


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**

ÚSTAV AUTOMATIZACE A MĚŘICÍ TECHNIKY
FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF CONTROL AND INSTRUMENTATION

ANALÝZA A ZPRACOVÁNÍ EEG SIGNÁLU

Analysis and processing of EEG signal

BAKALÁRSKA PRÁCE
BACHELOR THESIS

AUTOR PRÁCE
AUTHOR
VEDOUCÍ PRÁCE
SUPERVISOR

**AMIR HOSSEIN ESMAILDOKHT
MAMAGHANI
ING. PETR PETYOVSKÝ**

BRNO 2011

Abstrakt

Tato práce se zabývá problematikou měření a analýzy elektroencefalografických signálů. Prochází celou oblastí od základních principů měření přes metodiku a způsoby měření, předzpracování a zpracování signálu, klasifikaci jednotlivých elementů až po možnosti analýzy signálu. Dále nahlédne do světa produktů pro spotřebitelský trh a přinese přehled o open-source řešeních pro měření EEG signálů. V praktické části se zaměřuje na získávání, zpracování a analýzu naměřených dat, prochází jednotlivými kroky od předzpracování signálu k jeho konečné prezentaci. Nakonec vysvětlí stavbu a složení umělé neuronové sítě, s jejíž pomocí by bylo možné rozeznat a klasifikovat konkrétní EEG signál.

Klíčová slova

Snímání a analýza, signálové zpracování, elektroencefalografie, předpracování signálu, počítačové zpracování, grafoelementy, umělá neuronová síť

Abstract

This thesis deals with methods of electroencephalographic signals measurement and analysis. It covers the whole field of EEG from the basic principles of measuring through the methodology and various ways of measuring, signal preprocessing and processing, and classification of individual elements, up to the signal analysis capabilities. Then it provides an insight into the world of products for the consumer market and brings an overview of open-source solutions for EEG signal measuring. In the practical part it focuses on acquisition, processing and analysis of measured data, follows all individual steps from signal preprocessing up to its final presentation. Eventually it explains the structure and composition of an artificial neural network by which it would be possible to recognize and classify specific EEG signal.

Keywords

Measuring and analysis, signal processing, signal, electroencephalography, signal preprocessing, computer processing, graphoelements, artificial neural network

ESMAILDOKHT MAMAGHANI, A.H. Analýza a zpracování EEG signálu. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2012. 78s. Vedoucí semestrální práce byl Ing. Petr Petyovsky.

Prehlásenie

„Prohlašuji, že svou bakalářskou práci na téma Analýza a zpracování EEG signálu jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brne dňa: **28. 5. 2012**

.....
podpis autora

Pod'akovanie

Ďakujem pánovi Ing. Petrovi Petyovskému. za cenné rady, námety, pripomienky a ochotu pri vypracovávaní mojej semestrálnej práce.

V Brně dne: **28. 5. 2012**

.....
podpis autora

Obsah

1	Úvod.....	13
2	Elektroencefalografia.....	14
2.1	Čo je to elektroencefalografia	14
2.2	História.....	14
2.3	Charakteristika záznamu EEG	15
2.4	Charakteristika EEG vlny	16
2.5	Popis prístroja a metodika.....	16
2.6	Zdravotné riziká	17
2.7	Rozdelenie EEG vln.....	17
2.7.1	Alfa rytmus	17
2.7.2	MU rytmus.....	19
2.7.3	Beta rytmus	19
2.7.4	Theta aktivita	19
2.7.5	Delta aktivita.....	20
2.8	Artefakty	20
2.8.1	Endogénne artefakty	20
2.8.2	Exogénne artefakty	22
3	Spracovanie a analýza.....	24
3.1	Filtre	24
3.1.1	Horná priepusť	24
3.1.2	Dolná priepusť	24
3.1.3	Úzkopásmová zádrž.....	24
3.2	Metódy analýzy.....	25
3.2.1	Časová analýza	25
3.2.2	Spektrálna analýza	26
3.2.3	Topografické mapovanie aktivity - Brain mapping.....	27
3.2.4	Časovo-frekvenčná analýza	28
3.2.5	Vlnková transformácia.....	29
3.2.6	Evokované potenciály.....	29
3.2.7	Aplikácia umelých neurónových sietí.....	30

4	Open-Source EEG riešenia	31
4.1	OpenEEG, ModularEEG	31
4.2	OpenEXG	32
4.3	CEEGALS	33
4.4	The Programmable Chip EEG	34
4.5	EEGLAB - Open-source Matlab Toolbox	35
5	Oblasti využitia open-source EEG zariadení	36
5.1	Brain-computer interface - BCI	36
5.1.1	Delenie BCI	36
5.2	Porovnanie open-source projektov a komerčných produktov určených pre spotrebiteľský trh	37
5.2.1	Emotiv EPOC	38
5.2.2	MindWave	38
5.2.3	XWave	38
6	Moje riešenie - ModularEEG	39
6.1	Úpravy hardwaru	40
6.2	Konštrukcia skrinky a náhľad na celé zariadenie	42
6.3	Elektródy	44
6.4	Výsledky prvých meraní	45
7	Vylepšený ModularEEG - EEG-SMT	47
7.1	Elektródy	48
7.1.1	Aktívne elektródy SMT-AE	48
7.1.2	Pasívna DLR elektróda SMT-PA	48
7.2	EEG čiapka	49
8	Software Neuroline	50
8.1	Dekódovanie dát	51
8.2	Konverzia dát	53
8.3	Prostredie Neuroline	53
8.4	Signálové bloky	54
8.4.1	Blok Source	55
8.4.2	Blok RAW data	56
8.4.3	Blok Simple Operations > Amplify	56

8.4.4	Blok Simple Operations > Square/Root	56
8.4.5	Blok Simple Operations > Offset	57
8.4.6	Blok Simple Operations > Add Signal	57
8.4.7	Blok Processing > Average.....	57
8.4.8	Blok Counter.....	58
8.4.9	Blok Min a Max.....	58
8.4.10	Blok Processing > Exponential Smoothing (single).....	58
8.4.11	Blok Processing > Exponential Smoothing (double).....	60
8.4.12	Blok Processing > Filter	60
8.4.13	Blok Analysis > Time analysis	61
8.4.14	Simulinkový ekvivalent zapojenia.....	62
9	Umelá neurónová sieť.....	63
9.1	Definícia.....	63
9.2	Neurón.....	64
9.3	Dopredné siete.....	66
9.4	Učenie so spätným šírením chýb - Backpropagation.....	67
9.5	Návrh umelej neurónovej siete pre vyhodnotenie EEG signálu a jeho možná aplikácia v programe Neuroline.....	71
9.5.1	Filtrácia signálu.....	71
9.5.2	Vlnková transformácia.....	72
9.5.3	Umelá neurónová sieť.....	73
9.5.4	Zhodnotenie	76
10	Záver.....	77
	Literatúra.....	79
	Zoznam príloh.....	82

Zoznam obrázkov

Obrázok č. 1: Hans Berger, nemecký fyziológ, 1929 [15]	15
Obrázok č. 2: Systém umiestnenia elektród nazvaný 10-20 [16]	17
Obrázok č. 3: Alfa rytmus.....	17
Obrázok č. 4: Beta rytmus	19
Obrázok č. 5: Theta rytmus.....	19
Obrázok č. 6: Delta aktivita	20
Obrázok č. 7: Odras činnosti srdca v EEG zázname [17]	21
Obrázok č. 8: Artefakty spôsobené potením pacienta [17].....	21
Obrázok č. 9: Artefakt spôsobený pohybom očí ale unilaterálne - pacient má jedno oko sklenené.	22
Obrázok č. 10: Artefakty spôsobené rušením spektra sieťovým brumom o frekvencii 60Hz [17].....	23
Obrázok č. 11: Holterov monitor pre záznam EEG.....	25
Obrázok č. 12: Spektrálna analýza, Topografické mapovanie aktivity	27
Obrázok č. 13: Topografické mapovanie aktivity	28
Obrázok č. 14: Spektrogram	29
Obrázok č. 15: ModularEEG [21].....	31
Obrázok č. 16: OpenEXG [18]	32
Obrázok č. 17: CEEGALS [11]	33
Obrázok č. 18: Blokový diagram analógového obvodu Programmable Chip EEG [12]	34
Obrázok č. 19: Mikrokontrolerový obvod Programmable Chip EEG [12]	34
Obrázok č. 20: ADC obvod Programmable Chip EEG [12].....	34
Obrázok č. 21: Zobrazenie EEG záznamu v prostredí EEGLAB [13].....	35
Obrázok č. 22: Brain Mapping v prostredí EEGLAB [13].....	35
Obrázok č. 23: Odstránenie diódy D104 na digitálnej doske ModularEEG.....	40
Obrázok č. 24: Výmena mikrokontroléru na digitálnej doske ModularEEG	40
Obrázok č. 25: Prepájkovanie pinov pre použitie viacerých analógových dosiek pre ModularEEG	41
Obrázok č. 26: Odstránenie potenciometra na pre zosilnenie aktívnej zeme, následne skratovanie pinov 1 a 2.	41

Obrázok č. 27: Potenciometre pre nastavenie zosilnenia pre ModularEEG.....	42
Obrázok č. 28: Použitá skrinka pre ModularEEG	42
Obrázok č. 29: Moje riešenie ModularEEG	43
Obrázok č. 30: Zadná strana skrinky so vstupmi pre elektródy a napájanie	43
Obrázok č. 31: Riešenie spojenia kábel-elektroda.....	44
Obrázok č. 32: Koaxiálny kábel RG-174 použitý pri vedení signálu z elektród na vstup meracej techniky	44
Obrázok č. 33: konektory CINCH	44
Obrázok č. 34: Priebeh signálu kalibračného napätia.....	45
Obrázok č. 35: Zvýšená alfa aktivita pri absencii zrakového stimulu - pri zavretí očí... 45	45
Obrázok č. 36: Znížená alfa aktivita pri zrakovom stimule - otvorení očí.	46
Obrázok č. 37: Ukážka zostavenia aplikácie pomocou funkčných blokov v prostredí BrainBay	46
Obrázok č. 38: EEG-SMT [22].....	47
Obrázok č. 39: EEG-AE [22].....	48
Obrázok č. 40: Rozmiestnenie elektród.....	49
Obrázok č. 41: EEG čelenka.....	49
Obrázok č. 42: Prostredie programu Neuroline	50
Obrázok č. 43: Dekódovanie packetu	52
Obrázok č. 44: Pohyblivé okná programu Neuroline	54
Obrázok č. 45: Konfigurácia bloku.....	55
Obrázok č. 46: Schéma bloku Amplify	56
Obrázok č. 47: Schéma bloku Square/Root.....	56
Obrázok č. 48: Schéma bloku Offset.....	57
Obrázok č. 49: Schéma bloku Add Signal pri nastavení Sinus	57
Obrázok č. 50: Upravený signál pomocou funkcie Average. Vľavo pôvodný, vpravo upravený.....	57
Obrázok č. 51: Grafické zobrazenie výstupných hodnôt funkcií Min a Max.....	58
Obrázok č. 52: ZedGraph.....	61
Obrázok č. 53: Ekvivalent blokov v prostredí Simulink	62
Obrázok č. 54: Topológia umelej neurónovej siete [26]	64
Obrázok č. 55: Model neurónu	65

Obrázok č. 56: Lineárna charakteristická funkcia [24].....	65
Obrázok č. 57: Funkcia jednotkový skok [24].....	65
Obrázok č. 58: Funkcia Ramp [24].....	66
Obrázok č. 59: Sigmoidná funkcia [24].....	66
Obrázok č. 60: Gaussová funkcia [24].....	66
Obrázok č. 61: Jednovrstvový perceptor [26].....	67
Obrázok č. 62: Trojvrstvová neurónová sieť [26]	67
Obrázok č. 63: Tréning UNS [26]	68
Obrázok č. 64: Tréning UNS 2 [26]	68
Obrázok č. 65: Výpočet chyby δ v sieti backpropagation [26]	69
Obrázok č. 66: Šírenie chyby a nastavenie váh v sieti backpropagation [26]	70
Obrázok č. 67: Filtrácia signálu v programe Neuroline.....	71
Obrázok č. 68: Morletová vlnka	73
Obrázok č. 69: Signál po aplikácii vlnkovej transformácie [29]	75

Zoznam tabuliek

Tabuľka 1: Komerčné EEG produkty pre spotrebiteľský trh [19].....	37
Tabuľka 2: Skladba packetu P2	51
Tabuľka 3: Nastavenie sériovej komunikácie.....	55

1 ÚVOD

Elektroencefalografia je úspešnou klinickou metódou využívanou pri diagnostike ochorení mozgu a to najmä epilepsie či iných záchvatových ochorení. Okrem využitia v klinickej praxi sa však v posledných rokoch stáva predmetom záujmu aj u bežných ľudí a to najmä v oblasti experimentovania s meraním mozgovej aktivity počas stavu fyzického a psychického uvoľnenia, pozornosti či bdlosti ale aj v oblasti zábavného priemyslu ako EEG periférie hracích konzol.

Hlavným cieľom mojej bakalárskej práce je ozrejmienie postupov a metód pri meraní EEG signálu, opis základnej klasifikácie jednotlivých zložiek, popis artefaktov vyskytujúcich sa v EEG zázname a návrh vhodného riešenia pre meranie EEG signálov použitím všetkých dostupných prostriedkov.

Kapitola 2 popisuje základné požiadavky pri meraní, je teoretickým úvodom do celej problematiky v oblasti merania EEG signálu. Následne kapitola 3 predstaví základné metódy analýzy pre jeho jasnejšiu interpretáciu a parametrizáciu. V kapitole 4 rozoberám dostupné riešenia či už komerčné v oblasti spotrebiteľského trhu alebo open-source riešenia určené pre hobbistov. Následne kapitola 5 predstaví možnosti využívania týchto produktov, porovná open-source riešenia s komerčnými a pripraví priestor pre predstavenie môjho vlastného riešenia. Veľká pozornosť bude venovaná konštrukčnému riešeniu, spôsobu merania, spôsoby konštrukcie zariadenia a úprav hardwaru open-source zariadenia a v poslednom rade popíšem spôsob spracovania a analýzy EEG signálov pomocou výpočtovej techniky.

2 ELEKTROENCEFALOGRAFIA

2.1 Čo je to elektroencefalografia

Elektroencefalogram (skrátene EEG) je záznam časovej zmeny elektrického potenciálu spôsobeného mozgovou aktivitou. Tento záznam je zosnímaný elektroencefalografom. [5]

Je to významná pomocná klinická metóda, ktorá patrí medzi neinvazívne vyšetrovacie metódy. Pri vyšetrení sa zaznamenávajú zmeny kolísania potenciálových rozdielov vždy medzi dvoma bodmi, buď na povrchu hlavy alebo bodom na hlave a referenčným bodom, ktorým môže byť napríklad najčastejšie ušný lalôčik, brada, nos a iné. Výsledkom je krivka, ktorá predstavuje priebeh zmien potenciálových rozdielov v čase. Pôvod týchto potenciálových rozdielov a ich zmien v čase však nie je známy a je predmetom viacerých teórií. Predpokladajme teda že elektrické potenciály sú prejavom elektrickej polarizácie a depolarizácie povrchovej membrány neurónov. Ide o stav pripravenosti neurónov na činnosť v tom zmysle, že podprahovými výbojmi sú synapsy udržiavané v optimálnom stave dráždivosti. [4]

2.2 História

Obor snímania a analýzy mozgových vĺn je relatívne mladým oborom, jeho začiatky sa datujú od druhej polovice 18. storočia, kedy Luigi de Galvani a Alessandro Volt publikovali svoje prvé správy o produkcii elektrických fenoménov živým tkanivom. [1]

Krátko na to bolo od roku 1875 publikovaných hneď niekoľko publikácií poukazujúcich na bioelektrickú aktivitu mozgu. O viac ako pol storočia neskôr vyvinul Bois Reymond nepolarizovateľnú elektródu, pomocou ktorej registroval elektrickú aktivitu žabieho mozgu. V druhej polovici 19. storočia popísal Richard Caton elektrické prúdy králičích a opičích mozgov, pozoroval, že mozog vytvára pri svojej činnosti veľmi slabé elektrické prúdy. [2]

V roku 1913 popredný neurológ Pravdiez-Něminskij zachytil ako prvý EEG aktivitu u psa. Prvé meranie srdečnej aktivity bolo na začiatku 20. storočia kedy Willem Einthover po objavení citlivých galvanometrov postavil svoj prvý komerčný elektrokardiograf. [3]

Prvé snímanie EEG tak ako ho dnes poznáme sa uskutočnilo až v roku 1924 kedy Hans Berger snímal elektrickú aktivitu ľudského mozgu a tieto nazval elektroencefalogramom. [3]

Krátko na to Edgar Douglas Adrian v roku 1934 rozšíril znalosti o mozgových rytmoch a presnejšie definoval charakteristiku alfa aktivity. Prvé jednoúčelové zariadenie na registráciu elektrickej mozgovej aktivity vzniklo v tridsiatych rokoch 20. storočia u niekoľkých firiem súčasne: Walter, Kaiser, Drahočki, Toennies. [1]

Elektroencefalografia sa výrazným spôsobom pričiniła pri diagnostike a liečbe epilepsie a bola úspešne zavedená do klinickej praxe. EEG umožnila lekárom sledovať priebeh epileptického záchvatu (epileptický výboj) priamo v mozgu. [2]

Potvrdila sa predpokladaná spojitosť klinického priebehu záchvatu a EEG zmien. Veľký vývoj a rozmach zaznamenala elektroencefalografia v päťdesiatych rokoch 20. storočia, kedy bola povýšená na najdôležitejšiu pomocnú neurologickú metódu. Šesťdesiate roky nášho storočia znamenali búrlivý rozvoj EEG práce na celom svete. Zvyšuje sa počet laboratórií, prístrojov, laborantov, technikov a lekárov elektroencefalogistov. Od sedemdesiatych rokov až doteraz sa ďalej rozvíjajú štandardizácie v obore EEG. Vypracúvajú sa EEG normy a sleduje sa stav nálezov EEG so známymi morfológickými nálezmi. [4]



Obrázok č. 1: Hans Berger, nemecký fyziológ, 1929 [15]

2.3 Charakteristika záznamu EEG

Grafický záznam krivky mozgových rytmov sa nazýva elektroencefalogram. Mozgové rytmy sú jemným a citlivým ukazovateľom funkčného stavu mozgového tkaniva ktorá závisí aj na veku pacienta. Tieto krivky sa menia veľmi nepravidelne, avšak výrazne zmeny možno pozorovať medzi záznamom v bdelom stave, pri zaspávaní a spánku. Najväčšie a najvýraznejšie zmeny je možné pozorovať v prípade určitých mozgových ochorení ako napríklad nádor, krvácanie, zápal či epileptická aktivita.

Krivka EEG záznamu je zložitá a často veľmi neurčitá, mení sa v čase a vždy zaznamenáva aj signály so zdrojom mimo mozgovú kôru. Sprostredkuje informácie o činnosti mozgu, avšak možno ju hodnotiť iba vizuálne čo vyžaduje dlhú prax v oblasti. V tejto zložitej spleti kriviek ale možno rozlišovať určité základné prvky nazývané grafoelementy. Základným grafoelementom je vlna, je to grafický záznam jedného elektrického kmitu. Jej parametrami sú frekvencia (trvanie), amplitúda (jej elektrický potenciál), tvar, fáza a zoskupenie. [4]

2.4 Charakteristika EEG vlny

Elektroencefalogram obsahuje široké frekvenčné spektrum, nejde o náhodný šum ale priebeh tvoria určité zákonitosti v amplitúdach a frekvenciách.

