

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA ELEKTROTECHNIKY
A KOMUNIKAČNÍCH TECHNOLOGIÍ**

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

**HODNOCENÍ VLIVU MRKÁNÍ NA VÝSLEDEK FÚZE
SIMULTÁNNÍCH EEG-FMRI DAT**

EVALUATION OF EYE-BLINKING ARTIFACT EFFECT ON FUSION RESULT OF SIMULTANEOUS EEG-FMRI
DATA

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Lukáš Dobiš

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. René Labounek

BRNO 2018

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Lukáš Dobiš

ID: 186654

Ročník: 3

Akademický rok: 2017/18

NÁZEV TÉMATU:

Hodnocení vlivu mrkání na výsledek fúze simultánních EEG-fMRI dat

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši z oblasti fúze simultánních EEG-fMRI dat za pomoci spektrálních změn skalpového EEG signálu. 2) Dále se v rešerši zaměřte na metody předzpracování EEG signálu a zejména na metodiku potlačení vlivu mrkání ze simultánního EEG záznamu. 3) Navrhněte proces zpracování dat, včetně metodiky potlačení tíženého artefaktu. 4) Navržené metody realizujte a implementujte v programovacím prostředí MATLAB. 5) Na reálných simultánních EEG-fMRI datech testujte implementované metody. 6) Dosažené výsledky zhodnoťte a diskutujte úspěšnost potlačení artefaktu a jeho vliv na finální výsledky.

DOPORUČENÁ LITERATURA:

- [1] LABOUNEK, René, et al. Exploring task-related variability in fMRI data using fluctuations in power spectrum of simultaneously acquired EEG. *Journal of neuroscience methods*, 2015, 245: 125-136.
- [2] JOYCE, Carrie A.; GORODNITSKY, Irina F.; KUTAS, Marta. Automatic removal of eye movement and blink artifacts from EEG data using blind component separation. *Psychophysiology*, 2004, 41.2: 313-325.
- [3] DELORME, Arnaud; MAKEIG, Scott. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of neuroscience methods*, 2004, 134.1: 9-21.

Termín zadání: 5.2.2018

Termín odevzdání: 25.5.2018

Vedoucí práce: Ing. René Labounek

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

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

ABSTRAKT

Práce se zabývá základní teorií k simultánní fúzi EEG-fMRI dat. Principy akvizice jednotlivých dat a jejich artefakty s rozsáhlým zaměřením na jejich předzpracování. Konkrétně na potlačení artefaktu mrkání z EEG dat a metodou analýzy nezávislých komponent. Dále se zabývá technikou fúze dat v obecném lineárním modelu a vytvořením aktivizačních map statisticky významných korelací. Práce obsahuje popis metodiky potřebné na analýzu výsledků. Jsou popsány parametry použitých dat. Je navržen a aplikován proces předzpracování EEG dat, včetně potlačení artefaktu a fúze s vyhodnocením v prostředí MATLAB. Výsledky vyhodnocení prokázaly větší vliv mrkacího artefaktu na výsledky počítané z relativního výkonu a neúplnost kompletního potlačení artefaktu z dat pro testovanou metodu.

KLÍČOVÉ SLOVÁ

simultánní fúze EEG-fMRI dat, artefakt mrkání, analýza nezávislých komponent, BOLD signál, EEG regresor, obecný lineární model, aktivizační mapa EEG-fMRI dat, frekvenční pásma EEG

ABSTRACT

This thesis sets a theoretical framework about simultaneous EEG-fMRI fusion. The work contains a description of basic principles of acquisition, their individual artifact types and preprocessing techniques for each type of data. Thesis mainly deals with suppression of eye blink artifacts in EEG data, by the method of independent component analysis. The following part explains the technique of simultaneous EEG-fMRI fusion in a general linear model and the creation of activation maps of statistically important correlations. This chapter is concluded with a description of methodology needed for result analysis. Finally, the used data are described, and a solution is proposed and applied in process of EEG preprocessing with artifact suppression, data fusion and result evaluation in MATLAB environment. Evaluation results showed that eye blink artifact influences the fusion result computed from relative power values more than that constructed via absolute power values. Tested method didn't suppress eye blink artifact completely.

KEYWORDS

simultaneous EEG-fMRI, eye blink artifact, independent component analysis, BOLD signal, EEG regressor, general linear model, EEG-fMRI activation map, EEG frequency bands

DOBIŠ, Lukáš. *Hodnocení vlivu mrkání na výsledek fúze simultánních EEG-fMRI dat*. Brno, 2018, 68 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedúci práce: Ing. René Labounek

VYHLÁSENIE

Vyhlasujem, že som svoju bakalársku prácu na tému „Hodnocení vlivu mrkání na výsledek fúze simultánních EEG-fMRI dat“ vypracoval samostatne pod vedením vedúceho bakalárskej práce, využitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autor uvedenej bakalárskej práce ďalej vyhlasujem, že v súvislosti s vytvorením tejto bakalárskej práce som neporušil autorské práva tretích osôb, najmä som nezasiahol nedovoleným spôsobom do cudzích autorských práv osobnostných a/alebo majetkových a som si plne vedomý následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona Českej republiky č. 121/2000 Sb., o práve autorskom, o právach súvisiacich s právom autorským a o zmene niektorých zákonov (autorský zákon), v znení neskorších predpisov, vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia časti druhej, hlavy VI. diel 4 Trestného zákoníka Českej republiky č. 40/2009 Sb.

Brno

.....

podpis autora

POĎAKOVANIE

Rád by som sa poďakoval vedúcemu bakalárskej práce pánovi Ing. René Labounkovi za odborné vedenie, konzultácie, trpezlivosť a podnetné návrhy k práci.

Brno

.....

podpis autora

OBSAH

Úvod	13
1 Skalповá elektroencefalografia	14
1.1 Princíp EEG	14
1.2 Pásma EEG	15
1.3 Artefakty EEG	17
1.3.1 Artefakty prostredia	17
1.3.2 Svalové artefakty	18
1.3.3 EKG artefakt	18
1.3.4 Pulzný artefakt	18
1.3.5 Kožné artefakty	18
1.3.6 Respiračné artefakty	19
1.3.7 Očné artefakty	19
1.4 Predspracovanie EEG	20
1.4.1 Odstránenie magnetického gradientu	20
1.4.2 Odstránenie kolísania izolínie	20
1.4.3 Filtrácia pásmovou priepustou v rozmedzí 0,1-40 Hz	20
1.4.4 Normalizácia dát	20
1.4.5 Potlačenie artefaktu mrkania pomocou ICA	20
2 fMRI	23
2.1 Princíp fMRI založenom na BOLD signále	23
2.1.1 T_2^* čas tranzverzálnej relaxácie	23
2.1.2 Sekvencia pre BOLD fMRI	24
2.1.3 Morfológia hemodynamickej odozvy	25
2.1.4 Linearita hemodynamickej odozvy	26
2.2 Akvizícia BOLD signálu	28
2.2.1 Druhy experimentov	28
2.3 Artefakty BOLD signálu	29
2.3.1 Vnútorň tepelný šum	30
2.3.2 Systémový šum	31
2.3.3 Redundantná neuronálna aktivita	31
2.3.4 Kogničná variabilita vo výkone úlohy	31
2.3.5 Fyziologický šum	31
2.4 Predspracovanie BOLD signálu	32
2.4.1 Časová korekcia akvizície rezu	33
2.4.2 Korekcia artefaktu pohybu hlavy	33

