROENCEFALOGRAF

Ke kvalitnímu měření mozkové aktivity je zapotřebí technicky vyspělých elektroencefalografů. Tento lékařský přístroj je sestaven z několika funkčních bloků, jak znázorňuje Obr 2.1. Následující podkapitoly popíší funkci a požadavky těchto bloků.



Obr. 2.1– Blokové schéma EEG přístroje

2.1 Elektrody

Elektroda je prvním elektrickým prvkem v technice snímání a zpracování EEG signálu. Zprostředkovává přenos signálu přímo z pacienta dál do lékařského přístroje a přichází v přímý kontakt s pacientem. Zde se mohou objevit rušivé vlivy, například přechodový odpor nebo změna elektrických vlastností, a proto jsou na ně kladeny vysoké nároky.

2.1.1 Elektrody v EEG


Pro měření elektrické činnosti mozku se využívají elektrody Ag/AgCl. Elektrody jsou pokryty vrstvou chloridu stříbrného a nepodléhají tolik polarizačním změnám. Jsou to elektrody tzv. druhého druhu. Navíc mají lineární V-A charakteristiku.

2.1.2 Rozhraní elektroda – kůže


Náhradní schéma tohoto rozhraní, které lze vidět na Obr. 2.2, se dá popsat jako rezistor R_t zapojený v sérii s paralelní kombinací rezistoru R_s u kondenzátoru C_s a sériovým spojením elektrického zdroje E_{ps} .

Rezistor R_t představuje hlubší vrstvy kůže. Impedance $R_s C_s$ znázorňuje epidermis a E_{ps} vysvětluje koncentrační rozdíl iontů u semipermeabilní vrstvy nejsvrchnější vrstvy epidermu zvanou stratum cornemu.

Samotný odpor kůže se může měnit mezi 0,5 k Ω a 100 až 500 k Ω . Dále se může projevit vliv potních žláz.



Obr. 2.2 – Náhradní elektrické schéma kůže




Obr. 2.3 – Znázornění zapojení elektroda-kůže

Jak lze vidět na Obr. 2.3, mezi pokožku a elektrodu se nanáší malá vrstva gelu, tzv. elektroodové pasty. Tyto gely zlepšují kontakt a tím zajišťují malou impedanci ve spojení elektroda – tkáň. Aplikované gely se tak podílí na změně vodivosti iont - elektron. Vedení elektrického proudu u lidského organismu je totiž způsobeno ionty, kdežto u elektrody je přenos pomocí elektronů. Gely musí být šetrné k lidské pokožce a nesmí škodit organismu. Při dlouhodobých snímání se využívá látek proti vzniku plísní a bakteriím.

2.1.3 Elektroodová čepice

Jednoduché snímání EEG signálů umožňují speciální čepice, ve kterých jsou umístěny snímací elektrody. Rozvržení snímacích elektrod lze vidět na Obr. 2.4 [5].



Obr. 2.4 – Elektroodová čepice - rozmístění elektrod

Různé části mozku jsou odpovědné za elektrickou aktivitu při různých činnostech. Proto každá elektroda snímá aktivitu určitého centra. Například elektrody F8 snímají

aktivitu z emočního centra mozku, T5 a T6 jsou určeny pro paměťové centrum. C3, C4, Cz snímají napětí ze sensorické a motorické části. Za elektrické impulsy z centra vnímání a rozlišování jsou odpovědné elektrody P3, P4 a Pz.

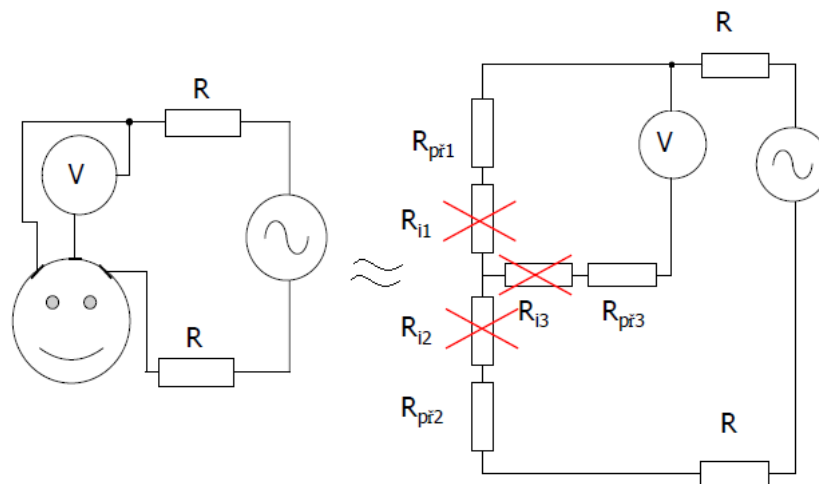
Pro rozmístění elektrod je definován podle mezinárodní úmluvy systém 10/20, který je určen anatomickými rozměry hlavy. Mapa rozložení elektrod na povrchu hlavy se dá představit jako zeměpisné poledníky a rovnoběžky, které jsou od sebe právě 10 % a 20 % obvodu. Jejich průsečíky určují polohy snímací elektrody.

Signál z elektrod se měří vůči referenční elektrodě, ta ovšem není přesně určena. Většinou se používají elektrody na ušních lalůčkách, elektroda Cz, Fpz, nebo signál ze zápěstí či nohy.

Elektrodové čepice se vyrábí v různých velikostech. Pro správné snímání je potřeba elektrodového gelu, jenž se nanáší pomocí dlouhé jehly na elektrodu. Pohled na dlouhou jehlu může mít negativní vliv na pacienta a jeho psychické rozpoložení.

2.2 Měřic odporu elektrod

V principu lze odpor elektrod stanovit obyčejným ohmmetrem – používá se zřídka - pacientem protéká ss. proud, který se nepříznivě uplatní na polarizaci elektrod.



Obr. 2.5 – Náhradní schéma měření přechodového odporu elektrod

Proto se používá zapojení na Obr. 2.5 [5] využívající zdroj střídavého proudu. Měřicí obvod je napájen ze zdroje střídavého napětí s frekvencí 15 Hz. Vnitřní odpor zdroje R je velký. Tímto způsobem jsou zapojeny všechny elektrody (zde pouze dvě). Je potřeba pouze jeden zdroj napětí a řadu odporů – dle počtu kanálů. Vlastnosti odporů jsou dané vzorcem (2.1).

$$R \gg R_{př1}, R_{př2}, R_{př3} \quad R_{i1}, R_{i2}, R_{i3} \ll R_{př1}, R_{př2}, R_{př3} \quad (2.1)$$

Vnitřní odpory organismu R_i lze zanedbat (nahradíme zkratem). $R_{př3}$ jsou přechodové odpory elektrod. Jako voltmetr se využívá měřící kanál elektroencefalografu. Úbytek napětí na přechodovém odporu lze na komparátoru porovnat s předem nastavenou hodnotou a signalizovat pomocí LED diody zda je přechodový odpor dostatečně malý. [4]

2.3 Přepínač

Tento blok slouží k přepínání svodů. Ten umožňuje výběr elektrod pro další použití. Většinou se jedná o přednastavenou skupinu elektrod, či elektrodu samotnou.

2.4 Zdroj kalibračního napětí

Abychom mohli správně kvantitativně měřit, je třeba přístroj kalibrovat.

EEG přístroje se kalibrují s citlivostí $100 \mu\text{V/cm}$.

Pro kalibraci přístroje existují následující metody:

1) Připojení všech paralelně spojených vstupů zesilovače k jednomu zdroji kalibračního napětí – zdroj kal. napětí je obvykle generátor obdélníkových impulsů nebo napěťový skok.

2) Připojení jednotlivých vstupů zesilovače k několika zdrojům kalibračního napětí – složitě; lze provádět kontrolu citlivosti i v průběhu snímání.

3) Biologický test – všechny elektrody se spojí a přivede se na ně biologický signál přímo z pacienta. Pokud mají všechny kanály přístroje stejné vlastnosti, měl být ve všech kanálech stejný záznam. [4]

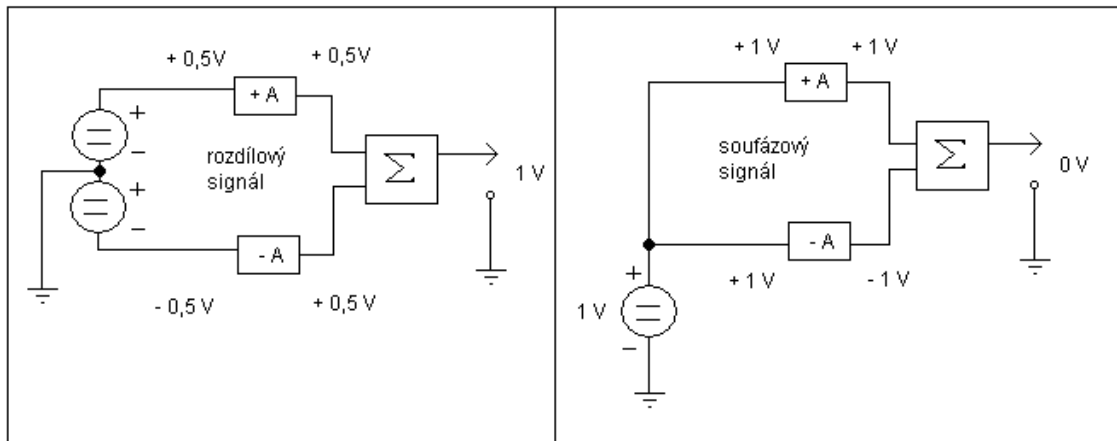
2.5 Zesilovač

Zesilovače biologických signálů zprostředkovávají funkci zesilovače naměřeného napětí, nebo isolačního zesilovače, kdy oddělují zdroj signálu od další částí přístroje. Požadavky na ně kladeny vyhází z ideálních předpokladů, a sice nekonečně vysoká hodnota napěťového zesílení, nulová hodnota výstupní impedance, nekonečně vysoká hodnota vstupní impedance, nulový šum.

Reálně požadujeme od zesilovačů, aby neovlivňovaly měřící proces, jejich vstupní odpor byl ($10^6 \div 10^9 \Omega$), hodnota zesílení $20\,000 \div 50\,000$, aby měly velkou hodnotu diskriminačního činitele CMRR, zanedbatelný únikový proud, který protéká vstupním obvodem a uzavírá se v pacientovi.

2.5.1 Diferenční zesilovač

Pro měření biologických signálů se používají diferenční zesilovače. Ty umožňují potlačit napětí z rušivých prvků a zesílit užitečný signál..



Obr. 2.6 – Princip diferenčních zesilovačů

Funkce diferenčních zesilovačů je patrná z Obr. 2.6 a ze vzorce určujícího diskriminační činitel (2.2) označovaného jako $CMRR$, kde A_{souf} označuje zesílení soufázového signálu (například napětí, které se dostane na svorky z elektrovedné sítě, indukci atd.) a A_{roz} je zesílení rozdílového signálu. Od soufázového zesílení požadujeme nejvyšší možné hodnoty, naopak u zesílení rozdílového hodnoty nejnižší, abychom získali vysoké hodnoty $CMRR$.

$$CMRR = Kd = 20 \log \frac{A_{roz}}{A_{souf}} . \quad (2.2)$$

V praxi se rozdílové napětí zesílí 10^6 x více než soufázové.

V blokovém schématu zobrazeném na Obr.2.1 jsou použity zesilovače dva. První slouží jako předzesilovač, neboť EEG signály jsou v řádech desítek μV a také z výše uvedeného důvodu eliminace soufázového napětí. Další zesilovač je zapojen za filtrační bloky, kde slouží ke konečnému volitelnému zesílení.

2.6 Filtry

Filtrování je neodmyslitelnou součástí měření a zpracování signálů. Používají se pro odstranění rušivých vlivů nebo pro výběr určitých frekvenčních pásem. Filtry se dělí na analogové, nebo digitální.

2.6.1 Filtr HP

Filtr horní propust je zapojený jako jednoduchý analogový RC článek a má za úkol eliminovat stejnosměrnou složku, která je zdrojem rušení. Dolní mezní kmitočet je kolem 0,5 Hz. Je-li v signálu stejnosměrná složka, je záznam poznamenán tzv. driftem, což se projevuje posunem hlavní linie. Použité filtry mají strmost přenosové charakteristiky 6 dB/okt., díky tomu v záznamu zůstanou i nízkofrekvenční signály důležité pro orientaci lékaře – pohyb očí, pocení.

2.6.2 Filtr DP

Užitečný signál standardně používaný v elektroencefalografické metodologii obsahuje složky $0,5 \div 70$ Hz. Vyšší frekvence by neměly v analýze využít, a proto se používají filtry dolní propusti. Vyšší frekvence by také kladly větší nároky na vzorkovací kmitočet.

Pokud není přímo zapojený filtr dolní propusti, horní kmitočet je určený zapisovacím systémem. Tento kmitočet se pohybuje v rozmezí 120 až 500 Hz.

2.6.3 Filtr ÚPZ

U EEG se setkáváme s několika filtry úzko-pásmových zádrží. Nejdůležitější je filtrace na 50 Hz. Rušení na tomto kmitočtu je způsobeno síťovým kmitočtem a v záznamu se projevuje jako pravidelné kmitání s malou amplitudou.

Tato filtrace ale způsobuje zkreslení nejdůležitějších grafoelementů – hrotů. Filtry mají přenosovou charakteristiku strmější – 16 dB/okt.

Další úzko-pásmové filtry jsou určeny pro vizualizaci jednotlivých vlnových pásem. Například filtr s mezním kmitočtem $8 \div 13$ Hz propouští pouze vlnové pásmo alfa.

2.7 Registrační systém

Registrační (zapisovací) systémy zaznamenávají naměřený signál. První systémy byly analogové. Používal se osciloskop s jedním a později i více kanály, ten ovšem záznam pouze ukazoval.

První zapisovací systém byl galvanometr s inkoustovým zápisem přímo na papír. Rychlost zápisu se ustálila na 30 mm/s a k zápisu signálu se zobrazuje mřížka dělicí čas po 200 ms. Citlivost přístroje je $100 \mu\text{V/cm}$.

Koncem 20. století se začaly používat ke zpracování počítače, a tím se změnily i registrační přístroje. Měřený a upravený EEG signál je zobrazován na monitor a poté v digitální podobě ukládán na paměťová média. Většina lékařů považuje pro vyhodnocování papírové zobrazení za nejvhodnější, to je ovšem pro vysoké náklady jen málo přípustné. [6]

3 METDOY ANALÝZY EEG

Snímaný EEG signál můžeme analyzovat ve dvou základních oblastech. Jedná se o časovou a frekvenční oblast. Jejich kombinací získáme třetí důležitou oblast, časově-frekvenční.

3.1 Časová oblast

Zobrazujeme-li mozkovou aktivitu v závislosti na čase bez použití transformací, jedná se o analýzu v časové oblasti. Zde pozorujeme hodnotu aktivity jako celku, nebo při použití frekvenčních filtrů aktivitu v určitých pásmech.

3.1.1 Dlouhodobý záznam

Pro průkaz diagnózy epilepsie, při vyhledávání hlavního epileptického ložiska a k dalším účelům je nutné často snímat signál EEG po dobu 24 až 72 hodin při běžné činnosti pacienta. Prohlížet takový záznam je náročná úloha, a proto se používají postupy, které vyhledávají typické grafoelementy nebo automaticky klasifikují a hodnotí křivku.

Metoda Wave-Finder umožňuje postupnou segmentaci do kvazistacionárních úseků, jejich klasifikaci a barevnou identifikaci významných grafoelementů (tvarových charakteristik grafických záznamů funkcí organismu) v závislosti na amplitudě. [6]

3.1.2 Videozáznam a signál EEG

Zvláštní alternativou dlouhodobého sledování signálu EEG je jeho kombinace se synchronním natáčením chování pacienta. Během pobytu v místnosti uzpůsobené životním aktivitám se zaznamenává jeho chování jednou nebo více kamerami. Současně je zaznamenáván i zvuk. Signál EEG je telemetricky přenášen do společné záznamové jednotky a na monitor umístěný v pracovně laborantky, která navíc zaznamenává poznámky (jídlo, spánek atd.). [6]

3.1.3 Neuronové sítě

Samo učící se neuronové sítě se používají pro vyhledávání grafoelementů – ať již artefaktů technických, biologických nebo způsobených patologií (epileptiformní projevy). Napodobením postupu lékaře je aplikace neuronových sítí na rozpoznávání podobné analýze obrázků, při které však zásadně záleží na rozhodování konkrétního experta a výsledky jsou závislé na jeho zkušenostech. [6]

3.2 Spektrální analýza

Nejstarší a nejrozšířenější metodou zpracování sejmutého signálu EEG je Fourierova analýza. Použijeme FFT, přibližuje se totiž pohledu lékaře na graf – na základní aktivity.

Transformace zvoleného úseku grafu z časové do frekvenční domény umožňuje s jistým přiblížením říci, jaké je celkové množství vln v jednotlivých frekvenčních pásmech, popř. určit frekvenci, která je nejvíce v záznamu zastoupena. Tento postup nahrazuje hodnotící pracovník zkušeností, ale nedokáže je přesně kvantifikovat. Na druhé straně však zásadně záleží na výběru intervalu pro výpočet.

Jednoučelové několika kanálové přístroje nebo funkční bloky komplexních monitorovacích jednotek jsou používány ke sledování pacientů při operacích, na ARO

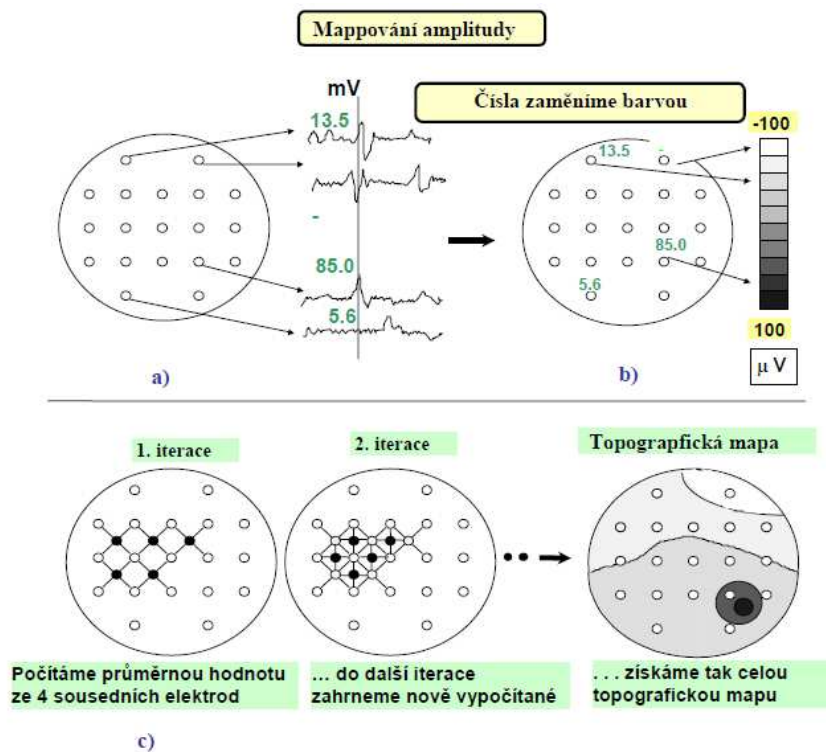
a neurologických JIP. Podle způsobu nastavení automaticky hlásí alarmem snížení činnosti mozku v důsledku nedostatečného metabolického zásobení. Rychlá Fourierova transformace je základním výpočtem i pro další, méně rozšířené postupy, jakými jsou sledování koherencí, okamžitých frekvencí nebo stanovení počátku tzv. generalizovaných výbojů. [6]

3.2.1 Brain mapping


Topografická mapování aktivity EEG, označována jako „brain mapping“ vznikla na začátku 80. let minulého století. Tento způsob mapování ukazuje plošnou interpolovanou aktivitu mozku snímanou jednotlivými elektrodami. V praxi se nejčastěji zobrazuje výkon na jednotlivých frekvencích či pásmech, získaný pomocí FFT. Současně se i zobrazí časové zpoždění mezi jednotlivými kanály nebo vzájemná koherence pro sledování interhemisferálních vztahů.