Frekvenčný rozsah EEG je v rozmedzí od 0.1 do 100Hz, väčšinou je ale postačujúci od 0.1 do 70Hz, pre použitie v oblasti biofeedbacku či BCI bohato vyhovuje pásmo do 40Hz. Toto spektrum je rozdelené do niekoľkých frekvenčných pásiem a to delta (0.1 - 4Hz), theta (4-8Hz), alfa (8 - 13Hz), beta (13 - 30Hz). [1]

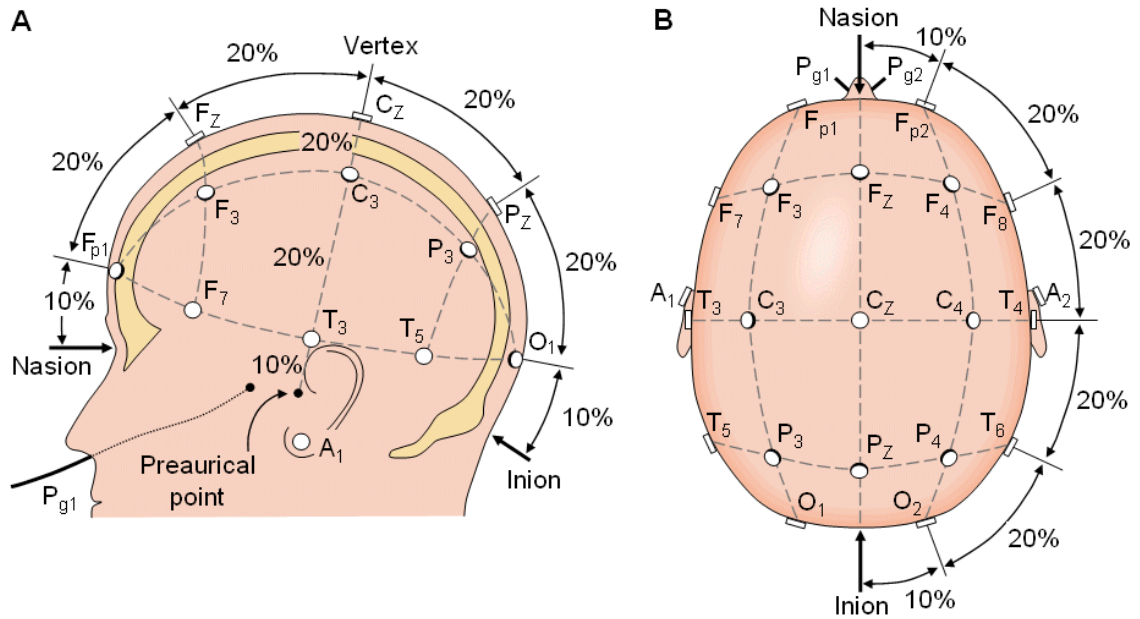
Amplitúdová charakteristika je v rozsahu od 10uV až dokonca do 1500uV. Táto hodnota závisí od zdroja signálu, jednotlivé mozgové vrstvy tento potenciál výrazne oslabujú. Orientačné rozmedzie pre alfa, theta a delta pásmo je rozdelené na tri pásma - nízke amplitúdy a to 10 až 30uV, stredné 30 - 70uV a vysoké nad 70uV. Pre beta vlny je pásmo rozdelené na nízke do 10uV, stredné pásmo od 10 do 25uV a vysoké pásmo od 25uV a viac. [1]

2.5 Popis prístroja a metodika

Pri snímaní EEG môžeme mať akokoľvek kvalitné zariadenie, avšak pri výbere zlých či nekvalitných elektród nám je prístroj nanič, sú totiž prvým elementom, ktorý zaisťuje prevod elektrickej aktivity z povrchu hlavy (alebo priamo z mozgovej kôry v prípade invazívnych metód) na vstup EEG prístroja. Ich charakteristika je daná druhom použitého kovu, elektrovodivej pasty, veľkosťou povrchu styčnej plochy a ďalších parametrov ktoré ovplyvňujú veľkosť elektrického potenciálu pri prechode prúdom - polarizáciu. V prípade aktívnych (napájaných) elektród záleží na ďalších mnohých parametroch ako je napríklad typ operačného zosilňovača, riešenie kontaktu medzi elektródou a kožou, typ a tienenie vodičov atď.

Pri snímaní EEG je nutné používať v stykových oblastiach kovy, ktoré sú nepolarizovateľné a umožňujú prenos rýchlych zmien. Najčastejšie sú tieto plochy pokryté tenkou vrstvičkou chloridu strieborného AgCl, niektoré sú zo špeciálnych zliatin či nerezových ocelí.

Umiestnenie povrchových elektród je štandardizované na rozmiestnenie podľa systému 10/20. Ten je pomenovaný na základe vzájomného umiestnenia elektród na povrchu hlavy kde vzdialenosť medzi určitými elektródami tvorí 20 alebo 10 percent z celkovej dĺžky povrchu. Tým pádom je možné rovnomerne rozmiestniť elektródy na povrchu celej hlavy.



Obrázok č. 2: Systém umiestnenia elektród nazvaný 10-20 [16]

2.6 Zdravotné riziká

Pri meraní EEG je nutné dávať pozor na bezpečnosť a zdravie pacienta. Možným zdravotným rizikom môže byť ale aj zle navrhnutý prístroj pre meranie EEG, napríklad je elektronika priamo pripojená k číslicovej technike bez oddelenia napríklad optočlenom. Vtedy sa môže stať, že skrat či výboj v zdroji počítača spôsobí elektrický šok pacientovi, ba až usmrtenie. Oddelenie pacienta a prístroja od počítača sa najčastejšie rieši práve optočlenom vďaka rýchlym prenosom informácie tohto elektronického komponentu.

2.7 Rozdelenie EEG vln

Pre lepšiu klasifikáciu EEG sa jednotlivé zložky signálu delia na alfa, beta, delta, theta vlny, MU rytmus. Toto delenie je na základe frekvenčného pásma a tvaru signálu.

2.7.1 Alfa rytmus



Obrázok č. 3: Alfa rytmus

Základná frekvencia je v rozmedzí od 8-13Hz, najčastejšie 9.5-10.5Hz, pri ospalosti 7-8Hz, je rovnako dominantná v oblasti oboch hemisfér, frekvenčný rozdiel medzi oboma hemisférami nesmie presiahnuť 1Hz. Alfa aktivita sa počas života človeka vyvíja, jej dolné frekvenčné úrovne zdokumentoval Lüders a Noachtar (1994,2000) a to nasledovne - 1. rok > 5Hz, 4.rok > 6Hz, 5.rok > 7Hz, 8.rok > 8Hz, ďalej by sa nemal meniť. Pokiaľ je signál pod touto hranicou, ide o abnormalitu. [6]

Amplitúda signálu je u detí vyššia ako 50-60uV, menej modulovaná, u dospelých je to 15-50uV, v ojedinelých prípadoch dokonca menej ako 15uV, u starších ľudí je ešte nižšia. Úbytok signálu je pri ospalosti, mentálnej činnosti, zvýšenej pozornosti. Hyperventilácia spôsobuje často zvýšenie amplitúdy. [6]

Vlna má tvar sínusoidy alebo ostro kontúrovaný v prítomnosti beta aktivity. Tie sa vyskytujú najmä u detí a mladšími jedincami. V centrotemporálnych oblastiach hlavy treba rozlíšiť alfa aktivitu od rolandického MU rytmu (ostrá záporná fáza, oblá kladná fáza) . Alfa je blokovaná stimulom a to najmä svetelným - otvorením očí, preto sa najlepšie sníma pri zavretých očiach, fyzickej relaxácii a pri nižšej mentálnej aktivite. U časti jedincov môže byť alfa aktivita prítomná iba v krátkych periódach po zavretí očí. [6]

Menštruačný cyklus má vplyv na alfa aktivitu, predmenštruačné obdobie a ovulácia spôsobujú zvýšenie maximálnej frekvencie alfa, spomalenie je počas menštruácie a po ovulácii. [6]

Najväčšie amplitúdy alfa rytmu je možné merať v systéme 10/20 pod elektródami O1, O2, P3, P4, T5, T6 čiže maximá sa nachádzajú nad zadnými kvadrantmi, často ale nastáva presah a to do oblasti C3, C4, A1, A2, T3, T4. [6]

2.7.2 MU rytmus

Taktiež prezývaný ako rolandický alebo mí rytmus, je veľmi podobný alfa aktivite ale topografia a fyziologický význam sa podstatne líši. Je charakterizovaný ostrou negatívnou fázou a zaoblenou pozitívnou fázou. Má arkádovitý tvar (comb-shaped), trochu pripomína malé písane písmeno „r“. [1]

Amplitúda je porovnateľná s alfa aktivitou. Frekvencia je v rozsahu 9 - 11Hz. Maximá sa vyskytujú v precentrálnej a postcentrálnej oblasti s prienikom až do parietálnej oblasti, čiže pod elektródami C3, C4, Cz, poprípade až P3 a P4. MU rytmus je blokovaný motorickou funkciou (pohybom) alebo len myšlienkou na ňu. Nakoľko alfa aktivita je blokovaná otvorením očí, u MU rytmu nemá vizuálny stimul žiadny vplyv. Vyskytuje sa u 20% populácie a to najmä mladých dospelých jedincov, nevyskytuje sa takmer vôbec pred 4. rokom života. [6]

2.7.3 Beta rytmus



Obrázok č. 4: Beta rytmus

Je to rytmická aktivita s frekvenciou nad 13Hz bez jasného ohraničenia hornej frekvencie ale najčastejšie sa udáva 15-25Hz s amplitúdou pod 20uV, niekedy ale aj 20-30uV. Charakteristický je tvar sínusoidy, hrotnaté alebo oblúkovité tvary u vyšších frekvenciách. Objavuje sa v krátkych úsekoch, v epizódach alebo až výbojmi. Beta aktivita nie je synchronná nad oboma hemisférami. Výskyt beta aktivity je obvyklý vo frontálnej oblasti, v centrálnej zmiešaný s MU rytmom, nad zadným kvadrantom kde ide o rýchlu alfa aktivitu. Amplitúda a distribúcia môže byť zvýšená pri ospalosti, NREM I-II, REM spánku. [6]


2.7.4 Theta aktivita



Obrázok č. 5: Theta rytmus

Frekvenčný rozsah má od 4 do 8Hz, je difúzna, sporadická, má nižšie amplitúdy (pod 30uV) a väčšinou sa vyskytuje v temporálnej oblasti. Neprevyšuje okcipitálnu alfa aktivitu o viac ako 50%. Oveľa častejšie sa vyskytuje u detí a adolescentov ako u dospelých. Theta aktivita sa najlepšie popisuje pri zázname jedinca v 25 až 30-tom roku života. [6]

2.7.5 Delta aktivita



Obrázok č. 6: Delta aktivita

Vyskytuje sa iba v zázname v štádiu III-IV NREM spánku, jej frekvenčný rozsah je 0.1 - 4Hz. V bdelom stave sa vyskytuje iba v patologických prípadoch. Záznam delta aktivity slúži výhradne na analýzu spánkových štádií. [6]

2.8 Artefakty

Takmer pri každom zázname vznikajú artefakty. Sú to biologické fenomény, ktoré nemajú svoj pôvod v činnosti mozgového tkaniva. [7]

Delia sa na endogénne a exogénne.

2.8.1 Endogénne artefakty


Endogénne artefakty vznikajú vplyvom telesných funkcií a delia sa podľa spôsobu ich vzniku.

2.8.1.1 Biologické artefakty

Sú dôsledkom prenosu QRS komplexu srdca do EEG záznamu a to najmä u ľudí so silnejším krkom alebo pri zlej polohe tela počas merania, pri zlom nastavení ušných elektród alebo elektródy driven-leg (aktívna zem), pri odraze cievnej pulzácie v prípade keď je elektróda blízko veľkej cievy, poprípade tlačí na povrch hlavy pacienta, potením pacienta, artefakty z dýchania, pohyby viečok a očí, pohyb úst, jazyka, škrípanie zubov, svalové pohyby alebo plač u malých detí. [4]



Obrázok č. 7: Odras činnosti srdca v EEG zázname [17]




Obrázok č. 8: Artefakty spôsobené potením pacienta [17]

2.8.1.2 Patologické artefakty

Sú spôsobené napríklad trasením a sťahmi viečok, nystagmom alebo trasením jazyka či vnútrolebečnej pulzácií. [4]

2.8.1.3 Vnútorne technické artefakty

Spôsobené sú stomatologickou prácou dutiny ústnej či protézou očného bulbu. [4]



Obrázok č. 9: Artefakt spôsobený pohybom očí ale unilaterálne - pacient má jedno oko sklenené.

2.8.2 Exogénne artefakty


Exogénne artefakty sú spôsobené vonkajším vplyvom na meraciu techniku alebo pacienta. Delia sa na prístrojové artefakty a artefakty iného pôvodu. [4]

2.8.2.1 Prístrojové artefakty

Tieto artefakty vznikajú dôsledkom nastavenia meracej techniky alebo, pri zlej inštalácii periférii napríklad z elektród (zlomený kábel, zlý dotyk, skorodovaná elektróda), čiapok alebo pri zlom usporiadaní elektród. [4]

2.8.2.2 Artefakty iného pôvodu

Príčinou ostatných artefaktov v EEG zázname môže byť spôsob uzemnenia prístroja, odrazom sieťového brumu, čiže zlé tienenie prístroja alebo zmeny kožného odporu. [4]



Obrázok č. 10: Artefakty spôsobené rušením spektra sieťovým brumom o frekvencii 60Hz [17]

Preveniou pred výskytom artefaktov je správne umiestnenie EEG laboratória, faradayova kletka okolo miestnosti alebo pacienta s meracím prístrojom a zatemnenie miestnosti.

3 SPRACOVANIE A ANALÝZA

Zosnímať a zosilniť EEG signál, správne ho zakódovať pre možnosť prehliadať ho v počítači ešte nie je konečný cieľ, je nutné ešte urobiť zopár krokov k jeho úspešnej interpretácii. Je nutné signál filtrovať. Vieme že použiteľné frekvenčné spektrum signálu je od 0.5 Hz do približne 70 Hz, aby sme vylúčili zložky nad týmto spektrom vrátane zložiek o kmitočte 50 Hz a 60 Hz, je nutné použiť niekoľko filtrov, či už hardwarových alebo softwarových.

3.1 Filtre

V nasledujúcich podkapitolách hovoríme o hardwarových analógových filtroch, ktorých aplikácia je v obvode dôležitá. Je nutné odfiltrovať jednosmernú zložku signálu, sieťový šum a všetky zložky nad 70 Hz, pretože nie sú pre nás podstatné. To všetko zabezpečíme použitím troch tipov filtrov a to horná priepusť, dolná priepusť a úzkopásmová zádrž.

3.1.1 Horná priepusť

Filter horná priepusť v prípade analógového filtra je RC článok s medzným kmitočtom od 0.1 Hz do 0.5 Hz pre elimináciu jednosmernej zložky signálu čo nám zabezpečí, že hlavná línia signálu sa nebude pohybovať. Zvyčajne sa používa filter druhého až štvrtého stupňa so stúpaním 40 dB/dek až 80 dB/dek.

3.1.2 Dolná priepusť

Filter dolná priepusť je takisto RC článok s medzným kmitočtom od 40 Hz do 70 Hz, slúži na potlačenie frekvencií, ktoré nemajú zdroj v mozgovej aktivite, poprípade ide o nízkonapäťový šum z okolia.

3.1.3 Úzkopásmová zádrž

V prípade, že u dolnej priepusti je zvolená medzná frekvencia vyššia ako frekvencia sieťového šumu, čo je pravidelný harmonický signál spôsobený kmitaním napätia v elektrickej sieti (v Európe je to 50 Hz, USA a ďalšie krajiny 60 Hz), je nutné do obvodu zakomponovať pásmovú zádrž. Čím dôležitejšie je zachovanie zložiek v okolí frekvencie 50 Hz, tým viac musí byť charakteristika úzkopásmovej zádrže strmšia.

3.2 Metódy analýzy

Pre čo najpresnejšiu interpretáciu toho, čo sa deje v mozgu, je nutné signál analyzovať. Existuje mnoho spôsobov analýzy EEG signálov, spomeniem však iba tie najdôležitejšie.

3.2.1 Časová analýza

V prípade že nepoužívame žiadne transformácie a pozorujeme priebeh signálu v čase, hovoríme o časovej analýze. Je možné zobrazit' isté frekvenčné spektrum signálu, to si zosilniť alebo zmeniť rýchlosť jeho vykresľovania.

Existuje niekoľko rôznych typov monitorovacích zariadení pre časovú analýzu.

3.2.1.1 Holterovo monitorovanie

Monitorovanie trvá 24 hodín a viac, okrem mozgovej aktivity sa zaznamenáva aj srdečná činnosť a tieto údaje sa ukladajú na prenosné médium ako napríklad v minulosti magnetofónová páska avšak v dnešnej dobe to už sú digitálne čipové karty.



Obrázok č. 11: Holterov monitor pre záznam EEG

Vyhodnotenie a analýza signálu sa prevádza až neskôr načítaním pamäťového média v počítači. Takýmto spôsobom je možné sledovať čo predchádzalo napríklad epileptickému záchvatu alebo jednotlivé mentálne stavy počas dňa pacienta. [1]

3.2.1.2 Monitorovacie systémy pre ARO, JIP a operačnú sálu

Ide o vysoko presnú a spoľahlivú techniku pre použitie v kritických situáciách ako napríklad počas operácii alebo na traumatológii. Signál je možno sledovať buď klasickými miskovitými elektródami ale vhodnejšie sú vpichové so stabilným odporom a najmä kvôli ich jednoduchej aplikácii v náročnejších podmienkach. [1]

3.2.1.3 Video EEG

Zariadenie je spojenie audiovizuálneho modulu a klasického EEG prístroja, slúži na zaznamenávanie mozgovej aktivity popri video a audio monitoringu pacienta. Takto zosnímané dáta sa zlúčia a výsledkom je video záznam so sprievodným záznamom EEG. Toto riešenie sa využíva najmä pri pozorovaní spánku a fyzických reakcií na mozgovú aktivitu ale aj pri pozorovaní ľudí postihnutých epilepsiou či inou mozgovou chorobou. [1]

3.2.2 Spektrálna analýza

Spektrálna analýza slúži obecné k nájdeniu popisu signálu pomocou jeho zložiek v spektrálnej oblasti. Budeme rozoberať len analýzu spektra z pohľadu Fourierovej transformácie . [8]

3.2.2.1 Diskrétna Fourierova transformácia DFT

Jednou z najstarších a najpoužívanejších metód pre analýzu EEG je Fourierova transformácia. Pri analýze EEG v číslicovej technike je používaná diskrétna fourierova transformácia (ďalej len DFT) a inverzná DFT. Pokiaľ spojitý periodický signál $f(t)$ nahradíme časovou postupnosťou N vzorkou $f(nT)$, pri splnení vzorkovacieho teóremu, potom môžeme stanoviť zodpovedajúci súbor N vzorkou spektra. [8]

$$DF\left(\frac{k}{NT_0}\right) = T_0 \sum_{n=0}^{N-1} f(nT_0) e^{-j\frac{2\pi kn}{N}}, \quad k = 0, 1, 2, \dots, N-1 \quad (3.1)$$

T_0 je perióda vzorkovacieho signálu, k označuje stupeň harmonického frekvenčného spektra, n značí poradové číslo vzorku a N predstavuje súbor vzorkou signálu.

3.2.2.2 Rýchla Fourierova transformácia FFT

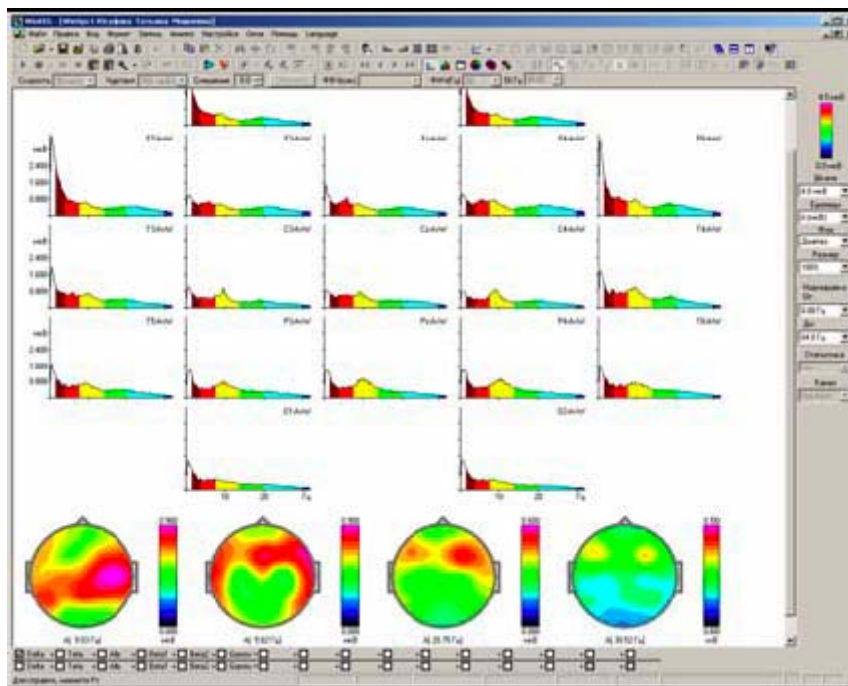
Rýchla fourierova transformácia má jednoduchší výpočet algoritmu, tým pádom je menej náročná pre výpočtovú techniku a dosiahnuté výsledky FFT a DFT sú rovnaké. Čiže jediným rozdielom medzi týmito dvoma algoritmami je iba ich čas výpočtu. [8]

Nech X_0 až X_{N-1} je komplexné číslo:

$$X_k = \sum_{n=0}^{N-1} x_n e^{-\frac{2\pi i}{N}nk} \quad k = 0, \dots, N-1 \quad (3.2)$$

Priame vyhodnotenie týchto súčtov by zabralo $O(N^2)$ aritmetických operácií. FFT naproti tomu poskytuje zložitosť iba $O(N \log N)$ operácií.