2.4.3	Koregistrácia fMRI a MRI	33
2.4.4	Priestorová normalizácia	33
2.4.5	Časová filtrácia	34
2.4.6	Priestorová filtrácia	34
3	Fúzia fMRI a EEG dát	35
3.1	Obecný lineárny model	35
3.2	Výpočet regresorov na fúziu dát z EEG	36
3.3	Skupinová analýza dát	37
3.4	Metodika porovnávania podobností viacrozmerných signálov	37
4	Metódy	39
4.1	Simultánne EEG-fMRI dáta	39
4.1.1	Semantic decision úloha	39
4.1.2	Akvizícia EEG dát a ich čiastočné spracovanie	39
4.1.3	Akvizícia fMRI dát a ich spracovanie	39
4.2	Návrh metodiky analýzy dát	40
4.2.1	MATLAB spracovanie	40
4.2.2	Naprogramované funkcie a skripty	41
4.2.3	Použité funkcie iných knižníc	42
4.3	Spracovanie dát	44
4.4	EEG-fMRI analýza	45
4.5	Hodnotenie efektu filtrácie mrkania na finálne výsledky	45
5	Vyhodnotenie výsledkov zo spracovaných dát	46
5.1	Spracovanie EEG dát	46
5.1.1	Originálne dáta a ich zmena po nulovaní spektrálnych čiar a normalizácií	46
5.1.2	Interpolácia znehodnotených elektród, vyraďovanie subjektov a odstránenie nebiologických komponentov	46
5.1.3	Potlačenie artefaktu mrkania z EEG dát	47
5.2	Analýza dát subjektu	49
5.3	Skupinová analýza dát subjektu	49
5.4	Vplyv filtrácie mrkania na finálne výsledky	49
6	Diskusia	61
7	Záver	62
	Literatúra	63

Zoznam symbolov, veličín a skratiek	67
Zoznam príloh	68

ZOZNAM OBRÁZKOV

1.1	Medzinárodný systém uloženia elektród 10/20 pre 30 elektród [3] . . .	14
1.2	Základní blokové schéma jedného kanálu elektroencefalografu [3] . . .	15
1.3	Schématické zapojenie pre meranie odporu [3]	15
1.4	Pásmo EEG vln	17
1.5	EEG signál zobrazujúci artefakt mrknutia	19
2.1	Hemodynamický model pre fMRI [28]	24
2.2	Zmeny v množstve ox-Hb a deox-Hb po neuronálnom stimule [27] . .	25
2.3	Hemodynamická odozva [27]	26
2.4	Priama úmernosť medzi vstupom a výstupom lineárneho systému [27]	26
2.5	Zobrazenie princípu superpozície [27]	27
2.6	Nelinearita signálu pri krátkych rozdielnych medzistimulových časoch [27]	27
2.7	Schéma blokového návrhu [30]	29
2.8	Schéma event-related návrhu [30]	29
2.9	Závislosť komponentov signálu ciev na sile stacionárneho magnetic- kého pola [27]	30
2.10	Závislosť BOLD signálu, šumu a SNR na sile stacionárneho magnetic- kého pola [27]	32
3.1	Maticový zápis obecného lineárneho modelu [32]	35
4.1	Blokový diagram EEG-fMRI analýzy s zameraním na predspracovanie EEG	41
5.1	Originálna podoba načítaných EEG dát, subjekt 2107	46
5.2	Podoba EEG dát po vynulovaní spektrálnych zložiek mimo pásma od 0,1 Hz do 40 Hz, subjekt 2107	47
5.3	Normalizovaná podoba EEG dát, subjekt 2107	48
5.4	Príklad morfológií elektród (Fz,FC2), ktoré boli určené na interpolá- ciu, subjekt 2201	49
5.5	Príklad abnormálnej elektródy (Fz) v topografickom zobrazení viace- rých komponentov, subjekt 2006	51
5.6	Príklad morfológie elektródy (Cz) určenej na interpoláciu, subjekt 1982	52
5.7	Signál z elektródy Cz pred a po sférickej interpolácií, subjekt 1982 . .	52
5.8	Topografické zobrazenie komponenty 14 a EEG signál pred (modrá) a po odstránení (červená) komponenty 14, subjekt 2159	53
5.9	Znehodnotenú EEG dáta, subjekt 1945	53
5.10	Topografické zobrazenie komponentov nebiologických artefaktov, sub- jekt 2194	54
5.11	Znehodnotenú EEG dáta, subjekt 2171	54

5.12	Komponenty z ICA SOBI dekompozície, subjekt 2028	55
5.13	Časový priebeh komponentov 4,8 a 12, subjekt 2028	56
5.14	Signál z elektródy FP1 pred a po odstránení komponenty 4, subjekt 2028	56
5.15	Aktivačná mapa relatívneho výkonu pre alfa pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne korelácie), subjekt 1973	57
5.16	Aktivačná mapa absolútneho výkonu pre gamma pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie), subjekt 2132	57
5.17	Aktivačná mapa skupinovej analýzy absolútneho výkonu pre delta pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)	57
5.18	Aktivačná mapa skupinovej analýzy absolútneho výkonu pre theta pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)	58
5.19	Aktivačná mapa skupinovej analýzy absolútneho výkonu pre alfa pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)	58
5.20	Aktivačná mapa skupinovej analýzy absolútneho výkonu pre beta pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)	58
5.21	Aktivačná mapa skupinovej analýzy absolútneho výkonu pre gamma pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)	59
5.22	Aktivačná mapa skupinovej analýzy relatívneho výkonu pre delta pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)	59
5.23	Aktivačná mapa skupinovej analýzy relatívneho výkonu pre theta pásmo, bez potlačenia vľavo, s potlačením vpravo. (negatívne korelácie)	59
5.24	Aktivačná mapa skupinovej analýzy relatívneho výkonu pre alfa pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne korelácie)	60
5.25	Aktivačná mapa skupinovej analýzy relatívneho výkonu pre beta pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)	60
5.26	Aktivačná mapa skupinovej analýzy relatívneho výkonu pre gamma pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)	60

ZOZNAM TABULIEK

5.1	Tabuľka interpolovaných elektród a čísiel odstránených komponentov každého subjektu	50
5.2	Tabuľka vyhodnotenia podobnostnými kritériami	51

ZOZNAM VÝPISOV

4.1	Kód skriptu SubjektspracGUI v prostredí Matlab.	42
4.2	Kód skriptu set2mat v prostredí Matlab.	42
4.3	Kód funkcie Podkrit v prostredí Matlab.	43


ÚVOD

Táto práca sa zaoberá oblasťou fúzie simultánne snímaných dát elektroencefalografie (EEG) a funkčnej magnetickej rezonancie (fMRI). Pričom sa zameriava na potlačenie artefaktu mrkania v dátach EEG a vyhodnotením jeho vplyvu na výsledky fúzných aktivačných máp. EEG predstavuje metódu merania zmien elektrického potenciálu pri činnosti mozgu. Voltmetrom alebo osciloskopom sa meria rozdiel elektrického napätia snímanom na elektródach z hlavy subjektu. Jej výstupom je 2D matica časového záznamu rozdielu napätia jednotlivých elektród voči referenčnej hodnote. Druhé dáta sú dáta z funkčného MRI (Magnetic resonance imaging), ktoré zaznamenávajú aktiváciu v určitej časti mozgu. Okrem popisu metodiky fúzie týchto dvoch odlišných záznamov mozgovej aktivity sa táto práca rozsiahlejšie venuje odstráneniu artefaktu mrkania z dát EEG cez vyššiu štatistickú metódu ICA (Analýza nezávislých komponentov - *Independent component analysis*). Tento artefakt je najviac náročný na odstránenie z dát EEG. Po potlačení artefaktu sa prevedie fúzia dát EEG s fMRI dátami v GLM (Všeobecný lineárny model - *General linear model*). Kde sa použijú EEG dáta v podobe modelových signálov ako tzv. regresory. Voxely fMRI dát budú pri štatisticky významnej korelácii na EEG regresor vyznačené ako aktivované. Vzniknuté aktivačné mapy sa budú počítať pre EEG regresory z dát EEG s a bez potlačenia artefaktu mrkania. Vyhodnotené boli odlišnosti medzi aktivačnými mapami s potlačeným artefaktom voči aktivačným mapám bez potlačeného artefaktu. Na vyhodnotenie boli použité zvolené podobnostné kritéria.