Princip topografického mapování a interpolačního výpočtu je patrný z Obr. 3.1 [7], kde pro zjednodušení bylo použito mapování amplitudy, nikoliv spektrální hustoty. Označení písmeny určuje postup analýzy.

Při frekvenčním mapování se využívá stejného principu jen s tím rozdílem, že na začátku provedeme FFT pro určitý časový okamžik, a tím brain mapping nezobrazí aktuální amplitudu v čase, ale výkonovou hustotu na vybrané frekvenci. Výsledek analýzy, který vidíme na Obr. 3.2 [7], zobrazuje mapování na každé frekvenci nebo na určitých pásmech



Obr. 3.1 – Amplitudový brain mapping



Obr. 3.2 – Frekvenční brain mapping zobrazující sled výkonových hustot na více frekvencích

3.3 Časově-frekvenční analýza

Chceme-li znát, ve které časové oblasti se nachází požadované frekvence, je třeba použít analýzu časově-frekvenční. Použít lze metodu spektrogramu nebo analýzu pomocí vlnkové transformace.


3.3.1 Spektrogram

Jedná se o 2D nebo 3D zobrazení EEG záznamu v závislosti na čase, frekvenci a intenzitě. Jedná se tedy o nejjednodušší typ časově-frekvenční analýzy. Na ose x je časové měřítko v sekundách, nebo minutách. Osa y zaujímá frekvenční měřítko v Hertzech. Intenzita signálu je ve 2D spektrogramu zobrazena barvou, přičemž musí být zobrazena barevná škála jako legenda. Ve 3D spektrogramu je intenzita znázorněna třetí osou.

Problém u tohoto zobrazení je ve výběru časového okna. Na jeho délce závisí časová a frekvenční rozlišovací schopnost. Výběrem krátkého časového intervalu se získá dobrá rozlišovací schopnost v čase, ovšem má negativní dopad na frekvenční rozlišovací schopnost. V malém časovém okně nedokážeme analyzovat vyšší frekvence.

Výběr časového okna je tedy určitým kompromisem. V praxi se používají spektrogramy s různými délkami časového okna, například v dyadické stupnici.

V elektroencefalografii se metoda s použitím 3D spektrogramu nazývá metoda zhuštěných spektrálních kulis označovanou pod anglickou zkratkou CSA (Compressed Spectral Arrays). Na obrázku Obr. 3.3 [7]. lze vidět výsledek této metody, kde jsou navíc jednotlivá frekvenční pásma barevně označena.



Obr. 3.3 – Výsledek metody CSA

3.3.2 Vlnková transformace

Vlnková transformace nám dává detailní popis frekvenčních oblastí v závislosti na čase. Na rozdíl od spektrogramu, který nás informuje o intenzitě frekvencí v určitém časovém okně, vlnková transformace nám dává podrobný náhled, ve kterém časovém okamžiku se daná frekvence objevuje a s jakou amplitudou. Jinými slovy nejnižší frekvence budou mít stejnou časovou rozlišovací schopnost jako u spektrogramu, ale vysoké frekvence nabývají tuto rozlišovací schopnost.

3.4 Dipólová analýza

Se zvýšením počtu snímacích elektrod a dostupností vyšetření magnetickou rezonancí vznikly a používají se modely, které umožňují lokalizovat v mozku jeden až tři generátory patologie projevující se na povrchu epileptiformní aktivitou. Cílem je alespoň v části případů nahradit neurochirurgickou metodu snímáním, tzv. stereo EEG. Jde o snímání aktivit ze zanořených multietážových elektrod se snahou nalézt, kde je epileptické ložisko, jehož odstraněním by došlo k vyléčení pacienta [6]. V rámci světového výzkumu se v tomto směru jako nejpřesnější ukázala tzv. Low Resolution Brain Electromagnetic Tomography (LORETA).

3.5 Evokované potenciály

Evokované potenciály lze získat v oblastech mozku, kde dochází ke zpracování vnějších podnětů. Jsou to významné změny neuronové aktivity tedy změny v EEG průběhu. Běžně se používá následujících evokovaných potenciálů:

- VEP – zrakově evokovaný potenciál
- AEP – akusticky evokovaný potenciál
- SSEP – potenciál vzniklý podprahovými elektrickými impulsy na končetinách

4 ČASOVÁ A FREKVENČNÍ ANALÝZA

Jak již bylo řečeno v kapitole 3, naměřený signál lze hodnotit ve dvou, respektive ve třech oblastech. Abychom jej mohli analyzovat a snadněji pochopit význam interpretace, je vhodné se seznámit se základními vlastnostmi signálu a použitých transformací.

4.1 Fourierova transformace

Každý analogový signál se dá rozložit do řady posloupností harmonických vln s určitým koeficientem a tím i zobrazit jeho spektrum. Jelikož je práce orientována na aplikaci ve výpočetní technice, budeme nadále hovořit o diskretizovaném (vzorkovaném) signálu. Signál musí být vzorkován minimálně dvojnásobnou frekvencí, než je maximální frekvence ω_m obsažena v signálu. Jedná se o tzv. Nyquistův teorém (4.1), který pokud není dodržen, dojde k překrytí spektra.

$$\omega_m = \frac{N\Omega}{2}, \quad \Omega = \frac{2\pi}{\tau} \quad (4.1)$$

Spektrum diskrétního signálu $\{f_n\}$ lze vypočítat jako součet spekter posunutých a váhovaných Diracových impulsů dle rovnice (4.2).

$$DFT\{f_n\} = F(\omega) = \sum_{n=-\infty}^{\infty} f_n e^{-j\omega nT} \quad (4.2)$$

Respektive vzorec (4.3) pro signál z leva omezený.

$$DFT\{f_n\} = F(\omega) = \sum_{n=0}^{\infty} f_n e^{-j\omega nT} \quad (4.3)$$

Jelikož DFT je možná pouze u signálu s konečnou délkou, můžeme zvolit ekvidistanční dělení kmitočtové osy, kde interval rozdělíme na $\langle -\varpi_v/2, \varpi_v/2 \rangle$. Tím získáme vzorec (4.4).

$$F(k\Omega) = \sum_{n=0}^{\infty} f_n e^{-k\Omega nT}, \quad \Omega = \frac{2\pi}{NT} \quad (4.4)$$

Fourierovu transformaci lze také vyjádřit vektorovou formou (4.5), kdy převádíme signál z časové oblasti $\{f_n\}$ do oblasti frekvenční $\{F_k\}$ pomocí vektorové matice (bázové funkce) $[W^{kn}]$.

$$[W^{kn}] = \begin{bmatrix} W^0 & W^0 & \dots & W^0 \\ W^0 & W^1 & \dots & W^{N-1} \\ \vdots & \vdots & \ddots & \vdots \\ W^0 & W^{N-1} & \dots & W^{(N-1)^2} \end{bmatrix}, \quad W^{kn} = e^{\frac{-j2\pi}{N}kn} \quad (4.5)$$

$$DFT\{f_n\} = \left\{ F_k = \sum_{n=0}^{N-1} f_n W^{kn} \right\} \quad (4.6)$$

DFT je tedy definovaná jako určitý algoritmus nad jistými vektory čísel, přičemž fyzikální význam je lhostejný. Zpravidla se ovšem pracuje s časovým signálem s odstupem vzorků T a spektrum signálu lze tedy interpretovat jako spektrum v koncepci se spojitým signálem, tedy jako funkci frekvence. Tím je výhodnější použít následující zápis (4.7).

$$F(k\Omega) = \sum_{n=0}^{N-1} f(nT) e^{-jk\Omega nT} \quad (4.7)$$

Chceme-li vyjádřit vztah DFT k harmonické analýze a tím k Fourierově řadě (4.8)

$$f(t) = \sum_{k=-\infty}^{\infty} c_k e^{jk\Omega t}, \quad (4.8)$$

jsou obecně komplexní koeficienty c_k dané následující rovnicí (4.9).

$$c_k = \frac{1}{\tau} \int_0^{\tau} f(t) e^{-jk\Omega t} dt \quad (4.9)$$

Uvažujeme-li funkci frekvenčně omezenou s mezí ω_m , a je-li jedna perioda o délce τ vzorkována počtem vzorků N , čili vzorkovací periodou $T = \tau / N$, lze konstatovat skutečností vzorce (4.10), že DFT nám dává za uvedených podmínek přesné hodnoty koeficientů Fourierova rozvoje. [11]

$$c_k = \frac{1}{N} F_k \quad (4.10)$$

4.1.1 Zpětná Fourierova transformace

Důležitou vlastností u použitých transformací je schopnost získat z vytvořené frekvenční oblasti signál odpovídající původnímu signálu v časové oblasti. Pokud to možné je, říká se dané inverzní funkci metoda zpětné transformace. Fourierova transformace disponuje i zpětnou transformací.

Pro zpětnou transformaci signálu, na který byly aplikovány vzorce (4.6) a (4.7), použijeme následující vzorce IDFT. [11]

$$IDFT\{F_k\} = \left\{ f_n = \frac{1}{N} \sum_{k=0}^{N-1} F_k W^{-nk} \right\} \quad (4.11)$$

$$IDFT\{F(k\Omega)\} = \left\{ f(nT) = \frac{1}{N} \sum_{k=0}^{N-1} F(k\Omega) e^{jnTk\Omega} \right\} \quad (4.12)$$

4.2 Rychlá Fourierova transformace

Fourierova transformace je výpočetně náročná. Pro hodnocení pracnosti uijme jednotku P, deklarovanou jako jeden komplexní součet a součin. Pracnost výpočtu jednoho spektrálního koeficientu užitím vzorce (4.6) je $N \times P$. Pracnost výpočtu celého spektra o N vzorcích je definována jako

$$N^2 P. \quad (4.13)$$

Jelikož se náročnost zvyšuje s druhou mocninou počtu vzorků, je výhodnější používat algoritmus rychlé Fourierovy transformace, označovaný jako FFT (Fast Fourier Transform). Přestože podobné algoritmy pro rychlý výpočet DFT byly publikovány už od roku 1903, s úspěchem se setkaly až algoritmy Cooleyho a Tukeyho.

Algoritmus FFT lze interpretovat jako faktorizaci jádra na součin menších matic, přičemž odpadá většina zbytečných operací. [11]

4.2.1 FFT v časové oblasti

Signál, respektive posloupnost hodnot $\{f_n\}$ s délkou určenou počtem vzorků N (sudé N), se rozdělí na dvě posloupnosti $g_l = f_{2l}$ (sudé členy původní posloupnosti) a $h_l = f_{2l+1}$ (liché členy původní posloupnosti). Na každou vytvořenou posloupnost aplikujeme DFT zvlášť.

$$F_k = \sum_{l=0}^{\frac{N}{2}-1} g_l (W^2)^{lk} + W^2 \sum_{l=0}^{\frac{N}{2}-1} h_l (W^2)^{lk}, \quad k \in \left\langle 0; \frac{N}{2} - 1 \right\rangle \quad (4.14)$$

Rozklad FFT můžeme vyjádřit následujícím součtem dílčích transformací, kde musíme uvažovat $k' = k \times \text{mod } N/2$ pro poloviční délku posloupnosti.

$$F_k = G_{k'} + W^k H_{k'} \quad (4.15)$$

Pracnost výpočtu FFT je dána součtem dílčích pracností obou transformací a pracností jejich zkombinování podle následujícího vzorce.

$$2 \times \left(\frac{N}{2}\right)^2 P + NP \quad (4.16)$$

Pracnost výpočtu FFT oproti DFT je tedy snížena přibližně na 50%. Pokud ale získané obě posloupnosti znovu rozdělíme na dílčí části, zjednodušíme tak pracnost téměř o další polovinu. Z uvedeného důvodu je tedy žádoucí, aby posloupnost byla složena ze 2^m vzorků. Výsledná pracnost FFT jde zjednodušit na:

$$P \times N \times \log_2 N. \quad (4.17)$$

Na základě uvedeného principu a vzorce (4.17) lze porovnat pracnost DFT a FFT, která je uvedena v Tabulka 4.1

Vzorků N [-]	8	256	1024	132072
Úspora pracnosti [%]	62,5	96,8	99	99,99

Tabulka 4.1 – Úspora pracnosti FFT oproti DFT

Ještě za zmínku stojí uvést orientaci vstupní a výstupní posloupnosti. Zatímco výstupní posloupnost je orientována přirozeně, na vstupu je posloupnost orientována s bitovou reverzí. [11]

4.2.2 FFT ve frekvenční oblasti

FFT ve frekvenční oblasti je podobná FFT v časové oblasti, pouze se liší několika málo, ale důležitými rozdíly. Princip rozdělení na polovinu je zachován, ale nedělí se na liché a sudé prvky, nýbrž na první ($g_l = f_l$) a druhou polovinu ($h_l = f_{l+N/2}$) posloupnosti $\{f_n\}$.

$$F_k = \sum_{n=0}^{\frac{N}{2}-1} \left(g_l W^{lk} + h_l W^{\left(l+\frac{N}{2}\right)k} \right), \quad l \in \left\langle 0; \frac{N}{2} - 1 \right\rangle \quad (4.18)$$

Oproti FFT v časové oblasti musí být na vstupu provedeny pomocné výpočty. Také vstupní posloupnost je v přirozeném sledu a výstupní v bitově reverzním pořadí, čili naopak vůči FFT v časové oblasti. [11]

4.3 Vlnkové transformace

Jelikož vlnková transformace je značně obsáhlé téma a v této diplomové práci, respektive v praktické analýze, není zastoupena, nebudeme ji popisovat do velkých detailů. V následujících odstavcích si vysvětlíme základní princip transformace.

Vlnková transformace (z francouzského originálu ondelette transformation překládáno do angličtiny jako wavelet transform – WT) není pouze jedna transformace.


Je to soubor více transformací tvořený ze stejného počtu bazových funkcí – vlnek. Na rozdíl od DFT je bazová funkce tvořena tak, aby umožnila časovou lokalizaci událostí i ve vytvořeném spektru. To je způsobeno tím, že každá bazová funkce (vlnka) má nenulové hodnoty pouze na konečném časovém intervalu (DFT je má nenulové na celé ose). Případně okolní hodnoty jsou blízké nule, respektive zanedbatelně malé. Kterákoli hodnota spektra je tedy ovlivněna pouze odpovídajícím úsekem signálu. Neboli vlastnosti, které jsou popsány určitou spektrální hodnotou, jsou vztažné pouze k určité časové hodnotě. Důsledkem popsaného principu WT umožňují tzv. časově-frekvenční analýzu. [11]

4.3.1 Spojité vlnkové transformace

Pro názorný popis WT je pravděpodobně nepraktičtější vycházet ze spojité vlnkové transformace (CWT – continuous wavelet transform), která je definovaná následovně

$$S_{CWT}(a, \tau) = \int_{-\infty}^{\infty} s(t) \frac{1}{\sqrt{a}} \psi\left(\frac{t}{a} - \tau\right) dt, \quad \tau \in R, \quad a > 0 \quad (4.19)$$

Ve výše uvedeném vzorci (4.19) a znázorňuje měřítko (scale), τ znázorňuje posuv v časové ose a ψ je mateřská vlnka. Hodnoty spektra $S_{CWT}(a, \tau)$, jenž je dvojrozměrnou funkcí, závisí na korelačním integrálu mezi analyzovaným signálem $s(t)$ a bazovou funkcí $(1/\sqrt{a})\psi$, přičemž výraz s odmocninou zajišťuje zachování energie při změně měřítka. Mateřskou vlnku a její modifikace lze vidět na Obr. 4.1 [11].



Obr. 4.1 – Mateřská vlnka a její modifikace


Volbou měřítka a lze řídit rozsah frekvencí pokrývaný ve spektru vlnky. Existuje ovšem mez dosažitelného rozlišení ve frekvenční i časové oblasti, přičemž zlepšení jednoho parametru (oblasti) nepřímo úměrně ovlivňuje vlastnosti druhého parametru. [11]

4.3.2 Diskrétní vlnková transformace

Pro reprezentaci diskrétního spektra musíme opět spojité signál (nyní dvojrozměrný) vzorkovat. Z několika hledisek je výhodné použít vzorkování dyadické, popsáno následujícím vzorcem (4.20).

$$a = 2^j, \tau = k2^j = ka \quad \text{pro } j, k \text{ celé, } j \geq 1 \quad (4.20)$$

Měřítko a je vzorkováno dyadicky, kdežto časová osa τ je dělena rovnoměrně. Způsob vzorkování lze vidět na Obr. 4.2 [11].



Obr. 4.2 – Dyadické vzorkování v prostoru měřítko – čas

Pro reprezentaci vzorce pro výpočet CWT v diskrétní oblasti použijeme následující vzorec (4.21), kde původní označení a, τ je nahrazeno indexy j, k , přičemž integrál nahradíme součtem.

$$S_{CWT}(j, k) = \sum_{n=0}^{N-1} s_{n, jk} w_n \quad (4.21)$$

Takto definované spektrum má konečný počet vzorků N . Pokud bychom použili rovnoměrné vzorkování, nikoliv dyadické, výsledné spektrum by obsahovalo N^2 vzorků, čímž bychom výrazně zvýšili obtížnost výpočtu. Přitom zcela postačující je vzorkování dyadické.

Inverzní diskrétní vlnková transformace je lineární kombinací použitých vlnek


$$IDWT = s_n(j, k) = \frac{1}{N} \sum_{j=0}^{\log_2 N} \sum_{k=0}^{\text{int}\left(\frac{N}{2^{j+1}}\right)} S_{j,k} s_{j,k} w_n \quad (4.22)$$

4.4 Stochastické procesy

Abychom lépe porozuměli pojmu stacionární signál, uveďme si, kdy je signál naopak nestacionární a stochastický. Stochastický (náhodný) signál není definován známou funkcí s neznámou proměnou, jak je tomu u signálu deterministického. U náhodného signálu předem nevíme, jakých hodnot bude nabývat.

4.4.1 Nestacionární stochastický proces

Stochastický signál nám pomůže vysvětlit rodina funkcí $f_w(t)$ z Obr 4.3 [11], která je množinou funkcí $\{f_{w_k}(t)\}$ lišící se od sebe parametrem $w_k \in W$, kde W je spočtená, případně i nekonečná množina. Tato rodina obsahuje všechny tvary, které můžeme prakticky očekávat. Představit si ji můžeme jako soubor k grafů s časovou osou x , přičemž hodnota k závisí na momentální fyzikální podstatě.