Transformácia zvoleného úseku grafu z časovej do frekvenčnej domény umožňuje s určitou presnosťou povedať, aké je celkové množstvo vln v jednotlivých frekvenčných pásmach, poprípade určiť frekvenciu, ktorá je najviac v zázname zastúpená.[8]

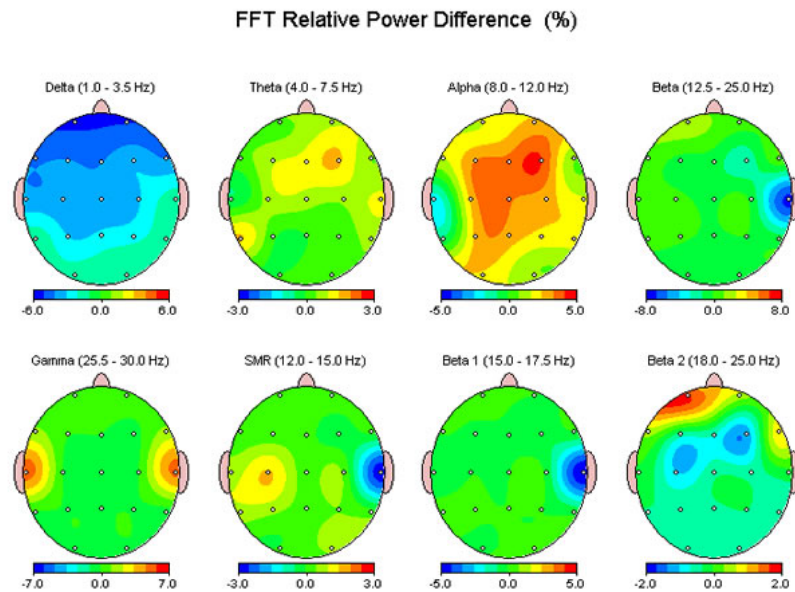


Obrázok č. 12: Spektrálna analýza, Topografické mapovanie aktivity

3.2.3 Topografické mapovanie aktivity - Brain mapping

Metóda Brain Mapping vznikla na začiatku 80. rokov 20. storočia a bola aplikovateľná vďaka počítačom. Používa sa mapovanie pomocou FFT, mapa vzniká lineárnou interpoláciou skutočne nameraných hodnôt z jednotlivých elektród po niekoľkých interpoláciách. Mapy zobrazujú topografické rozloženie aktivity a jej množstva na povrchu lebky. Grafické údaje, ktoré zo zosnímaných dát vytvárame, sú závislé na

mnohých faktoroch ako napríklad na prechodových odporoch elektród alebo hrúbke lebky. [9]



Obrázok č. 13: Topografické mapovanie aktivity

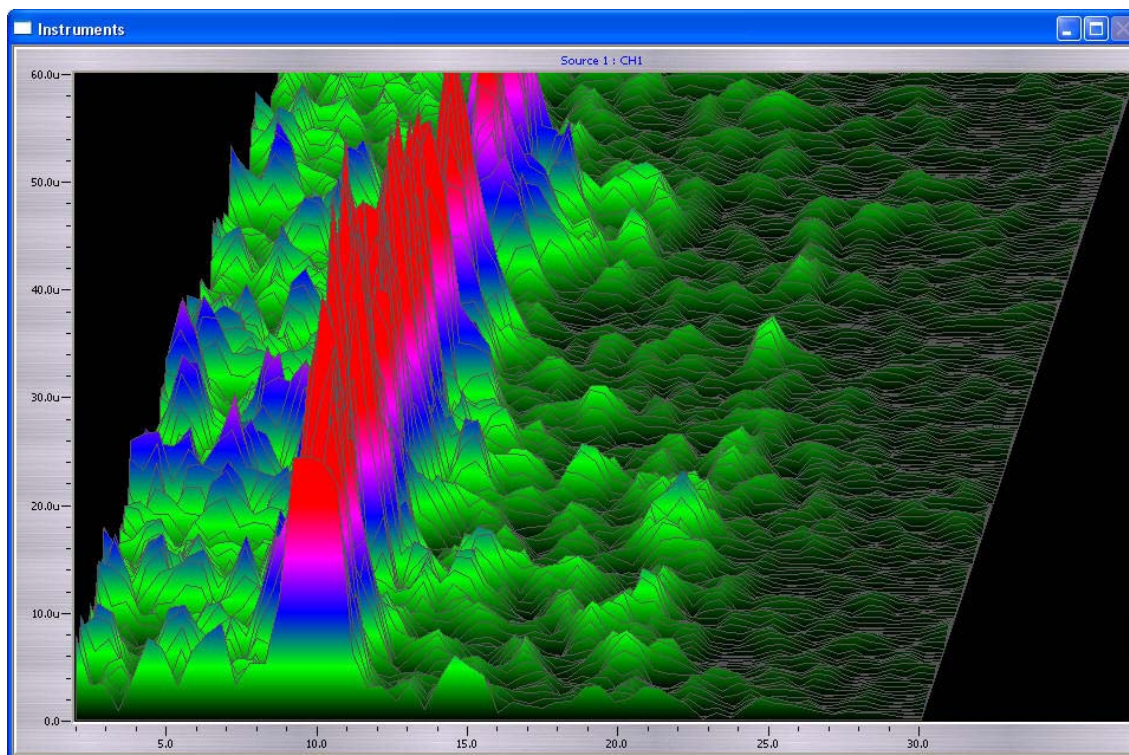
3.2.4 Časovo-frekvenčná analýza

Pri analýze signálu, ktorých charakter sa v čase rýchlo mení, tzv. signály prechodového charakteru, je často nutné uvažovať o frekvenčnom obsahu jednotlivých krátkych časových úsekoch signálu. Tento koncept umožňuje formulovať spektrum ako dvojrozmernú funkciu závislú na čase a frekvencii a nazýva sa časovo-frekvenčná analýza. [8]

Nakoľko obecná fourierova transformácia v teoretickej podobe pracuje so signálmi s nekonečnou dĺžkou, praktická analýza vždy vychádza iba z konečných úsekov signálu vymedzených použitým oknom. Pokiaľ je teda okno s vhodnou dĺžkou formulované ako kľzavé na časovej ose, môže byť tento prístup použitý pre časovo-frekvenčnú analýzu. [8]

3.2.4.1 Spektrogram

Spektrogram je grafická, časovo závislá reprezentácia zastúpenia frekvenčných zložiek spektra signálu, taktiež môže byť definovaný ako graf znázorňujúci intenzitu (obvykle v logaritmickej meradle, ako je napríklad dB) krátkodobej fourierovej transformácie (STFT). SFTP je jednoduchá sekvencia zobrazenia FFT v čase. 3D alebo 2D zobrazenie je už len na výberom užívateľa. [10]



Obrázok č. 14: Spektrogram

3.2.5 Vlnková transformácia

Vlnková transformácia nie je vlastne jednou transformáciou ale o určitý typ transformácii so spoločnými rysmi vzájomne sa líšiacich tvarom zvolenej bázevej funkcie - vlnky.

Vlnková transformácia sa od fourierovej transformácie líši tým, že každá bázeová funkcia - vlnka - je podporovaná, čiže má nenulovú hodnotu, iba na konečnom časovom intervale, alebo prinajmenšom jej hodnoty mimo tento interval sú zanedbateľne malé. Následkom toho, ktorákoľvek hodnota spektra založená na využití tejto vlnky je ovplyvnená iba zodpovedajúcim úsekom analyzovaného signálu. [8]

3.2.6 Evokované potenciály

Metóda evokovaných potenciálov bola veľmi populárna v 70. rokoch minulého storočia, rozšírila sa vďaka spoľahlivým výsledkom poskytujúcich reprodukovateľné kvantitatívne údaje. Pod pojmom evokovaný potenciál rozumieme zmenu akčného mozgového potenciálu ku ktorému dochádza externým podráždením. Zistilo sa, že pri senzorickej stimulácii je možné vyvolať v mozgovej kôre elektrickú odpoveď tvorenú sledom pozitívnych a negatívnych vln. [1]

Evokované potenciály delíme podľa dĺžky časového úseku na krátkolatentné, strednelatentné a dlholatentné, tzv. kognitívne evokované potenciály. [1]

3.2.7 Aplikácia umelých neurónových sietí

Umelé neurónové siete (UNS) sa využívajú pre detekciu grafoelementov - technických artefaktov, biologických alebo patologických. UNS pomáhajú a napodobňujú rozhodovanie lekára pri rozpoznávaní jednotlivých častí záznamu. K svojmu rozhodovaniu používajú pokročilé metódy ako sú metóda analýzy hlavných komponentov (PCA) alebo metódu analýzy nezávislých komponentov (ICA). [9]

Viac o umelých neurónových sieťach sa môžete dočítať v kapitole 9 - Umelé neurónové siete.

4 OPEN-SOURCE EEG RIEŠENIA


Už dlhé desaťročia je pre mnohých fanúšikov technológií, hobbistov a technologických fanatikov oblasť snímania EEG biosignálov veľkou fantáziou avšak tam to často celé končilo a to z jediného dôvodu - cena. Dostupné komerčné EEG riešenia sú priveľmi drahé na to, aby ste si domov mohli nejaký zohnať. Cena aj skromného prístroja s dvoma kanálmi stojí okolo 100.000 korún. Avšak mnohí, najmä elektrotechnicky zdatní užívatelia si cestu k svojmu snu našli a vyvinuli vlastné riešenia, ktoré ponechali pod nálepkou Open-source, čiže sprístupnili postupy a zdrojové kódy ich aplikácie.

4.1 OpenEEG, ModularEEG

Najstarším ale zároveň najznámejším open-source EEG projektom je bezpochyby OpenEEG. Cieľom projektu bolo vytvorenie čo najlacnejšieho zariadenia ale zároveň s dostatočne uspokojivými parametrami pre EEG biofeedback tréning taktiež prezývaný neurofeedback. Projekt spočíva vo vytvorení a zlepšovaní softwaru a zariadenia s názvom ModularEEG, ktorý je možné si doma postaviť.

Projekt slúži a to najmä amatérom a nadšencov, ktorí by radi experimentovali s technológiou EEG a slobodne vyvíjať ich vlastné riešenia.

ModularEEG je zariadenie pozostávajúce z dvoch častí, tj. dvoch samostatných elektronických dosiek prepojených 34 pinovým ribbon káblom - analógová (zosilňovač) a digitálna (AD prevodník, RS232 rozhranie, napájanie). Dizajn je možné rozšíriť až na šesť kanálov oproti klasickým dvom a to pridaním ďalších dvoch analógových dosiek.



Obrázok č. 15: ModularEEG [21]


4.2 OpenEXG

OpenEXG je open-source projektom založeným na staršom projekte OpenEEG, Jeho autorom je Stefan Jung a momentálne vydal jeho poslednú verziu návrhu pod názvom OpenEXG-2. Oproti ModularEEG má vylepšenia

- + podpora pripojenia k PC pomocou USB,
- + možnosť priameho napájania pomocou adaptéru,
- + 16-bitový AD prevodník zaručuje vyššiu presnosť,
- + využíva menej elektronických súčiastok,
- + možnosť snímať viacero biosignálov a to EEG, EKG, EMG, EOG
- + nepotrebuje žiadne prepájanie káblov, dodatočné páskovanie ani úpravy,
- + všetky nutné komponenty sú len na jednej DPS
- + nie je nutné riešiť obal, návrh presne sedí na štandardné krabičky

Výhod ma zjavne nespočetne ale má aj zopár nevýhod:

- podpora maximálne dvoch kanálov
- príliš malé SMD komponenty, nemožnosť zhotoviť si návrh doma, poprípade vylepšiť či opraviť
- nemožnosť jednoduchej výmeny operačného zosilňovača v prípade poruchy
- vyššia cena oproti ModularEEG avšak je tu možnosť že sa cena vyrovná vzhľadom k tomu že ku ModularEEG treba dokúpiť množstvo ďalších komponentov ako napríklad USB-RS232 prevodník, napájací obvod + adaptér, vlastnú krabičku atď. [18]

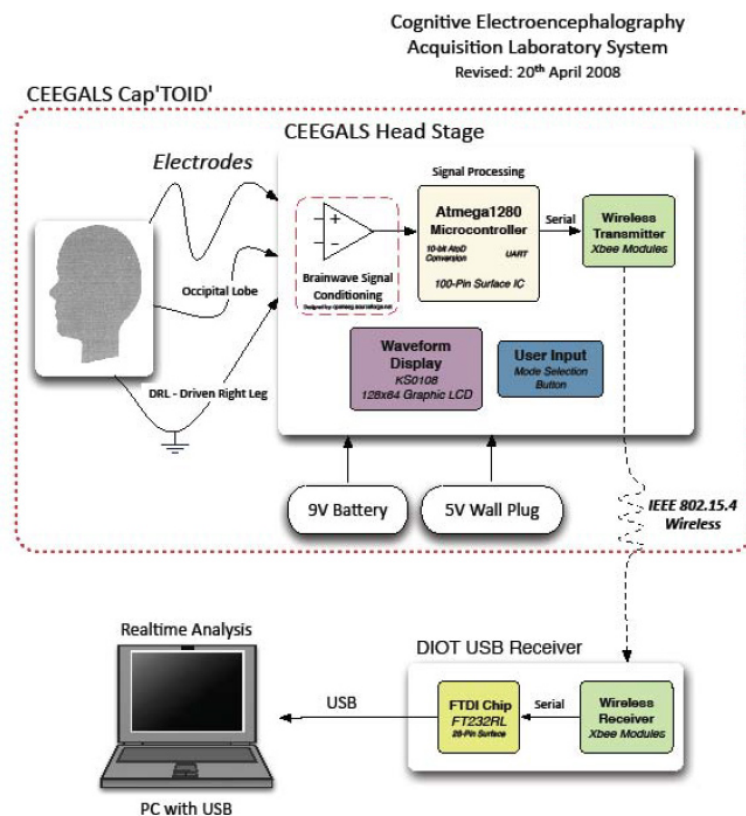


Obrázok č. 16: OpenEXG [18]

4.3 CEEGALS

Názov je skratkou pre *Cognitive Electroencephalography Acquisition Laboratory System*. Ide o ďalší z vylepšení návrhu ModularEEG. Autormi sú Daniel Schoonover a José J. Perez, študenti z University of Florida. Návrh spočíval v pridaní displeja zobrazujúci biosignál v časovej rovine a bezdrôtového prenosu dát medzi zosilňovačmi umiestnenými priamo na hlave a počítačom.

Zosilňovač je analógová elektronická doska z návrhu ModularEEG ku ktorej je pripojený obvod s mikroprocesorom AVR1280 poskytujúci dostatočnú výpočtovú kapacitu na prevod údajov pre rozhranie Xbee a zároveň výstup na display. Na strane počítača je už len Xbee receiver s FTDI čipom pre pripojenie cez USB do PC. [11]

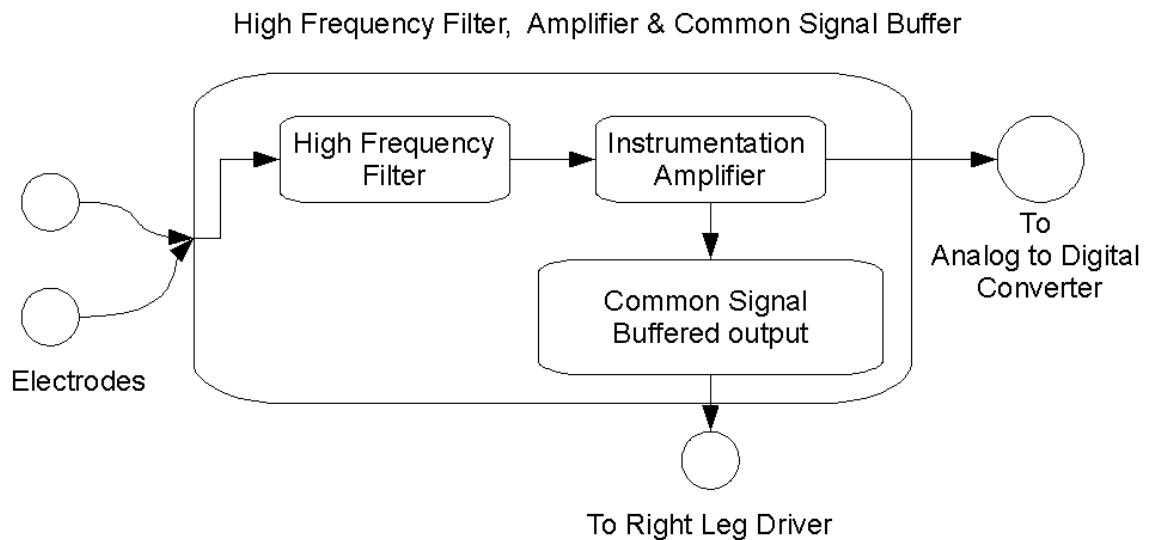


Obrázok č. 17: CEEGALS [11]

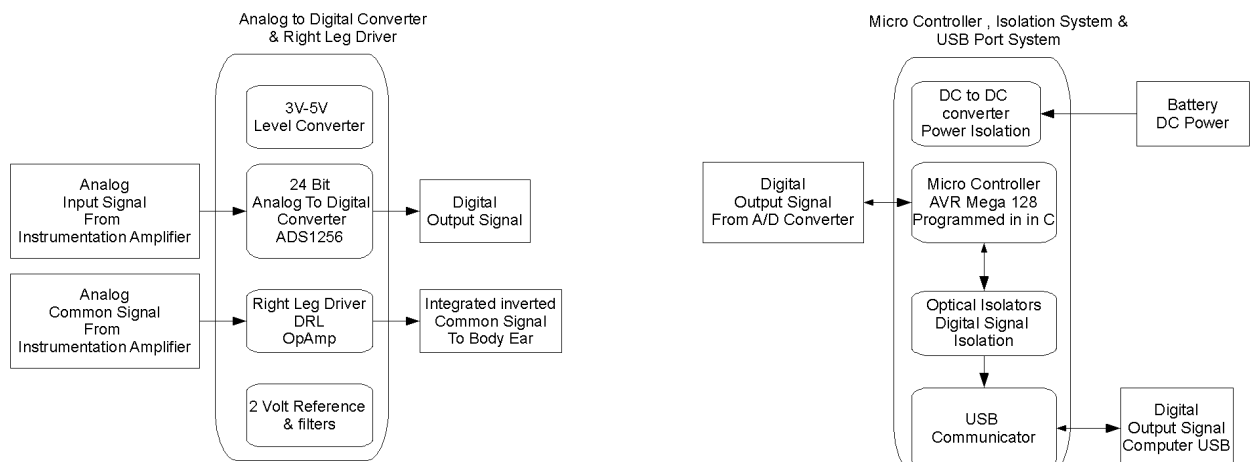
4.4 The Programmable Chip EEG

Jedným z posledných návrhov založených na ModularEEG je Programmable Chip EEG. Tento názov nesie podľa jeho najväčšej prednosti ktorou je zmena hardwarových (nastavenie zosilnenia pomocou čipu LT11168) a softwarových vlastností priamo pomocou počítača.