Prvá kapitola sa venuje teórii snímania a predspracovania EEG dát s rozpisom ICA metodiky pre potlačenie mrkancového artefaktu z EEG dát. Druhá kapitola uvádza základnú teóriu k fMRI spolu s metodikou predspracovania týchto dát. Tretia kapitola sa zaoberá popisom metodiky fúzie simultánnych EEG-fMRI dát pomocou obecného lineárneho modelu (GLM – general linear model), spolu s popisom následnej metodiky kvantifikácie rozdielu výsledku pri fúzii s a bez potlačenia mrkacieho artefaktu. V štvrtej kapitole sú popísané reálne dáta na ktorých je metodika testovaná a je navrhnuté riešenie na potlačenie artefaktu spolu s analýzou dát. V kapitole sú popísané funkcie a skripty písané v programovacom jazyku MATLAB, použité v procese celej analýzy [1]. V piatej kapitole sú výsledky jednotlivých fáz predspracovania dát a potlačenia artefaktu spolu s príkladom výsledku fúzie pre jednotlivca a všetkými výsledkami skupinovej analýzy. Šiestou kapitolou sú komentované dosiahnuté výsledky. Siedma kapitola je zhrnutím dosiahnutých cieľov práce v závere.

1 SKALPOVÁ ELEKTROENCEFALOGRAFIA


EEG je technika snímania elektrickej aktivity mozgu, ktorá vzniká prenosom nervového vzruchu medzi neurónmi. Má výborné časové rozlíšenie v rádoch niekoľkých ms, ale slabšie priestorové rozlíšenie v rozmedzí niekoľkých cm na skalpe hlavy [2]. EEG snímané na povrchu hlavy je nazývané skalpové a predstavuje základnú neinvazívnu modalitu pri neurologickej diagnostike. Na jeho meranie sa používa systém po hlave rozmiestnených elektród z Ag/AgCl alebo vzácnych kovov. Tie snímajú rozdiel elektrického potenciálu voči referenčnej elektróde v čase. Elektródy sú vsadené do tzv. elektródovej čapice, ktorá je nasadená na hlavu pacienta. V miestach kontaktu skalpu s elektródami bolo aplikované vodivé médium pre čo najmenší odpor pri meraní zmien elektrického potenciálu voči referenčnej hodnote [3].



Obr. 1.1: Medzinárodný systém uloženia elektród 10/20 pre 30 elektród [3]


1.1 Princíp EEG

Signál EEG je meraný z elektrickej činnosti rôznych častí mozgu, preto je jeho výsledná hodnota superpozíciou rady jednoduchších signálov. Hlavnou časťou elektroencefalografu je zosilňovač, ktorý zosilní elektrický signál z povrchu hlavy tlmený lebkou, kožou a vlasmi z hodnôt desiatok mikrovoltov na veľkosť vhodnú pre zobrazenie a ďalšie spracovanie. Tento zosilňovač má veľký vstupný odpor v rozmedzí desiatok $M\Omega$, jeho rozdielové zosilnenie býva rádovo 10^6 s minimálnym vlastným šumom a veľkou hodnotou CMR (*Common mode rejection ratio*). Ten predstavuje činiteľ potlačenia súhlasného rušenia ako bezrozmerná veličina (alebo v dB) charakterizujúca pomer zosilnenia diferenčného signálu voči súhlasnému signálu [3].



Obr. 1.2: Základní blokové schéma jedného kanálu elektroencefalografu [3]

Elektródy majú neustále meraný svoj prechodový odpor, ktorý je premenlivý. Pre získanie kvalitného neskresleného záznamu je potrebné, aby bola hodnota tohto odporu čo najviac stála. Preto sa meria aj počas merania EEG. Na meranie tohto odporu stačí ohmmeter, pri ktorom pacientom preteká striedavý prúd mimo kmitočtového pásma podstatných zložiek EEG signálu z dôvodu ovplyvnenia polarizácie elektród [3].



Obr. 1.3: Schématické zapojenie pre meranie odporu [3]

1.2 Pásma EEG

Medzi hlavné zložky EEG signálu patria takzvané mozgové vlny, ktoré sa delia podľa ich frekvencie na frekvenčné pásma δ (0.1 – 4 Hz), θ (4 – 8 Hz), α (8 – 12 Hz), β (12 – 20

Hz) a γ (20–40) Hz). Dnešný moderný neurologický výskum sa zaoberá vlastnosťami a pôvodom týchto vln, a hľadá korelácie medzi miestom ich vzniku s určitými centrami pre vyššiu nervovú činnosť. Morfológia vln jednotlivých pásiem je zobrazená na obrázku (1.4)[4].


Vlny δ má každý človek vo fázi hlbokého spánku. U dospelého človeka sú mimo spánku abnormálne. S amplitúdou v rozmedzí 10–300 μ V majú najvyššiu amplitúdu zo všetkých EEG vln [2]. Zdroj δ vln môže byť ohniskový, ale aj rozptýlený po celej hlave [5].

Vlny θ sú prítomné hlavne počas spánku u každého človeka nezávisiac na vekovom rozdiely. Amplitúda θ vln je pod 30 μ V [2]. Sú spájané s meditáciou. Počas bdlosti, sa pri určitých úlohách, úmerne k záťaži, zvýši ich výskyt v stredno frontálnej oblasti mozgu. Tieto činnosti sú napríklad sebapozorovanie, učenie informácie alebo záťažové využitie časti krátkodobej pamäti venujúcej sa okamžitému spracovávaniu informácií z reči a zmyslov, tzv. pracovnej pamäti [5][6].

Vlny α sú súčasťou EEG u každej vekovej skupiny, ale najčastejšie u dospelých jedincov. Hlavným zdrojom α vln je zadná časť hlavy, hlavne, ak má subjekt zatvorené oči a je v stave relaxácie. Ich bežnou amplitúdou je 50–100 μ V [2]. U zdravých jedincov α aktivita klesne javom tzv. '*event-related desynchronization*' (ERD) po začatí koncentrácie na akúkoľvek činnosť či už mentálnu alebo fyzickú. α aktivita s vysokou amplitúdou vzniká javom tzv. '*event-related synchronization*' (ERS). Tento jav je možné vyvolať vedomou inhibíciou zastaralej informácie z pracovnej pamäte, ktorá by svojou podobnosťou mohla zbytočne miasť, pri koncentrácii na súčasnú úlohu. Tento nárast je očividný hlavne v horných frekvenciách α pásma, a je úmerný záťaži kladenej na pamäť. Jediný prípad α vln patológie je u kómy spôsobenej krvácaním do mozgu. V tomto prípade sú snímané vlny uniformne v prednej aj zadnej časti hlavy u subjektu, ktorý nereaguje na podnety [5][7].

Vlny β sú u každej vekovej skupiny. Majú amplitúdu vo výške 10–20 μ V so symetrickou morfológiou [2]. Sú znakom intenzívnej mozgovej činnosti pri riešení problému. Ich zdroj býva hlavne v prednej časti hlavy. Sú ovplyvňované liekmi z rady barbiturátov a benzodiazepínov [5].