Obr. 4.3 – Rodina funkcí jako zdroj náhodného signálu

V určitém časovém okamžiku t_m můžeme očekávat hodnotu $f_w(t_m)$, jež je popsána obvyklými pravděpodobnostními funkcemi. Jedná se například o pravděpodobnost jednotlivých diskrétních funkčních hodnot z_j ze vzorce (4.23), které mohou být dány konečnou tabulkou pro každé m popsané vzorcem (4.24).

$$p_f(z_j, m) = P\{f_m = z_j\} \quad (4.23)$$

$$P_f(z, m) = \sum_j p_f(z, m), \quad j \in \{j : z_j \leq z\} \quad (4.24)$$

Tyto okamžité charakteristiky se ovšem nevztahují k různým okamžikům procesu a tím nevystihují vzájemné vazby v procesu. K tomu je potřeba sdružených pravděpodobností definovaných vzorcem (4.24), kde uvažujeme dva různé okamžiky. [11]

$$p_f(z_j, z_k, m, n) = P\{f_m = z_j, f_k = z_k\} \quad (4.25)$$

4.4.2 Stacionární stochastický proces

Jak bylo zmíněno v kapitole 4.4.1, stochastický (obecně nestacionární) proces je vyjádřen lokálními pravděpodobnostními charakteristikami, které jsou pro různé časové okamžiky navzájem odlišné. Nestacionarita a její mnohorozměrné pravděpodobnosti jsou obecně závislé na konkrétních časových okamžicích. V praxi se setkáváme s procesy, které mají lokální pravděpodobnostní charakteristiku v čase téměř neměnnou. Hovoříme o procesech stacionárních.

Posuneme-li všechny vyšetřované okamžiky ze stacionárního procesu v užším smyslu o stejný časový úsek d , libovolně mnohorozměrné charakteristiky kteréhokoli řádu se nezmění.

$$\begin{aligned} p_f(z_{j_1}, z_{j_2}, \dots, z_{j_r}, m_1, m_2, \dots, m_r) &= \\ &= p_f(z_{j_1}, z_{j_2}, \dots, z_{j_r}, m_1 + d, m_2 + d, \dots, m_r + d) \end{aligned} \quad (4.26)$$

Prakticky je velmi obtížné hodnotit stacionaritu podle vzorce (4.26), a proto se zavádí pojem stacionární proces v širším smyslu. Od takového procesu požadujeme, aby lokální střední hodnota (4.27) a autokorelační funkce (4.28) byly v čase neměnné. [11]

$$\mu_f(m) = \mu_f(m + d) = \mu_f \quad (4.27)$$

$$R_{ff}(m, n) = R_{ff}(m + d, n + d) = R_{ff}(m - n) \quad (4.28)$$

4.5 Odhad výkonových spekter stochastických procesů

Vzhledem k vlastnostem stochastického procesu jsou všechny charakteristiky, včetně spekter, pouze statistickými odhady, zatíženými statistickými i náhodnými chybami v závislosti na metodách výběru dat a jejich zpracování. Vypočtené hodnoty odhadů charakteristik procesů jsou náhodnými veličinami s vlastními pravděpodobnostními parametry.

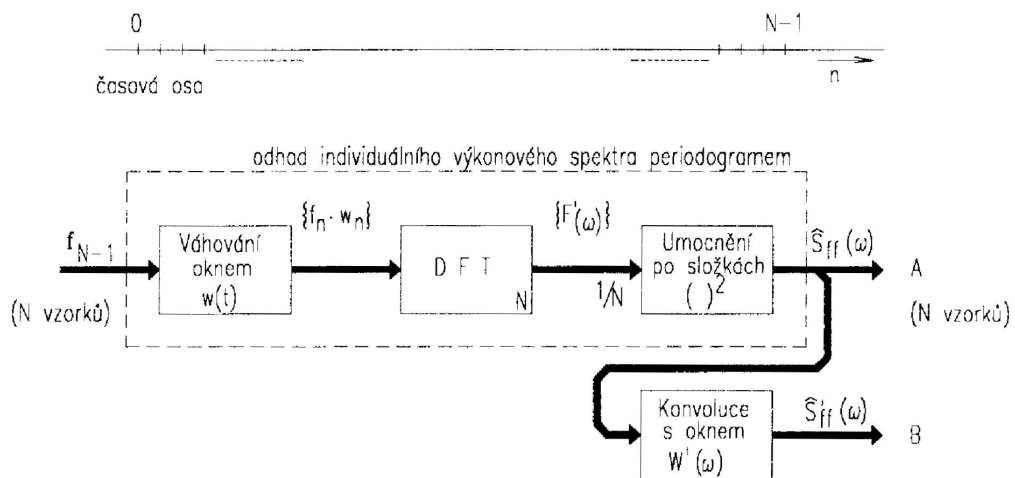
Odhady výkonových spekter můžeme rozdělit na metody parametrické a neparametrické. Druhé zmíněné metody jsou typické tím, že se celá analýza aplikuje pouze na právě změřená data bez použití jakýchkoliv modelů vzniku signálu. Parametrické metody obsahují parametry, které znázorňují systém vzniku signálu. Vytvořené spektrum je vyhlazené, oproti neparametrickým metodám, kde je navíc výsledek ovlivněn značným rozptylem. Pro složitost návrhu, ale především pro obtížnost správného vybrání parametrů, které by neměly za důsledek změnu transformovaného signálu, se budeme dále zabývat pouze neparametrickými metodami.

4.5.1 Metoda periodogramu

V této metodě vycházíme ze souborového průměrování individuálních výkonových spekter z M realizací o délce N vzorků s koeficientem $1/N$ ve vztahu k již zmíněnému vzorci (4.10). Odhad výkonového spektra se realizuje kvadrátem absolutních hodnot DFT (resp. FFT) dle vzorce (4.29) a Obr. 4.4 [11].

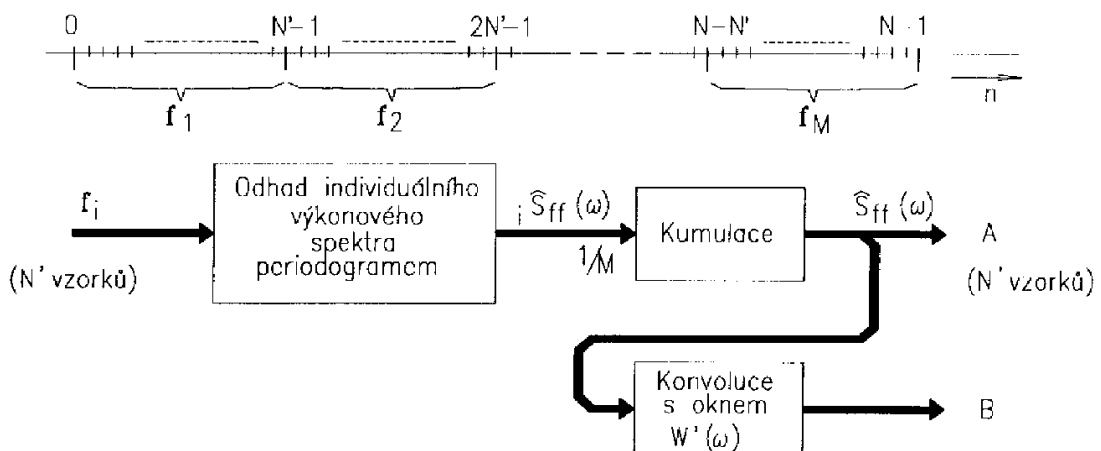
$$S_{ff}(\omega) = \frac{1}{M} \sum_{w_i} \frac{1}{N} |F_{w_i}(\omega)|^2 \quad (4.29)$$

Nejjednodušší přístup je při předpokládání $M = 1$. Tedy předpokládat, že vlastnosti individuálního výkonového spektra jsou dostatečně blízké průměrným vlastnostem procesu. To lze předpokládat pouze při zpracovávání dostatečně dlouhého stacionárního úseku. Čím delší okno signálu, tím získáme větší frekvenční rozlišovací schopnost, ale na druhé straně se značně projeví rozptyl odhadů. Důsledek toho je, že na výstupu nebudeme mít hladký průběh spektra. Vzorčky vstupního signálu můžeme ovšem váhovat volitelným oknem (Hamming, flat-top, atp.), čímž omezíme prosakování spektra.



Obr. 4.4 – Princip výpočtu periodogramu

Vyhlazení spektra podle Obr. 4.5 [11] jde provést rozdělením zkoumaného úseku na několik menších úseků s poměrem $N = N'/M$. Spektrum bude hladší nejen díky prosakováním spektra, ale především v důsledku zmenšením rozptylu průměrováním spekter.



Obr. 4.5 – Princip výpočtu periodogramu se segmentováním

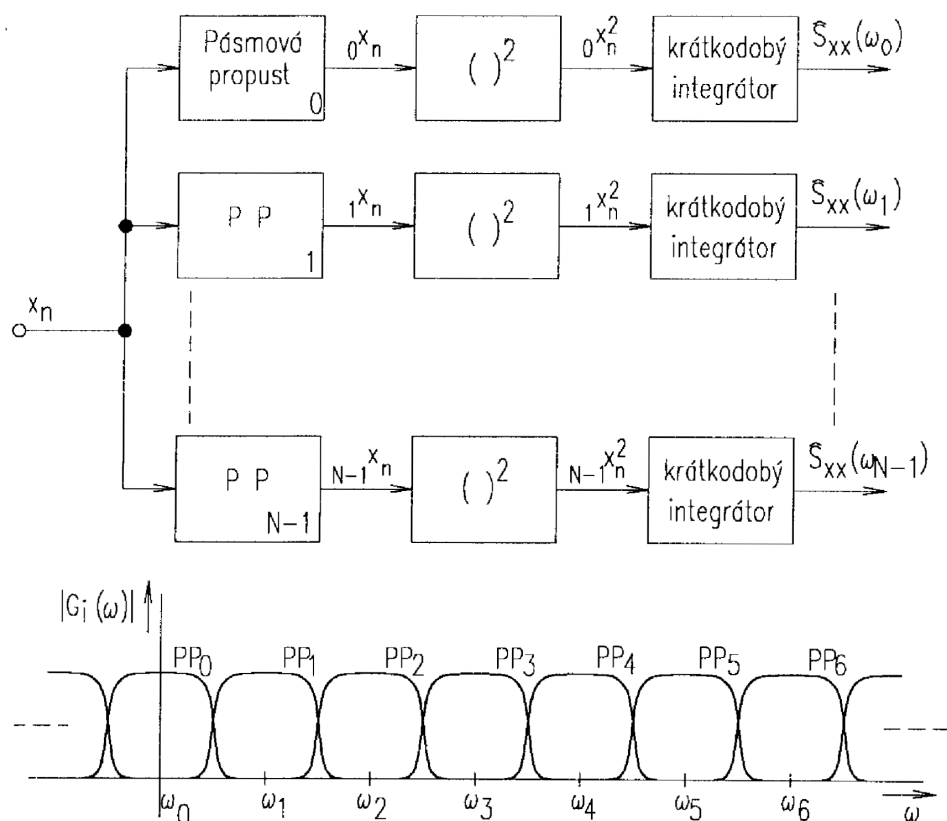
Z hlediska přesnosti nejvýhodnější výpočet pomocí periodogramu je založen na skutečně M realizací náhodného procesu. [11]

4.5.2 Metoda pásmové lineární filtrace

Metoda pásmové lineární filtrace se převážně využívá v reálném čase. Princip metody, jak popisuje Obr. 4.6 [11], je založen na paralelní bance filtrů (pásmových propustí), které mají mezní kmitočty zvoleny tak, aby pokrývaly celé požadované spektrum – navazují na sebe.

Signál získaný v každé větvi za pásmovou propustí je umocněn na druhou. Tím dostáváme okamžitý výkon v daném frekvenčním pásmu. Jelikož předpokládáme stacionaritu signálu, lze časovým průměrováním získat odhad středního výkonu v příslušném pásmu. Průměrovat můžeme celý měřený úsek signálu, nebo jen zvolenou část. Integrací kratších úseků vyhodnocujeme odhad krátkodobého výkonového spektra. To nám umožňuje sledovat vývoj spektra u signálů s krátkodobou stacionaritou.

Abychom získali srovnatelné hodnoty výkonových spekter mezi všemi filtry, musíme signál podělit šířkou pásma daného filtru. Výhodou této metody je možnost aplikace pro časově – frekvenční analýzu, kdy je šířka pásma filtrů exponenciálně navyšována. Nevýhodou je frekvenční charakteristika, která není ideální, a tím pádem dochází k prosakování spektra. [11]



Obr. 4.6 – Princip pásmové lineární filtrace

5 BIOFEEDBACK

Biofeedback znamená zavedení zpětné vazby odvozené z nějaké veličiny, kterou lze měřit na člověku. Když tuto informaci zobrazíme, dokážeme měnit různé fyziologické pochody v našem těle. Je tak možné například měřit tep a člověku pak toto číslo zobrazit. Není potom složité si tepovou frekvenci zrychlit či zpomalit pouze soustředěním se na cílenou změnu.

Je-li námi měřeným parametrem EEG signál, mluvíme o EEG biofeedbacku. K osobě, která se rozhodne biofeedback provádět, připevníme EEG elektrody (postačí jen 3 elektrody, dvě na ušní lalůčky a jedna na temeni hlavy), signály zesílíme a zobrazíme výkon v jednotlivých frekvenčních pásmech (například alfa, beta, jejich poměr apod.). Na základě této informace se snaží osoba uvést do stavu, kdy se tyto parametry změní.

5.1 Praktické využití biofeedbacku

Prakticky se tento trénink provádí pomocí EEG zesilovače, spektrální analýzy EEG křivky a dvou počítačů. Na jednom počítači klient sleduje počítačovou hru, druhý počítač slouží pro spektrální analýzu EEG signálu, výběr spektra pro trénink a nastavení prahů vybraných frekvencí pro ovládání hry, které řídí psychoterapeut. [9]

EEG biofeedback se používá především v následujících oblastech:

- klinický biofeedback
- léčení fobií
- omezení stresu
- sledování pozornosti
- poruchy učení, dyslexie, dysgrafie
- poruchy spánku
- deprese z dětství
- závislosti
- syndrom chronické únavy
- u závažných stavů (epilepsie či stavů po zranění mozku) je EEG biofeedback trénink účinným doplňkem medikace

5.2 Biofeedback a hry

Na popsaném principu lze realizovat například počítačové hry. Děti pravidelně chodí ke specialistovi, u kterého hrají hru, ve které se snaží být co nejlepší. Hra je založena například na principu, že dané autíčko, či lodička jede tím rychleji, čím více je dítě klidnější. Takto se může dítě (které může mít například problém se soustředěním) naučit vyvolat stav, kdy je klidné. Tento stav si mozek zapamatuje a příště se do něj dostane i bez biofeedbackového přístroje. K tomu ovšem jedno sezení nestačí, zpravidla je potřeba 10 či 20 návštěv (v intervalech jednou až dvakrát týdně). Příklad hry ilustruje Obr. 5.1. [8].



Obr. 5.1 – Jednoduchá hra pro biofeedback

5.3 Biofeedback a epilepsie

Epileptické záchvaty byly vůbec prvním zdravotním problémem, na kterých byla metoda EEG biofeedbacku úspěšně uplatněna. Záchvaty mají po terapii nižší intenzitu, snižuje se jejich frekvence, v některých případech vymizí úplně.

U závažných stavů, jako je epilepsie, nemůže EEG trénink nahradit léky. Úspěšný trénink však může vést ke snížení medikace. EEG - biofeedback také často "zabral" u pacientů, kteří trpí záchvaty, i když užívají léky. [10]

5.4 ADHD

ADHD (Attention Deficit Hyperactivity Disorder) dříve označované jako LMD (lehká mozková dysfunkce) a s touto poruchou související projevy jako je agresivita, citová nestabilita, impulzivnost, obtíže v komunikaci, poruchy koncentrace pozornosti, nerovnoměrnost rozvoje pracovní složky osobnosti. Řada výzkumů potvrdila častou souvislost s poruchami učení a s poruchou řečového projevu, ale i skutečnost, že děti s ADHD častěji trpí enurézou, poruchami spánku a mají větší sklony k různým nehodám a úrazům. Včasná péče o předškolní děti, kde jsou tyto obtíže jasně signalizovány, vážne. Chybí dostatečná terapie a speciální náprava v době, kdy ještě dítě není pod tíhou školní zátěže, kdy ještě školsky přímo neselhává a kdy prožitky neúspěchu nemají takový dopad na osobnost dítěte a jeho vztahový rámec. [14]

5.5 Úspěšnost biofeedbacku

Úspěšnost Biofeedbacku lze odvodit z následujících tabulek: Tabulka 5.1 [14] a Tabulka 5.2 [14], kde jsou popsány výsledky ze dvou studií zabývajících se léčbou epilepsie a ADHD.

MONASTRA et al., 2002			
Probandi	N = 100,		
Skupiny	N = 51		N = 49
	EEG Biofeedback		bez alternativy k EEG Biofeedbacku (obě skupiny však byly edukované a medikované metylfenidátem)
	pozitiv.	16-20Hz	
	negativ.	4-8 Hz	
	Počet sezení: 34-50 (dokud QEEG nesplňovalo stanovená kritéria)		
Výsledky	zlepšení obou skupin v testu pozornosti, hodnocení rodiči i učiteli, při opětovném hodnocení po týdenním vysazení metylfenidátu se však zlepšení udrželo jen u skupiny léčené i EEG Biofeedbackem, pouze u skupiny léčené EEG Biofeedbackem došlo k redukci nadbytku pomalé aktivity (theta) v QEEG		
Pozn.:	léčba obou skupin zahrnovala i spolupráci s rodiči a školou		

Tabulka 5.1 – Úspěšnost terapie pro ADHD

LANTZ A STREMAN, 1988			
Probandi	N = 24, skupiny párované vzhledem k věku a typu epilepsie		
Skupiny	N = 8	N = 8	N = 8
	EEG Biofeedback - odměňovali SMR (11 ÷ 15 Hz), inhibovali 0 ÷ 5 Hz a 20 ÷ 25 Hz	Biofeedback zaměřený na kontrolu dýchání	pouze zapisování záchvatů
Výsledky	Signifikantní snížení počtu záchvatů pouze po SMR tréninku		
KOTCHOUBEY et al. 2001			
Probandi	N = 52		
Skupiny	N = 34	N = 11	N = 7
	EEG Biofeedback - odměňovali posun SCPs k zápornějším hodnotám	Biofeedback zaměřený na kontrolu dýchání	nové antiepileptikum
Výsledky	Sign. Snížení počtu záchvatů po tréninku SCPs a po medikaci		

Tabulka 5.2 – Úspěšnost terapie pro epilepsii

Z výše uvedených tabulek je tedy patrné, že léčba za pomoci biofeedbacku může být považována za úspěšnou.

6 PRAKTICKÁ ČÁST – ANALÝZA V MATLABU


Matlab v této diplomové práci zajišťuje základní analýzu naměřeného signálu a tvorbu brain mappingu. Využívá naměřeného EEG signálu pomocí systému Alien, který byl zajištěn vedoucím práce. Jedná se o tří minutový záznam, kdy pacient poslouchal relaxační hudbu.

Vstupní soubor obsahuje několik proměnných. Jsou jimi: [data, chans, sampling, sens, chann, id, pr, jm, date, time]. Hodnoty proměnných dokážeme zjistit pomocí funkce Read_alien, která byla taktéž poskytnuta vedoucím diplomové práce. V proměnné “data“ jsou uloženy naměřené hodnoty svodu, který se určuje v proměnné “chann“.

6.1 Základní analýza


Princip programu spočívá v načtení vstupního signálu, zjištění jeho parametrů, vytvoření spektrální analýzy a uložení signálu do přijatelnějšího formátu pro lepší manipulaci v programu Matlab a Labview. Pro všechny naměřené svody jsou vytvořeny kopie signálu s přičteným simulovaným šumem.

Pomocí funkce Read_alien jsou zjištěny parametry signálu. Důležitým parametrem je vzorkovací frekvence a délka signálu. Na základě těchto údajů je vytvořena časová osa pro vykreslení signálu. K vybranému signálu je připočten šum ve tvaru sinusoidy s frekvencí 45 Hz a amplitudou 100 μV . Následuje vykreslení signálu bez šumu a se šumem do Obr. 6.1, kde na horizontální ose je čas [s] a na vertikální amplituda [μV].