Hardwarový návrh takisto ako ModularEEG umožňuje pridať ďalšie kanály najviac, tiež pozostáva z digitálneho, analógového obvodu plus obvod s AD prevodníkom, obsahuje senzory pre detekciu pohybu, prednosťou je výkonnejší mikroprocesor Atmega168 a až 20-bitový AD prevodník (možnosť rozšírenia až na 24-bitov). [12]



Obrázok č. 18: Blokový diagram analógového obvodu Programmable Chip EEG [12]



Obrázok č. 20: ADC obvod Programmable Chip EEG [12]

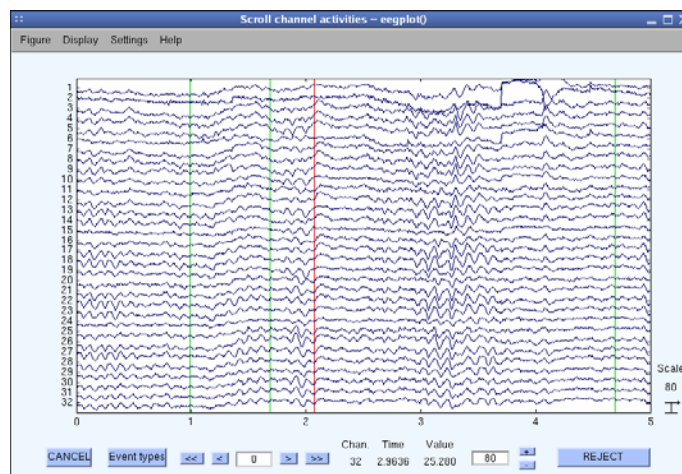
Obrázok č. 19: Mikrokontrolérový obvod Programmable Chip EEG [12]

4.5 EEGLAB - Open-source Matlab Toolbox

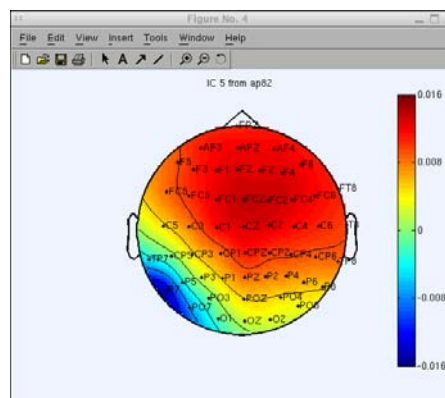
EEGLAB je interaktívny toolbox v prostredí Matlab pre analýzu EEG, EMG, EKG a mnoho ďalších biosignálov, umožňuje analýzu nezávislých komponentov, časovo-frekvenčnú analýzu, filtráciu artefaktov taktiež obsahuje mnoho vizualizačných metód pre reprezentáciu dát.

Výhodou je GUI (grafic-user-interface, grafické užívateľské prostredie), pre skúsenejších používateľov Matlabu je tu možnosť zapnutia prostredia pre písanie štruktúrovaných programov na uchovávanie, prístup, meranie a manipuláciu, vizualizáciu EEG dát.

Je tiež možné tento toolbox rozšíriť o množstvo zásuvných modulov napríklad BCILAB (rozhranie pre BrainComputerInterface, viac v kapitole 5), SIFT pre analýzu zdrojov EEG signálu a mnoho iných. Momentálne je aktuálna verzia 10, ktorá obsahuje približne 400 funkcií, zdrojový kód tvoria celkovo 50000 riadkov a je k dispozícii 300 stranový manuál. Momentálne pre toolbox existuje niečo málo cez 30 zásuvných modulov. [13]



Obrázok č. 21: Zobrazenie EEG záznamu v prostredí EEGLAB [13]



Obrázok č. 22: Brain Mapping v prostredí EEGLAB [13]

5 OBLASTI VYUŽITIA OPEN-SOURCE EEG ZARIADENÍ

Keďže open-source (ďalej len OS) projekty sú určené pre širokú verejnosť a je možnosť si tieto dizajny ďalej upravovať a vylepšovať, dokonca v istých prípadoch aj svoje návrhy predávať, je oblasť využitia naozaj široká a pestrá. Od diagnostiky mozgu cez mentálny tréning až po BCI.

Podľa môjho názoru, diagnostika chorôb a porúch mozgu pomocou týchto OS zariadení nie je práve najlepšou voľbou, zameriam sa preto viac na oblasť BCI pretože metódami zahŕňa aj mentálny tréning.

5.1 Brain-computer interface - BCI

Brain-computer interface (skrátene BCI) je priama komunikácia medzi mozgom a externým zariadením. Prvé pokusy s BCI boli v 70. rokoch minulého storočia na University of California Los Angeles vďaka grantu od Národnej Vedeckej Nadácie. Rozdiel medzi BCI a neuroimplantátmi je ten že neuroimplantáty sú súčasťou nervového systému zatiaľ čo BCI tvorí len akýsi nástroj či rozšírením na báze "čítania mysle" a umožňujúce prepojenie s externým zariadením. [14]

5.1.1 Delenie BCI

Takisto ako EEG, aj BCI sa delí podľa typu invazívnosti do ľudského organizmu.

5.1.1.1 Invazívne BCI

Tento typ BCI sa implantuje priamo do šedej kôry ľudského mozgu počas operačného zákroku, slúži predovšetkým ako umelá náhrada. V posledných rokoch sa invazívne BCI využívalo pre komunikáciu medzi robotickou protetickou rukou a mozgom, pacient bol schopný ovládať pohyby svojej umelej ruky iba myšlienkami. [14]

5.1.1.2 Čiastočne invazívne BCI

Pokiaľ sa elektródy implantujú pod lebečnú kosť ale nie priamo do šedej kôry, hovorí sa o čiastočne invazívnom BCI. Okrem toho že po takomto zásahu je menšie riziko vytvorenia veľkých jaziev než po invazívnom, je zaručené aj získavanie lepšieho signálu ako neinvazívne BCI pretože lebečná kosť vo veľkej miere deformuje signál. [14]

5.1.1.3 Neinvazívne EEG BCI

Práve takýto spôsob prepojenia mozgu s počítačom je cieľom mojej práce. Využitím umelých neurónových sietí sa klientsky software v počítači naučí vzorce, ktoré asociuje s operáciami, ktoré má počítač vykonať.

Prvé úspešne BCI sedenie, kedy sa počítač pomocou merania EEG naučil ovládať 80 pohybov ľavej a 80 pohybov pravej ruky, sa uskutočnilo až v roku 1998 Christopherom Gugerom. Tento systém využíval 27 elektród umiestnených na povrchu hlavy.

Výskum však pokračuje ďalej, momentálne prebiehajú experimenty s BCI pod záštitou amerického vojenského výskumného ústavu DARPA, kde sa pokúšajú vytvoriť užívateľ-užívateľ interface pomocou analýzy neurónových signálov. Ich cieľom je vytvoriť technológiu nazvanú Silent Talk, ktorá by umožnila neverbálnu komunikáciu medzi dvoma ľuďmi len pomocou snímania ich mozgových vln - technologická náhrada telepatie. [14]

5.2 Porovnanie open-source projektov a komerčných produktov určených pre spotrebiteľský trh

Na trhu existuje celá škála produktov so zameraním na zábavný priemysel. Ich cena sa však pohybuje v rozmedzí od 50 až 20000 dolárov, čo si široká verejnosť ako hračku dovoliť nemôže. Najúspešnejším produktom na spotrebiteľskom trhu je Emotiv EPOC od austrálskej spoločnosti Emotiv Systems, jeho cena začína na 299 dolároch. V ďalších podkapitolách uvediem najvýznamnejších zástupcov zariadení.

Tabuľka 1: Komerčné EEG produkty pre spotrebiteľský trh [19]

Zariadenie	Cena	Počet elektród	Interpretácia dát	Výrobca
MindWave	\$99.95	2	2 mentálne stavy, žmurkanie	NeuroSky
MindFlex	\$50	2	1 mentálny stav	Mattel
Emotiv EPOC	\$299	14	4 mentálne stavy, 13 vedomých myšlienok	Emotiv Systems
StarWars Force Trainer	\$45	2	1 mentálny stav	Uncle Milton

MindSet	\$199	2	2 mentálne stavy	NeuroSky
Neural Impulse Actuator	\$90	3	2 typy EEG vln (alfa a beta), tvárove svalstvo a pohyby očí	OCZ technology
Mindball	\$20,000	2	1 mentálny stav	Interactive Productline
XWave headset	\$90	3	8 EEG pásiem	Pôvodne XWave, dnes Neurosky
MyndPlay	£99	2	8 EEG pásiem	MyndPlay

5.2.1 Emotiv EPOC

Ako spomínam vyššie, jedná sa o produkt austrálskej spoločnosti Emotiv Systems. Tá od roku 2003 vyvíja zariadenia za báze EEG pre spotrebiteľský trh. Ich najväčším úspechom je produkt Emotiv EPOC, 14 kanálový headset systém s bezdrôtovým pripojením k PC a integrovaným gyroskopom. Je možné si zakúpiť verziu s SDK (určené pre vývojárov), taktiež je v ponuke verzia určená pre výskum. Najlacnejší variant prístroja stojí 299 dolárov, ceny sa však pohybujú až do takmer 8000 dolárov (enterprise verzia s SDK).

5.2.2 MindWave

Dvojelektrodové riešenie od spoločnosti NeuroSky patrí medzi tie lacnejšie zariadenia na trhu, jeho cena sa pohybuje od 100 dolárov. Takisto ako EPOC má bezdrôtové pripojenie k PC avšak jeho možnosti sú veľmi obmedzené a to práve použitím len dvoch elektród z čoho jedna je iba referenčná - ušná elektróda. Systém dokáže rozoznať mentálny stav ako napríklad relaxácia, pozornosť či únava, ale aj žmurkanie vďaka umiestneniu druhej elektródy na čelo, kde sa artefakt žmurkania veľmi jasne objavuje.

5.2.3 XWave

Pôvodne sa jednalo o produkt spoločnosti XWave, dnes je však vývoj pod velením NeuroSky. Ide o kompaktné zariadenie s troma elektródami určené pre mobilné zariadenia od Apple ako sú iPad, iPhone, iPod. Zariadenie meria iba váš mentálny stav a energiu jednotlivých frekvenčných pásiem (ako napríklad alfa, beta, delta, theta atď.). Konektivita je riešená cez kábel do audio vstupu Apple zariadení.

6 MOJE RIEŠENIE - MODULAREEG

Pri výbere zariadenia pre moju prácu som mal na výber zo širokej škály produktov, od komerčných kde by bolo možné riešiť len software až po open-source projekty kde je celý dizajn dobre zdokumentovaný. Keďže som zástancom voľného softwaru, uvažoval som nad open-source riešeniami a rozhodol som sa pre ModularEEG a to z niekoľkých dôvodov:

- hardware je pomerne jednoduchý a pre mňa pochopiteľný, rozumiem funkciám jednotlivých častí obvodu a som schopný si v prípade poruchy tieto problémy sám opraviť. Operačné zosilňovače nie je problém bez pájkovania vytiahnuť keďže sú osadené v pätiaciach, takisto mikrokontrolér nie je problém vytiahnuť či prehodiť s iným.

- cena a dostupnosť - samotné DPS som si už osadené objednal od bulharskej spoločnosti OLIMEX, ktorá mi dodala jeden digitálny obvod a tri analógové (jeden analógový obvod = 2 kanály, využívam 6 kanálov) v celkovej cene 400 eur aj s poštovným. Obvody som si podľa potreby prepájkoval a upravil, napájanie som vyriešil interným zdrojom pre mini itx počítač, zdroj napájam externým adaptérom s výstupom 12V DC.

- dokumentácia - OpenEEG projekt má viac ako 10 rokov a je pomerne kvalitne zdokumentovaný, má podporu vo viacerých programoch ako napríklad BioExplorer, BioEra, ElectricGuru, BrainBay, OpenVibe či Matlab toolbox EEGLAB.

- RS232 - Pre niektorých je to možno nevýhodou, pre mňa to znamená jednoduchšie programovanie keďže protokol je jednoduchý a taktiež je takmer všade podporovaný, nielen v oblasti PC.


- možnosť veľkých úprav hardwaru - Keďže analógový a digitálny obvod sú oddelené a výstupy sú triviálne, je možnosť ďalej upravovať celé zariadenie napríklad pridávaním ďalších modulov poprípade menšou úpravou vložiť medzi obvody ešte kvalitnejší A/D prevodník či rozšírenie o strmšie filtre.

- oživenie legendy - OpenEEG projekt už dlhšiu dobu spí a je neaktívny. Túto prácu vidím ako príležitosť mu znova dýchnuť život a podnietiť širší záujem o túto oblasť.

6.1 Úpravy hardwaru

Hardware zariadenia ModularEEG som musel upraviť aby najlepšie vyhovoval mojim podmienkam:


1. Podľa návodu písaného priamo v schéme digitálneho obvodu som odstránil diódu D104 v digitálnom obvode keďže ho napájam 12V a nie klasicky 5V. Túto variantu som si zvolil z dôvodu neskoršej úpravy napájania pomocou trafo-adaptéru, pri ktorých je 12V výstup dostupnejší ako 5V či 7V.



Obrázok č. 23: Odstránenie diódy D104 na digitálnej doske ModularEEG


2. Pôvodný mikrokontrolér Atmega8 (m8) som nahradil Atmega88 (m88). M88 má na rozdiel od predchádzajúceho m8 6x10 bitový AD prevodník, zatiaľ čo m8 iba 4x 10 bit a 2x 8bit. Pôvodný firmware P2 som nahradil novším P3, ktorý je dostupný na stiahnutie na oficiálnej stránke OpenEEG -

<http://http://openeeg.sourceforge.net/doc/modeeg/firmware/modeeg-p3.c>




Obrázok č. 24: Výmena mikrokontroléru na digitálnej doske ModularEEG

3. Na druhom a treťom analógovom obvode som prepájkoval piny SJ201 až SJ206, čo je nutnosť pokiaľ chceme mať viac ako len jeden analógový modul. Opäť som postupoval podľa návodu uverejnenom na oficiálnej stránke - http://openeeg.sourceforge.net/doc/modeeg/modeeg_building.html




Obrázok č. 25: Prepájkovanie pinov pre použitie viacerých analógových dosiek pre ModularEEG

4. Odstránil som potenciometer P201 zo všetkých analógových modulov keďže nie sú nutné v prípade použitia prístrojového zosilňovača INA114, piny 2 a 1 som medzi sebou prepojil skratom.



Obrázok č. 26: Odstránenie potenciometra na pre zosilnenie aktívnej zeme, následne skratovanie pinov 1 a 2.

5. Aby som mohol zariadenie využívať aj na EMG a EKG, poprípadne pre korekciu zosilnenia z dôvodu slabého signálu z elektródy, odstránil som potenciometre P203 a P202 zo všetkých analógových dosiek a nové, ručne nastaviteľné potenciometre som umiestnil na krabičku v ktorej je celé zariadenie umiestnené. Rozsah zosilnenia je od 6 do 40-krát.



Obrázok č. 27: Potenciometre pre nastavenie zosilnenia pre ModularEEG


6.2 Konštrukcia skrinky a náhľad na celé zariadenie

Pri zostrojovaní skrinky som musel hlavne rátať s dobrým tienením, preto som sa rozhodol pre kovovú konštrukciu. Ako vhodné riešenie bola skrinka pre Mini-PC Eurocase mini-ITX 850. Vybral som si ju z dôvodu že má externý zdroj, čiže 50 Hz sieťový šum v zázname bude nižší než v prípade interného zdroja, taktiež je veľmi jednoducho nahraditeľný za hocijaký 12V adaptér. Ďalším dôvodom výberu tejto skrinky bola hrubá hliníková konštrukcia po stranách a plechová na hornej a dolnej časti. Z estetického hľadiska je veľmi vyhovujúca, je možné ju mať v horizontálnej i vertikálnej polohe.



Obrázok č. 28: Použitá skrinka pre ModularEEG

Skrinku bolo nutné ešte upraviť pre umiestnenie vstupov a výstupov, umiestnenie potenciometrov a výstup kalibračného napätia.




Obrázok č. 29: Moje riešenie ModularEEG

Potenciometre pre nastavenie zosilnenia EEG signálu.

Digitálna doska s mikrokontrolérom Atmega88.

Napájací zdroj



Vstupy pre elektródy

Tri analógove dosky prepojené jedným ribbon káblom k digitálnej doske.

Vstup pre elektródu ako aktívna zem

Výstup vo forme sériovej linky pre pripojenie k PC

12V vstup pre napájací zdroj

Obrázok č. 30: Zadná strana skrinky so vstupmi pre elektródy a napájanie

6.3 Elektródy

Pri svojej práci používam jednorazové AgCl elektródy SKINTACT Premier 0952, ktoré obsahujú aj elektrovodivý gél, ktorý znižuje prechodový odpor na rozhraní koža-elektroda. Káble pripájam k elektródam pomocou hlavičiek (samice) z nitovacích gombíkov, ktoré majú takmer rovnakú veľkosť ako samce na elektródach. Hlavičky som namočil do izopropylalkoholu aby som ich zbavil masnôt pre zníženie prechodového odporu medzi elektródou a hlavičkou.



Obrázok č. 31: Riešenie spojenia kábel-elektroda

Pri výbere vhodného kábla som uvažoval najmä o dobrom tienení, preto som sa rozhodol pre koaxiálny kábel RG-174 s hrúbkou 2,8 mm, ktorý bol najtenší dostupný. Do hlavičky nitovacieho gombíka som navrtal dieru, miesto som opäť ošetril isopropylalkoholom a zaletoval. Toto moje riešenie je veľmi efektívne pretože umožňuje jednoduché odpájanie káblu od elektród a zaručuje dobrý kontakt medzi nimi.



Obrázok č. 32: Koaxiálny kábel RG-174 použitý pri vedení signálu z elektród na vstup meracej techniky

Pripojenie káblov do meracej techniky som riešil pomocou pozlátených a postriebrených CINCH konektorov pre ich jednoduchú manipuláciu, dobrú konštrukciu a vďaka materiálu (postriebrené, pozlátené) ako najlepšiu voľbu pre redukciu prechodového odporu medzi konektorom a samicou namontovanou na skrinke.




Obrázok č. 33: konektory CINCH

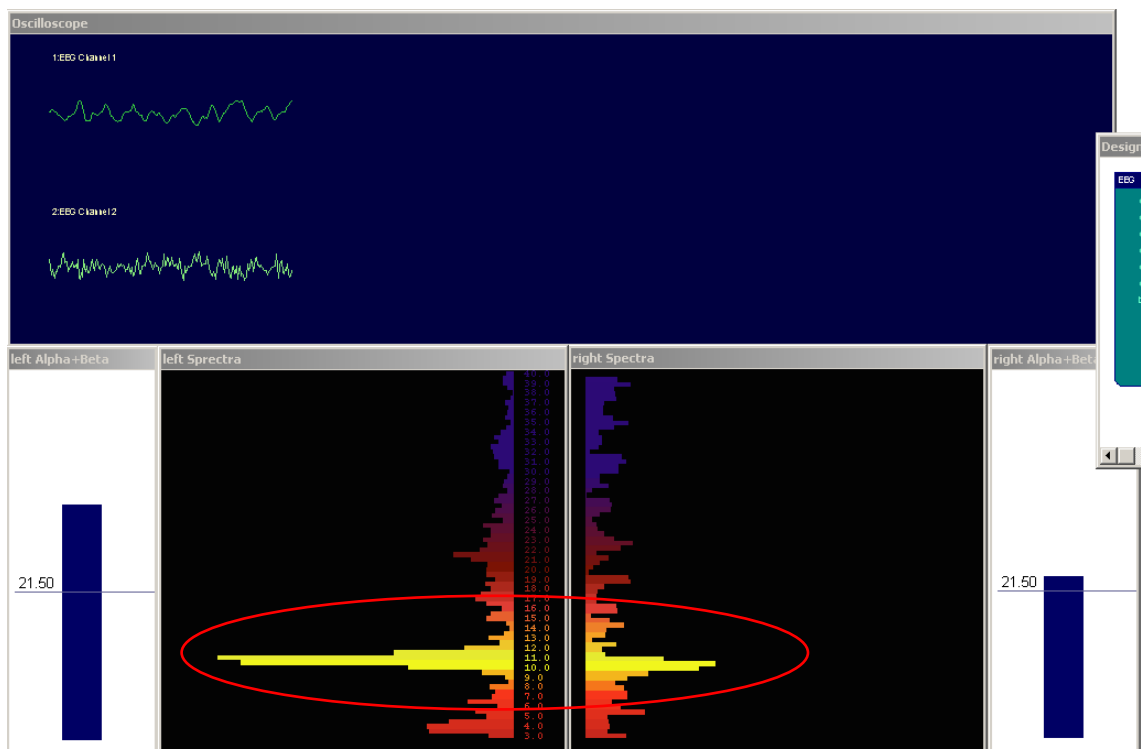
6.4 Výsledky prvých meraní

Prvé úspešné merania s kvalitnými výsledkami sa mi podarilo dosiahnuť mesiac od začiatku zostrojovania zariadenia, na subjekte som pozoroval zvýšenie alfa rytmu pri zavretí očí, zníženie pri otvorení a výskyt sieťového šumu v signáli.

Zistil som, že veľmi záleží na dobrom kontakte DLR elektródy s kožou, v prípade, že elektróda nie je správne pripojená, v signáli sa vo veľkej miere prejavuje sieťový šum, v prípade dobrého kontaktu je zas takmer nulový.