Vlny γ sú prítomné u každého človeka. Nemajú ale konkrétnu morfológiu a sú zaradené iba podľa frekvenčného pásma. γ aktivita je spájaná s pozornosťou, rozpoznávaním objektov a pracovnou pamäťou. Prejavuje sa pri činnosti integračného mechanizmu pre významové spájanie informácií, z viacerých zmyslov. To je dokázané poklesom amplitúd u jedincov s schizofréniou alebo Alzheimerovou chorobou a nárastom amplitúd u jedincov prežívajúcich halucinácie, epileptické záchvaty a trpiacich na ADHD [2][8][9].



Obr. 1.4: Pásma EEG vln

1.3 Artefakty EEG

Elektrody počas merania zaznamenávajú všetky rozdiely elektrického potenciálu voči referenčnej hodnote, čím sa k signálu z neurologickej aktivity mozgu pričítava aj šum z nechcených zdrojov. Vzniknutý šum u EEG delíme podľa pôvodu na artefakty z tela meraného človeka a z okolitého prostredia [10].

1.3.1 Artefakty prostredia

Najčastejším príkladom je neúplný kontakt elektródy s povrchom skalpu subjektu, čo sa prejaví ako náhla zmena amplitúdy signálu, vplyvom strmého nárastu impedance u konkrétnej elektródy. Ďalším artefaktom je 50 Hz brum zo siete, tomuto artefaktu predídeme správnym uzemnením, ale dá sa odstrániť nulovaním jeho zložky

v spektrálnej oblasti. Artefakty z prostredia môžu byť spôsobené aj pohybom v blízkosti elektród alebo vonkajšími elektrickými prístrojmi, preto je potrebné pri meraní minimalizovať pohyb a prítomnosť elektrických zariadení v okolí elektród [10].

1.3.2 Svalové artefakty

Myogénne potenciály patria medzi najbežnejšie EEG artefakty. Vznikajú hlavne pri zatínaní čeluste u frontálnych a temporálnych svalov. Majú špecifickú morfológiu, dĺžku a frekvenciu. U funkčných pohybových poruchách, ako Parkinsonová choroba a tras (z ang. *Essential tremor*), vzniká sinusoidný signál v medziach 4 – 6 Hz, ktorý sa môže podobáť na neurologickú činnosť. Na potlačenie sa dá využiť vlnkovo vylepšená ICA s adaptívnym filtrom [10][11].

Špeciálnym prípadom myogénneho artefaktu je jazykový artefakt, ktorý vzniká pohybom jazyka počas merania. Je spôsobený tým, že jazyk má vlastnosti dipólu. Špička jazyka je negatívne nabitá voči základni jazyka, čo sa pri pohybe prejaví šumom so širokým rozsahom. Dosahuje menších amplitúd a frekvenčne sa pohybuje v oblasti delta vln. Je častý u detí a pacientov trpiacich na demenciu [10].

1.3.3 EKG artefakt

Predstavuje zachytený EKG signál na EEG elektródach. Dá sa rozpoznať podľa synchronizácie s EKG signálom, konkrétne QRS komplexom, ktorý sa na EEG prejaví ostrým posunom hodnôt. Je problematický ak sa zároveň prekrýva s iným EEG artefaktom. Na jeho potlačenie sa využíva snímania EKG zároveň s EEG vyšetrením. Podľa EKG signálu odčítame jeho zložku z EEG signálu. Ďalšou možnosťou potlačenia je využitie tzv. *'average artifact subtraction'* (AAS) algoritmu [10].

1.3.4 Pulzný artefakt

U temporálnych elektród umiestnených na pulzujúcom telese (tepny) vznikajú pomalé vlny simulujúce EEG. Tieto pomalé pulzácie povrchu tela sú spôsobené mechanickou činnosťou srdca. Takže nasledujú 200 – 300 ms po QRS komplexe. Na jeho potlačenie sa používajú najčastejšie algoritmy AAS, *'optimal basis set'* (OBS) metóda a ICA [10][12].

1.3.5 Kožné artefakty

Produkty kožných žliaz alebo neuniformné zloženie kože spôsobené hematómom môžu spôsobiť lokalizovanú zmenu odporu, čo sa prejaví znížením amplitúdy EEG


signálu. Preto je potrebné dobré odmastenie kože a dostatočné množstvo aplikovaného vodivého média v kontakte s elektródami [10].

1.3.6 Respiračné artefakty

Sú spôsobené mechanickým pohybom pri dýchaní. Sú dva typy. Prvý sú pomalé rytmické pohyby súvisiace s pohybom tela, počas dýchania často ovplyvňujúce impedanciu jednej elektródy. Druhý je ak pacient počas merania leží, tak sú na elektródach pod pacientom zaznamenané rýchle a pomalé vlny, závisiace na pohybe subjektu pri nádychu a výdychu. Artefakt je možné potlačiť automatizovaným algoritmom na odstránenie artefaktov ako napríklad vlnková ICA [10][13].

1.3.7 Očné artefakty

Patria k nim artefakty z pohybu oka a artefakty žmurkania. Tieto artefakty sú netriviálne na zmeranie a modelovanie, lebo sú generované dvoma dištinktnými mechanizmami s veľmi rôznorodým vzorom propagácie naprieč skalpovým povrchom. Oko ako celok sa správa ako nabitý dipól s kladne nabitou rohovkou v prednej časti oka, oproti záporne nabitej sietnici v zadnej časti oka. V celku býva tento náboj v rozmedzí 4 – 10 mV v sume z oboch očí. Pri rotácii rohovko-sietnicovej osi sa mení orientácia tohto dipólu v 3D priestore, čo sa vo výsledku sa prejaví ako zmena meraného elektrického signálu pri pohybe oka. Artefakt žmurkania má pôvod v zmene vodivosti zapríčinennej dotykom očného viečka s rohovkou. Trvá zvyčajne 200 – 400 ms a má amplitúdu viac než 10 násobok bežného signálu mozgového pôvodu. Veľká časť signálu artefaktu zostáva na povrchových vrstvách tváre a hlavy a s rastúcou vzdialenosťou od očí rýchlo klesá. Napriek tomu majú oba signály artefaktov rozsiahle šírenie s dopadom na značnú časť elektród [14]. Obrázok (1.5) Príklad artefaktu mrkania na frontálnych elektródach, z použitých dát.



Obr. 1.5: EEG signál zobrazujúci artefakt mrknutia

1.4 Predspracovanie EEG

EEG dáta namerané počas simultánneho EEG-fMRI merania je potrebné predspracovať na získanie čistého signálu EEG vhodného na ďalšie spracovanie pre fúziu s fMRI dátami.

1.4.1 Odstránenie magnetického gradientu

Pri fMRI akvizícii dát sa na elektródach EEG indukuje tzv. artefakt magnetického gradientu z fMRI akvizície. Tento artefakt bol odstránený pomocou AAS algoritmu a následného adaptívneho filtrovania zvyškového šumu [15].

1.4.2 Odstránenie kolísania izolínie

Kolísanie izolínie je spôsobené zložením respiračných artefaktov a zlého kontaktu na elektródach vytvárajúce artefakty vo veľmi malých frekvenciách. Je odstránená potlačením prenosu veľmi nízkych kmitočtov nasnímaného signálu inak povedané filtráciou hornou priepustou [16].

1.4.3 Filtrácia pásmovou priepustou v rozmedzí 0,1-40 Hz

Následne je na signál aplikovaná filtrácia pásmovou priepustou v našom záujmovom rozsahu frekvencií EEG signálu. Získame tým dáta, obsahujúce iba vybrané frekvenčné pásma EEG vln, zvolených na analýzu a ďalšie spracovanie.