Obr. 6.1– Matlab - časový průběh EEG signálu

Druhý graf zaznamenaný v Obr 6.2 zobrazuje rychlou Fourierovu transformaci, která nás informuje o spektrálním složení signálu, kde na ose x je frekvence [Hz] a osa y znázorňuje amplitudu [μV]. Transformace je vypočítána pomocí funkce FFT.



Obr. 6.2 – Matlab - spektrum EEG

Poslední graf na Obr. 6.3 ukazuje spektrální výkon signálu. Horizontální osa označuje frekvenci [Hz] a osa vertikální spektrální výkonovou hustotu $[(\mu\text{V})^2/\text{Hz}]$. Zde je patrné zobrazení šumu.



Obr. 6.3 – Matlab - výkonové spektrum


Poslední blok programu slouží k uložení jednoho ze 21 možných signálů, v závislosti na vybraném svodu. Takto uložený signál je kompatibilní s programem LabView a Matlab.

6.2 Brain mapping

V této aplikaci jsou na vstup přiváděny naměřené EEG signály upravené pomocí výše zmíněné aplikace. Je načteno 16 záznamů EEG, každý z jiného svodu.

Amplitudový brain mapping v jednom okamžiku využívá načtení 16ti okamžitých hodnot amplitudy do čtvercové matice $[4 \times 4]$. Následuje soubor osmi interpolací, pomocí příkazu `interp2(x,k)` s koeficientem 1 až 8. Takto vytvořená amplitudová mapa je vidět v příloze B.3.

Další část programu vypočítává interpolované hodnoty amplitud EEG signálu pro celou jeho délku. Jsou zde použity 3 druhy interpolací, a sice s koeficientem 4, 5 a 6. Nakonec se vykreslí graf, který nás informuje o době výpočtu pro signál o určité délce a interpolačním koeficientem.



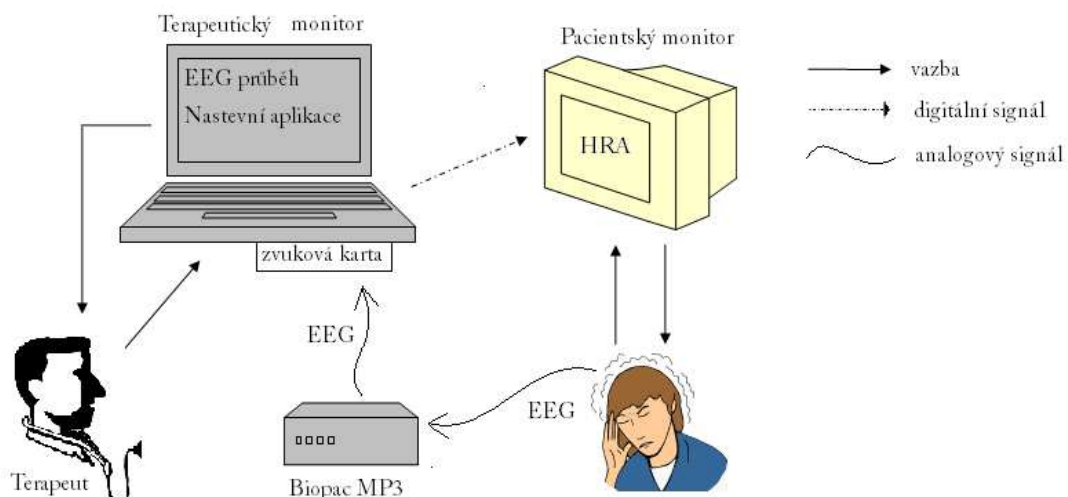
Obr. 6.4 – Doba výpočtu interpolace s různým koeficientem

- a) interpolace s koeficientem 4
- b) interpolace s koeficientem 5
- c) interpolace s koeficientem 6

Na Obr 6.4 vidíme interpolovaný signál o délce 184 960 vzorků, což odpovídá tříminutovému záznamu se vzorkovací frekvencí 1024 Hz. Je patrné, že vyšší koeficient interpolace zvyšuje dobu zpracování. Přitom grafické rozlišení oproti předchozím interpolacím není již natolik kvalitní, abychom podstoupili tak vysoké časové zatížení. Výpočet interpolace s koeficientem 4 trvá 16 minut, s koeficientem 5 je tato doba 48 minut. Grafické rozlišení i časový rozdíl je celkem patrný. Přesto jsou obě možnosti dostačující.

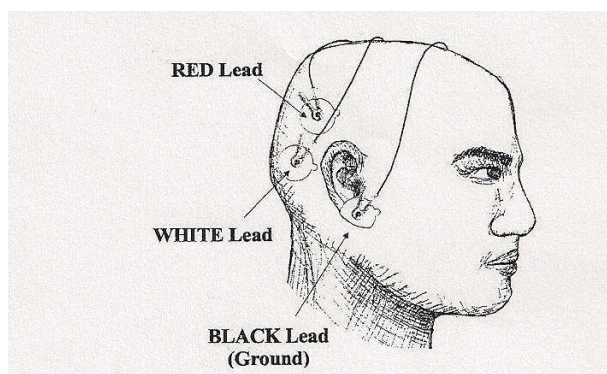
7 PRAKTICKÁ ČÁST – EEG BIOFEEDBACK

K vytvoření EEG biofeedbacku bylo použito zapojení pomocí jednotky Biopac MP35 a osobního počítače a sekundárního monitoru, jak je znázorněno na Obr. 7.1.



Obr. 7.1 – Blokové schéma zapojení EEG biofeedbacku

Pro měření EEG jsou použity 3 měřicí samolepící elektrody, které se správně dle manuálu firmy Biopac System zapojují podle Obr. 7.2 [12]. Pokud bychom opravdu chtěli připojit elektrody dle návodu, museli bychom buď pacienta zbavit vlasů v měřicím místě, nebo použít jiné elektrody, než samolepící, například již zmíněnou elektrodovou čepici. Připojením elektrod na vlasy bychom způsobili nežádoucí zvýšení přechodového odporu. Navíc následné odstranění elektrod by bylo pro pacienta značně nepříjemné. Proto bylo zvoleno jiné zapojení, a sice přesunutí červené (red lead) a bílé (white lead) elektrody do spánkové oblasti. Tím jsme ale zapříčinili zašumění měřeného signálu pohybovým artefaktem očí a očních víček. Černá elektroda (black lead) sloužící jako zemnicí elektroda a zůstává na ušním boltci.



Obr. 7.2 - Zapojení EEG elektrod dle manuálu firmy Biopac

Analogový signál EEG je přiváděn do měřicí jednotky Biopac MP35 (podrobně popsáno v následující kapitole), kde z analogového výstupu je veden na vstup zvukové karty terapeutického počítače. Zde dochází ke zdigitalizování signálu EEG, který je analyzován ve vývojovém prostředí LabView 7.1 v reálném čase. Měřený signál a jeho analýzu vidí terapeut na svém monitoru. Přitom na počítači nastavuje mez mozkové aktivity (přesněji řečeno odhad krátkodobého výkonového spektra v daném frekvenčním pásmu). Paralelně s tím vidí pacient na svém monitoru grafickou počítačovou hru. Ta mu dává podnět k soustředění se a zapojení mozkové aktivity v určitém frekvenčním pásmu. Pacient se tak snaží ovlivnit průběh hry překročením nastaveného prahu mozkové aktivity, obecně řečeno pouhými myšlenkami. Tím vzniká zpětná vazba – biofeedback.


7.1 Biopac MP35

Měřicí jednotka Biopac MP35 je produktem firmy Biopac System, která se zabývá výrobou technických zařízení pro měření bio-signalů. Tento přístroj slouží jako akviziční, zesilovací a filtrovací jednotka, která převádí měřený analogový biologický signál na digitální a přenáší jej do počítače přes USB port, kde je následně zobrazen pomocí softwaru firmy Biopac System. V našem případě je Biopac MP35 použit pouze jako zesilovač s pásmovou propustí. Strukturu přístroje lze vidět na následujících obrázcích: Obr. 7.3 [13], Obr. 7.4 [13], Obr.7.5 [13].



Obr. 7.3 – Přední panel přístroje Biopac MP35

Přední panel se skládá z 5-ti 9-ti pinových vstupních portů, přičemž 4 z nich slouží jako plnohodnotné měřicí kanály (CH1 až CH4) a 1 (Electrode check) jako vstupní port pro kontrolu zapojení elektrod. Na pravé straně jsou umístěny 2 led diody indikující stav a činnost zařízení.




Obr. 7.4 – Zadní panel přístroje Biopac MP35

Zadní strana přístroje je vybavena jedním vstup-výstupním portem ke komunikaci s číslicovými přístroji, dále jedním BNC konektorem pro vzájemnou synchronizaci více MP35 jednotek, výstupem pro připojení stereofonních sluchátek (zvukově evokované potenciály) s konektorem Jack 3,5 mm, sériovým portem a USB portem pro přenos digitalizovaného signálu do počítače a komunikaci s aplikací Biopac a samozřejmě vstupem pro napájení ze sítě. Posledním pro nás důležitým výstupem je analogový 9-ti pinový D-SUB port pro zesílení snímaného signálu a jeho následný přenos. Pro účel naší aplikace je využít pouze pin číslo 1 a pin číslo 3 výstupního DSUB portu, které jsou pro názornost označeny žlutě.

MP Analog Output — Back Panel

9 PIN MALE DSUB



Pin MP35

1	Buffered AC output Z out = 2.200 μ F Cap V out range MP35: (+/- 2.0 V)	5	Buffered digital output Z out = 1 k Ω V out range (0 to 5 V)
2	Buffered DC output Z out = 50 Ω V out range MP35: (0 to 4.096 V)	6	+12 V (100 mA max)
3	GND GND	7	I ² C SCL
4	+5.0 V (100 mA max)	8	I ² C SDA
		9	Not used

Obr. 7.5 – Popis analogového výstupního portu DSUB

Z katalogového listu výrobce můžeme zjistit důležité technické vlastnosti přístroje. Odstup S/N (signál/šum) výrobce garantuje větší než 90 dB. Napěťový rozsah je od 400 μ V_{p-p} po 2 V_{p-p} v závislosti na zvoleném vstupním zesílení (10, 20, 50, 100, 200, 500, 1000, 2000, 5000, 10 000, 20 000, 50 000). Z důvodu velmi nízkých hodnot vstupního napětí by bylo vhodné zvolit největší zesílení. Jelikož ale používáme pro vstup analogového signálu do PC zvukovou kartu, která má omezenou hodnotu maximálního vstupního napětí, volíme z bezpečnostních důvodů zesílení 10 000. Převodník A/D (analogový/digitální) je 24-bitový, což přináší 16 777 216 kvantizačních úrovní. Výstupní D/A převodník je již 12-ti bitový a rozsah výstupního napětí je 0 V až 4,096 V.

Zařízení také obsahuje 3 nezávislé IIR filtry sloužící k odfiltrování stejnosměrné složky, zamezení driftu a odstranění síťového brumu. Lze volit PP (pásmovou propust) s mezními kmitočty 0,05 ÷ 100 Hz či 0,5 ÷ 35 Hz, nebo PZ s volitelným kmitočtem.

Výstupní analogový signál tedy prochází A/D převodníkem, základní filtrací a D/A převodníkem. Vzorkovací frekvence je 200 Hz, oproti předpokládaným 256 Hz.

7.2 Zvuková karta

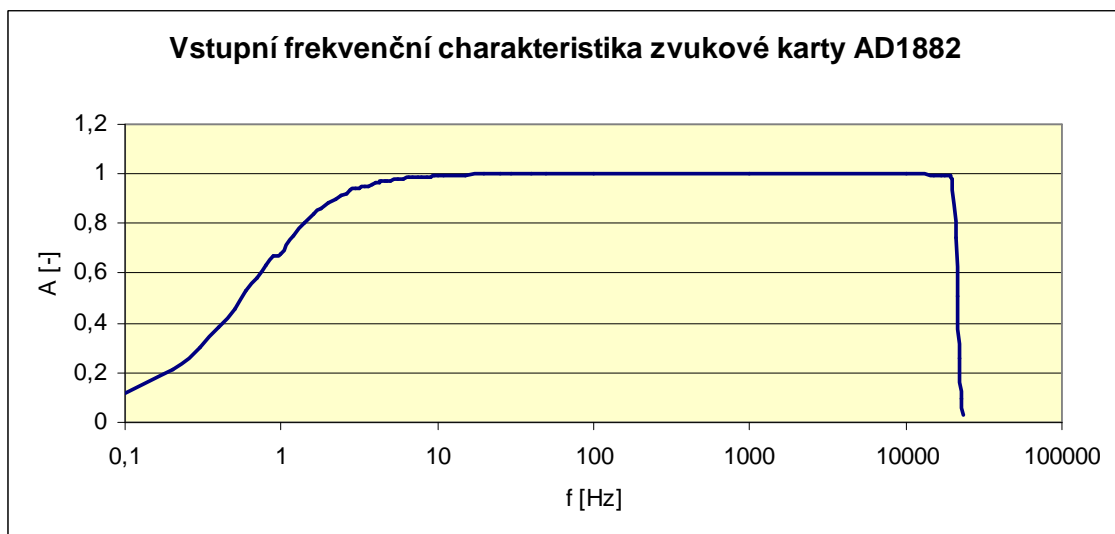
V programovacím prostředí LabView využíváme inicializaci dat v reálném čase pomocí zvukové karty. Užitečný signál EEG podle teoretického rozboru má kmitočtové zastoupení v rozmezí $0,5 \div 35$ Hz. Frekvenční charakteristika použité zvukové karty (AD1882 High Definition Audio Codec) je tedy zlomovým bodem pro vytvoření aplikace. Původní domněnka, že vstupní frekvenční charakteristika je kmitočtově omezena horní propustí s mezním kmitočtem 20 Hz se ukázala jako lichá. Vyvrátil ji katalogový list a následné skutečné proměření frekvenční charakteristiky. Z katalogového listu se mimo jiné dozvídáme poměr odstupu signál/šum = 90 dB a maximální vstupní napětí $3,65 V_{p-p}$.

K proměření vstupní charakteristiky byl použit generátor harmonického signálu Agilent 33220A a aplikace vytvořena v LabView. Generátorem jsme přiváděli harmonický signál s amplitudou $1 V_{p-p}$ s měnícím se kmitočtem na mikrofonní vstup. Přenos byl zajištěn prodlužovacím kabelem typu Jack 3,5 mm – Cinch. Na výstup generátoru firmy Agilent byla umístěna redukce BNC – Cinch. Kontrola takto vedeného signálu byla provedena na osciloskopu Agilent DSO1012A.


V LabView jsme inicializovali zvukovou kartu s natavením vzorkovacího kmitočtu na 8 KHz (nejmenší možné nastavení), 8-bitový A/D převodník a mono signál. Aplikace obsahovala výpočet hodnoty RMS (root means square), která vyháází ze vzorce (7.1) kde N je velikost pole.

$$\Psi = \sqrt{\frac{1}{N} \sum_{n=0}^{N-1} x_n^2} \quad (7.1)$$

Jelikož ovladače zvukové karty nastavují vstupnímu portu zesílení s bezrozměrnou veličinou v rozsahu 1 až 100 a tím zamezují kvantitativnímu měření, byly naměřené hodnoty vztaženy k nejvyšší dosažené hodnotě.



Obr. 7.6 – Vstupní frekvenční charakteristika zvukové karty AD 1882



Obr. 7.7 – Detail vstupní frekvenční charakteristiky zvukové karty AD1882

Z naměřené charakteristiky zobrazené na Obr 7.6 a Obr. 7.7 je patrná horní propust s mezním kmitočtem 1 Hz, přestože v katalogovém listě není o této skutečnosti žádná poznámka. Použití zvukové karty tedy omezuje EEG signál v pásmu Delta vln (které jsou od $0,5 \div 3$ Hz) a použitelné pásmo Delta se mění na rozsah od 1 po 3 Hz. Poněvadž se pásmo Delta nevyužívá jako hlavní oblast tréninku, ale jako doplňková (používá se v tréninku SMR/Delta, nikoliv jako samostatně trénované pásmo), můžeme sestavit měření i s takto omezenou zvukovou kartou. Ba dokonce můžeme omezení frekvenční charakteristiky brát jako výhodu. Horní propust na vstupu filtruje artefakty působící drift izolinie.

Pokud bychom se nespokojili s frekvenčním omezením, je možné přenášet signál z Biopacu přes měřicí kartu NI-6221-USB od firmy National Instruments, která dokáže přímo komunikovat přes USB port s LabView. Nevýhoda této metody je cenová relace měřicí karty a nutností přidávání dalšího hardwaru do zapojení. Jak známo, každé další zařízení může být potencionálním zdrojem chyb. Přesto tato možnost byla funkčně vyzkoušena.

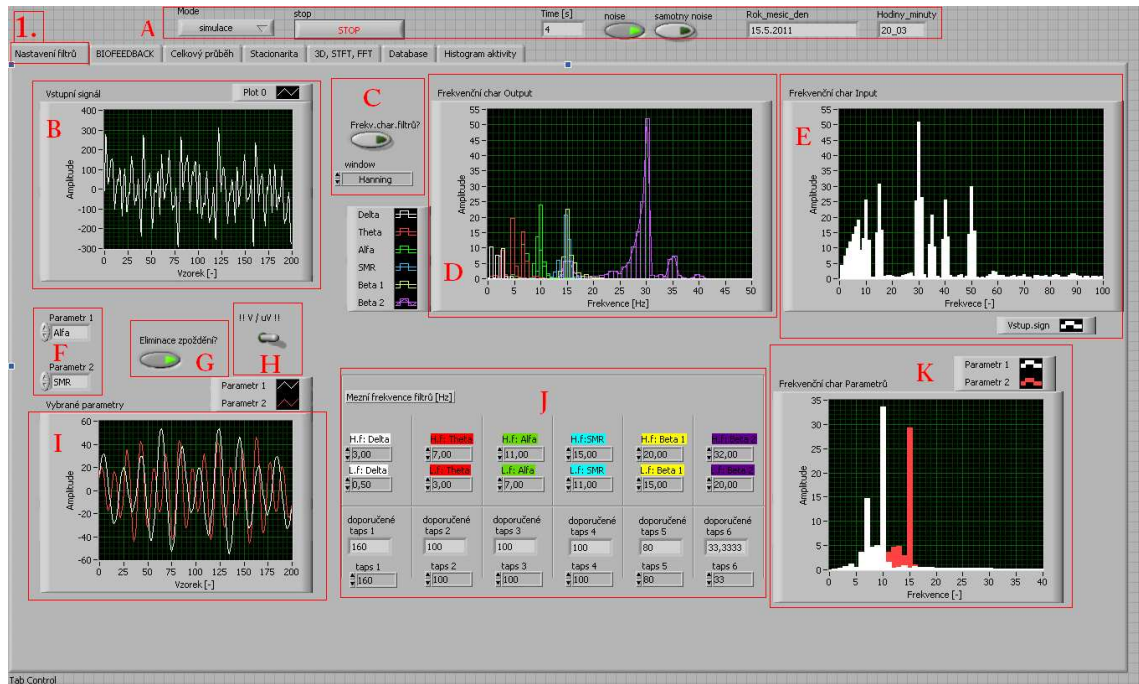
7.3 Terapeutický monitor

Jak již bylo zmíněno, aplikace pro EEG Biofeedback byla vytvořena ve vývojovém prostředí LabView 7.1 od Firmy National Instruments. Funkce programu je rozdělena na část blokovou, do které uživatel vkládá bloky splňující požadovanou funkci a na část Přední panel, která zobrazuje nejen měřené hodnoty, ale obsahuje i ovládací prvky. Proto výstup programu je označován jako virtuální přístroj.