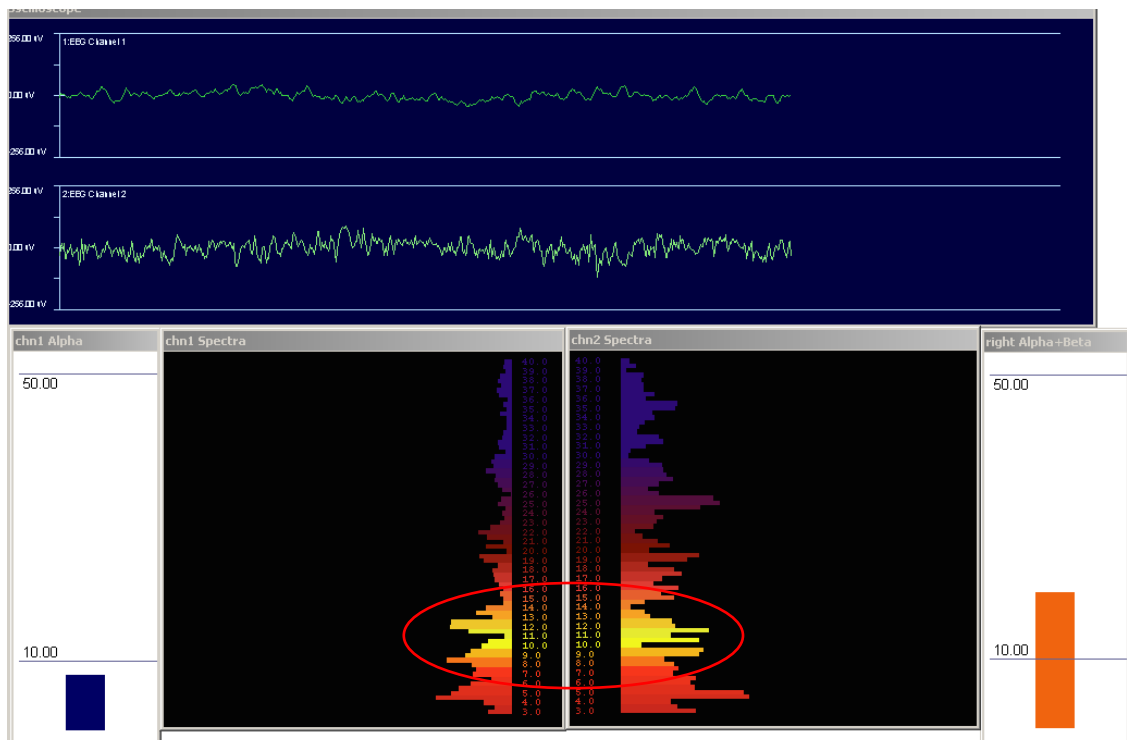
Obrázok č. 34: Priebeh signálu kalibračného napätia



Obrázok č. 35: Zvýšená alfa aktivita pri absencii zrkovného stimulu - pri zavretí očí.

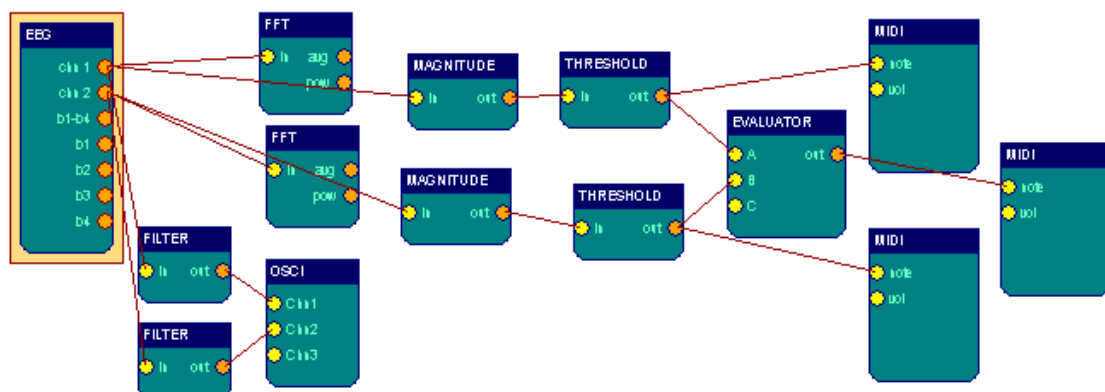
Ako je zo signálu vidieť, nenachádza sa v priebehu sieťový šum. Horný signál je potenciálom medzi elektródami frontálnou a occipitálnou. Vďaka dobrému kontaktu a

použitím gélu sa eliminoval šum a to vo veľkej miere oproti priebehu 2 (spodný) pri ktorom nebol použitý gél.



Obrázok č. 36: Znížená alfa aktivita pri zrakovom stimule - otvorení očí.

Merania prebiehali pomocou open-source softwaru BrainBay, v ktorom je možné si pomocou funkčných blokov zostaviť vlastnú aplikáciu podobne ako v prostredí Matlab Simulink.




Obrázok č. 37: Ukážka zostavenia aplikácie pomocou funkčných blokov v prostredí BrainBay

7 VYLEPŠENÝ MODULAREEG - EEG-SMT

Počas práce na tomto bakalárskom projekte spoločnosť Olimex vydala vylepšenú verziu tohto open-source riešenia nazvanú EEG-SMT. Ide v podstate o to isté zariadenie ako ModularEEG, akurát komponenty sú vyrobené technológiou SMT a obsahuje mnoho vylepšení:

1. Obsahuje vstupy pre aktívne aj pasívne elektródy, ktoré sú súčasťou riešenia.
2. Signál je oveľa čistejší a šum je nižší ako pri staršom ModularEEG
3. Má v sebe integrovaný USB-RS232 prevodník
4. Napájanie pomocou USB
5. Jednoduchá manipulácia so zariadením



Obrázok č. 38: EEG-SMT [22]

EEG-SMT má na rozdiel od ModularEEG mikroprocesor ATmega16 vybavený 8x A/D prevodníkom s rozlíšením 10-bit, zariadenie však používa iba 4 A/D revodníky. Jedinou nevýhodou je obmedzený počet kanálov oproti ModularEEG a to 2.

Toto zariadenie som si zaobstaral aj z dôvodu možnosti pripojenia k displeju PanelCard od spoločnosti TaskIt ktorý som mal k dispozícii v rámci školského projektu a súťaže EEICT, kde bola moja práca úspešne zaradená do zborníku.

7.1 Elektródy

Ako som v predchádzajúcom odseku spomenul, súčasťou riešenia EEG-SMT sú aj aktívne a pasívne elektródy, ktoré nepotrebujú žiadne hardwarové úpravy a sú hneď pripravené na použitie.

7.1.1 Aktívne elektródy SMT-AE

Aktívne elektródy slúžia ako snímacie, pre každý kanál sú nutné dva kusy. Sú napájané napätím 5V, pozostávajú z koncovky Jack, tieneneho koaxiálneho káblu a dosky plošných spojov na ktorej sa nachádza operačný zosilňovač TL062CD zapojený ako sledovač s jednotkovým zosilnením. Toto zapojenie je z dôvodu impedančného prispôsobenia pri kontakte koža-elektroda. Schéma elektródy je priložené v časti príloh.



Obrázok č. 39: EEG-AE [22]

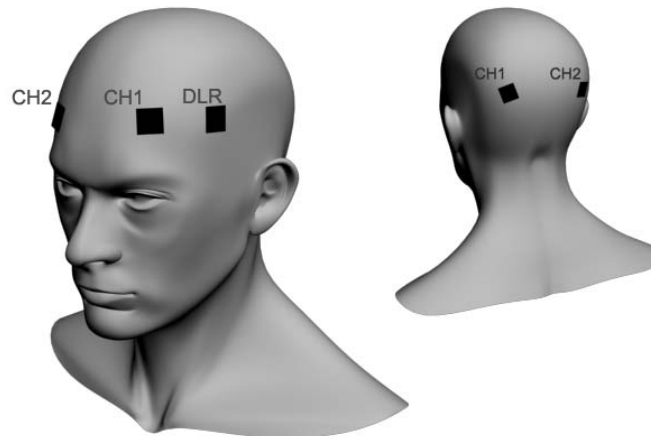
7.1.2 Pasívna DLR elektróda SMT-PA

Pasívna elektróda slúži ako aktívna zem, neobsahuje žiadne elektronické komponenty na rozdiel od aktívnej a je nutná z dôvodu uzemnenia a potlačenia súhlasného signálu CMRR. Správnym a kvalitným kontaktom koža-elektroda pri tejto elektróde sme schopný veľmi dobre vyrušiť sieťový šum čím sa nám zvýši kvalita meraných vzorkou.


7.2 EEG čiapka

Veľmi dôležitou súčasťou merania je dobre navrhnutá čiapka na ktorú sa umiestňujú elektródy. Keďže v mojom projekte používam aktívne elektródy, klasická čiapka je nepoužiteľná a taktiež veľmi nepraktická. Vyrobil som preto vlastné riešenie a to EEG čelenku so všitými elektródami. Umiestnenie som volil nasledovne - vieme, že najlepším miestom pre meranie alfa vln je occipitálna oblasť a beta vlny sa najlepšie merajú vo frontálnej oblasti.

Preto meriam potenciál medzi frontálnou časťou hlavy s umiestnením elektród na F_{p1} a F_{p2} (systém 10-20) a zadnou occipitálnou časťou v miestach O_1 a O_2 . Potenciál medzi týmito časťami sa zosumarizuje a som schopný zo získaného signálu vyčítať aj alfa aj beta aktivitu. DLR elektródu (aktívna zem) som umiestnil tiež do frontálnej oblasti F_7 , kde sa signál vo všeobecnosti javil ako dostatočne kvalitný. Rovnaké výsledky som získaval aj s pripojením DLR na ucho či tvár avšak z dôvodu praktickosti som zvolil práve oblasť F_7 .



Obrázok č. 40: Rozmiestnenie elektród



Obrázok č. 41: EEG čelenka

8 SOFTWARE NEUROLINE

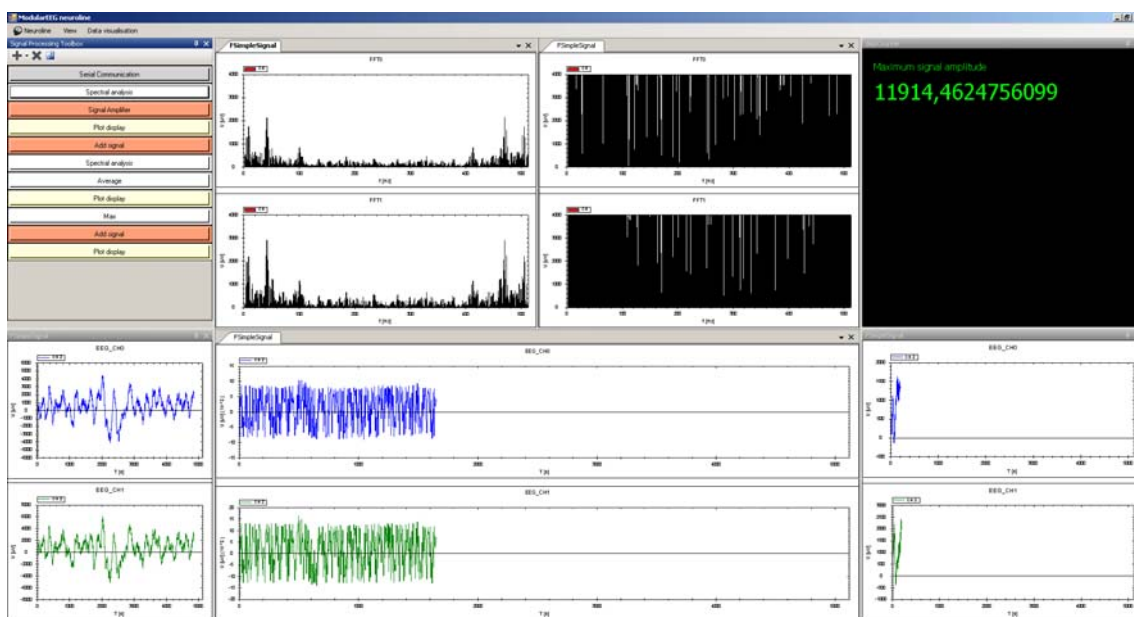
Jednou z hlavných súčastí merania a analýzy EEG signálov je práve software, počítačový program pre zobrazovanie a následnú analýzu signálu. Ako vhodný programovací jazyk som z dôvodu dlhoročných skúsenosti zvolil C#.NET v prostredí Visual Studio 2010.

Program pozostáva z niekoľkých častí:

1. Dekódovanie ModularEEG/EEG-SMT packetu
2. Prevod dát do správneho formátu vhodného pre ďalšie spracovanie
3. Signálové bloky určené pre manipuláciu so signálom
4. Zobrazovacia časť

Pri návrhu programu Neuroline som sa inšpiroval softwarom NI LabVIEW SignalExpress, kde sa pomocou jednotlivých blokov signál modifikuje a analyzuje. Jednotlivé bloky popíšem v nasledujúcich kapitolách.

Neuroline je schopný zobrazovať signál v jednotlivých fázach jeho úpravy, obsahuje blok pre spektrálnu analýzu a nie je problém k nemu doprogramovať v budúcnosti ďalšie moduly.



Obrázok č. 42: Prostredie programu Neuroline

8.1 Dekódovanie dát

Obe zariadenia, aj ModularEEG aj EEG-SMT používajú tie isté protokoly a to P2. Tento protokol je súčasťou ModularEEG firmwaru pre jednosmernú komunikáciu. Autormi protokolu sú Joerg Hansmann, Jim Peters a Andreas Robinson. V dobe vývoja som používal v snímacom zariadení firmware verzie v0.5.4-p2.

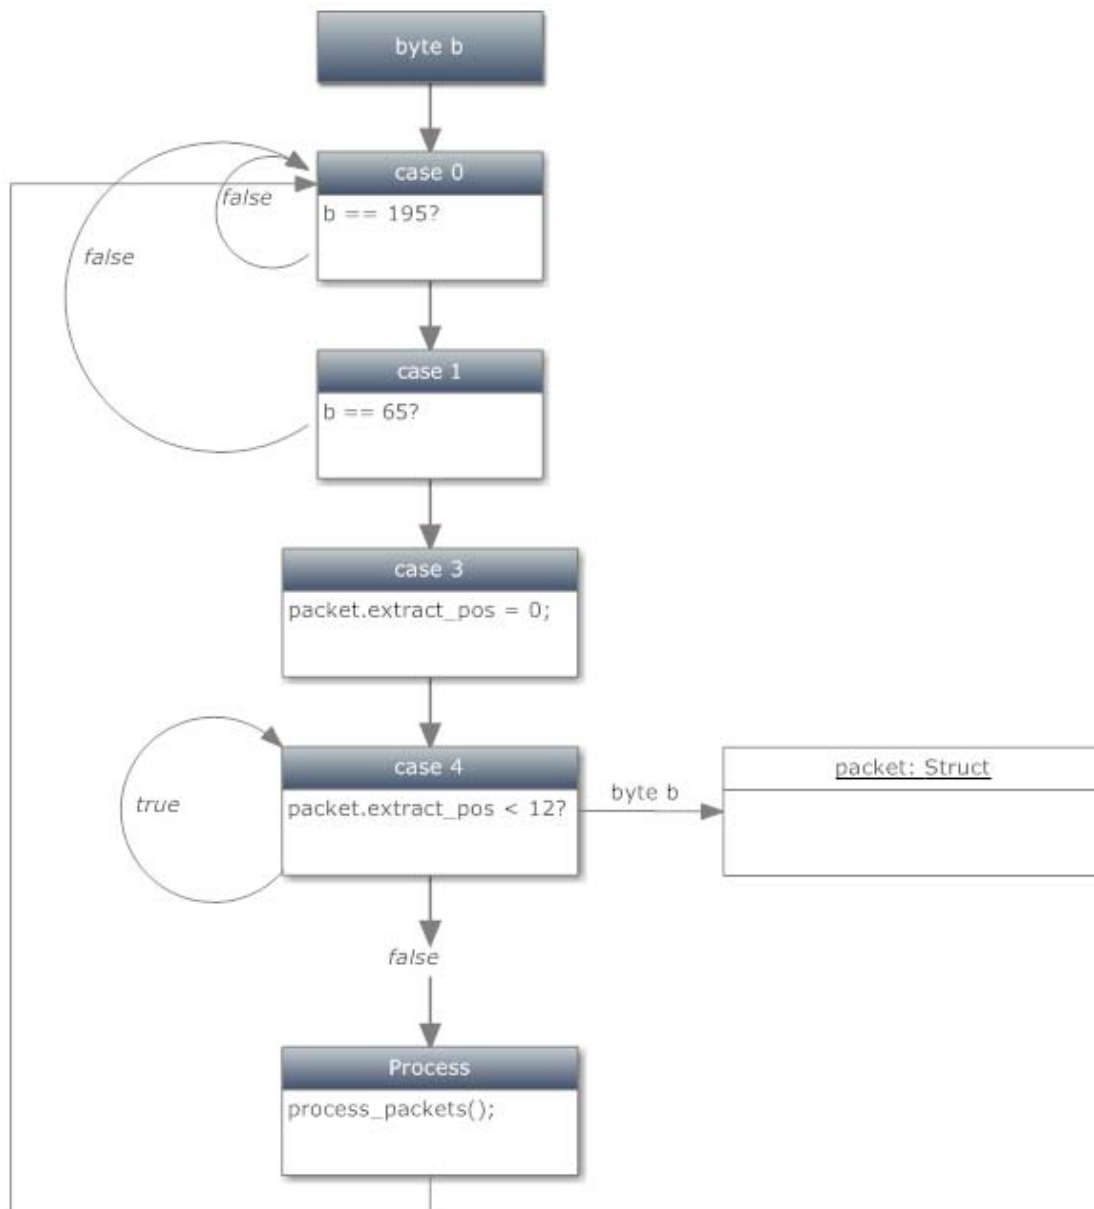
P2 packet pozostáva zo 17 bajtov, hlavička tvorí dva bajty a pozostáva zo sekvencie čísel 165 a 90. Ďalej nasledujú údaje ako číslo verzie (1b), číslo packetu (1b) a hodnoty pre jednotlivé meracie kanály (12b) a koniec tvorí jeden bajt signalizujúci stav tlačidiel, ktorý bol používaný v ranných dobách pri vývoji ModularEEG avšak teraz sa už nepoužíva. Lepšie znázornenie skladby packetu je v nasledujúcej tabuľke.

Tabuľka 2: Skladba packetu P2

Popis	Veľkosť [byte]	Hodnoty
Hlavička	2	[165, 90]
Číslo verzie	1	n
Číslo packetu	1	1..n
Hodnoty pre kanál 0	2	0..1023
Hodnoty pre kanál 1	2	0..1023
Hodnoty pre kanál 2	2	0..1023
Hodnoty pre kanál 3	2	0..1023
Hodnoty pre kanál 4	2	0..1023
Hodnoty pre kanál 5	2	0..1023
Stav tlačidiel	1	0/1
<i>Spolu</i>	<i>17</i>	

Packet je treba samozrejme dekódovať, bolo teda nutné navrhnuť vhodný algoritmus ktorý je rýchly a zároveň spoľahlivý, inšpiroval som sa teda algoritmom z

open-source programu BrainBay, ktorý som prepísal z jazyka C++ do jazyka C#. Ide o stavový automat s piatimi stavmi znázornenými v nasledujúcom diagrame.



Obrázok č. 43: Dekódovanie packetu

Pre dekódovanie packetu som vytvoril samostatnú triedu kde sú aj ďalšie procedúry pre správne naformátovanie dát, ktoré sa používajú v ďalších častiach programu. Výstupom je pole `double[][]` kde prvý rozmer tvorí číslo kanálu a druhý je samostatný packet.

8.2 Konverzia dát

Hodnoty z jednotlivých kanálov sú čísla v rozmedzí 0 až 1024, kedy 0 reprezentuje najnižšiu zápornú hodnotu alebo chybu, 512 je nulový potenciál a 1024 najvyššia kladná hodnota.

Keďže často nastáva v A/D prevodníkoch chyba a na výstupe sa objavuje hodnota 0, túto hodnotu mením hodnotu reprezentujúcu nulový potenciál. O to všetko sa stará metóda

```
public double[][] parse_buffer(byte[] buffer);
```

Tá si volá `parse_byte_P2(b)`; ktorá packet dekoduje a následne ho pridá do pola k ostatným získaným packetom.