1.4.4 Normalizácia dát

Amplitúda EEG dát je rozdielna medzi subjektmi z rôznych príčin. Tu je normalizácia využitá na potlačenie efektu vzdialenosti od referenčnej elektródy pre všetky elektródy. V prípade tejto bakalárskej práce bol na normalizáciu dát použitý vzorec (1.1), kde $x(i)$ je prvok signálu, $\bar{x}$ jeho priemer a σ_x je jeho smerodajná odchýlka.

$$\frac{x(i) - \bar{x}}{\sigma_x} \quad (1.1)$$

1.4.5 Potlačenie artefaktu mrkania pomocou ICA

Na odstránenie artefaktu mrkania existuje viacero metód. Prvotné metódy boli analógového charakteru patril medzi ne napríklad Girtonov a Kamiyov výpočet korekčného koeficientu. Podstatou bolo odčítanie váhovaného EOG od EEG signálu. Analógové metódy ale v porovnaní s matematický založenými metódami poskytovali horšie výsledky. Preto boli analógové metódy nahradené dvomi matematickými

prístupmi. Prvým je regresná analýza využívajúca funkcie najmenších štvorcov. Tá je založená na výpočte odhadu propagačných koeficientov medzi jedným alebo viacerými EOG signálmi voči signálu každej EEG elektródy [17]. Druhým teoreticky odlišný prístup sú metódy založené na modely komponentov. Tie predstavujú jednotlivé nezávislé zložky signálu z ktorých sa dá daný artefakt odčítať v podobe komponentu a následne signál spätne reštaurovať. Regresné metódy boli porovnané s metódou analýzy nezávislých komponentov (ICA) a na základe výsledkov sa preukázala ICA ako lepšia metóda na supresiu mrkacieho artefaktu [18].

ICA patrí pod *Blind source separation* (BSS, slepá separácia zdrojov) štatistické metódy, ktorých funkciou je hľadanie jednotlivých zdrojov signálov v lineárnom zmesi na sebe nezávislých signálov. Na roztriedenie signálov využíva ICA ich lineárnu štatistickú nezávislosť. ICA pristupuje k dátam ako množine superpozícií viacerých nezávislých signálov snímaných na rôznych polohách. Výsledkom sú čo najviac od seba nezávislé komponenty jednotlivých zdrojov signálov s nulovou vzájomnou koreláciou. Počet komponentov je limitovaný počtom elektród, preto s počtom elektród stúpa schopnosť ICA oddeliť jednotlivé zdroje. V ICA maticovom zápise (1.2) predstavuje matica $\mathbf{X}$ namerané dáta, ktoré sú lineárnym mixom komponentov z matice $\mathbf{S}$ po vynásobení lineárnou mixovacou maticou $\mathbf{A}$ v rovnici (1.2)[19][20][21].

$$\mathbf{X} = \mathbf{A} \cdot \mathbf{S} \quad (1.2)$$

Tým, že ICA patrí pod BSS algoritmy, sú hodnoty iteračne získanej mixovacej matice ICA váh, približným odhadom inverznej matice $\mathbf{A}$ na základe zvoleného kritéria nezávislosti pre ICA. V praxi sa ako kritérium nezávislosti pri výpočte, používajú odhady maximálnej *mutual information* (MI), entropie alebo moment štvrtého rádu distribúcie *kurtóza*. Všetky kritériá určujú mieru negaussovosti dát. Inými slovami negaussovosť dát znamená nezávislosť, pretože podľa Centrálného limitného teorému má súčet dvoch nezávislých rád premenných distribúciu dát bližšiu ku Gaussovskej distribúcii ako jednotlivá nezávislá premenná [22]. Zo získanej mixovacej matice $\mathbf{A}$ počítanej pre maximálnu nezávislosť medzi komponentmi matice $\mathbf{S}$, sa inverzná matica $\mathbf{A}$ vynásobí s maticou dát $\mathbf{X}$ na získanie približnej odhadovanej matice komponentov $\mathbf{S}$ [20][23][24].

Výsledná matica komponentov $\mathbf{S}$ sa použije na potlačenie artefaktov z originálneho signálu EEG dát. Topografickým zobrazením výkonu komponenty v 2D rovine skalpu spolu s časovým priebehom danej komponenty sa dá klasifikovať pôvod jednotlivých komponentov. Hľadaný komponent obsahujúci mrkací artefakt má dominujúcu topografickú projekciu na frontálnej časti skalpu v okolí frontálnych elektród. Zároveň komponent má charakteristický repetitívny peak v časovej rade. Vynulovaním komponenty s týmito charakteristickými črtami sa dosiahne potlačenie

mrkacieho artefaktu. Spätným sčítaním komponentov vrátane vynulovaných komponentov sa získa EEG signál s potlačeným mrkacím artefaktom[14].

Pre túto prácu bol použitý ICA variant využívajúci algoritmus SOBI (*Second order blind interference*). SOBI využíva časovej koherencie zdrojov signálu na určenie $\mathbf{A}^{-1}$, a to cez spojitú diagonalizáciu teda minimalizáciu sumy odmocnín vzájomných korelácií medzi jedným komponentom v čase t a ďalším komponentom v čase $t + \tau$, počítaných pre viacero časových posunov τ (počet možných τ daný počtom komponentov) a pre všetky možné páry komponentov. Vzájomné korelácie sú citlivé na vnútorné časové vlastnosti časových rád, čo umožňuje separáciu zdrojov pomocou časovej informácie obsiahnutej v EEG signále [25][26].

2 FMRI


V dobe písania tejto práce nastáva rozmach neurovedného výskumu vďaka metóde fMRI, ktorá sa zameriava na funkčné snímky neurálnej aktivity v časovej oblasti. Táto metóda patrí pod modalitu zobrazovania pomocou nukleárnej magnetickej rezonancie (MRI), ktorá prináša vysoko kvalitné anatomické snímky s vynikajúcim rozlíšením. Využíva rozdiel v magnetických vlastnostiach atómov rôznych prvkov. Tie získajú v stacionárnom magnetickom poli MRI, vektor magnetizácie paralelný voči siločiarom stacionárneho magnetického pola MRI. Tým je vektor orientovaný do tzv. longitudálnej roviny. Na oblasť, zvolenú na zobrazenie, je aplikovaný radiofrekvenčný (RF) impulz. Atómy s rezonančnou frekvenciou na úrovni frekvencie RF impulzu, svojím magnetickým spinom prijímu energiu RF impulzu a tým otočia svoj vektor magnetizácie z longitudálnej roviny do roviny tranzverzálnej. Návratom do pôvodného stavu magnetizácie vzniká zmena v elektro-magnetickom poli, ktorá je merateľná ako elektrický signál, ktorý sa indukuje v merajúcich cievkach. Pozícia atómu je v signáli kódovaná v jeho frekvencií a fáze. Výsledkom je 2D matica komplexných signálov zvoleného excitovaného rezu v ktorej majú jednotlivé voxeli hodnoty sumy signálov ich vnútorných atómov [27].

2.1 Princíp fMRI založenom na BOLD signále

Meranie fMRI nesníma priamo neuronálnu aktivitu, ale z jej metabolizmu naväzujúcu hemodynamickú odozvu (HRF). Tá vyjadruje zmenu lokálnej koncentrácie okysličenej a neokysličenej krvi v mieste vzniku neuronálnej činnosti. HRF predstavuje výstup na hemodynamickom modeli po nadprahovej impulznej neuronálnej činnosti. Na obrázku 2.1 je $u(t)$ neuronálnou aktivitou, ktorá vyvolá zmenu v vazodilatačnom signály $s(t)$. Na to bude reagovať rastom krvný tok $f(t)$, čo ovplyvní zmenu krvného objemu $v(t)$ a v ňom koncentráciu deoxyhemoglobínu (deox-Hb) $q(t)$. Nelineárnou odpoveďou na tieto zmeny je BOLD (*blood oxygen level dependence*) signál $y(t)$, ktorého hodnoty v čase je možné snímať pomocou fMRI gradient echo (GE) alebo spin echo (SE) akvizície [28].