Vytvořený virtuální přístroj se skládá z primárních a sekundárních řídicích a indikačních prvků. Za primární jsou považovány prvky: Výběr módu, který definuje a inicializuje vstupní data (načtení signálu, zvuková karta, NI-USB a simulace); Stop (ukončuje aplikaci i průběh hry); aktuální čas (datum a čas); doba tréninku; noise (zapnutí šumu v simulaci, který slouží pro otestování aplikace). Sekundárními prvky jsou záložky funkcí aplikace. Jsou jimi: Nastavení filtrů; Biofeedback; Celkový průběh; Stacionarita; 3D, STFT, FFT; Databáze a Histogram aktivity.

7.3.1 Nastavení filtrů

První záložka funkcí aplikace je nazvána Nastavení filtrů. Její obsah vyobrazený na Obr. 7.8 je podrobně popsán po jednotlivých blocích.



Obr. 7.8 – První záložka - Nastavení filtrů

Blok 1.A – primární nastavení

Zde volíme typ vstupních dat. Máme na výběr možnost Načtení – jedná se o načtení naměřených dat EEG záznamu (viz. kapitola 6), která sloužila pro testování funkce přístroje a tím umožňovala tvorbu aplikace bez nutnosti reálného měření. Dál možnost NI-USB. V aktuální verzi programu není tento výběr zcela funkční. Použití této volby nepřináší větší výhody, než akvizice pomocí zvukové karty (viz. kapitola 7.2). Další možnost je vybrat Simulaci, která slouží pro jednoduché testování funkčnosti použitých filtrů a ostatních prvků jako například FFT. Poslední možností je načítání signálu přes zvukovou kartu.

Tlačítkem Stop vypneme terapeutický i patientský monitor. V neposlední řadě je zobrazení aktuálního data a času se současným zobrazením doby běhu programu, resp. doby tréninku.

Blok 1.B – vstupní signál

Grafický výstup vstupního signálu. Osa x zobrazuje počet vzorků N vstupního signálu a osa y zobrazuje amplitudu signálu. Amplituda je zobrazena v závislosti na stavu tlačítka v bloku H. Jedná se o zobrazení v mikrovoltech [μV] nebo ve voltech [V]. Zobrazuje se každých N nových vzorků.

Blok 1.C – volba vstupu pro frekvenční charakteristiku

Zapnutím tlačítka zobrazíme v bloku D frekvenční charakteristiku filtrů sloužících k lineární pásmové filtraci (viz. kapitola 4.5.2). Vypnutý stav zobrazuje frekvenční

oblast takto filtrovaného signálu. Blok C obsahuje menu window, kde je na výběr jedna váhová funkce z devíti možných (none, Hanning, Hamming, Triangular, Blackman, Exact Blackman, Blackman – Harris, Kaiser – Bessel, Flat top).

Blok 1.D – frekvenční charakteristika output

Podle stavu tlačítka v bloku C se zobrazuje buď frekvenční charakteristika použitých filtrů, nebo spektrum signálu za těmito filtry. Osa x zobrazuje frekvenci [Hz] a osa y hodnotu koeficientů Fourierovy řady. Výpočet spektra byl odvozen v kapitole 4.1 vzorcem (4.10). Připomeňme si, že pro výpočet spektra se používá DFT, respektive FFT. V našem případě se jedná o blok FFT, který umožňuje rychlejší výpočet.

Blok 1.E – frekvenční charakteristika input

Jedná se principiálně o shodné zobrazení jako v bloku C s tím rozdílem, že na vstupu je signál ještě před lineární pásmovou filtrací. Jedná se tedy přímo o spektrum vstupního signálu.

Blok 1.F – výběr parametrů

Pro trénink se využívá jednoho, nebo dvou frekvenčních pásem. Zde volíme, které to budou (delta, theta, alfa, SMR, beta 1, beta 2). Dále v diplomové práci bude pojem parametr uvažován jako označení pro vybrané frekvenční pásmo EEG signálu.

Blok 1.G – eliminace zpoždění

Jelikož aplikace využívá FIR filtry, které se vyznačují konečnou impulsní charakteristikou a vnášením zpoždění do filtrovaného signálu, je žádoucí vzniklé zpoždění eliminovat. Zpoždění z je dáno počtem vzorků *taps* v impulsní charakteristice.

$$z = \frac{taps - 1}{2} \quad (7.2)$$

Blok 1.H – volba měřítka

Signál EEG se pohybuje v rozmezí desítek až stovek mikrovoltů, proto je vhodné měřítko os u grafů převést na požadované jednotky. Přesto je zde i možnost ponechat základní jednotku [V]. Pro správné interpretování výsledků analýzy je důležité dané nastavení brát v potaz, neboť ovlivní všechny zobrazovací jednotky.

Blok 1.I – zobrazení parametrů

Tento blok zobrazuje oba parametry vybrané v bloku F. Filtrovaný signál je zobrazen buď se zpožděním nebo bez něj, v závislosti na stavu tlačítka v bloku G.

Blok 1.J – nastavení filtrů pro pásmovou lineární filtraci

Jak již bylo zmíněno, aplikace využívá filtry FIR. Je to z důvodu zamezení nestability systému a také pro možné zkreslení signálu nelineární fázovou charakteristikou filtrů IIR. Pásmová filtrace je složena ze 6-ti filtrů typu PP s nastavitelnými mezními kmitočty. Předem jsou ovšem definované na teoretické meze frekvenčních pásem mozkové aktivity. Možnost měnit frekvenční pásmo je důležité, neboť ani autoři, publikující články o EEG nejsou sjednoceni v jednom názoru. Navíc každý pacient může mít charakteristické amplitudové vlastnosti signálu pro dané pásmo mírně posunuté v oblasti frekvenční. Důležité je také nastavení počtu vzorků v impulsní

charakteristice. Vyšší počet vzorků má za následek strmější charakteristiky filtrů, což je žádoucí. Na druhou stranu se tím zvyšuje doba zpoždění a výpočetní náročnost. Je tedy vhodné volit určitý kompromis. Doporučenou hodnotu získáme podělením vzorkovací frekvence poloviční šířkou pásma, jak napovídá vzorec (7.3).

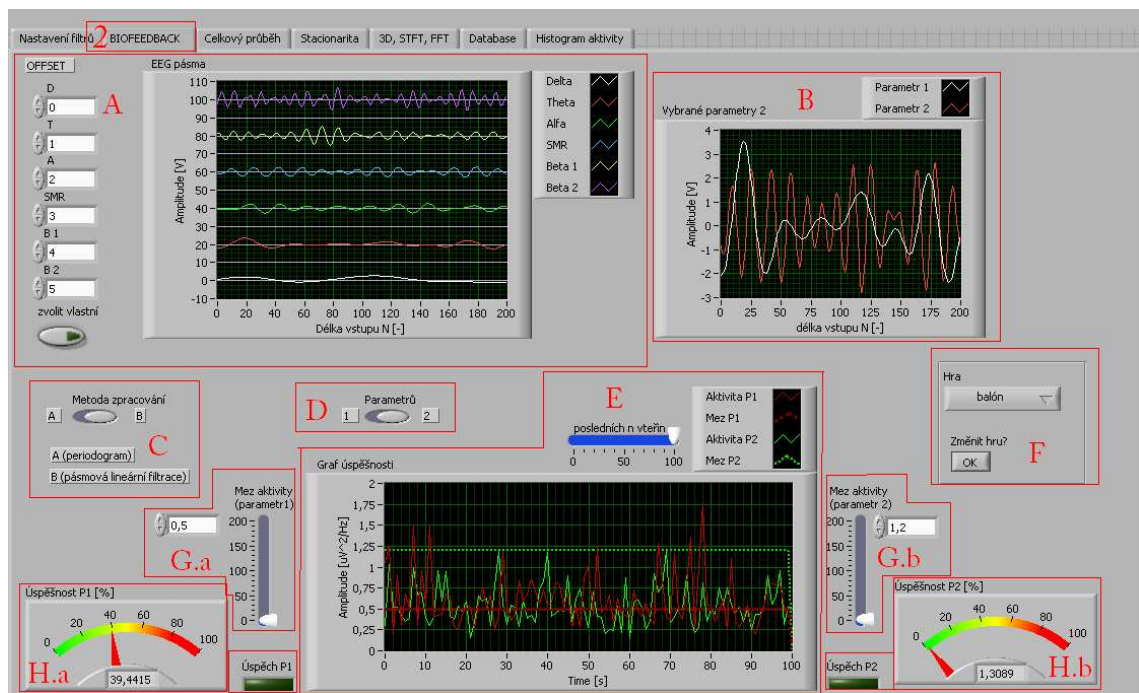
$$taps = \frac{2 \cdot fvz}{B} \quad (7.3)$$

Blok 1.K – spektrum parametrů

Jak název napovídá, jedná se o zobrazení spektra vybraných parametrů, tedy signálů zobrazených v bloku J. Princip výpočtu spektra je obdobný jako u bloků D a E.

7.3.2 Biofeedback

Druhá záložka v programu zobrazená na Obr. 7.9 slouží ke sledování EEG, nastavení mezí k dosažení úspěchu a sledování změn úspěšnosti v čase. Dále ke zvolení metody zpracování a k výběru hry.



Obr. 7.9 – Druhá záložka - Biofeedback

Blok 2.A – EEG pásma

Rozklad EEG signálu v časové oblasti na užitečná pásma můžeme vidět právě v tomto bloku. Jedná se o rozklad pomocí filtrů popsaných v bloku 1.J. Jelikož LabView nedokáže zobrazit více grafů v jednom tak, aby každý měl svoji vertikální osu (respektive je tato možnost dostupná pouze pro vstupní data typu scalar, nikoli pro pole), byl použit offset. Hodnoty offsetu jsou voleny pro přehlednost jako násobky desíti. Pokud uživatel není spokojen s přednastavenými hodnotami, může je změnit.

Blok 2.B – vybrané parametry

Jedná se o blok totožný s blokem 1.I v předchozí záložce. Je zde umístěn pro zachování uživatelsky příjemného rozhraní, aby nemusel terapeut stále měnit vybranou záložku.

Blok 2.C – metoda zpracování

Navržená aplikace vypočítává aktuální aktivitu EEG signálu pomocí 2 možných metod. Jedná se o metody periodogramu nebo pásmové lineární filtrace, které jsou popsány v kapitole 4.5.1 a 4.5.2. V souladu s teorií, mluvíme-li o aktivitě, jedná se vlastně o odhad krátkodobého výkonového spektra v daném frekvenčním pásmu.

Blok 2.D – počet parametrů

Vytvořené hry, se kterými je pacient ve zpětné vazbě, jsou ovládány pomocí aktivity v jednom nebo ve dvou parametrech. Terapeut zde volí, kolik parametrů bude hru ovlivňovat. V jakém vzájemném vztahu vůči sobě parametry jsou, bude popsáno v kapitole Pacientský monitor u jednotlivých her.

Blok 2.E – graf úspěšnosti

Zde vidíme 4 grafy v jednom. Červený spojitý zobrazuje aktivitu prvního parametru a červený šrafovaný zobrazuje zvolenou mez pro aktivitu v prvním parametru. Obdobně je tomu tak pro zelené grafy, které se vztahují k druhému parametru. Uživatel má možnost zobrazení posledních n ($1 \div 100$) vteřin průběhu.

Blok 2.F – výběr hry

Při spuštění aplikace se zároveň spustí vybraná hra pro pacienta, která je paralelně zobrazena na pacientském monitoru. Máme možnost zapnout aplikaci i bez zobrazení hry, například pro zobrazení již naměřených průběhů.

Blok 2.G.a a Blok 2.G.b – meze aktivit

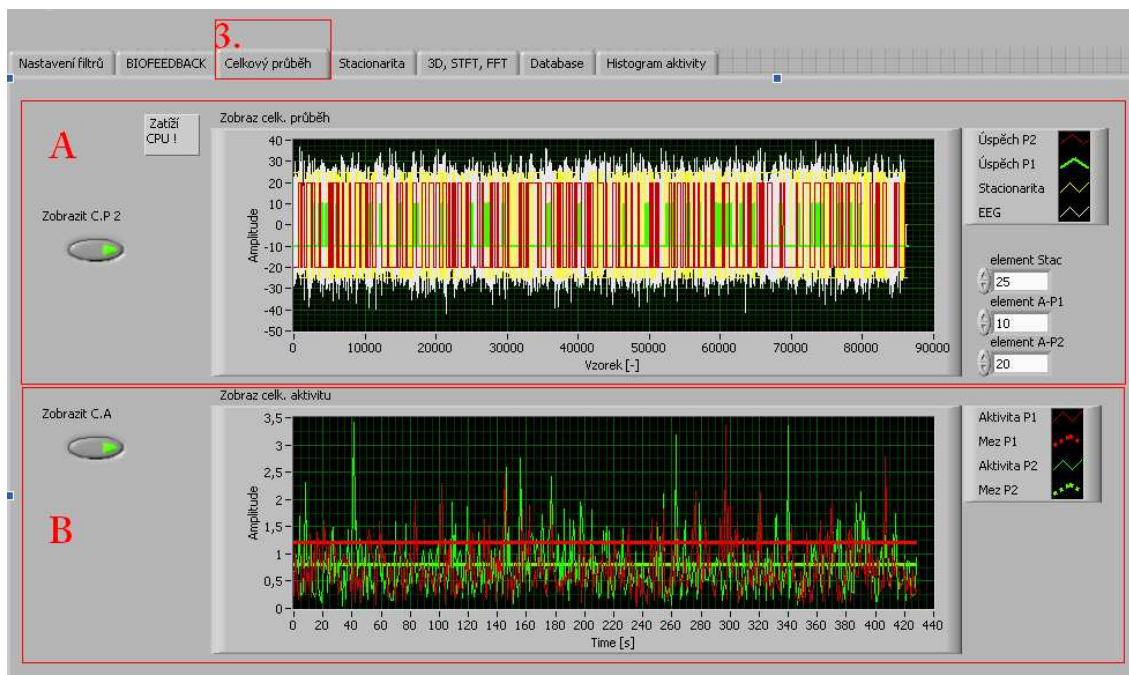
Nastavení mezí aktivit je jednou z nejdůležitějších částí aplikace biofeedbacku. Meze pro parametr 1 a parametr 2 jsou voleny právě v těchto blocích.

Blok 2.H.a a Blok 2.H.b – úspěšnost

Na začátku hry má pacient stoprocentní úspěšnost. V průběhu tréninku se počítá, kolikrát byla aktivita nad požadovanou mezí a kolikrát nikoliv. Každým neúspěchem si pacient snižuje celkovou úspěšnost, která je zde zobrazena. Navíc, je-li pacient úspěšný, svítí zelená led dioda.

7.3.3 Celkový průběh

V prvních dvou záložkách je vidět pouze aktuální průběh EEG signálu. Je tedy žádoucí, aby terapeut měl možnost shlédnout výsledky celého tréninku. To umožňuje záložka Celkový průběh, jak lze vidět na Obr. 7.10.



Obr. 7.10 – Třetí záložka - Celkové průběhy

Zobrazení celkového průběhu je možné stisknutím tlačítka v daném bloku. Každé z těchto dvou zobrazení ale výrazně zatěžuje počítač. Proto by mělo být voleno s rozmyslem.

Blok 3.A – celkový průběh 1

Na obrázku (Obr. 7.10) vidíme zdánlivě chaotický průběh s vloženými impulsy. Skutečnost se má tak, že zkoumaný signál je zde bílý šum, který byl zvolen pro ukázkou funkce aplikace. Při změně vstupního signálu na měřené EEG by se měla skutečnost následovně.

Bílý signál zobrazuje měřené EEG od spuštění aplikace. Souměrně k němu jsou vloženy průběhy úspěchů v obou parametrech. První parametr je značen červenou barvou a druhý parametr zelenou barvou, jak tomu je i u aktivity. K tomu žlutý průběh zobrazuje, zda byl proces stacionární.

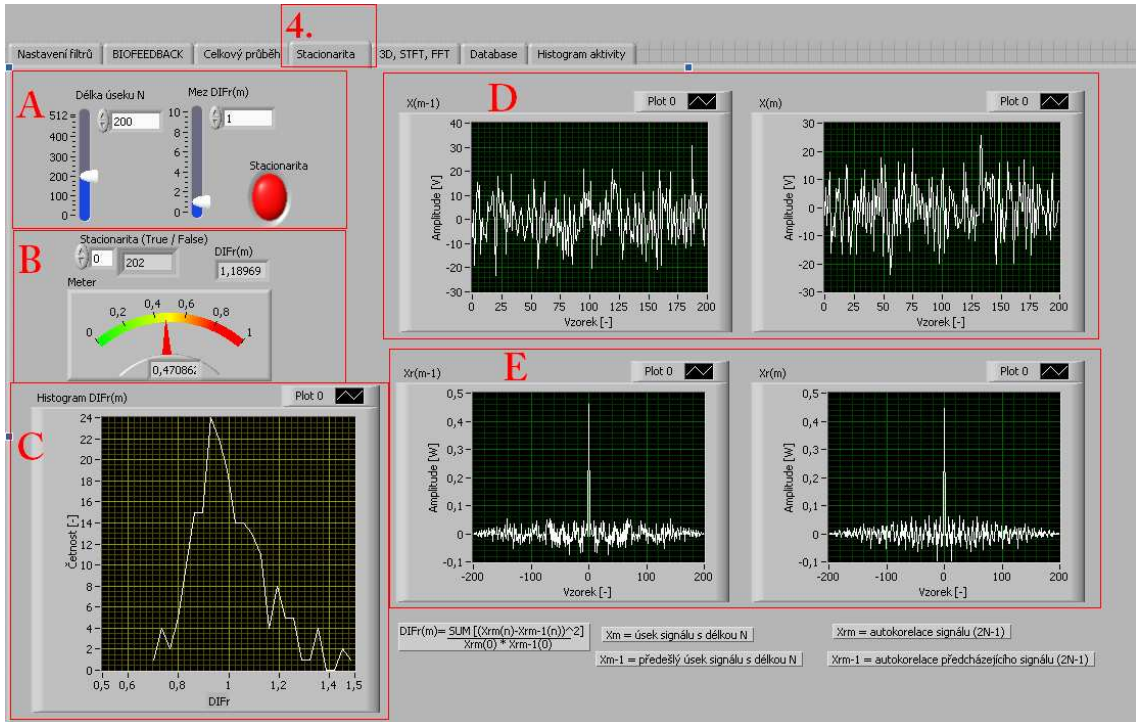
U vložených průběhů (myšleno kromě EEG) se nastavuje amplituda impulsů. Je-li potvrzen úspěch tréninku v některém z vybraných parametrů, impuls bude nabývat hodnoty kladné amplitudy. Nepotvrdí-li se úspěch, amplituda impulsu bude záporná. Obdobně je tomu i u zobrazení stacionarity. U všech třech vložených signálů lze tedy nastavit hodnotu amplitudy.

Blok 3.B – celkový průběh 2

Tento blok je v podstatě blok 2.E, s tím rozdílem, že nezobrazuje posledních n vteřin průběhu aktivity, ale dává přehled o celém průběhu.

7.3.4 Stacionarita

Jak již bylo zmíněno v kapitole 4.4 a v kapitole 4.5, pro analýzu stochastických procesů je důležité, aby signál byl stacionární. Pokud tomu tak není, nemůžeme zaručit správnou interpretaci získaných hodnot. Ke zjištění stacionarity slouží právě záložka zobrazena na Obr. 7.11.