Nakoniec vráti hodnotu ktorú *Source blok* pošle ďalej pre ďalšie spracovanie.

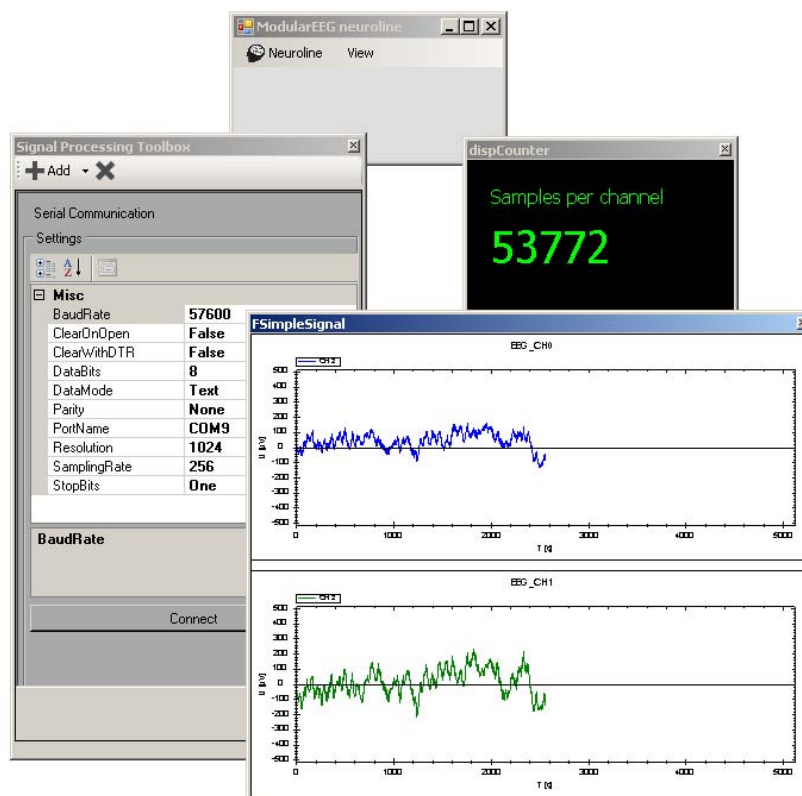
```
public double[][] parse_buffer(byte[] buffer)
{
    int res = Settings.Default.Resolution;
    packets.Clear();
    foreach (byte b in buffer)
    {
        parse_byte_P2(b);
    }

    double[][] _values = new double[packets.Count][];
    int x = 0;
    foreach (PACKET p in packets)
    {
        double[] fbuffer = new double[6];
        for (int i = 0; i < p.buffer.Length; i++)
        {
            if (p.buffer[i] == 0) fbuffer[i] = 0;
            else if (p.buffer[i] == 256) fbuffer[i] = 0;
            else fbuffer[i] = p.buffer[i] - res/2;
        }
        _values[x] = fbuffer;
        x++;
    }

    return _values;
}
```

8.3 Prostredie Neuroline

V obrázku číslo 41. je náhľad na prostredie programu Neuroline. V ľavej časti vidieť signálové bloky, všetky okná sú modifikovateľné a presúvateľné vďaka komponente DockPanel Suite. Ide o napodobeninu rozhrania Visual Studio, všetky jej metódy sa nachádzajú v namespace `WeifenLuo.WinFormsUI.Docking`. Dokonca je možné okná "odlepiť" z hlavného okna programu a rozmiestniť si ich po obrazovke ako vidieť v nasledujúcom obrázku.



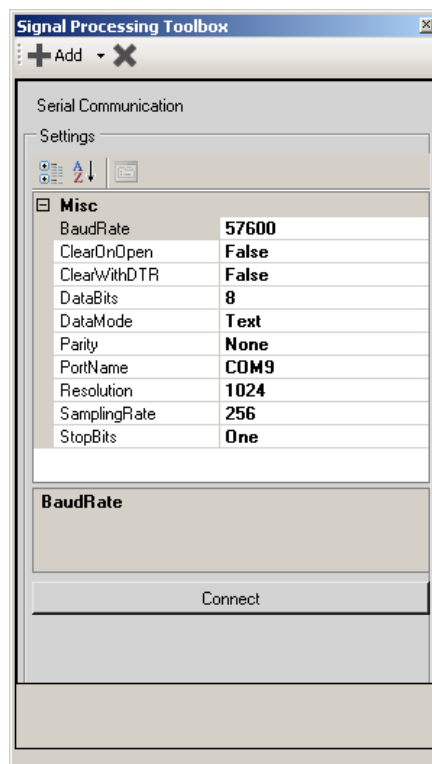
Obrázok č. 44: Pohyblivé okná programu Neuroline

8.4 Signálové bloky

Ako bolo v predchádzajúcich kapitolách spomenuté, signálové bloky slúžia na úpravu, modifikáciu, analýzu a zobrazovanie signálu. Je možné za chodu programu a merania meniť ich konfiguráciu napríklad zvýšiť zosilnenie či pridať ofset a skúmať zmeny, ktoré sa prejavajú na signáli.

Všetky bloky sú zapuzdrené do nadriadenej triedy *blockItem* a pomocou metód *input()* a *output()* si medzi sebou predávajú upravený signál. Po pridaní bloku sa umiestni do objektu *blockHolder*, ktorý s blokom manipuluje, obsahuje metódy napríklad pre odstránenie bloku, posunutie či zmenu rozmerov.

Každý blok obsahuje svoju konfiguráciu, ktorá sa zobrazí pri dvojitom kliknutí naň. To je možné vidieť na obrázku 45.



Obrázok č. 45: Konfigurácia bloku

8.4.1 Blok Source

Tento blok slúži na pripojenie k ModularEEG/EEG-SMT zariadeniu skrze COM port, čiže zaručuje sériovú komunikáciu so zariadením. Po stlačení tlačidla Connect sa spustí celý proces získavania dát a preposielania surových dát ďalej do ďalších blokov. Jeho rozbalenú podobu zobrazuje obrázok 45. Nastavenia tohto bloku sa pri každej zmene uložia a po vypnutí a štarte programu znova načítajú. Štandardné nastavenie pre komunikáciu s ModularEEG/EEG-SMT je nasledovné:

Tabuľka 3: Nastavenie sériovej komunikácie

Kľúč	Hodnota
BaudRate	57600
ClearOnOpen	false
ClearWithDTR	false
DataBits	8


DataMode	Text
Parity	None
PortName	<číslo_portu>
Resolution	1024
SamplingRate	256
StopBits	One

8.4.2 Blok RAW data

Pokiaľ je z určitých dôvodov nutné vidieť priamo číselné hodnoty surového signálu, je tu pre tento účel RAW data blok.

8.4.3 Blok Simple Operations > Amplify


Niekedy sa stáva, že signál je príliš slabý a tak sa veľmi zle pozoruje v časovej či frekvenčnej oblasti. Amplify je určený pre zosilnenie signálu. Vynásobí vstup a ten pošle na výstup.



Obrázok č. 46: Schéma bloku Amplify

8.4.4 Blok Simple Operations > Square/Root


Tento blok je veľmi účinným nástrojom pomocou ktorého sa dá najrýchlejšie zbaviť záporných hodnôt signálu a jeho prevod do kladných. To sa deje vďaka matematickej funkcii mocnenie.



Obrázok č. 47: Schéma bloku Square/Root

8.4.5 Blok Simple Operations > Offset


Jednoduchá operácia ktorá pridá jednosmernú zložku do signálu so zosilnením X.



Obrázok č. 48: Schéma bloku Offset

8.4.6 Blok Simple Operations > Add Signal

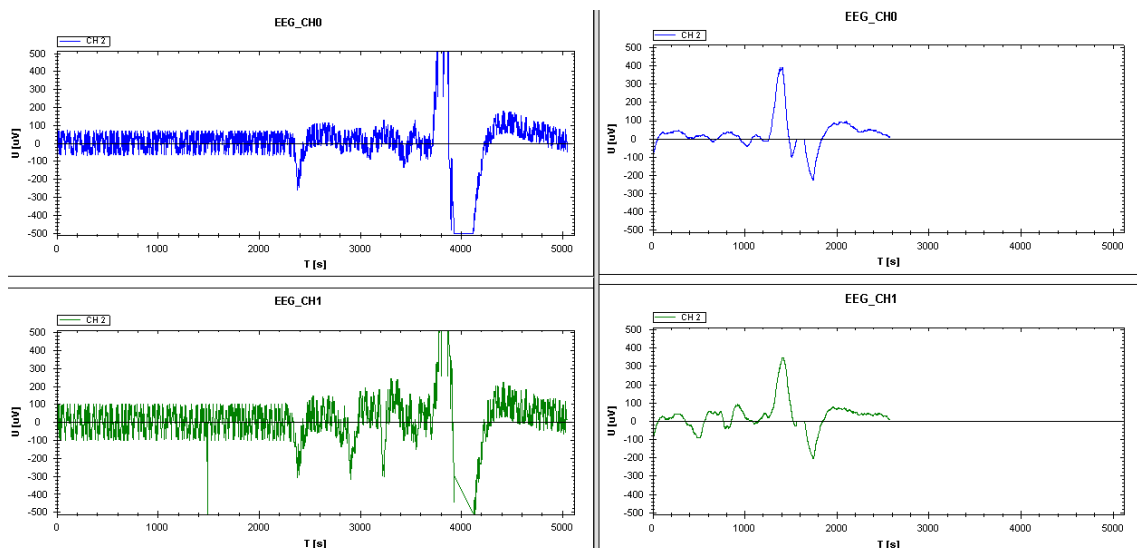
Funkcia Add Signal je realizovaná čisto len z experimentálnych dôvodov, do signálu pridá ďalšiu signálovú zložku, ktorej amplitúda a tvar je možné navoliť. Takto je možné dať za sebou niekoľko týchto blokov a zostaviť kompletný signál.



Obrázok č. 49: Schéma bloku Add Signal pri nastavení Sinus

8.4.7 Blok Processing > Average

Average je veľmi užitočná funkcia ktorá slúži aj ako filter signálu. Jej úlohou je priemerovanie voliteľného rozsahu prvkov signálu. Je možné ju použiť ako vstupný parameter pre umelú neurónovú sieť, pretože nepopisuje signál exaktne ale iba jeho približný, zjednodušený, časový obraz.



Obrázok č. 50: Upravený signál pomocou funkcie Average.

Vľavo pôvodný, vpravo upravený

8.4.8 Blok Counter

Counter je blok, ktorého úlohou je zobrazovať počet získaných packetov. Niekedy pri analýze je nutné vedieť koľko vzorkou sme už prečítali a tým získavame lepší prehľad o snímaní.

8.4.9 Blok Min a Max

V prípade použitia umelej neurónovej siete je funkcia min a max užitočným nástrojom, zobrazujú totiž minimálnu a maximálnu amplitúdu z n vzorkou signálu. Tento údaj môže byť použitý ako vstup pre UNS.

Pri rozbalení bloku Min a Max je možnosť zmazať minimálny a maximálny údaj a merať opäť od nominálnych hodnôt. Blok tiež po vložení otvorí grafické okno pre zobrazovanie aktuálnych hodnôt.



Obrázok č. 51: Grafické zobrazenie výstupných hodnôt funkcií Min a Max

8.4.10 Blok Processing > Exponential Smoothing (single)

Exponenciálne vyhladzovanie je veľmi populárna schéma pre tvorbu vyhladených časovo závislých hodnôt.

Ako prvé si musíme ujasniť termín "moving average". Ide o počítanie priemerov z menšieho počtu dát tak, že postupujeme časovým radom s určitým oknom, napr. veľkosti 3.

Keď dáta v okne nahradíme ich priemerom (MA), zároveň ich aj vyhladzujeme. Táto funkcia je vyjadrená v tvare

$$M_t = [Y_t + Y_{t-1} + Y_{t-2} + \dots + Y_{t-N+1}] / N \quad (8.1)$$

kde N je dĺžka okna.

Exponenciálne vyhladzovanie sa od MA líši tým, že prideluje starým prvkom exponenciálne klesajúce váhy v závislosti na ich poradí zatiaľ čo priraduje všetkým prvkom rovnaké. [23]

Pre exponenciálne vyhladzovanie predpokladajme, že platí $y_t = b(t) + \varepsilon$, kde b je pomaly sa s časom meniaci "trend" a ε je "chybová zložka", ktorá sa s časom rýchlo mení.

Počítame "moving average" ale tak, že pozorovania v čase bližšie majú väčšiu váhu ako vzdialenejšie pozorovania.

Exponenciálne vyhladzovanie je v podstate jednoduchý filter pri ktorom nastavením koeficientov môžeme dostať požadované hodnoty zlomov vo frekvenčnej charakteristike. Predpokladajme y ako výstup a u ako vstup, potom platí:

$$y(t) = \alpha * u(t) + (1 - \alpha) * y(t - 1) \quad 0 < \alpha < 1 \quad (8.2)$$

Pre možnosť rozsiahlejšieho nastavenia som do rovnice namiesto člena $(1 - \alpha)$ pridal koeficient β . U tohto bloku je možné "uzamknúť" hodnoty koeficientov α a β , kedy platí

$$\beta = 1 - \alpha \quad 0 < \alpha < 1. \quad (8.3)$$

Konečná rovnica teda vyzerá nasledovne

$$\begin{aligned} y(t) &= \alpha * u(t) + \beta * y(t - 1) & (8.4) \\ 0 < \alpha < 1 \\ 0 < \beta < 1. \end{aligned}$$

V jazyku C# je táto funkcia vyjadrená ako:

```
y[i] = alfa * u[i] + beta * y[i];
```

8.4.11 Blok Processing > Exponential Smoothing (double)

V predchádzajúcom prípade exponenciálne vyhladzovanie nesleduje dáta dostatočne presne, čo sa kompenzuje zavedením ďalšieho koeficientu označovaného napríklad γ , ktorý je v konjunkcii s koeficientom α . [23]

Tento vzťah je vyjadrený nasledujúcou rovnicou

$$y(t) = \alpha * u(t) + (1 - \alpha) * [y(t - 1) + \beta(t - 1)] \quad 0 < \alpha < 1 \quad (8.5)$$

$$\beta(t) = \gamma * [y(t) - y(t - 1)] + (1 - \gamma) * \beta(t - 1) \quad 0 < \gamma < 1 \quad (8.6)$$

Je nutné stanoviť počiatočné hodnoty koeficientu β , pričom existuje viacero možností:

$$\beta(1) = y(t - 1) - y(t) \quad (8.7)$$

$$\beta(1) = \frac{\{ [y(t - 6) - y(t - 5)] + [y(t - 4) - y(t - 3)] + [y(t - 2) - y(t - 1)] \}}{3} \quad (8.8)$$

$$\beta(1) = \frac{y_n - y_1}{n - 1} \quad (8.9)$$

Funkcia v jazyku C# vyzerá nasledovne:

```
double _y = y[i]; //predchádzajúca hodnota výstupu
y[i] = alfa*data[i] + (1-alfa) * (y[i] + beta[i]);
if (loop == 0) beta[i] = _y - y[i]; //počiatočné podmienky
beta[i] = gama * (y[i] - _y) + (1 - gama) * beta[i];
```

8.4.12 Blok Processing > Filter

Tento filter sa v anglickej terminológii nazýva Biquad Butterworth, je principiálne založený na klasickom Butterworth filtri. Na výber je horná či dolná priepusť, nastavenie frekvencie zlomu a rezonančného faktora. Algoritmus vyzerá nasledovne:

$$out(n) = a1 * in + a2 * in(n - 1) + a3 * in(n - 2) - b1 * out(n - 1) - b2 * out(n - 2); \quad (8.10)$$

$$c = \frac{1}{\tan\left(\Pi \frac{f}{sample_rate}\right)},$$
$$a1 = \frac{1}{(1 + r * c + c * c)},$$

$$b2 = (1 - r * c + c * c) * a1,$$

$$a3 = a1,$$

$$r \in \langle \sqrt{2}, 0.01 \rangle.$$

Pre dolnú priepusť platí:

$$a2 = 2 * a1,$$

$$a3 = a1,$$

$$b1 = 2 * (1 - c * c) * a1.$$

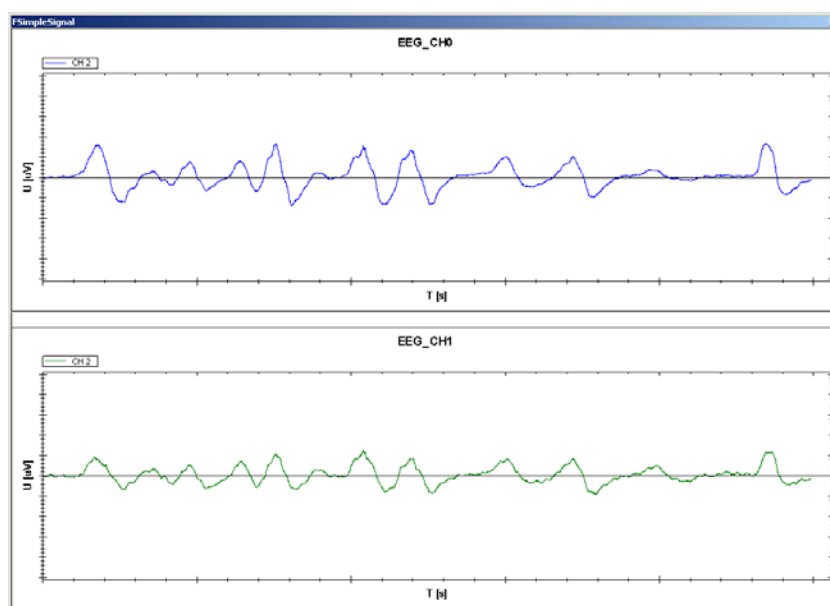
Pre hornú priepusť platí:

$$a2 = -2 * a1,$$

$$b1 = 2 * (c * c - 1) * a1.$$

8.4.13 Blok Analysis > Time analysis

Jednou z kľúčových funkcií celého programu je práve tento blok. Jeho úlohou je zobrazovať časový priebeh signálu. Pre grafickú reprezentáciu dát používam knižnicu ZedGraph, ktorá sa spomedzi viacerých javila ako najlepšia voľba. ZedGraph je objektová knižnica, obsahuje užívateľské a webové prvky pre platformu .NET. Je písaná v jazyku C# a slúži pre vykresľovanie 2D čiarových, stĺpcových a koláčových grafov. Všetky jeho vymoženosti sú veľmi kvalitne zdokumentované a na domovskej stránke projektu sa nachádza plno užitočných príkladov realizácie grafov. Viac tu: <http://zedgraph.sourceforge.net/samples.html>.

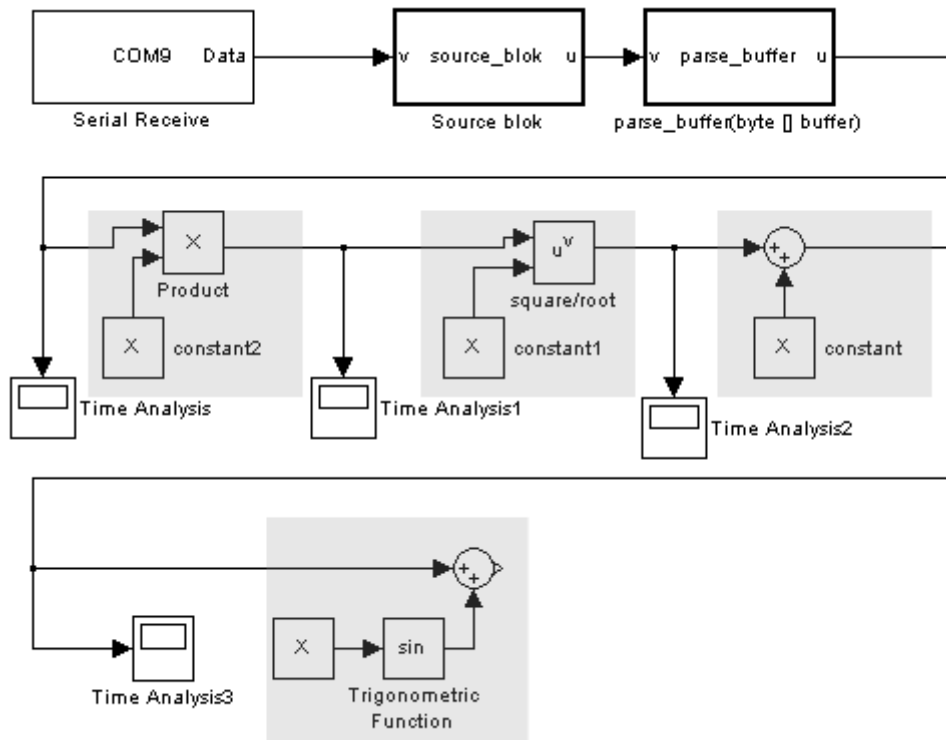


Obrázok č. 52: ZedGraph

Blok Time Analysis sa dynamicky prispôsobuje rozmeru dát, ktoré prijíma na vstupe. Maximálny počet kanálov je 6, v mojej aplikácii ale využívam iba 2.