2.1.1 T_2^* čas tranzverzálnej relaxácie

Pri neuronálnej činnosti, ktorú definujeme ako vznik akčného potenciálu jednotlivých neurónov oblasti mozgu sa spotrebúva kyslík. Ten je využitý na energiu potrebnú pre navrátenie koncentrácií iónov do stavu, aby bol na membráne neurónu možný ďalší prenos nervového vzruchu. Táto spotreba kyslíka je merateľná MRI pretože neokysličená krv obsahuje deoxyhemoglobín, ktorý je paramagnetický a preto



Obr. 2.1: Hemodynamický model pre fMRI [28]

má nenulový magnetický moment. Zatiaľ čo oxyhemoglobín (ox-Hb) u okysličenej krvi má nulový magnetický moment a preto je diamagnetický. Výsledný rozdiel v ich magnetických vlastnostiach je 20%. To sa prejavuje vznikom lokálnych nehomogenít v stacionárnom magnetickom poli pri prítomnosti zvýšenej koncentrácie deox-Hb. Nehomogenita spôsobuje skracovanie T_2^* času relaxácie, ktorá je konštantou poklesu transversálnej magnetizácie atómu. Zmena T_2^* pri lokálnej nehomogenite je vyjadrená vzťahom (2.1) kde T_2 je čas poklesu transversálnej magnetizácie na 37% svojej hodnoty, γ je gyromagnetická konštanta je pomer medzi nábojom a hmotnosťou atómu, ΔB_0 predstavuje zmenu v stacionárnom magnetickom poli, z nehomogenity [27].

$$\frac{1}{T_2^*} = \frac{1}{T_2} + \gamma \cdot \frac{\Delta B_0}{\pi} \quad (2.1)$$

S nízkym T_2^* časom dochádza k zníženej intenzite signálu na T_2^* vážených snímkoch. Na základe týchto faktov sa využíva k záznamu prejavu neuronálnej aktivity BOLD signál, ktorý zaznamenáva zmeny pomeru koncentrácie ox-Hb voči deox-Hb v čase podľa zmeny T_2^* pre daný individuálny voxel [27].


2.1.2 Sekvencia pre BOLD fMRI

Na meranie fMRI využíva MR tomograf a T_2^* gradient-echo (GE) pulzné sekvencie. Sú založené na rýchlych zmenách gradientov po vyslaní excitačného impulzu. Dôležitými parametrami akvizície je repetičný čas (Time of repetition - TR) a snímkovací čas (Time of Echo - TE). TR predstavuje časový interval na snímanie celého 3D fMRI skenu v čase t a TE časový interval medzi impulzom a maximom snímaného indukovaného elektrického signálu, tzv. echo čas. Hlavnými variantmi GE sekvencie sú *echo-planar imaging* (EPI) a *spiral imaging*. Obe techniky majú vysokú rýchlosť

akvizície potrebnú pre získanie viacerých snímok počas jednej neurálnej aktivácie. Bežná doba celej akvizície je rádovo v stovkách ms až pár s. *Spiral imaging* používa oproti EPI, sínusoidné zmeny gradientov čo skracuje celkový čas akvizície oproti EPI času. Ale dáta je nutné navyše previesť do karteziánskeho priestoru. Finálna podoba dát je 3D priestorová matica s časovým záznamom zmien BOLD signálu v jednotlivých voxeloch [27].


2.1.3 Morfológia hemodynamickej odozvy

Na obrázku (2.2) je graficky znázornené ako ovplyvňuje neuronálna aktivita koncentráciu ox-Hb a deox-Hb. Koncentrácia deox-Hb dosahuje maxima po 2 s od stimulu s následným poklesom k minimu pri 6 s a návratu k pôvodným hodnotám pri 12 s. Ox-Hb odozva dosahuje vyššie hodnoty, ale nedáva špecifickú informáciu o mieste vzniku neuronálnej aktivity. Z toho dôvodu, lebo po stimulácii mozog rozsiahle prekrví okysličenou krvou viaceré oblasti, aby boli schopné okamžitej funkčnosti. Výsledný BOLD kontrast po neuronálnej aktivite sa tvorí z vyplavenia deox-Hb, ktorý potláčal signál [27].



Obr. 2.2: Zmeny v množstve ox-Hb a deox-Hb po neuronálnom stimule [27]


Podľa týchto časových zmien koncentrácií sa vytvára HRF, ktorá je navzorkovanou impulznou charakteristikou hemodynamického modelu. Tá ma zobrazenú morfológiu na obrázku (2.3). Na začiatku je vidieť pokles signálu tzv. *"initial dip"*. Predstavuje prvotnú metabolizáciu kyslíka v okolí aktivácie neurónu. Je zachytiteľná pri MRI s silnejším stacionárnym magnetickým polom. Nasleduje stúpanie k maximu v 5 s, potom signál poklesne v 10 s pod úroveň začiatočných hodnôt. Tento úsek je nazvaný *"undershoot"*, po ktorom sa signál vráti k pôvodnej kludovej línii. Je spôsobený tým, že návrat k pôvodným hodnotám u krvného toku je rýchlejší ako u cievneho objemu. Tým zostáva v krvi zvýšená hladina deox-Hb, ktorý znižuje BOLD kontrast [27].



Obr. 2.3: Hemodynamická odozva [27]

2.1.4 Linearita hemodynamickej odozvy


HRF sa prejavuje lineárne ako výstup voči stimulu, ktorý predstavuje aproximáciu Diracovho budenia vstupu daného systému. To znamená, že platia dva princípy lineárneho systému. Prvý princíp predpokladá, že výška vstupu je priamo úmerná výške výstupnej amplitúdy BOLD signálu. V prípade stimulu sa jedná o veľkosť kontrastu alebo intenzity. Grafické znázornenie je na obrázku (2.4) [27].



Obr. 2.4: Priama úmernosť medzi vstupom a výstupom lineárneho systému [27]


Druhým princípom je superpozícia. Ak sú dva stimuly dané v krátkom časovom

intervale začnú sa prekryvať a výstupom bude suma oboch výstupov, obrázok (2.5).



Obr. 2.5: Zobrazenie princípu superpozície [27]

Ale pri príliš krátkom intervale medzi stimulmi nastáva zníženie výšky amplitúdy ďalších neskorších výstupov, obrázok (2.6). Táto nelinearita je tzv. *"refractory efekt"* a jeho perióda je rôzna pre rozdielne časti mozgu a druhy stimulov. Silne sa prejavuje u krátkych stimulov a počíta sa s jeho prítomnosťou počas analýzy dát [27].