Obr. 7.11 – Čtvrtá záložka – Stacionarita

Blok 4.A – nastavení pro výpočet stacionarity

Na základě vybrané hodnoty délky úseku N a míry difference od stacionarity $DIFr(m)$ je posuzována stacionarita procesu, respektive úseku. Hodnota $DIFr(m)$ se vypočítá podle vzorce (7.4), jenž je modifikovanou formou vzorce (4.28). Pokud vypočítaná hodnota překročí nastavenou mez, splní podmínku stacionarity a rozsvítí se červená dioda.

$$DIFr(m) = \frac{\sum_{n=0}^{N-1} (r_{x_m}(n) - r_{x_{m-1}}(n))^2}{r_{x_m}(0) - r_{x_{m-1}}(0)} \quad (7.4)$$

Přičemž autokorelace r_{x_m} se počítá podle vzorce (7.5).

$$r_{x_m}(n) = \begin{cases} \frac{1}{N} \sum_{n=0}^{N-1-n} x_m(i+n) \cdot x_m(i), & n = 0, 1, \dots, N-1 \\ 0, & n = N, N+1, \dots \end{cases} \quad (7.5)$$

Blok 4.B – statistika výsledků stacionarity

V tomto bloku se dozvíme, kolikrát byl proces stacionární a kolikrát naopak. Názorně to je vidět na barevném ukazateli úspěšnosti, který zobrazuje poměr stacionárních úseků ku celkovému počtu úseků.

Blok 4.C – histogram stacionarity

Vypočítané hodnoty pro zjištění stacionarity jsou v určitém rozmezí. Toto rozmezí právě zobrazuje histogram.

Blok 4.D – časové úseky

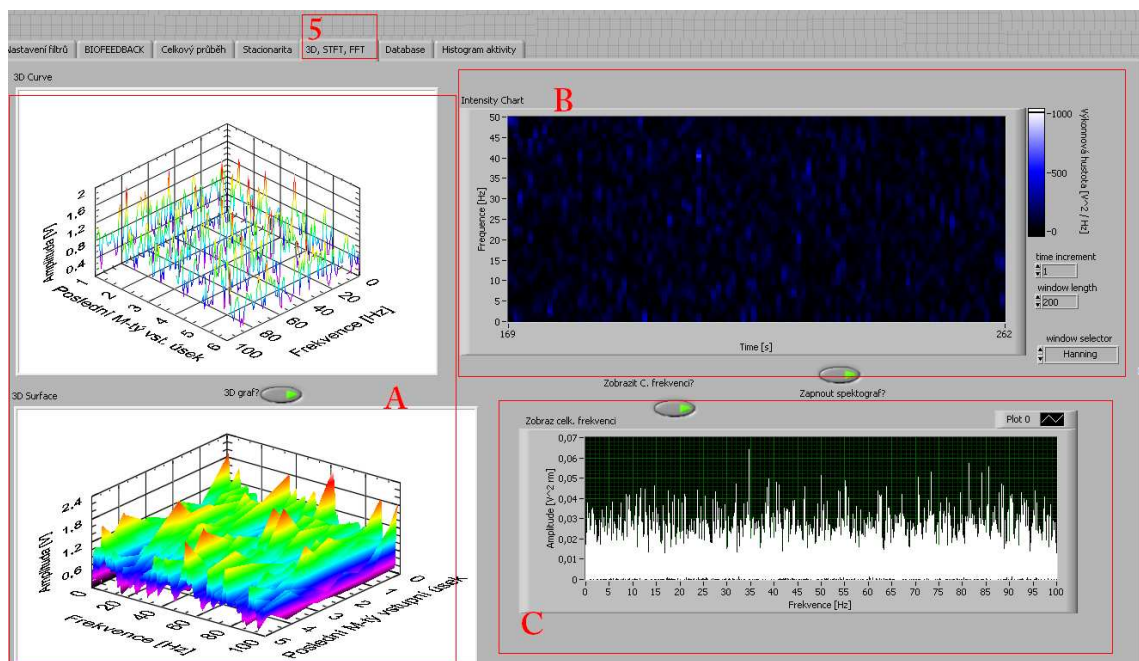
Zobrazení aktuálního úseku a minulého úseku v čase. Minulým úsekem je myšlen časový úsek zpožděný o N hodnot.

Blok 4.E – autokorelace

Autokorelace aktuálního úseku a autokorelace minulého úseku.

7.3.5 3D, STFT, FFT

Pátá záložka na Obr. 7.12 slouží k zobrazení frekvenční a časově frekvenční analýzy. Každý blok zobrazení se dá opět zapnout nebo vypnout pomocí tlačítka, neboť znatelně zatěžuje PC.



Obr. 7.12 – pátá záložka - 3D, STFT, FFT

Blok 5.A – 3D graf

Převedení posledních M vstupních úseků čítajících každý N hodnot do frekvenční oblasti pomocí algoritmu FFT zobrazují dva 3D grafy. Horizontální rovina je složena

z frekvenční osy [Hz] a z osy informující o pořadí posledních vstupních úseků. Pro výpočetní náročnost je voleno pouze 6 posledních vstupních úseků. Na vertikální ose najdeme amplitudy jednotlivých harmonických složek.

Blok 5.B – Spektrogram

Jak již bylo zmíněno v teoretické části, spektrogramy jsou nejjednodušší formou časově-frekvenční analýzy. Jedná se o tzv. STFT (Short Time Fourier Transform; krátkodobou časovou Fourierovu transformaci). Zde volíme hodnoty *time increment* a *window length*. První zmíněná hodnota určuje, z jak dlouhé doby (z kolika oken) se bude počítat výsledné spektrum. Druhá zmíněná hodnota určuje, kolik hodnot má být uvažováno do jednoho okna. Zvýšení doby hodnot *time increment* snižuje výpočetní nároky, ale snižuje časovou rozlišovací schopnost. Třetí osa přiřazuje barevné škále hodnoty vypočítané výkonové hustoty.

Blok 5.C – Celkové spektrum

Z celkového záznamu signálu je vypočítáno výkonové spektrum. Jelikož na celé délce je signál nestacionární, výsledný graf je zatížen chybou, a proto musí být brán spíše jako orientační. Aby došlo ke správné interpretaci dat, muselo by se spektrum pomocí FFT počítat pouze ve stacionárních úsecích signálu. A takto vypočítaná dílčí spektra následně kumulovat.

7.3.6 Databáze (Database)

Každá medicínská aplikace by měla obsahovat databázi pacientů, se kterou se dá později operovat. Jak je vidět na Obr. 7.13, v naší aplikaci tomu není jinak.



Obr. 7.13 – Záložka šestá - Databáze

Blok 6.A – načtení celkového průběhu

Stisknutím tlačítka pro načtení, zobrazíme průběh měření, který je již uložený v počítači. Jedná se o dřívější průběh zobrazující stejné údaje jako graf v bloku 3.A.

Blok 6.B – načtení celkového průběhu

Obdoba bloku 6.A s tím rozdílem, že zobrazuje dříve uložený průběh z bloku 3.B

Blok 6.C – databáze

Zde terapeut vkládá nové pacienty a nejdůležitější záznamy o nich. Jméno, Rodné číslo a diagnózu. Tyto informace jsou účelné pouze pro použití biofeedbacku a k vedení statistiky na pracovišti. Jelikož tato metoda není proplácena zdravotní pojišťovnou, není potřeba vést rozsáhlejší databáze.

Tento blok také obsahuje tlačítko pro založení nového pacienta. Tím se v počítači vytvoří složka se jeho jménem. Dále tlačítko s vytvořením dnešního měření, které vytvoří ve jmenované adrese složku s datem měření a poslední tlačítko pro uložení průběhu, které zajišťuje uložení obou celkových průběhů do složky s aktuálně vybraným pacientem a datem měření. Průběh je uložen v textovém souboru s názvem aktuálního času s příponou *.txt*

Tento postup vytváří možnost zpětného dohledání záznamů a také umožňuje zálohování dat klasickou metodou například na vyměnitelný disk.

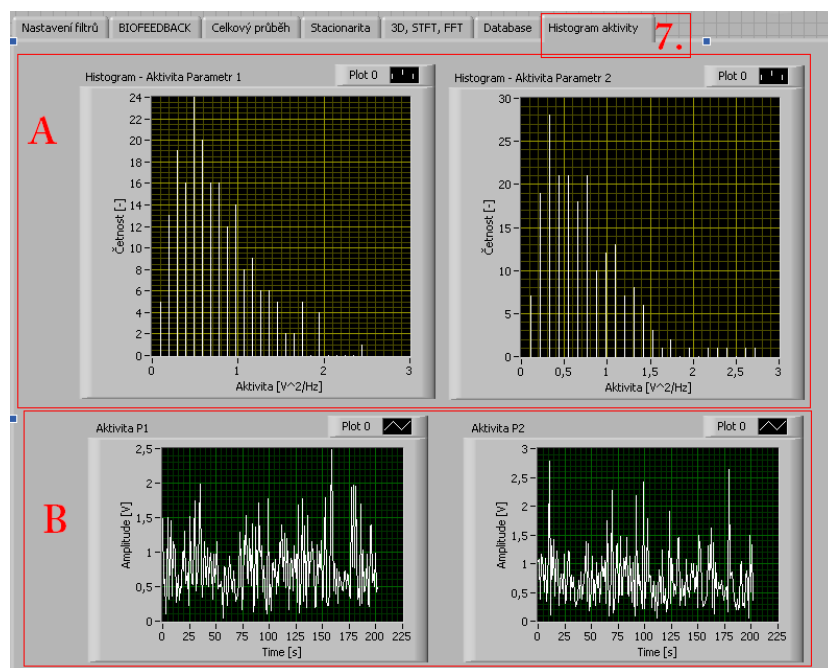
Blok 6.D – statistika

V tomto okně se dá po výběru pacienta v bloku 6.C zobrazit dosažené výsledky zvolených tréninků ze všech pacientových měření. Obsahuje tedy jméno pacienta, datum měření, úspěšnost v parametru 1, úspěšnost v parametru 2, počet parametrů nastavených k ovládání hry, výběr parametrů, výběr metody zpracování a dobu tréninku.

Takto vytvořená statistika je taktéž uložena do textového souboru.

7.3.7 Histogram aktivity

Poslední, sedmou záložkou je histogram aktivity, který je vidět na Obr.7.14.



Blok 7.A – Histogram aktivity

Zobrazení četnosti dosažených aktivit po dobu celého tréninku. Rozděluje se na 2 grafy, podle vybraného parametru.

Blok 7.B – Aktivita v čase

Zobrazení aktivity, ze které je počítán výše uvedený histogram.

7.4 Pacientský monitor

Pro zobrazení her, díky kterým se pacient učí ovládat svoji mysl, slouží pacientský monitor. Může se jednat o klasický CRT či LCD monitor nebo televizi, která se připojí k počítači, na němž je nainstalovaná aplikace pro biofeedback. Na takto rozšířenou plochu se umístí okno se spouštěnou hrou.

7.4.1 Balon

Jedná se o hru znázorněnou na Obr. 7.15, kde zvolené parametry, respektive aktivita ve zvolených parametrech je v logické vazbě AND (pokud jsou zvoleny oba parametry). To znamená, že pro úspěšný pohyb ve hře musí být splněna úspěšnost jak v prvním parametru, tak i ve druhém. Čili aktivita EEG musí překonat obě zvolené meze.

Hra je rozdělena na 2 fáze. V první musí balon letět vertikálně od země. To je splněno při úspěchu. Pokud aktivita EEG není nad stanovenou mezí, balon začne klesat. Jakmile se balon dostane dostatečně vysoko, nastane druhá fáze, kdy se musí balonem dostat na pravou stranu obrazovky. Pokud pacient není úspěšný, balon opět klesá do první fáze. Naopak pokud úspěšný je a dostane se až na konečnou značku na pravé straně, dostává se na druhou úroveň (označenou jako level) hry. Balon se objeví na počátečním místě a úkol je stejný. Rozdíl nastává při neúspěchu, kdy balon klesá k zemi dvakrát rychleji.

V pravé dolní části je vidět úspěšnost [%] a stav dosažené úrovně.



Obr. 7.15 – Hra Balon


Hra je tedy vhodná pro typ tréninku, kde chceme aktivitu zvyšovat. Například trénink SMR, Beta 1 nebo Alfa.

7.4.2 Plachetnice

Pokud jsou zvoleny 2 parametry, jsou v logické vazbě OR. To znamená, že pro úspěch ve hře stačí překonat mez jen v jednom parametru. Každý parametr ale ovlivňuje průběh hry jinak.

Při úspěchu v parametru 1 se začnou stahovat plachty a rozsvítí se slunce žlutě. Neúspěch způsobí, že se plachty začnou opět navíjet a slunce svítí červeně. Úspěch v parametru 2 ovlivní barvy plachet. Čím více je pacient úspěšný, tím více plachty zesvětlají, až nakonec změni barvu z původní černé na bílou. Navíc jako indikátor se rozsvítí mrak světle modrou barvou. V opačném případě se barva plachet vrací zpátky k černé a mrak nesvítí. Hra je demonstrována na Obr. 7.16.

Úspěšnost může pacient odvodit ze zbarvení stěžně. Na začátku je na 100 % a je celý hnědý. Snižující se úspěšností se stěžně odbarvuje.




Obr. 7.16 – Hra Plachetnice

Hra je tedy vhodná nejen pro typ tréninku, kde chceme aktivitu v obou pásmech zvyšovat. Například trénink SMR, Beta 1 nebo Alfa, kde cílem hry bude plout s roztaženýma bílými plachtami. Ale i pro trénink typu SMR/delta, kdy chceme, aby druhé pásmo bylo minimální. V tom případě bude cílem plout s roztaženými, ale černými plachtami.

7.4.3 Box

Přesto že je tato hra trochu agresivní a v některých kruzích by se mohla setkat s nesouhlasem, byla přesto do tréninku zařazena pro větší oblíbenost pacientů (v našem případě spolužáků). Navíc dokáže více udržet pozornost.



Obr. 7.17 – Hra Box

V této hře, ukázané na Obr. 7.17 se stává pacient boxerem v modrých šortkách v levé straně ringu. Pokud aktivita EEG v parametru 1 překročí nastavenou mez, udeří soupeře. Je-li aktivita pod prahem, boxer stojí a nic nedělá. Boxer v červených šortkách je řízen parametrem 2. Překročí-li EEG aktivita nastavený práh v tomto vybraném frekvenčním pásmu, udeří červený boxer modrého.

Každý boxer má určitý počet životů (20), které po jednom ztrácí, je-li zasažen. Pokud má hráč posledních 5 životů, rozsvítí se červená kontrolka nad, respektive pod životy jako upozornění. Ztratí-li všechny své životy, spadne k zemi, zobrazí se na obrazovce vítězství protihráče a připočte se jedno vítězství do zobrazovaného počítadla. Při každém úderu se navíc rozsvítí rohy útočícího hráče.

Hra je vhodná pro typ tréninku, kde chceme aktivitu v jednom pásmu zvyšovat a ve druhém naopak snižovat. Například trénink SMR/delta, kdy chceme, aby druhé pásmo bylo minimální.

7.5 Použitý algoritmus

Funkčnost programu byla částečně vysvětlena v předchozích kapitolách pomocí popisování jednotlivých bloků na předním panelu. Nyní si popíšeme funkci programu chronologicky a odůvodníme použitý algoritmus, který lze vidět v příloze A.1.

Zvuková karta vzorkuje vstupní analogový signál s možnými kmitočty 8000, 11025, 22050, 4410. Buffer, neboli zásobník lze nastavit maximálně na 8192 vstupních hodnot. Navíc můžeme volit, zda signál bude mono či stereo a zda se použije 8-mi nebo 16-ti bitový A/D převodník. Naše volba byla vzorkovací frekvence 8 KHz, zásobník s 8000 prvky a osmi bitový mono signál. Vzorkovací frekvence je zbytečně vysoká, ale jiná volba nebyla. Nejnižší možná vzorkovací frekvence by byla 80 Hz, aby ještě vyhovovala Nyquistovu kritériu, neboť užitečné frekvence EEG signálu jsou do 40 Hz. Protože na vstup dostáváme příliš mnoho vstupních vzorků a tím bychom zbytečně zatěžovali operační výkon, podvzorkujeme signál pomocí decimace tak, že signál se

kterým budeme od začátku pracovat, bude mít místo původních 8000 vzorků za vteřinu vzorků 250. Tím jsme získali novou vzorkovací frekvenci 250 Hz.

Nevýhoda vstupního signálu s 250-ti vzorky je, že se nedá zcela hodnotně použít algoritmus FFT, který je založen na aplikaci transformace na úsek čítající 2^n hodnot. Podle vzorce (4.16) můžeme zjistit, že použití algoritmu FFT oproti DFT zrychluje výpočet jen o polovinu. Pokud bychom ale použili například zásobník s 8192 hodnotami, mohli bychom docílit decimací vzorků 256. Tím bychom již neměli vstupní úsek o délce 1 s, ale přibližně 1,2 vteřiny. Přičemž každé navýšení délky vstupních dat snižuje účinnost zpětné vazby v reálném čase. Další závažnější důvod, proč jsme k této volbě nepřistoupili je, že pokud bychom vzali 8192 vzorků ze signálu, který je vzorkován 8 KHz, zapříčinili bychom rozmazání spektra.

Signál, se kterým budeme tedy nadále pracovat, obsahuje 250 vzorků a mění se všechny jeho hodnoty každou jednu vteřinu. Změna po jedné vteřině je způsobena bufferem. Teoreticky by bylo možné nastavit jeho hodnotu například na 4000 hodnot a získávat tak signál každou půl vteřinu. Prakticky to možné není, protože nastane chyba programu s příliš nízkou hodnotou zásobníku.

Následuje výpočet výkonového spektra z celkového průběhu. Celkový průběh se navyšuje o přijatá data každou vteřinu. Jak již bylo popsáno v kapitole 7.3.5 u bloku 3.C, výsledné hodnoty jsou pouze orientační z důvodu nesplnění stacionarity signálu. Zároveň probíhá výpočet pomocí STFT algoritmu a tím získáváme spektrogram.

Dále nastává výpočet autokorelace a s tím spojené zjištění stacionarity signálu. Zde je program ošetřen proti nesplnění časové kontinuity, neboť výpočet je aplikován na aktuální úsek vstupních dat a na úsek následující, respektive opožděný.

Ze vstupního úseku je také počítáno spektrum blokem FFT, který odpovídá vzorci (4.15). Výstupní komplexní signál je upraven na reálnou část a je dále veden na vstup tří bloků. Jeden z nich vykresluje 3D graf získaného spektra u posledních 6-ti vstupních úseků. Opět je zde třeba ošetřit vstup proti nesplnění kauzality. Ostatní dva bloky mají za úkoly vypočítat odhad krátkodobého výkonového spektra na základě teoretického rozboru metody periodogramu z kapitoly 4.5.1. Před tím je ale vybráno, ze kterého frekvenčního pásma (např. alfa), budou tento odhad počítat. Výsledky nám určují aktivitu A1 a aktivitu A2.

Vstupní úsek se také objevuje na vstupu banky FIR filtrů, která je tvořena ze 6-ti pásmových propustí. Jejich mezní kmitočty a váhovací okno je možné natavit v první záložce na čelním panelu virtuálního přístroje. Z výstupu banky filtrů dostáváme šest zpožděných signálů (čas zpoždění popsán v kapitole 7.3.1 u bloku 1.G). Po eliminaci způsobeného zpoždění přivádíme signál do čtyř bloků. První vypočítává spektrum EEG signálů v jednotlivých filtrovaných pásmech. Druhý přidává offset a zobrazuje EEG signál v časové oblasti. Poslední dva vypočítávají odhad krátkodobého výkonového spektra u vybraných parametrů. Jedná se tedy o metodu pásmové lineární filtrace, popsané v kapitole 4.5.2. Tím jsme získali aktivitu B1 a B2.

Na vstup filtrů je také možno přivést Diracův impuls, díky kterému zjistíme impulsní charakteristiku filtrů a pomocí FFT přenosovou charakteristiku ve frekvenční oblasti.