8.4.14 Simulinkový ekvivalent zapojenia

Ako som už spomínal, bloky sa dajú zoraďovať sériovo za sebou, čím sa upravuje postupne signál a je možné ho sledovať v rôznych dobách a etapách jeho úprav. Pre prehľadné znázornenie funkčnosti to je možné demonštrovať na ekvivalente zapojenia v prostredí Simulink v Matlabe.



Obrázok č. 53: Ekvivalent blokov v prostredí Simulink

9 UMEĽÁ NEURÓNOVÁ SIEŤ

Vytváranie efektívnych analýz s dostačujúcou reprezentáciou je jednou z kľúčových úloh vo vývoji systémov pre snímanie a analýzu biosignálov. K tomuto cieľu najlepšie pomáhajú práve umelé neurónové siete (ďalej len UNS). V poslednej dobe vniká na trhu zábavného priemyslu mnoho zariadení s implementovanou UNS ako je napríklad Epos Emotiv či iné, a ide o veľmi úspešné produkty. Avšak zábavný priemysel nie je jediným miestom využívania umelej inteligencie, spoločnosti ako IBM či americká DARPA už dlhé roky vyvíjajú systémy na rozoznávanie ľudských myšlienok.

Vráťme sa ale späť do oblasti klinickej elektroencefalografie, jednou z dôležitých oblastí snímania EEG signálov je rozoznávanie grafoelementov, čo je veľmi užitočná pomôcka pre zdravotného pracovníka, pretože slúži ako asistenčný nástroj. V nasledujúcich riadkoch sa zoznámime s princípmi UNS, definujeme si základné pojmy a vzťahy a neskôr prejdeme k teoretickému návrhu UNS pre rozoznávanie grafoelementov.

9.1 Definícia


Umelú neurónovú sieť môžeme rozumieť ako realizáciu zobrazenia vstupného vektorového priestoru do vektorového priestoru výstupného, $\{x\} \rightarrow \{y\}$, pričom dimenzie týchto priestorov môžu byť obecné rôzne.

Aplikácia UNS je veľmi široká, v tejto práci však budeme UNS používať ako signálový procesor a klasifikátor. Dôležitou funkciou UNS v tomto prípade je asociatívna pamäť schopná vybaviť si informáciu iba na základe neúplného zadania. [8]

UNS spracovávajú informáciu paralelne, čo v prípade hardwarovej realizácie radikálne zvyšuje rýchlosť spracovania, avšak pri použití u sekvenčných počítačoch to býva práve naopak. [8]

Procesné elementy, tzv. neuróny, pracujú spravidla autonómne, v UNS obvykle nie je centrálna synchronizácia a ide teda o asynchrónnu činnosť s distribuovaným riadením. [8]

Neuróny sú nahusto prepojené, pričom váhy medzi nimi vyjadrujú stupeň jednosmerného alebo viacsmerného vplyvu.



Obrázok č. 54: Topológia umelej neurónovej siete [26]

9.2 Neurón

Neurón je definovaný ako procesný prvok, ktorý má N vstupov a jeden výstup a je charakterizovaný rovnicou

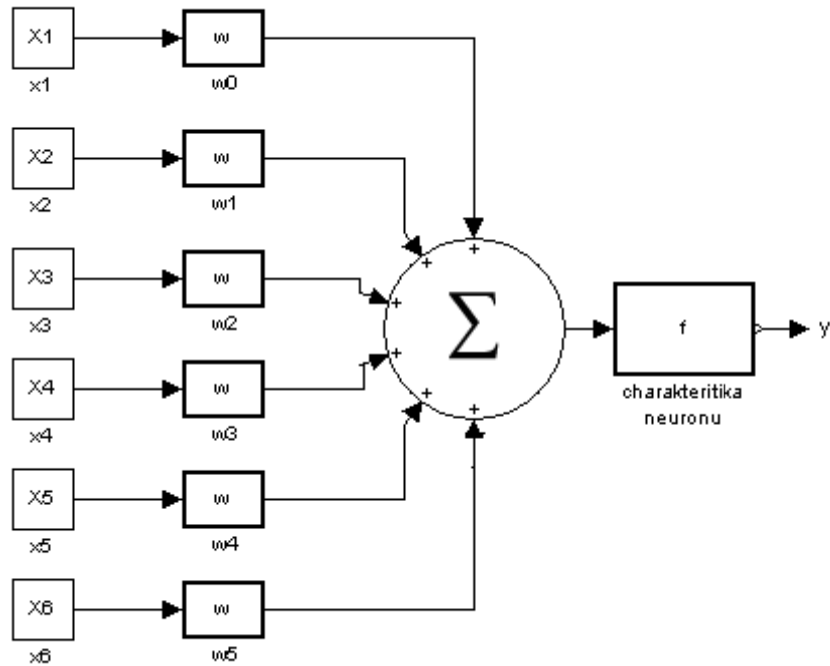
$$y = f\left(\sum_{i=1}^N w_i x_i - v\right), \quad (9.1)$$

udávajúcou jeho výstup y pre vstupný vektor $x = [x_1, x_2, \dots, x_N]^T$, pričom $w = [w_1, w_2, \dots, w_N]^T$ je vektorom aktuálnych váh, v je aktuálny prah neurónu a $f(\alpha)$ je zvolená, ale ďalej už nemenná spravidla nelineárna funkcia, ktorá sa chová ako *charakteristika* neurónu. Argument funkcie neurónu sa nazýva *aktivácia* neurónu. [8]

Priebehy charakteristík neurónu sú rôzne, avšak medzi najpoužívanejšie patrí lineárna charakteristika, obmedzená lineárna charakteristika, veľmi často používaná prahová funkcia $sign(\alpha)$ a sigmoidná funkcia definovaná ako


$$f(\alpha) = \frac{1}{1 + e^{-\frac{\alpha}{T}}}, \quad (9.2)$$

ktorej výhod sa využíva najmä v dopredných sieťach.




Obrázok č. 55: Model neurónu


Uvediem niekoľko príkladov charakteristík neurónu:




Obrázok č. 56: Lineárna charakteristická funkcia [24]




Obrázok č. 57: Funkcia jednotkový skok [24]



Obrázok č. 58: Funkcia Ramp [24]



Obrázok č. 59: Sigmoidná funkcia [24]




Obrázok č. 60: Gaussová funkcia [24]

Riadené učenie neurónu predpokladá, že existuje tzv. *učebná množina* dvojíc (x, y_d) , reprezentujúcich požadovanú korešpondenciu; y_d je teda požadovaná odozva neurónu na vstupný vektor x . Učenie spočíva v tom, že sa porovnáva skutočná odozva neurónu s odozvou žiaducou a na základe toho je vhodne upravovaný vektor váh w . [8]

9.3 Dopredné siete


Dopredné siete sú také, kde informácia putuje od vstupov do výstupov skrze vrstvy UNS tvorené neurónmi. Konceptne najjednoduchšou UNS je *jednovrstvový perceptron* (Obrázok č. 63). Charakteristiky všetkých neurónov v sieti bývajú rovnaké, líšia sa akurát vektory váh medzi neurónmi. [8]



Obrázok č. 61: Jednovrstvový perceptor [26]


9.4 Učenie so spätným šírením chýb - Backpropagation

Okrem jednosmerných neurónových sietí existujú tiež so spätným šírením chýb. Pre lepšie pochopenie si predstavme trojvrstvovú sieť znázornenú na obrázku č. 64.




Obrázok č. 62: Trojvrstvová neurónová sieť [26]

Aby sa UNS dokázala niečo naučiť, je nutné vyslať na vstup siete X_1 a X_2 nejaké dáta, tzv. tréningovú množinu čo môže byť aj EEG signál či výsledné koeficienty analytických funkcií aplikovaných na EEG signál (napr vlnková transformácia či FFT).




Obrázok č. 63: Tréning UNS [26]

Takýmto spôsobom sa informácia šíri po neurónoch vrstvou po vrstve až k výstupnému neurónu f_6 (obrázok č. 66).



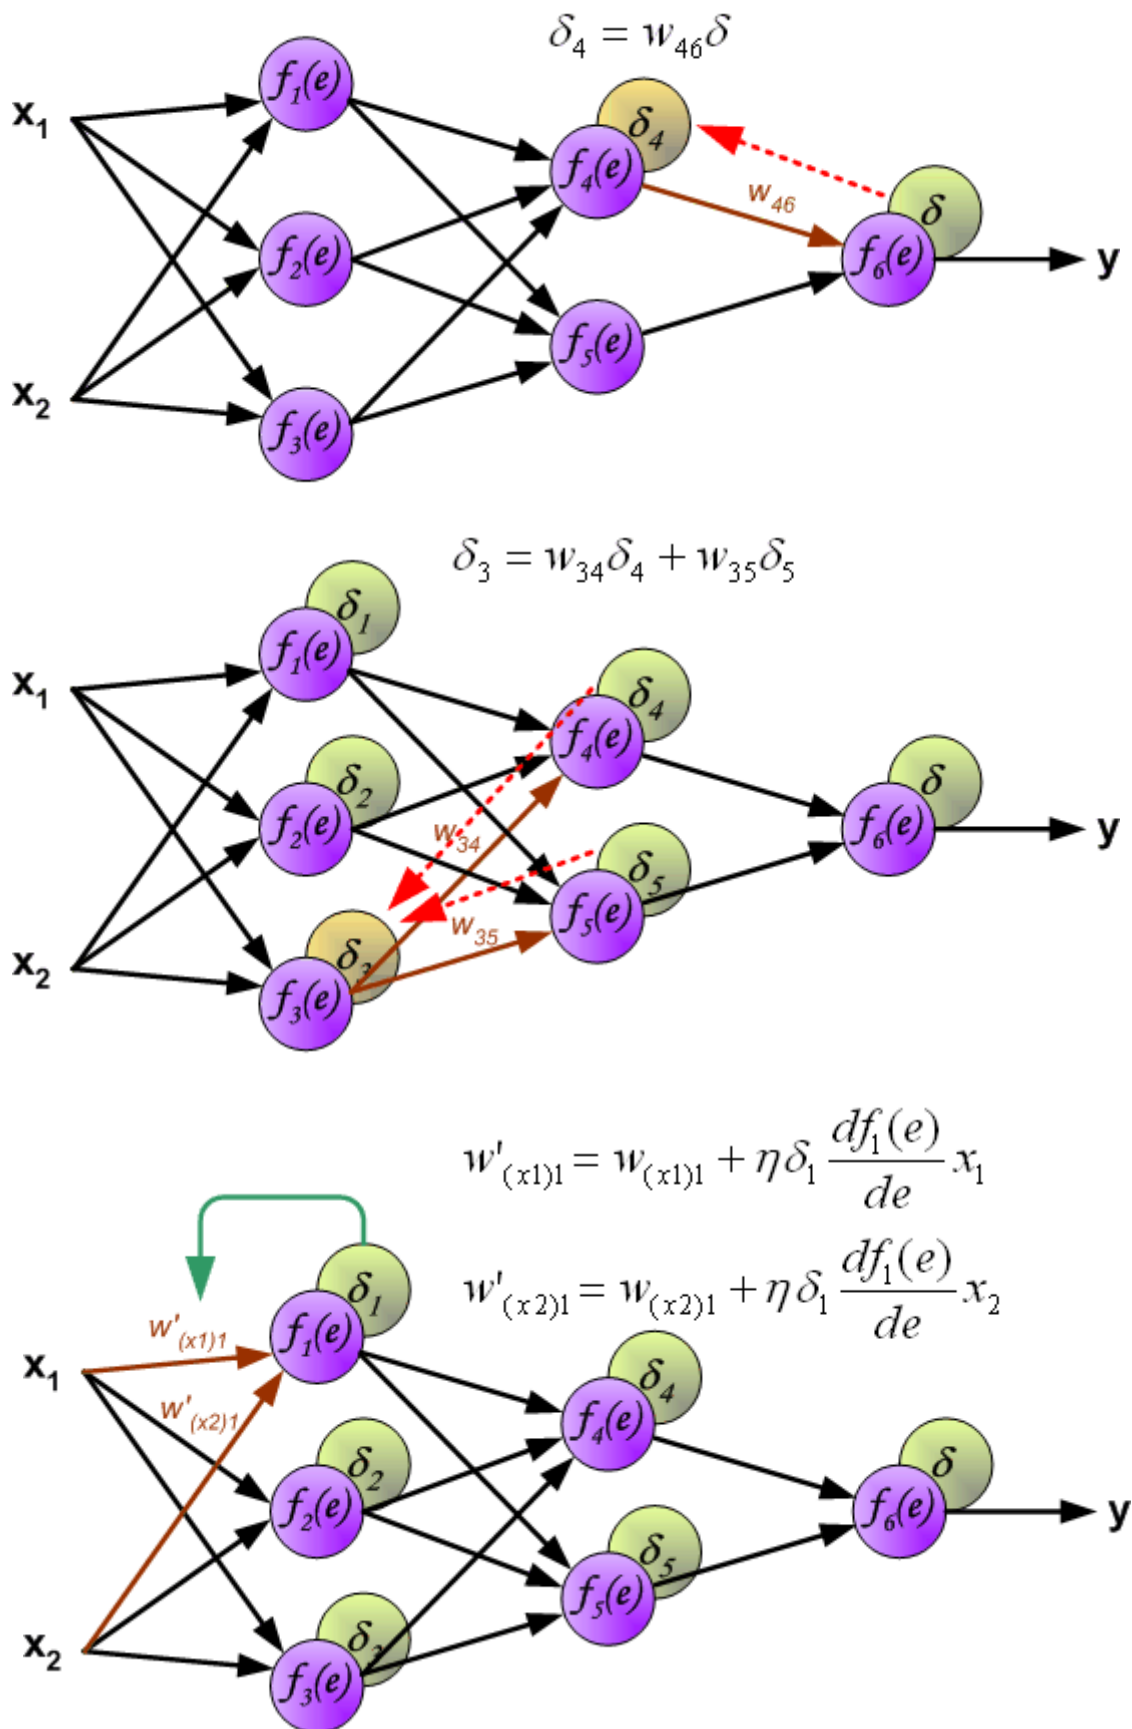
Obrázok č. 64: Tréning UNS 2 [26]

V nasledujúcom kroku sa výstupný signál siete y porovná s požadovanou hodnotou a ich rozdiel sa označuje δ . Táto hodnota sa posiela zase späť, opačným smerom zase k vstupným neurónom.



Obrázok č. 65: Výpočet chyby δ v sieti backpropagation [26]

Po výpočte odchýlky sa začnú vypočítavať hodnoty δ pre každý neurón v sieti ako to demonštruje obrázok č. 68. Akonáhle sa vypočíta posledná chybová hodnota, začne UNS upravovať na základe tejto hodnoty váhy medzi neurónmi ako je vidieť na obrázku č. 68. Po úprave váh je UNS pripravená na ďalší tréning (doučenie) či testovanie jej funkčnosti.



Obrázok č. 66: Šírenie chyby a nastavenie váh v sieti backpropagation [26]


9.5 Návrh umelej neurónovej siete pre vyhodnotenie EEG signálu a jeho možná aplikácia v programe Neuroline

Môj návrh UNS pre vyhodnocovanie EEG signálu je zatiaľ iba teoretickým rozborom možných spôsobov realizácie skutočného algoritmu. Vyhodnocovať a klasifikovať EEG záznam sa dá realizovať pre mnoho aplikácií, či už ide o rozoznávanie grafoelementov alebo BCI, vždy je princíp rovnaký - spozorovať v signáli určité ukazovatele a na základe nich signál zaradiť. Prvým krokom pre klasifikáciu EEG signálu je jeho filtrácia.

9.5.1 Filtrácia signálu

Ako som v predchádzajúcich kapitolách spomínal, použiteľné pásmo pre plnohodnotnú analýzu EEG je od 0.1 do 40 Hz, ale nám bude stačiť pásmová priepusť v rozsahu 1 - 40 Hz, čiže pásmo delta, theta, alfa až vysoké beta pásmo. Tento frekvenčný rozsah zaručí, že budeme schopný rozoznať všetky stavy bdlosti, pozornosti a dokonca spánku.

V nasledujúcom obrázku je príklad filtrovaného signálu pomocou lineárneho diskrétného filtra, ktorý popisujem v predchádzajúcich kapitolách. Je vidno že signál je dostatočne čistý a použiteľný. Takto upravený signál je nutné podrobiť určitej transformácii pre jeho ďalšiu analýzu. Signál filtrujeme pre každé pásmo zvlášť čím dostaneme 4 rôzne časové priebehy signálu.



Obrázok č. 67: Filtrácia signálu v programe Neuroline

9.5.2 Vlnková transformácia

Vlnková transformácia vedie k získaniu časovo-frekvenčného popisu signálu. Historicky staršia Fourierova transformácia poskytuje informácie o tom, ktoré frekvencie sa v signáli nachádzajú, nehovorí však o umiestnení v čase. Je teda vhodná len pre popis stacionárnych signálov.

Ideou vlnkovej transformácie je vhodnou zmenou šírky "okna" v čase a jeho tvarom dosiahnuť optimálneho pomeru rozlíšiteľnosti v čase a frekvencii. Pre nízke frekvencie je "okno" širšie, pre vysoké užšie. Toto okno sa nazýva materská vlnka y . Pomocou parametru a , ktorý sa volá mierka, je možné meniť jej šírku, parametrom b nazývaným poloha, sa mení umiestnenie na časovej osi. [28]

$$y_{a,b}(t) = \frac{1}{\sqrt{a}} y\left(\frac{t-b}{a}\right) \quad (9.3)$$

Člen $\frac{1}{\sqrt{a}}$ slúži k normalizácii energie vlnky pri zmenách mierky, $y(t)$ je tzv. prototyp vlnky. Spojitá vlnková transformácia je pre signály s konečnou energiou definovaná nasledovne:


$$[W_{\Psi}f](a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} \Psi\left(\frac{x-b}{a}\right) f(x) dx \quad (9.4)$$

Keďže ale pracujeme s číslicovou technikou, je nutné hovoriť o diskretnej vlnkovej transformácii. Spomedzi viacerých možností som si za materskú vlnku vybral Morketovú vlnku, ktorá sa javí ako najvhodnejší kandidát z radov materských funkcií vlnkových transformácií.

Jedná sa o komplexnú exponenciálu modulovanú Gaussovským oknom (obrázok č. 70). Je výsledkom kompromisu medzi polohovou lokalizáciou jednorazových dejov a frekvenčným rozlíšením. Je symetrická a nemá kompaktný nosič. [28]

Morletová vlnka je definovaná nasledovne:

$$y(x) = a \cdot e^{-\frac{1}{2}x^2} (\cos(5x) + j \sin(5x)) \quad (9.5)$$



Obrázok č. 68: Morletová vlnka

Popri práci na projekte sa mi dostala do rúk práca Abdulhamita Subasiho (*Classifications of EEG signals using neural network and logistic regression*), kde popisuje použitie vlnkovej transformácie typu LBDWT ako najlepšia voľba pre klasifikáciu EEG signálu. Dokazuje, že LBDWT pracuje rýchlejšie než iný typ vlnkovej transformácie a to aj bez použitia špeciálneho hardwaru.

Základnou myšlienkou LBDWT je vzťah medzi všetkými biortogonálnymi vlnkami, ktoré zdieľajú tú istú zosilňovaciu funkciu. Využitie LBDWT alebo vlnkovej transformácie s Morletovou vlnkou je otázkou testovania a následného výberu varianty s lepšími výsledkami.

Každopádne, v predchádzajúcom kroku sme signál filtrovali a získali sme 4 rôzne priebehy signálu v čase, pre každé pásmo jeden priebeh. V tomto kroku na každé z týchto pásiem aplikujeme vlnkovú transformáciu, čím dostaneme mikroskopický pohľad na priebeh, môžeme jasne pozorovať každú zmenu signálu, čo nám vytvorí jasný obrazec.

9.5.3 Umelá neurónová sieť

.Na obrázku 29 môžeme vidieť vľavo filtrovaný signál pomocou jednotlivých pásmovo-priepustných filtrov a vpravo ich reprezentáciu pomocou vlnkovej transformácie.