Obr. 2.6: Nelinearita signálu pri krátkych rozdielnych medzistimulových časoch [27]


2.2 Akvizícia BOLD signálu

2.2.1 Druhy experimentov

Experimenty fMRI by mali mať jasne interpretovateľný výsledok analýzy dát. V fMRI BOLD experimente predstavujú prezentované stimuly nezávislú premennú (*Independent variable* - IV) a BOLD signály zas závislú premennú (*Dependent variable* - DV). Testuje sa tzv. nulová hypotéza či zmeny IV budú mať za následok zmenu DV. Experiment má potvrdiť alebo zavrhnúť nulovú hypotézu. Tá predstavuje tvrdenie o stave, respektíve správaní vecí v reálnom svete. Nulovou hypotézou pre túto prácu je, že voxel fMRI dát, nie je korelovaný s neurálnou aktivitou zvoleného frekvenčného pásma vln EEG dát. Experiment musí mať aspoň 2 hodnoty IV aby bolo možné odmerať zmenu DV. Pre otestovanie hypotézy sa navrhne experiment v experimentálnej podmienke (*experimental condition* - Ex-con) a kontrolnej podmienke (*control/baseline condition* - C-con). Ex-con zahrňuje v sebe stimul alebo úlohu dôležitú pre test skúmanej hypotézy, kým C-con predstavuje štandard oproti, ktorému je/sú Ex-con porovnané. U týchto podmienok je potrebný minimálny počet tzv. "*confounding*" faktorov. Tie predstavujú parametre korelované s testovanou IV ale je možné ich oddeliť od nej inak navrhnutým experimentom. Aby sa zamietla možnosť že výsledok by mohol byť zapríčinený inou zmenou ako zmenou IV [27].


Sú 4 hlavné kategórie experimentov u fMRI. Delia sa podľa prezentácie stimulu na blokový, event-related (závislý na krátkom stimule), zmiešaný návrh a bez vonkajšej stimulácie (tzv. '*resting-state experiment*'). V blokovom návrhu (2.7) sa prezentuje zmena IV kontinuálne počas istej časovej periódy. To predstavuje jeden blok danej Ex-con. Počas merania sa striedajú viaceré druhy Ex-con blokov. Často sa používa tzv. "*null-task*" (nečinný) blok, počas ktorého nie je prezentovaný žiadny stimul danej IV aby sa odčítali od signálu centrá neurálnej činnosti aktívne v neprítomnosti stimulu. Tento typ návrhu je jednoduchý a efektívny s silnou odozvou a ľahkou interpretáciou výsledku. Sú vhodné na detekciu voxelov s silnou aktiváciou a dokážu identifikovať zmeny zapríčinené úlohami, ktorú subjekt vykonáva ako reakciu na stimul. Z dĺžky periódy stimulu IV môže vznikať heterogénna neuronálna aktivita obmedzujúca využitie blokového návrhu. Zároveň sa nedá využiť pre odhad aktivačného času v aktivovaných voxeloch.

U event-related návrhu (2.8) sú stimuly rôznych IV náhodne rozmiestnené s mezdistimulovým časom rôznej dĺžky. Umožňujú extrahovať morfológiu a načasovanie HRF z čoho sa odhadujú vlastnosti budiacej neuronálnej aktivity ako jej prechodnú aktivácia, načasovanie alebo prepojenia v skúmaných funkčných oblastiach mozgu. Používajú sa aj pre analýzu je tzv. "*event-related potential*" (ERP) predstavujúci priebeh aktivácie závislej na konkrétnom type stimulu. Nevýhodou u event-related



Obr. 2.7: Schéma blokového návrhu [30]

návrhu je nižšia celková amplitúda signálu, požadované veľké množstvo meraní a náročná analýza dát.




Obr. 2.8: Schéma event-related návrhu [30]

Zmiešaný návrh kombinuje prvky blokového a event-related návrhu. Dokáže rozlíšiť dlhodobú pretrvávajúcu aktivitu od prechodnej aktivity. Najdôležitejšia vec pri voľbe návrhu je či daný návrh umožňuje merateľný rozdiel v BOLD aktivácií pri manipulácii hodnoty IV [27].

2.3 Artefakty BOLD signálu

Nameraná zmena BOLD signálu počas merania je úplne malá v porovnaní s celkovou intenzitou signálu. Rozdiel medzi nameranými hodnotami počas kludu a maxima HRF je iba 5%. To vytvára problém ak dochádza k skresleniu signálu šumom. Samotný meraný BOLD signál je zložený z užitočnej zložky a šumu. Užitočná zložka je

tvorená HRF po neuronálnej aktivite vzniknutej ako reakcia na stimul. Šum predstavuje zmes pre experiment nepodstatných zmien v BOLD signály. Tieto skresľujúce zmeny majú viacero zdrojov s charakteristickými vlastnosťami. Na hodnotenie signálu sa používa pomer užitočnej zložky signálu voči šumu SNR (*signal to noise ratio*). Aby sa dosiahlo vyššej hodnoty BOLD signálu tak sa používa silnejšie stacionárne magnetické pole, ktoré umožňujú zlepšiť priestorové rozlíšenie zmenšením veľkosti voxelu pri zachovaní pôvodnej intenzity signálu. S väčším počtom voxelov na ten istý priestor, sa zlepši priestorová špecificita. Zároveň sa zvyšuje extra-vaskulárny komponent kapilárneho signálu, ktorý pochádza z miesta aktivácie. A potlačuje sa nadbytočný šumový signál z veľkých ciev, obrázok (2.9)[27].



Obr. 2.9: Závislosť komponentov signálu ciev na sile stacionárneho magnetického poľa [27]

2.3.1 Vnútorný tepelný šum

Tepelný šum vzniká z tepelného pohybu elektrónov v meranom priestore. Voľné elektróny si pri kolízii s atómom vymieňajú energiu. Pri vyšších teplotách systému sa zvyšuje počet kolízií a tým celkový tepelný šum. Je lineárny s priamou úmernosťou k sile stacionárneho magnetického poľa. Celková jeho intenzita sa odvíja od frekvenčného pásma a odporu detektorov signálu u MR tomografu. Preto sa hodnotia prístroje na základe ich "raw" SNR, kde sa počíta pomer intenzity signálu v meranom objekte k tepelnému šumu okolia [27].

2.3.2 Systémový šum

Sú to rôzne systémové odchýlky funkčných častí MR tomografu. Ako posunutá frekvencia excitačného pulzu, nehomogenity v stacionárnom magnetickom poli, časovo posunutá akvizícia. Najvýraznejšou zložkou je tzv. "scanner" drift. Je to postupná periodická zmena hodnôt do $5 \cdot 10^{-7}$ Tesla u intenzity v stacionárnom magnetickom poli [27].

2.3.3 Redundantná neuronálna aktivita


Patria sem rutinné neurálne aktivácie z bežnej činnosti mozgu nesúvisiace s experimentom. Subjekt počas merania prijíma a reaguje na podnety z prostredia merania. A ďalšie vnútorné mentálne procesy ako plánovanie činnosti po ukončení merania, vybavovanie si spomienok. Tieto neurálne aktivácie sústavne ovplyvňujú BOLD signál, preto je nevyhnutné dostať počas merania mozog do stavu vysokej aktivácie vhodnou úlohou [27].

2.3.4 Kogničná variabilita vo výkone úlohy

Príčinou je variabilita výkonu subjektu pri reakcii na stimul. Čím je úloha komplexnejšia tým bude variabilita väčšia. Hodnotí sa čas reakcie a odozvy. Čas reakcie pri úlohách, kde subjekt iba zareaguje na prítomnosť stimulu. Úlohy s časom odozvy vyžadujú navyše od subjektu spraviť úvahu o povahe stimulu. Preto sú dlhšie v porovnaní s časom reakcie. Správnosť odpovedí pri úlohách s odozvou sa často využíva pri vyhodnocovaní dát [27].