Ze všech konečných vykonaných operací je veden grafický výstup na terapeutický monitor, jak lze lépe vidět v již jednou zmíněné příloze A.1.

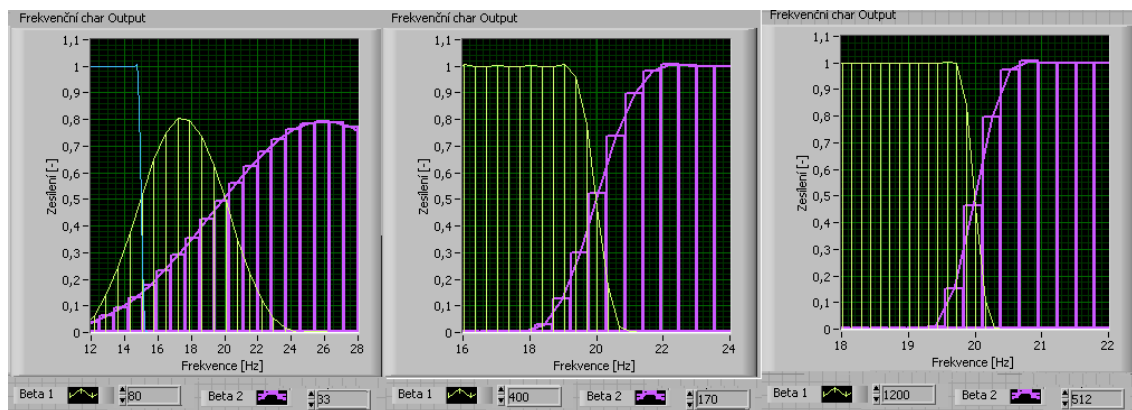
Nyní vybíráme, zda pro aplikaci má být použita metoda A (periodogram), nebo B (pásmová lineární filtrace). Aktivita A1 a A2 se tedy od aktivity B1 a B2 rozlišuje vybraným typem výpočtu. Hodnoty vybraných aktivit se porovnávají s nastavenou mezí a do druhého virtuálního přístroje Hra se pomocí globálních proměnných vloží hodnoty *True* nebo *False* v závislosti na splnění porovnávací podmínky. Průběh hry je tedy ovlivněn příchozími hodnotami *True* – splnění podmínky a *False* – nesplnění podmínky. Hra je nyní zobrazována na patientském monitoru.

Paralelně s probíhající aplikací je v terapeutickém monitoru vidět aktuální datum a čas současně s dobou tréninku. Je tu i možnost uložení a zpětného načtení průběhů a výsledků jednotlivých pacientů, které se ukládají do databáze.

7.6 Diskuze nad dosaženými výsledky

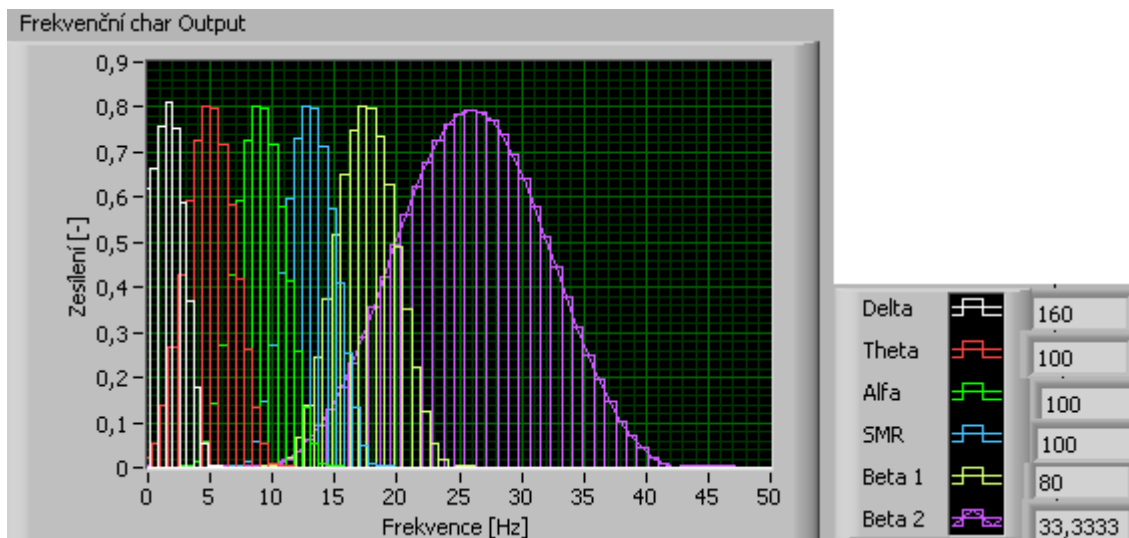
Výsledky, kterých jsme dosáhli, jsou dány technickým a principiálním omezením. Jedná se převážně o získanou frekvenční rozlišovací schopnost, prosakování spekter vlivem nastavení filtrů a správnou interpretaci dat vlivem stochastického procesu, který je omezeně stacionární.

Prosakování spektrem, které je v aplikaci způsobeno, je především zapříčiněno volbou impulsní charakteristiky. Kratší délka impulsních charakteristik má negativní vliv na prosakování spektra, nicméně má kladný vliv na výpočetní náročnost. Naopak delší impulsní charakteristika prosakování spektra omezuje, ale zvyšuje se tím zatížení PC. Správná volba počtu prvků v impulsní charakteristice tedy není možná. Jde vždy o určitý kompromis, jak ukazuje Obr. 7.18.



Obr. 7.18 – Detail prosakování spektra

Na všech třech částech obrázku (Obr. 7.18) jsou frekvenční charakteristiky použitých FIR filtrů pro pásmo $\beta 1$ ($15 \div 22$ Hz) a $\beta 2$ ($22 \div 35$ Hz). První obrázek vlevo ukazuje filtr s impulsní charakteristikou o 80-ti a 33 vzorcích podle vzorce (7.5). Uprostřed najdeme filtr s 5-ti násobnou délkou impulsní charakteristiky a napravo s 15-ti násobkem zmíněné délky.



Obr. 7.19 – Frekvenční charakteristika filtrů

Celkovou frekvenční charakteristiku s možnými použitými hodnotami délky impulsní charakteristiky je možno vidět na Obr.7.19.

Jelikož je důležité, aby aplikace pracovala opravdu s EEG v cílových pásmech, měla by být zvolena delší impulsní charakteristika na úkor výpočetních nároků.

Vraťme se ke kapitole 7.2., kde popisujeme vlastnosti zvukové karty. Z naměřené frekvenční charakteristiky jsme usoudili, že vstupní signál je do 1 Hz filtrován a že pokud bychom chtěli zachovat dosažení signálu na 0,5 Hz, bylo by třeba použít měřící kartu NI-USB. Z výše uvedené frekvenční charakteristiky filtrů (Obr. 7.19) je patrné, že vytvořené filtry nejsou tak kvalitní, jak bychom potřebovali. Softwarově totiž nedokážeme vytvořit přesné ideální filtry, které by odrušily stejnosměrnou složku, aniž by nezasahovaly do užitečného pásma, nebo by nebyly výpočetně náročné. Použití zvukové karty nám přináší vytvoření filtru horní propusti se stejně omezeným pásmem, jako bychom použili měřící kartu firmy National instruments a k ní vytvořili neideální filtr HP.

Zamysleme se také nad možným dosažitelným frekvenčním rozlišením. Při použití FFT získáváme koeficienty Fourierovy řady. Užitečné pásmo EEG signálu je od 0,5 Hz po cca 35 Hz. Abychom získali tento koeficient pro 0,5 Hz, museli bychom použít FFT na úsek o délce 2 vteřiny. Pro účely biofeedbacku je tato doba příliš dlouhá. Přijatelná doba pro trénink je 1 vteřina. Nižší hodnoty by měly za následek příliš dynamickou změnu průběhu hry a pacient by se nedokázal soustředit. Máme-li vstupní úsek o délce 1 s, nejnižší dosažitelná identifikovatelná frekvence je 1 Hz. Tato frekvence je akceptovatelná i z výše uvedeného omezení zvukové karty a charakteristik filtrů. Krok mezi jednotlivými frekvencemi ve spektrální oblasti je díky zachování poměru 250 vzorků ku vzorkovací frekvenci 250 Hz jeden Hertz. Pokud bychom požadovali větší rozlišení, například 0,5 Hz, museli bychom zvýšit délku úseku například vložení nuly mezi jednotlivé vzorky. Přesto dosažené frekvenční rozlišení je dostačující.

Poslední otázka patří dosažené stacionaritě procesu. Aby proces byl stacionární, musela by být hodnota $DIFr(m)$ ideálně nulová. Znamenalo by to, že autokorelace mezi vedlejšími úseky je stejná, a tím pádem vlastnosti systému neměnné. K takové hodnotě

bychom se měli i blížit analyzováním bílého šumu. Abychom se ale dostali k nulové hodnotě, musel by být úsek bílého šumu nekonečně dlouhý, což z praktického hlediska není možné. Při praktické analýze bílého šumu jsme dospěli k hodnotě $DIFr(m) \approx 1$.

Pro zjišťování stacionarity z již změřeného signálu EEG byl vytvořen nový virtuální přístroj. V něm je možné znovu nastavovat meze pro stacionární signál a měnit délku úseku, ze kterého se má uvažovat autokorelace signálu.

Ve zpětné analýze byly použity 3 úseky s různou délkou, respektive se 250, 125 a 72 vzorky. K nim byl vytvořen test stacionarity se 4 různými hodnotami $DIFr(m)$ ($DIFr(m) = 1$; $DIFr(m) = 2,5$; $DIFr(m) = 5$ a $DIFr(m) = 10$). Výsledky jsou vidět v příloze A.2 a A.3. Kratší úseky měly podle teoretického předpokladu větší úspěšnost ve splnění stacionarity. Zvýšení meze mělo taktéž vliv na větší úspěšnost. Tím jsme ale měnili stacionaritu myšlenou v užším smyslu na stacionaritu myšlenou v širším smyslu [11]. Krátké úseky pro aplikaci nejsou možné, neboť bychom nedokázali identifikovat nízké frekvence.

Nabízí se jedno řešení, a sice jistý případ adaptivní analýzy. Přijatý jednovteřinový úsek by se rozdělil na více menších částí. V těch by byla stacionarita v užším smyslu zaručena. Pro každé frekvenční pásmo by tak byla optimální velikost úseku. Princip by byl tedy podobný jako u multiresolučních spektrogramů. Tím bychom ale zvýšili počet vstupních dat a nároky kladené na operační paměť. Vzhledem k práci v reálném čase, od tohoto řešení bylo opuštěno.

Optimální nastavení plynoucí z analýzy pro úsek trvající jednu vteřinu je $DIFr(m) = 5$. Při nižším nastavením na 2,5 je příliš málo úseku stacionárních. Při zvýšení na hodnotu 10 se neobjeví tak výrazné změny, abychom podmínky stacionarity takto navyšovali.

Z výsledků je také patrné, že při zašumění EEG signálu očními artefakty (pohyb očí a mrkání), které jsou značně znatelné jako vysoké zákmity, signál přestane být stacionární.

Celkově vzato stacionaritu signálu nijak ovlivnit nemůžeme (až na odstranění artefaktů). Hodnocení, zda signál je stacionární či není, případně zda je stacionární v užším nebo širším smyslu, je důležité pro správnou interpretaci dat. Uvidí-li terapeut, že signál není stacionární, musí brát výsledek s určitou rezervou. Uvažovat ale výsledek za nepravdivý by bylo nesprávné.

8 ZÁVĚR

V semestrální práci byly vytvořeny dvě aplikace v programu Matlab pro analýzu naměřeného EEG signálu, přičemž každá splnila svůj účel. Následně došlo k seznámení se s programem LabView využitého pro pokračování v diplomové práci. Po předchozí domluvě s Ing. Hrozkem byla diplomová práce dále vedena pro tvorbu EEG biofeedbacku v prostředí LabView, které je koncipováno i pro aplikace v reálném čase.

První aplikace v programu Matlab informuje o naměřeném signálu a jeho spektru. Vytváří také zašuměný signál a dokáže vstupní signál uložit do formátu pro lepší zpracování v tomto programu i v programu LabView. S pomocí této aplikace je možno zjistit, že měřený signál byl vzorkován s frekvencí 1024 Hz, bylo měřeno na 21 elektrodových svodech a většina z těchto elektroencefalogramů je zašuměna stejnosměrnou složkou a síťovým šumem.

Druhá aplikace v programu Matlab vytváří amplitudový brain mapping. Poukazuje na různé výsledky pro různé interpolační koeficienty. Vzhledem ke grafickému rozlišení a časové náročnosti pro dlouhé signály je nejvýhodnější používat interpolaci s koeficientem 4 nebo 5. Je to ovšem kompromis mezi lepším grafickým rozlišením a delším časem zpracování a naopak.

V programu LabView byly vytvořeny také dvě aplikace. První slouží jako EEG biofeedback a druhá pro zpětnou analýzu stacionarity signálu. EEG signál je měřen pomocí akvizičního systému Biopac MP35, který v našem případě slouží jako diferenční zesilovač a filtr s pásmovou propustí $0,05 \div 100$ Hz. Takto naměřený signál je do počítače přiveden přes analogový vstup zvukové karty s frekvenčním omezením typu horní propust s mezním kmitočtem 1 Hz. Tím je omezen nežádoucí drift izolínie. Omezení užitečného signálu v pásmu delta mezi $0,5 \div 1$ Hz, při zapojení se zvukovou kartou, není pro funkčnost aplikace limitující.

Hlavní funkcí první aplikace v programu LabView je vypočítání odhadu krátkodobého výkonového spektra EEG signálu za dobu jedné vteřiny metodou periodogramu nebo pásmovou lineární filtrací. Na základě porovnání takto vypočítané hodnoty s předem nastavenou mezí je ovlivněn průběh zobrazované hry. Dále vytvořený program umožňuje vytvoření databáze pacientů, zobrazení jejich úspěšnosti, časové a frekvenční zobrazení EEG signálu v jednotlivých pásmech a časově-frekvenční zobrazení pomocí 2D a 3D spektrogramů.

Druhá aplikace v programu LabView slouží ke zpětnému zjištění stacionarity procesu při změnách vstupních podmínek. Pomocí ní byla zjištěna míra difference od stacionarity za dobu jedné vteřiny, a sice $DIFr = 5$. Pomocí této hodnoty můžeme signál interpretovat jako signál stacionární v širším smyslu.

Vytvořený EEG biofeedback byl otestován na dvou dobrovolnících. U obou z nich byla potvrzena funkce zpětné vazby. Meze aktivit byly nastaveny na podprůměrnou hodnotu a tím se zvýšila pravděpodobnost úspěchů ve vybrané hře. Jakmile dobrovolník zaznamenal na monitoru úspěšný posun hrou, jeho EEG aktivita se zvýšila. V daný okamžik mohla být mez přenastavena na vyšší hodnotu.

Přesto že ovládání aplikace je intuitivní, je důležité si ji osvojit. Pokud terapeut na začátku tréninku nastaví příliš vysoký práh aktivity, negativně tím ovlivní soustředění pacienta.

Jelikož je biofeedback tvořen ze dvou virtuálních přístrojů, přičemž jeden obsahuje terapeutický monitor a druhý patientský monitor, je bez velkých obtíží možné do aplikace přidávat nově vytvořené hry.

Pro zavedení vytvořeného biofeedbacku do praxe by musela naprogramovaná aplikace úspěšně splnit alfa a beta testy se zkušenými terapeuty a vybranými pacienty.

Tato diplomová práce byla také úspěšně zařazena do soutěže EEICT 2011.

LITERATURA

- [1] *Biosignal analysis and medical imaging group* [online]. 2010 [cit. 2010-04-28]. EEG Analysis. Dostupné z WWW: <<http://bsamig.uku.fi/research/qeeg.shtml>>.
- [2] *Laboratory Gerstner* [online]. 2010 [cit. 2010-04-28]. EEG. Dostupné z WWW: <<http://gerstner.felk.cvut.cz/biolab/X33BMI/biosig/>>.
- [3] *Biogetic* [online]. 2004 [cit. 2010-04-28]. Brain waves. Dostupné z WWW: <<http://www.biogetic.com/research.html>>.
- [4] *VUT* [online]. 2010 [cit. 2010-04-28] Elektrody. Dostupné z WWW: <<https://www.vutbr.cz/elearning/course/view.php?id=86249>>.
- [5] *VUT* [online]. 2010 [cit. 28. 2010-04-28], Elektroencefalografie. Dostupné z WWW: <<https://www.vutbr.cz/elearning/course/view.php?id=86249>>.
- [6] ROZMAN, J. A KOLEKTIV. *Elektronické přístroje v lékařství*, Academia, Praha, 2006, 406s. ISBN 80-200-1308-3
- [7] *Zpracování biologických signálů* [online]. 2010 [cit. 2010-04-28] Spektrální analýza. Dostupné z WWW: <<http://www.elearn.vsb.cz/archivcd/FEI/ZBS/>>.
- [8] *Životní energie* [online]. 2010 [cit. 2010-04-28] EEG biofeedback. Dostupné z WWW: <<http://zivotni-energie.cz/eeg-biofeedback-a-jeho-hlavni-pouziti.html>>.
- [9] *IQ roma servis* [online]. 2009 [cit. 2010-04-28] EEG biofeedback. Dostupné z WWW: <<http://www.iqrs.cz/view.php?navezclanku=eeg-biofeedback&cislocclanku=2007030028>>.
- [10] *Biofeedback centrum* [online]. 2008 [cit. 2010-04-28] Nové metody nápravy lehkých mozkových dysfunkcí. Dostupné z WWW: <<http://eeg-feedback.cz/html/lmd.html>>.
- [11] JAN, Jiří. *Číslicová filtrace, analýza a restaurace signálů*. 2.vydání. Brno, Antonínská 1: Nakladatelství VUTIUM, 2002. str. 428. ISBN 80-214-1558-4.
- [12] BIOPAC Systems [Online] 2004 [cit. 2011-05-17.] Inc. *BSL hardware guide. BIOPAC Systems, Inc* Dostupný z WWW: <<http://www.biopac.com>>.
- [13] *Communication research facility* [online]. 2010 [cit. 2011-05-17]. Department of Communication, Virginia Tech. Dostupné z WWW: <[13] <http://www.comm.vt.edu/researchfacility/equipment.html>>.
- [14] *EEG Biofeedback* [online]. 2011 [cit. 2011-05-17]. EEG BIOFEEDBACK JAKO PREVENCE U PŘEDŠKOLNÍCH DĚTÍ. Dostupné z WWW: <[14] <http://www.eegbiofeedback.cz/cesky/cesky.php?menu=3>>.