Pre túto ukážku aplikácie UNS predpokladajme trojvrstvovú sieť typu backpropagation. Hneď stojíme pred prvým problémom a to výber vhodnej aktivačnej funkcie pre neuróny. Je možnosť použiť populárnu sigmoidálnu funkciu (obrázok č. 61) avšak volím radšej *tanh* funkciu a to z niekoľkých dôvodov:

- Je výpočtovo menej náročná ako exponenciálna funkcia (ako napr. sigmoida)

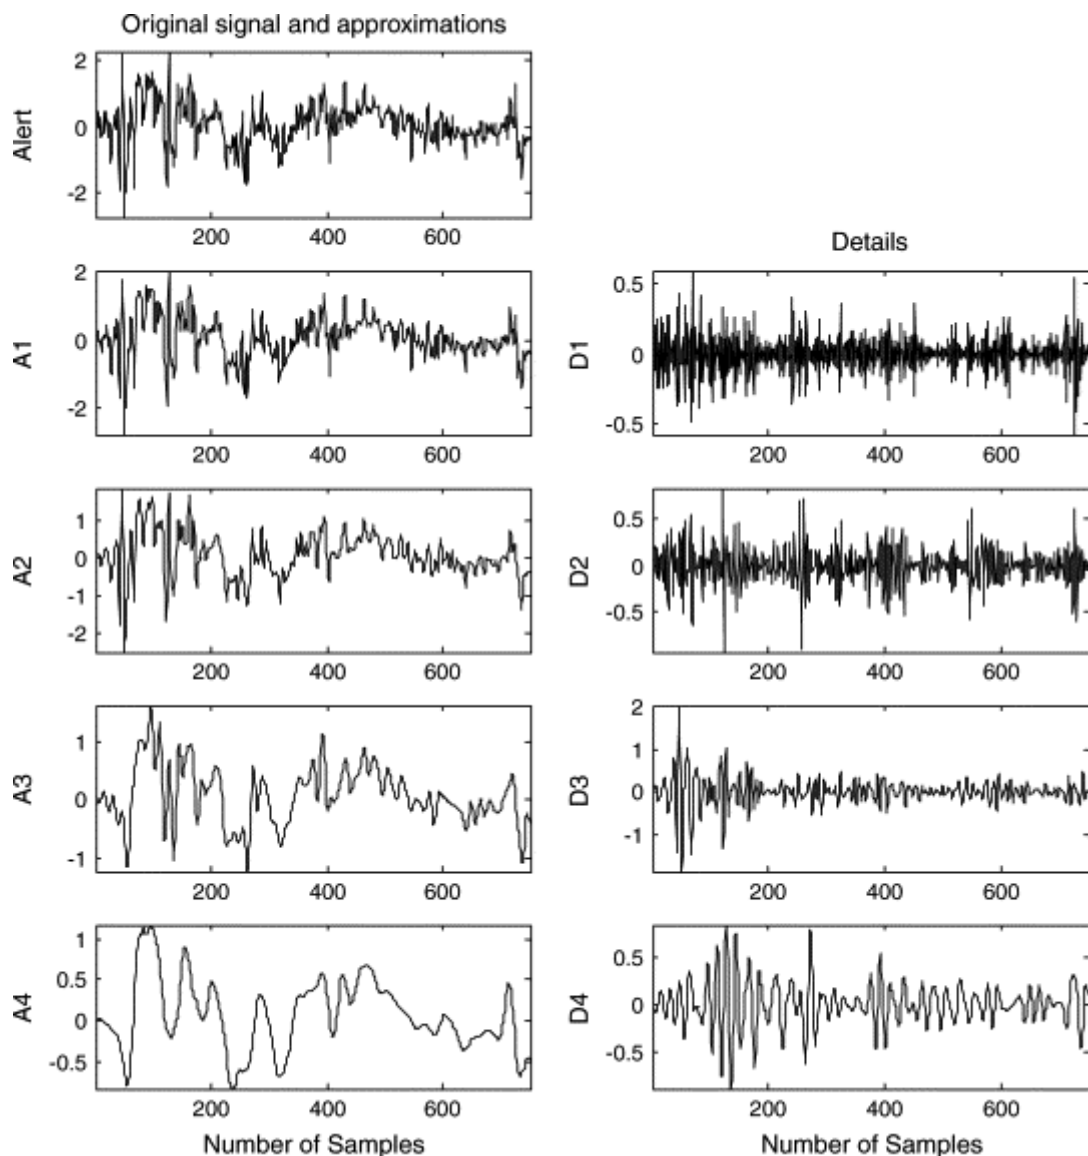
- Má väčší definičný obor (± 1) a záporné hodnoty čo môže byť často žiaducim faktorom pri normalizácii tréningovej sady, čiže má nulový priemer a jednotkovú smerodajnú odchýlku
- Asymetrická funkcia ako napríklad *tanh* vedie k rýchlejšiemu naučeniu sa UNS oproti sigmoide.

Pre každé EEG pásmo (delta, theta, alfa, beta) je vyhradený jeden vstupný neurón, čiže počet vstupných neurónov je 4. Počet skrytých neurónov v strednej vrstve je kritickým faktorom pri návrhu UNS

Sieť s príliš malým počtom skrytých neurónov bude neschopná rozlišovať medzi zložitými vzormi signálu čo by viedlo len k lineárnemu odhadu skutočného. Naopak, pokiaľ by mala sieť príliš veľa skrytých neurónov, viedlo by to k zarušeniu dát z dôvodu nadmernej parametrizácie, ktoré by spôsobila zlé zovšeobecnenie netrénovaných dát. [29]

So zvyšujúcim sa počtom skrytých neurónov sa rapídne zvyšuje doba tréningu UNS. Spôsob voľby počtu neurónov v skrytej vrstve je teda najlepší pomocou metódy pokus-omyl.

Ak sme na začiatku tréningu nastavili váhy náhodne, na konci tréningu budú ich hodnoty vyzerat' úplne odlišne. Počas toho ako sa UNS neustále trénuje, dochádza k dolad'ovaniu váh k zmenšovaniu odchýlok δ .



Obrázok č. 69: Signál po aplikácii vlnkovej transformácie [29]

Takýmto usporiadaním vstupnej a skrytej vrstvy neurónov je možné doplnením výstupnej vrstvy klasifikovať napríklad mentálny stav človeka. V prípade, že by sme nastavili výstupnú vrstvu ako 4 neuróny s logistickou aktivačnou funkciou, môžeme jednoducho dostať sériu čísel napr. [1 0 0 0] čo by v našom prípade znamenalo vysokú mentálnu aktivitu (všimnime si, že prvá vstupná vrstva je obrazom beta aktivity).

Ďalšie príklady možných hodnôt z výstupu UNS:

- [1 0 0 0] = vysoká pozornosť
- [1 1 0 0] = pozornosť
- [0 1 1 0] = znížená pozornosť
- [0 0 1 1] = relaxácia
- [0 0 0 1] = spánok

9.5.4 Zhodnotenie

Praktická realizácia neurónovej siete v jazyku C# môže byť dosť náročná. Je vhodné túto sieť navrhnuť najprv v prostredí Matlab, určiť vhodné aktivačné funkcie hoci aj metódou pokus-omyl, určiť si správny počet neurónov v skrytej vrstve, čo je pre nás veľmi významný faktor a až po získaní relevantných výsledkov túto konfiguráciu programovať v C#.

Pri návrhu tejto UNS som sa opieral najmä o výskumy Abdulhamita Subasiho z University of Gaziantep, Turecko a Christina Schäfera z Technical University Munich, Nemecko. Na pár ukázkach som demonštroval možnosti a spôsoby návrhu UNS s príkladom možného využitia.

10 ZÁVER

Vo svojej práci som opísal základné parametre snímania a analýzy EEG signálu, vysvetlil rôzne spôsoby a metodiku merania EEG v klinickej praxi a možnosti ďalšieho spracovania dát získaných meraním.

Okrem toho som nahliadol aj do sveta zábavného priemyslu, kde si EEG ako rozhranie človek-stroj získava veľkú obľubu. Porovnal som komerčné produkty vyskytujúce sa na trhu a zistil, že mnohé produkty na trhu nespĺňajú vo veľkej miere ani malú časť toho, čo je možné dosiahnuť lacnejšími open-source riešeniami. Preto som zhodnotil klady a zápory týchto produktov ako aj open-source projekt ModularEEG.

Po zaobstaraní si komponentov zariadenia ModularEEG, jeho poskladaní a sprevádzkovaním som opísal spôsoby zapojenia, možnosti vylepšenia hardwaru a spôsoby merania pomocou tohto zariadenia. Všetko som zabalil do fungujúceho celku, kládol som veľkú pozornosť na dosiahnutie kvalitných výsledkov pri získavaní dát. Výmena mikrokontroléru ATmega8 za ATmega88 sa ukázala mierne prospešná, došlo k miernemu spresneniu výsledkov z dôvodu že ATmega8 obsahuje iba 4 10-bitové A/D prevodníky a 2 8-bitové, zatiaľ čo ATmega88 má 10-bitové všetky AD prevodníky.

Paradoxne, zostavenie konštrukcie pre celé zariadenie bolo pre mňa najväčším problémom. Bolo nutné sa popasovať s dobrým tienením citlivej techniky čo sa dosiahlo umiestnením elektronických dosiek do kovovej skrinky s dodatočným tienením DC zdroja od analógovej elektronickej dosky. Taktiež postranné plechy skrinky dostatočne tienia techniku čo je možné demonštrovať odmontovaním vrchného plechu - signál sa zaruší sieťovým šumom.

Popri mojej činnosti na tejto bakalárskej práci spoločnosť Olimex uvoľnila do predaju open-source zariadenie EEG-SMT, ktoré je nasledovníkom ModularEEG a keďže som chcel túto prácu udržať aktuálnu, toto zariadenie som si zaobstaral a zhodnotil jeho vlastnosti. EEG-SMT má oproti staršiemu ModularEEG nielenže lepšie filtračné vlastnosti, ale aj možnosť pripojenia aktívnych elektród, vstavané rozhranie USB-RS232 a mnoho ďalších o ktorých sa dá dočítať v kapitole č.7.

Pre ModularEEG aj pre EEG-SMT som navrhol a realizoval program Neuroline, ktorý obsahuje v sebe dekodér protokolu P2 vďaka ktorému zariadenia komunikujú s PC, navrhol som viaceré číslicové filtre a nástroje na vyhladzovanie signálu a celý koncept programu Neuroline som sa snažil pojať spôsobom, aby bolo užívateľovi jasné, čo sa so signálom deje v jednotlivých častiach jeho úpravy a spracovania. Užívateľ má možnosť jednotlivito zoraďovať funkčné bloky slúžiace ako funkcie, operátory a zobrazovače signálu. Prostredie programu Neuroline som vybavil viacerými komponentmi pre jednoduchú prácu ako je napríklad DockSuite Panel, vďaka ktorému

je teraz prostredie modifikovateľné a prispôsobiteľné na mieru. Program som tiež obohatil rozhraním umožňujúce jednoduché doprogramovanie ďalších modulov pre analýzu a predspracovanie EEG signálu. Všetky doterajšie funkcie programu Neuroline slúžia na opis presnej charakteristiky meraného EEG a sú to dáta vhodné pre vstup do umelej neurónovej siete.

Mojou poslednou úlohou bol koncepčný návrh umelej neurónovej siete, vďaka ktorej by bolo možné presnejšie klasifikovať a reprezentovať nameraný signál. Oprel som sa o práce viacerých vedcov v obore merania a analýzy EEG, aby bol môj návrh čo najrelevantnejší. Navrhol som 3 vrstvovú doprednú umelú neurónovú sieť so spätným šírením chýb pre klasifikáciu mentálneho stavu meraného subjektu. Sieť má na vstupe 4 neuróny s *tanh* aktivačnou funkciou, bližšie nešpecifikovaný počet skrytých neurónov a 4 výstupné neuróny s logistickou aktivačnou funkciou.

Túto bakalársku prácu som v jej modifikovanej podobe prihlásil do študentskej súťaže EEICT. Práca bola úspešne zaradená do zborníka.

Popri práci na bakalárskom projekte som neváhal kontaktoval viacerých hlavných prispievateľov do projektu OpenEEG a konzultoval s nimi problémy s ktorými som sa popri vývoji stretol. Rád by som svoje poznatky, ktoré som vďaka tomuto projektu nadobudol, šíril ďalej pre open-source komunitu a program Neuroline zverejním vrátane jeho zdrojových kódov. Rád by som týmto spôsobom späť oplatil komunitu vedcov, inžinierov a hobbistom cenné poznatky, ktoré som vďaka ModularEEG nadobudol.

LITERATÚRA

- [1] MORÁŇ, Miroslav. *Praktická elektroencefalografie*. 1. vyd. Brno: Institut pro další vzdělávání pracovníků ve zdravotnictví, 1995, 146 s., grafy. ISBN 80-701-3203-5.
- [2] SVATÝ, Jaromír, Miroslav RÖSSLER a Milada NOVÁKOVÁ. *Diagnostika a léčení dětských nervových záchvatů*. Praha: Avicenum, 1976. ISBN 08-050-76.
- [3] LESNÝ, Ivan. *Dětská neurologie*. 1. vydání. Praha: Avicenum, 1980. ISBN 80-724-2544-3.
- [4] SYSLOVÁ, Zuzana, Dušan SYSEL, Oto MASÁR, Eliška KUBÍKOVÁ a Mária BROZMANOVÁ. *Elektroencefalografie v praxi*. V Tribunu EU vyd. 1. Brno: Tribun EU, 2010, 134 s. Librix.sk. ISBN 978-80-7399-913-1.
- [5] Elektroencefalogram. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001- [cit. 2011-12-07]. Dostupné z: <http://cs.wikipedia.org/wiki/Elektroencefalografie>
- [6] HOVORKA, Jiří. *Klinická elektroencefalografie: základy klasifikace a interpretace*. 1. vyd. Praha: MAXDORF, 2003, 289 s. ISBN 80-734-5001-1.
- [7] KELLEROVÁ, Valja. *Elektroencefalografie jako metoda v klinické neurotoxicologii*. Vyd. 1. Praha: Avicenum, 1990. ISBN 978-802-0100-238.
- [8] JAN, Jiří. *Číslicová filtrace, analýza a restaurace signálů*. Vyd. 2. Brno: VUTIUM, 2002, 427 s. ISBN 80-214-1558-4.
- [9] ROZMAN, Jiří. *Elektronické přístroje v lékařství*. Vyd. 1. Praha: Academia, 2006, 406 s., xxiv s. barev. obr. příl. ISBN 80-200-1308-3.
- [10] SMITH, Julius O. *Mathematics of the discrete fourier transform (DFT): with audio applications*. 2nd ed. s.l.: W3K Publishing, 2007, xiv, 306 s. ISBN 978-0-9745607-4-8. Dostupné z: <https://ccrma.stanford.edu/~jos/mdft/Spectrograms.html>
- [11] SCHOONOVER, Daniel a Jose PEREZ. *Cognitive Electroencephalography Acquisition Laboratory System: Team 10 : MindView*. [online]. 2008 [cit. 2011-12-18]. Dostupné z: http://mil.ufl.edu/4924/projects/spring_08_preliminary_design/Perez_Schoonover_proposal.pdf

- [12] WOJNAS, Joshua. Programmable Chip EEG. The Programmable Chip EEG BCI [online]. 2008, 2012-04-02 [cit. 2012-05-20]. Dostupné z: http://www.opencircuits.com/Programmable_Chip_EEG
- [13] DELORME, Arnaud a Scott MAKEIG. EEGLAB. UNIVERSITY OF CALIFORNIA SAN DIEGO. *Swartz Center for Computational Neuroscience: Institute for Neural Computation* [online]. 2004 [cit. 2011-12-26]. Dostupné z: <http://sccn.ucsd.edu/eeglab/>
- [14] Brain-Computer Interface. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001- [cit. 2012-01-21]. Dostupné z: http://en.wikipedia.org/wiki/Brain%E2%80%93computer_interface
- [15] Berger, Hans. *S9.com* [online]. 2007, 2007-06-04 [cit. 2012-05-01]. Dostupné z: <http://www.s9.com/Biography/Berger-Hans>
- [16] User Tutorial:EEG Measurement Setup. In: *Bci2000.org* [online]. 2009, 2009-08-14 [cit. 2012-01-26]. Dostupné z: http://www.bci2000.org/wiki/index.php/User_Tutorial:EEG_Measurement_Setup
- [17] EEG Artifacts. In: *Slideshare.net* [online]. 2010, 2010-11-11 [cit. 2012-01-26]. Dostupné z: <http://www.slideshare.net/anjupaed/eeg-artifacts>
- [18] Welcome to the OpenEXG-2 project. JUNG, Stefan. *Google Sites* [online]. 2009, 2009-04-21 [cit. 2012-01-26]. Dostupné z: <http://sites.google.com/site/openexg/>
- [19] Comparison of consumer brain–computer interfaces. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2001-, 2012-01-24 [cit. 2012-01-28]. Dostupné z: http://en.wikipedia.org/wiki/Comparison_of_consumer_brain%E2%80%93computer_interfaces
- [20] BRAIN COMPUTER INTERFACING PROJECT. *BCI Review - The EEG* [online]. [cit. 2012-05-21]. Dostupné z: <http://www.robots.ox.ac.uk/~parg/projects/bci/rev1.html>
- [21] ModularEEG:The amplifier and digital boards. In: <http://openeeg.sourceforge.net/> [online]. 2001 [cit. 2011-12-12]. Dostupné z: <http://openeeg.sourceforge.net/doc/gallery/nelo/index.html>
- [22] EEG-SMT. In: *Olimex.com* [online]. 2012 [cit. 2012-03-11]. Dostupné z: <http://www.olimex.com/gadgets/index.html>

- [23] NIST/SEMATECH. E-Handbook of Statistical Methods. In: *National Institute of Standards and Technology* [online]. U.S.A., 2003, 2012-01-04 [cit. 2012-03-24]. Dostupné z: <<http://www.itl.nist.gov/div898/handbook/tool aids/pff/index.htm>>
- [24] DEBES, Klaus, Andreas KOENIG a H. M. GROSS. *Brains, minds: Transfer Functions in Artificial Neural Networks* [online]. 98684 Ilmenau, Germany, 2007 [cit. 2012-04-12]. ISBN 1861-1680. Dostupné z: <<http://www.brains-minds-media.org/archive/151/bmm-debes-suppl-050704.html>>. Vedecký článok. Department of Neuroinformatics and Cognitive Robotics, Technical University Ilmenau, P.O.Box 100565, 98684 Ilmenau, Germany.
- [25] STERGIOU, Christos a Dimitrios SIGANOS. NEURAL NETWORKS. In: *Imperial College London: Department of Computing* [online]. [cit. 2012-05-10]. Dostupné z: <http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html>
- [26] KENDALL, Graham. G5AIAI - Introduction to Artificial Intelligence. In: *The University of Nottingham* [online]. 2001, 2001-09-21 [cit. 2012-05-27]. Dostupné z: <<http://www.cs.nott.ac.uk/~gzk/courses/g5aiai/006neuralnetworks/neural-networks.htm>>
- [27] TEDEUSIEWICZ, Ryszard. *Sieci neuronowe*. Wyd. 2. Warszawa: Akademska Oficyna Wydawnicza, 1993. ISBN 978-838-5769-033. Dostupné z: <http://home.agh.edu.pl/~vlsi/AI/backp_t_en/backprop.html>
- [28] ŠMÍD, Radislav. Úvod do vlnkové transformace. In: *ČVUT FEL katedra měření* [online]. ČVUT FEL katedra měření, Technická 2, CZ-166 27 Praha 6, 2001, 2001-01-11 [cit. 2012-04-28]. Dostupné z: <<http://measure.feld.cvut.cz/usr/staff/smid/wavelets/wavelet-intro-html.html>>
- [29] SUBASI, Abdulhamit. *Expert systems with applications: Automatic recognition of alertness level from EEG by using neural network and wavelet coefficients*. Kahramanmaraş, Turkey, 2005. ISBN 0957-4174. Dostupné z: <<http://www.sciencedirect.com/science/article/pii/S0957417404001745>>. JOURNAL. Department of Electrical and Electronics Engineering, Kahramanmaraş Sutcu Imam University, Karacasu Kampusu, 46601 Kahramanmaraş, Turkey.

ZOZNAM PRÍLOH

Príloha 1	Schéma analógového obvodu ModularEEG
Príloha 2	Schéma digitálneho obvodu ModularEEG
Príloha 3	Schéma EEG-SMT
Príloha 4	Schéma aktívnych elektród SMT-AE
Príloha 5	CD / DVD