SEZNAM ZKRATEK

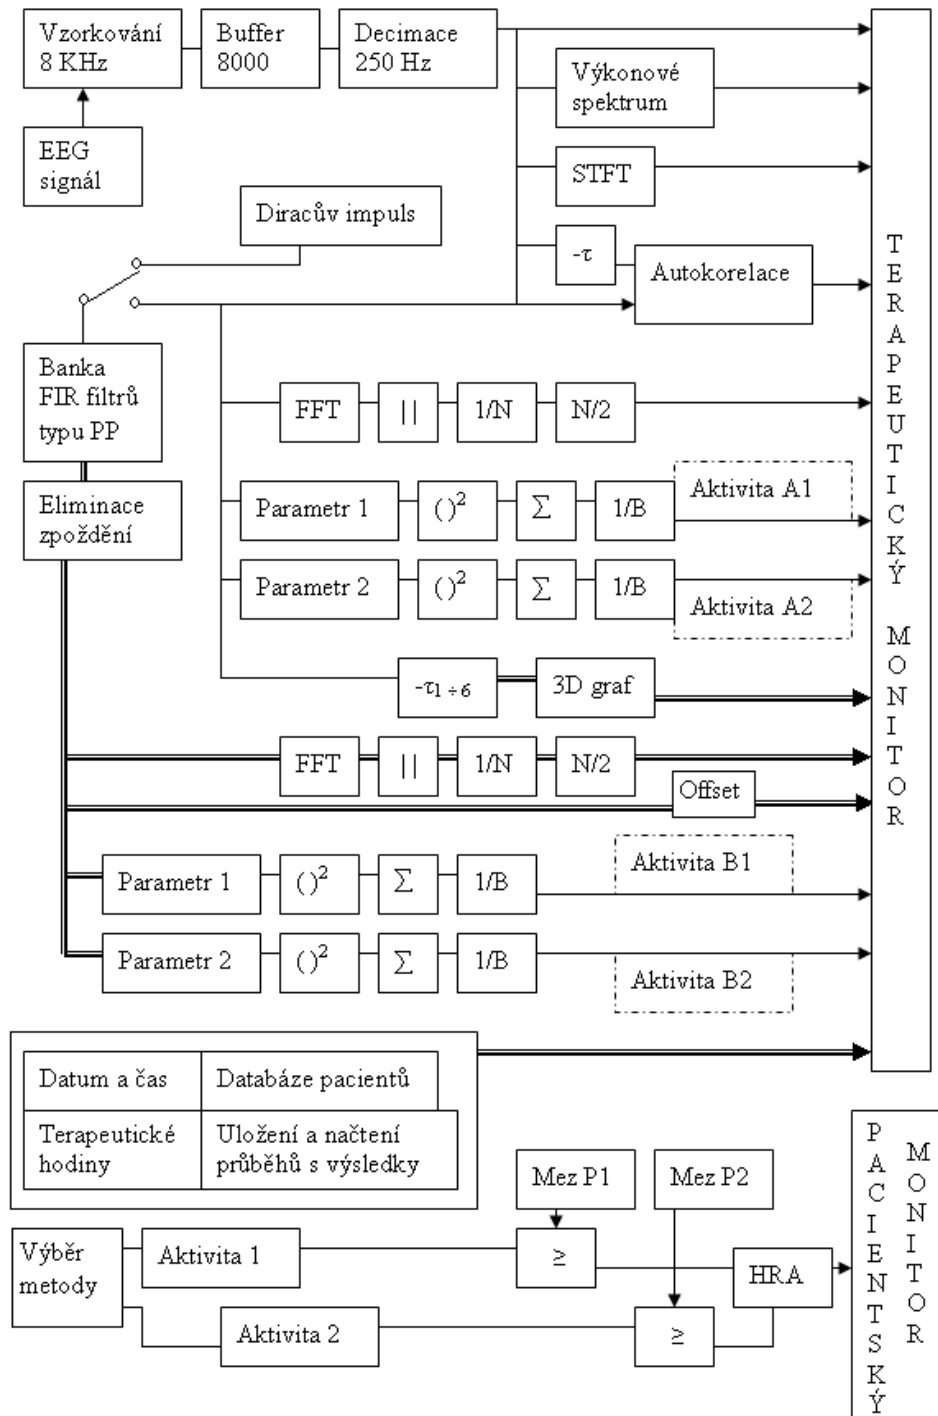
EEG	Elektroencefalograf
DP	Dolní propust
HP	Horní propust
PP	Pásmová propust
PZ	Pásmová zadrž
FFT	Fast Fourier Transform – rychlá Fourierova transformace
DFT	Discrete Fourier Transform – diskrétní Fourierova transformace
STFT	Short Time Fourier Transform – krátkodobá časová Fourierova transformace
LORETA	Low Resolution Brain Electromagnetic Tomography
VEP	zrakově evokovaný potenciál
AEP	akusticky evokovaný potenciál
SSEP	potenciál vzniklý podprahovými elektrickými impulsy na končetinách
ADHD	Attention-Deficit / Hyperactivity-Disorder
SCp	Slow Cortical Potentials – pomalé kortikální potenciály
SMR	sensorimotor rhythm – senzomotorický rytmus
CRT	Cathode ray tube, katodová trubice
LCD	Liquid crystal display – Displej z tekutých krystalů
NI	National Instruments
USB	Universal serial bus – univerzální sériová sběrnice
D-SUB	D-subminiature
CMMR	common-mode rejection ratio – diskrementační činitel
CSA	Compressed Spectral Arrays – zhuštěné spektrální kulidy
DIFr	míra difference od stacionarity

SEZNAM PŘÍLOH


A	labview	67
A.1	Blokové schéma.....	67
B	Matlab	70
B.1	Základní analýza – zdrojový kód.....	70
B.2	Brain mapping – zdrojový kód	71
B.3	Brain mapping s různými koeficienty interpolace	75

A LABVIEW

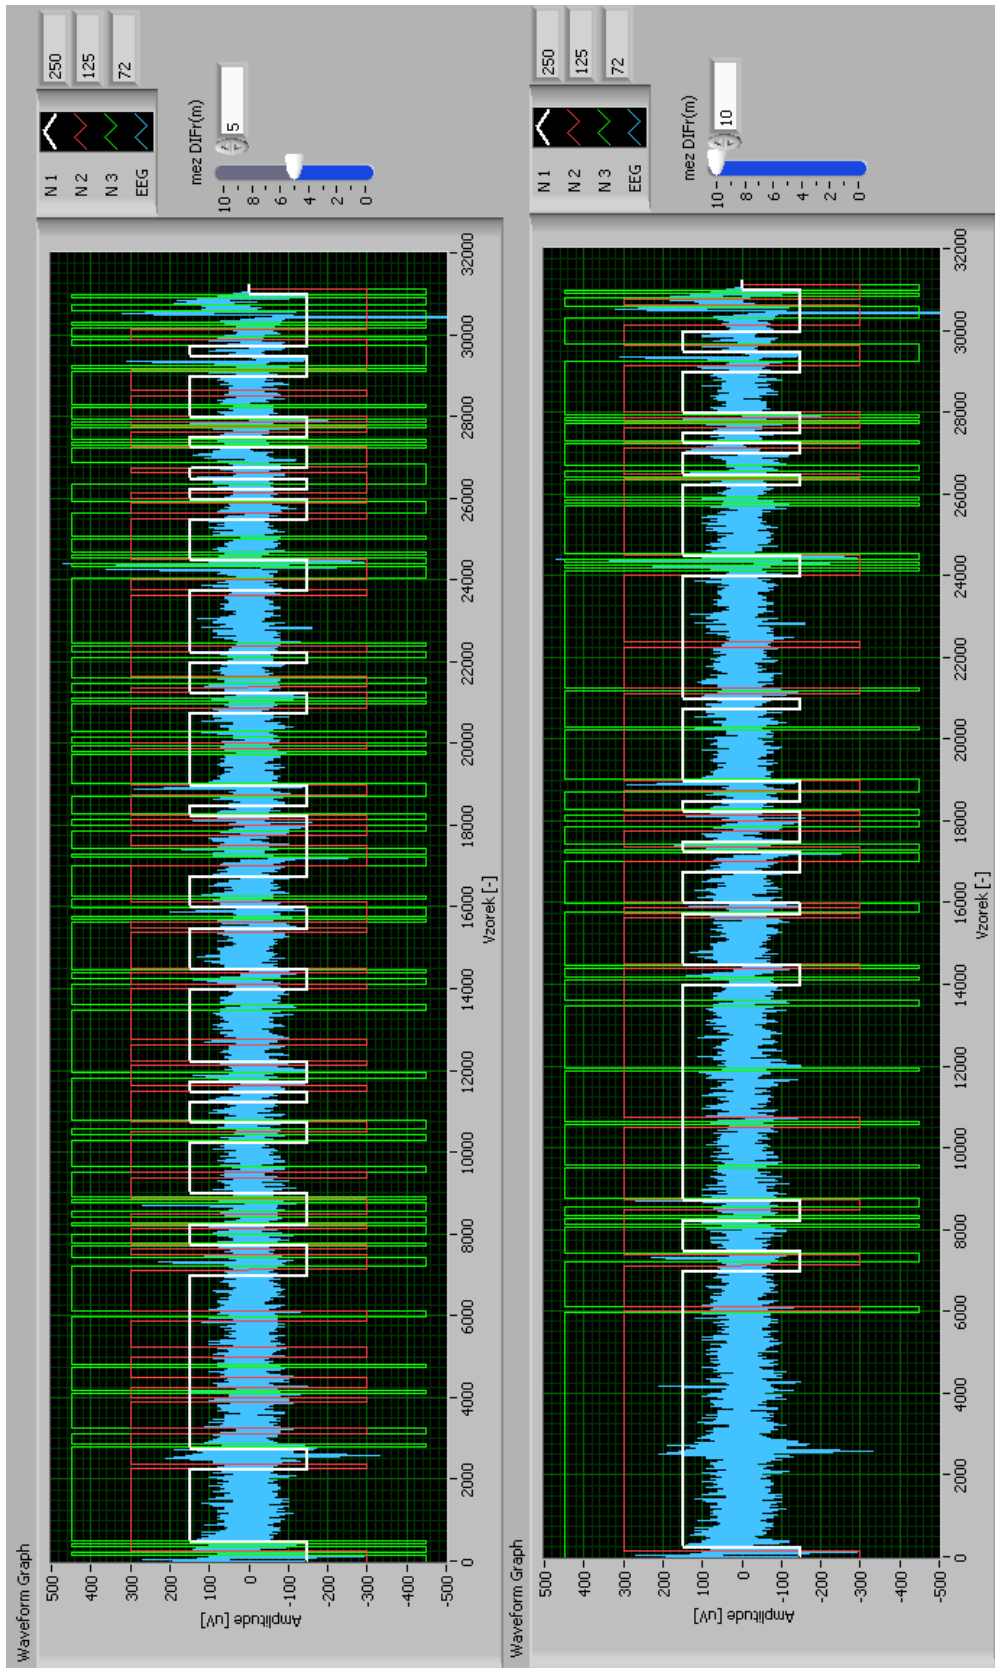
A.1 Blokové schéma použitého algoritmu



A.2 Stacionarita – 1. nastavení



A.3 Stacionarita – 2. nastavení



B MATLAB

B.1 Základní analýza – zdrojový kód

```
clear all;
close all;
clc;

%_____naplneni promenych z namereneho signalu_____
[data,chans,sampling,sens,chann,id,pr,jm,date,time]=read_alien('relax.
dat');

%_____zakladni nastaveni_____
tvz=1/sampling; % vzorkovaci frekvence (v casove oblasti)
N=length(data); % delka signalu
maxt=(N-1)*tvz; % doba signalu

t1=(0:tvz:maxt); % casova osa - vypocet zpusobem 1
t2=(0:N-1)/sampling; % casova osa - vypocet zpusobem 2

c1=data(21,:); % vyber elektrody 1 a namereneho signalu

%_____sum_____
f=45; % frekvence sinusoveho sumu
A=100; % amplituda sinusoveho sumu
sum=A*sin(2*pi*f*t1); %vytvoreni sumu
sum=int16(sum);
c2=c1+sum; %zasumeni signalu sumem

%_____graf 1_____
figure(1)
subplot(3,1,1)
plot(t1,c1); %vykresleni signalu s casovou osou pomoci zpusobu 1
subplot(3,1,2)
plot(t2,c1); %vykresleni signalu s casovou osou pomoci zpusobu 2
subplot(3,1,3)
plot(t2,c2); %vykresleni zasumeneho signalu s casovou osou pomoci
zpusobu 2
%_____

%_____Fourierova transformace - zjisteni spektra_____
f=(0:N-1)/maxt; % frekvencni osa
c1d=double(c1);
C1=fft(c1d); % rychla fourierova transformace -
%- frekvenci spektrum nezasumeneho signalu
c2d=double(c2);
```

```

C2=fft(c2d); % rychla fourierova transformace -
             %- frekvenci spektrum zasumeneho signalu

%_____Graf 2_____
figure(2)
subplot(2,1,1);
plot(f,abs(C1));
stem(f,abs(C1)); % vykresleni spektra nezasumeneho signalu

subplot(2,1,2);
plot(f,abs(C2));
stem(f,abs(C2)); %vykresleni spektra zasumeneho signalu

%_____Spektralni hustota - vykonove spektrum_____
spektrum1=C1.*conj(C1)/N; %vykonove spektrum nezasumeneho signalu
spektrum2=C2.*conj(C2)/N; %vykonove spektrum zasumeneho signalu

%_____graf 3_____
figure(3)
subplot(2,1,1);
plot(f,abs(spektrum1));
stem(f,abs(spektrum1)); %vykresleni vykonoveho spektra nezasumeneho
signalu

subplot(2,1,2);
plot(f,abs(spektrum2));
stem(f,abs(spektrum2)); %vykresleni vykonoveho spektra zasumeneho
signalu

%___vytvoreni souboru pro LabView_____
%vybereme svod
%c1 = data(1,:);

% otevreme soubor pro zapis
fid = fopen('G:\VUT\ING\Diplomka\data\eeg21m.dat', 'w');

% ulozime vektor s
fprintf( fid, '%6.6f\n', c1);

% zavreme soubor
fclose(fid);

```

B.2 Brain mapping – zdrojový kód

```

clc
clear all;
close all;

%n=50; %delka nactaneho signalu [vzorek]
i=25; % pozice vypoctu pro brain mapping [vzorek]

%__nacteni signalu_

```

```

text='nacteni zapocato'
s1= load ('eeg1m.dat'); text='signal 1 nacten'
n=length(s1);
s1=s1(1:n);
s2= load ('eeg2m.dat'); text='signal 2 nacten'
s2=s2(1:n);
s3= load ('eeg3m.dat'); text='signal 3 nacten'
s3=s3(1:n);
s4= load ('eeg4m.dat'); text='signal 4 nacten'
s4=s4(1:n);
s5= load ('eeg5m.dat'); text='signal 5 nacten'
s5=s5(1:n);
s6= load ('eeg6m.dat'); text='signal 6 nacten'
s6=s6(1:n);
s7= load ('eeg7m.dat'); text='signal 7 nacten'
s7=s7(1:n);
s8= load ('eeg8m.dat'); text='signal 8 nacten'
s8=s8(1:n);
s9= load ('eeg9m.dat'); text='signal 9 nacten'
s9=s9(1:n);
s10= load ('eeg1m.dat'); text='signal 10 nacten'
s10=s10(1:n);
s11= load ('eeg2m.dat'); text='signal 11 nacten'
s11=s11(1:n);
s12= load ('eeg3m.dat'); text='signal 12 nacten'
s12=s12(1:n);
s13= load ('eeg4m.dat'); text='signal 13 nacten'
s13=s13(1:n);
s14= load ('eeg5m.dat'); text='signal 14 nacten'
s14=s14(1:n);
s15= load ('eeg6m.dat'); text='signal 15 nacten'
s15=s15(1:n);
s16= load ('eeg6m.dat'); text='signal 16 nacten'
s16=s16(1:n);

text='nacteni ukonceno'
text='brain mapping1 zapocat'

%AMPLITUDOVÝ BRAIN MAPPING pro jeden okamzik
m1=[s1(i) s2(i) s3(i) s4(i)
     s5(i) s6(i) s7(i) s8(i)
     s9(i) s10(i) s11(i) s12(i)
     s13(i) s14(i) s15(i) s16(i)];

interp_m1=interp2(m1,1,'cubic'); % interpolace matice s koeficientem 1
interp_m2=interp2(m1,2,'cubic'); % interpolace matice s koeficientem 2
interp_m3=interp2(m1,3,'cubic'); % interpolace matice s koeficientem 3
interp_m4=interp2(m1,4,'cubic'); % interpolace matice s koeficientem 4
interp_m5=interp2(m1,5,'cubic'); % interpolace matice s koeficientem 5
interp_m6=interp2(m1,6,'cubic'); % interpolace matice s koeficientem 6
interp_m7=interp2(m1,7,'cubic'); % interpolace matice s koeficientem 7
interp_m8=interp2(m1,8,'cubic'); % interpolace matice s koeficientem 8

text='brain mapping ukoncen'
text='vykreslovani grafu 1'

figure(1);
colormap(jet);

```



```

subplot(3,3,1)
imagesc(m1); title('bez interpolace')
subplot(3,3,2)
imagesc(interp_m1); title('k = 1')
subplot(3,3,3)
imagesc(interp_m2); title('k = 2')
subplot(3,3,4)
imagesc(interp_m3); title('k = 3')
subplot(3,3,5)
imagesc(interp_m4); title('k = 4')
subplot(3,3,6)
imagesc(interp_m5); title('k = 5')
subplot(3,3,7)
imagesc(interp_m6); title('k = 6')
subplot(3,3,8)
imagesc(interp_m7); title('k = 7')
subplot(3,3,9)
imagesc(interp_m8); title('k = 8')

text='vykreslovani grafu 1 ukonceno'

%_____brain mapping pro celou delku
signalu_____
text='brain mapping k=4 zapocato'
tic; % zacatek vypocetniho casu 1
for i=1:185 %vytvoreni matice amplitud 16ti EEG signalu v jednom
okamziku pro celou delku signalu.

    m1=[s1(i) s2(i) s3(i) s4(i)
        s5(i) s6(i) s7(i) s8(i)
        s9(i) s10(i) s11(i) s12(i)
        s13(i) s14(i) s15(i) s16(i)];

interp_t4=interp2(m1,4,'cubic'); % interpolace matice s koeficientem 4
end
t4=toc*(n/185); % konec vypocetniho casu 1
t4m=t4/60;

text='brain mapping k=5 zapocato'
tic; %zacatek vypocetniho casu 2
for i=1:185 %vytvoreni matice amplitud 16ti EEG signalu v jednom
okamziku pro celou delku signalu.

    m1=[s1(i) s2(i) s3(i) s4(i)
        s5(i) s6(i) s7(i) s8(i)
        s9(i) s10(i) s11(i) s12(i)
        s13(i) s14(i) s15(i) s16(i)];

interp_t5=interp2(m1,5,'cubic'); % interpolace matice s koeficientem 5
end
t5=toc*(n/185); % konec vypocetniho casu 2
t5m=t5/60;

text='brain mapping k=6 zapocato'
tic; %zacatek vypocetniho casu 3
for i=1:185 %vytvoreni matice amplitud 16ti EEG signalu v jednom
okamziku pro celou delku signalu.

```

```

m1=[s1(i) s2(i) s3(i) s4(i)
    s5(i) s6(i) s7(i) s8(i)
    s9(i) s10(i) s11(i) s12(i)
    s13(i) s14(i) s15(i) s16(i)];

interp_t6=interp2(m1,6,'cubic'); % interpolace matice s koeficientem 5
end
t6=toc*(n/185); % konec vypocetniho casu 3
t6m=t6/60;

text='vykresleni grafu 2 zapocato'
figure(3)

subplot(1,3,1)
imagesc(interp_t4),title(['počet vzorků: ',int2str(n)];'koeficient
interpolace 4';[' Doba vypoctu: ',num2str(t4), ' s' ];['=
',num2str(t4m), ' min']})

subplot(1,3,2)
imagesc(interp_t5),title(['počet vzorků: ',int2str(n)];'koeficient
interpolace 5';[' Doba vypoctu: ',num2str(t5), ' s' ];['=
',num2str(t5m), ' min']})

subplot(1,3,3)
imagesc(interp_t6),title(['počet vzorků: ',int2str(n)];'koeficient
interpolace 6';[' Doba vypoctu: ',num2str(t6), ' s' ];['=
',num2str(t6m), ' min']})

text='konec aplikace'

```

B.3 Brain mapping s různými koeficienty interpolace