2.3.5 Fyziologický šum

Pohyb počas merania vyvolá priestorovú nestálosť nasnímaných dát pre každý individuálny voxel. Tento pohyb má viac zdrojov. Nestálosť tela živého organizmu aké má meraný subjekt vyplýva z toho že vykonáva rôzne sebaobstarávajúce procesy. Tie zapríčiňujú pohyb. Medzi tieto zdroje pohybu patrí mechanická činnosť srdca, dýchanie, pulz a mimovoľné fluktuácie krvného toku a objemu. Ďalšie fyziologické artefakty vznikajú pohybom subjektu pri reakciách na stimul alebo mimovoľne pri dlhých meraniach. Fyziologický šum tvorí najväčšiu zložku šumu u funkčného SNR, kde sa pre pomer využíva celkový šum. Funkčné SNR je hlavnou kvantitou na vyhodnotenie kvality signálu. Pre zlepšenie funkčného SNR sa zvyšuje sila stacionárneho magnetického pola. Ale fyziologický šum rovnako ako BOLD signál rastie kvadraticky so silou pola. To dáva asymptotický horný limit pre hodnoty funkčného SNR. Zobrazené na obrázku (2.10). Zmenšením veľkosti voxelu sa dá zvýšiť tento limit a tým využiť zisk signálu z vyššej sily pola [27].



Obr. 2.10: Závislosť BOLD signálu, šumu a SNR na sile stacionárneho magnetického poľa [27]

Pohyb hlavy ako objektu záujmu merania predstavuje najnáročnejší artefakt na odstránenie. Veľký pohyb spôsobuje až nezvratiteľné skreslenie dát. Pohyb nie je náhodný, ale často je korelovaný s činnosťou subjektu pri výkone úlohy. Ako nádech subjektu po stisnutí tlačidla odozvy v úlohe. Pohybom hlavy sa úplne zmení pôvod signálu v individuálnom voxel. To predstavuje veľký problém u funkčných snímkov v čase. Napríklad okrajový voxel so signálom z šedej hmoty bude po pohybe na mieste so signálom z mozgovomiešneho moku [27].

2.4 Predspracovanie BOLD signálu

Dáta získané v akvizícii je potrebné najprv predspracovať. Výstupom by mali byť dáta zbavené zbytočných častí signálu ako šum a redundantné aktivácie. Zároveň musí každý voxel individuálne zastupovať jednu unikátnu nemennú polohu v priestore časových funkčných snímkov. Po týchto úpravách sú dáta podrobené štatistickej analýze. Dobrým predspracovaním sa mohutne zvýši funkčné rozlíšenie v experimente [27].

2.4.1 Časová korekcia akvizície rezu

Pulzné sekvencie fMRI získavajú jednotlivé rezy postupne počas celého akvizičného času. Aby nedochádzalo k slabej excitácii susedného rezu sú jednotlivé rezy snímané s odstupom. Napríklad 1, 3, 5, 7, 9, 11, 2, 4, 6, 8, 10, 12. Táto metóda snímania sa nazýva *"interleaved"* akvizícia a používa sa vo väčšine fMRI meraní. To ale pri dlhých TR časoch spôsobí fázový rozdiel v získanej HRF. Pri TR o dĺžke 3 s by druhý rez mal oneskorenie 1, 5 s. Na korekciu sa využíva časová interpolácia využívajúca informácie zo susedných rezov. Ako funkcia interpolácie sa najčastejšie volí sinc funkcia [27].

2.4.2 Korekcia artefaktu pohybu hlavy

V meraní sa pohybom hlavy subjektu získajú snímky s mozgom v odlišných pozíciách. Cieľom korekcie je získanie série snímok, na ktorých je mozog vždy v rovnakom priestore. Priestorové zarovnanie obsahu dvoch snímok sa nazýva koregistrácia. Používajú sa tzv. *"rigid-body"* transformačné funkcie, ktoré majú predpoklad, že mozog a jeho tvar je nemenný. Tie pracujú s obsahom snímku tak, že ho postupne geometricky transformujú a približujú sa k obsahu referenčného netransformovaného fixného snímku. Nato využívajú dve transformácie v 3D priestore a to rotácia a translácia (posun). Parametre funkcií dvoch pohybov sú potom v transformácii použité na prevzorkovanie dát. Dáta sú následne priestorovo dointerpolované. Ako funkcia interpolácie sa používa sinc alebo priemer okolia. Potom sa vypočíta tzv. *"cost"* (chybová) funkcia. Tá predstavuje ako sa kvantitatívne zhoduje snímok s referenčným snímkom. Tento proces sa opakuje, kým nedosiahne *cost* funkcia jej globálneho minima, pri ktorom sú snímky zarovnané [27].

2.4.3 Koregistrácia fMRI a MRI

Snímky fMRI majú veľmi slabé priestorové rozlíšenie, preto sú koregistrované na anatomické MRI snímky. Tieto anatomické snímky sú merané tesne pred začiatkom fMRI akvizície a sú spravidla založené na T_1 čase. Ten predstavuje čas návratu 63% longitudálnej magnetizácie výsledné snímky majú vysoké priestorové rozlíšenie. Využívajú sa transformačné funkcie s *cost* funkciou založenou na princípe *"mutual information"* (vzájomnej informácii). Okrem translácie a rotácie sa používajú ďalšie lineárne geometrické transformácie (zväčšenie a zkosenie) [27].

2.4.4 Priestorová normalizácia

Tvar mozgu sa líši medzi subjektmi. Pre porovnávanie dát od viacerých subjektov je nutné snímky normalizovať. Jedná sa o typ koregistrácie, kde sa snímky líšia

samotným tvarom objektu. Snímky mozgu sú nelineárne a priestorovo variantne stláčané, natahované a ohýbané, aby boli zarovnané na jednotný tvar. Na to sú použité lineárno afinné a nelineárne transformačné funkcie. Toto prebieha v tzv. stereo-taxickom priestore. Je to precízny mapovací systém využívajúci 3D koordináty. Sú dva varianty Talaraichov a MNI (*Montreal neurological institute*) súradný systém. Talaraichov systém je založený na normalizácii na priestor nasnímaný z mozgu staršej ženy. MNI systém využíva na normalizáciu priemer priestoru z vyše 100 individuálov s optimalizáciou na Talaraichov systém [27].

2.4.5 Časová filtrácia

Použitie časovej filtrácie zvyšuje kvalitu fMRI dát zvýšením funkčného SNR. Používajú sa filtre dolná a horná priepust. Horná priepust filtruje nízkofrekvenčný fyziologický a systémový šum. Ako štandard sa na výpočet medznej frekvencie, často používa násobok periódy odozvy na úlohu. Dolná priepust filtruje frekvenčné zložky s vyššou frekvenciou ako odozva na úlohu. Tým je rôzny fyziologický šum z mechanických oscilácií pri dýchaní ($0,2 - 0,3$ Hz) a činnosti srdca ($1 - 1,5$ Hz). Je dôležité aby filter nepotláčal frekvencie, na ktorých sa vyskytuje HRF z reakcie na stimul [27].

2.4.6 Priestorová filtrácia

Priestorové filtre typu dolná priepust sú použité na vyhladenie 3D priestorových dát každého funkčného snímku. Prevažne sa používa Gaussov filter, ktorý rozloží intenzitu každého voxelu na k nemu susedné voxeli. Šírka filtru rozhoduje medzi koľko voxelov sa rozloží intenzita jedného voxelu. Kvantifikuje sa tzv. "FWHM" (*full width half maximum*) parametrom, ktorý má zvyčajne veľkosť 6 až 10 mm. Ten zodpovedá šírke filtru v polovici maxima. Dáta po filtrácii majú lepšie funkčné SNR a normalitu vhodnú pri analýze dát, vhodné hlavne pre detekciu signálu v oblastiach nízkeho funkčného SNR, kde by bez použitia priestorovej filtrácie nedošlo k detekcií (napr. oblasť s vaskulárnou malformáciou) [27].

3 FÚZIA FMRI A EEG DÁT

3.1 Obecný lineárny model


Po predspracovaní dát fMRI sú dáta analyzované technikou mnohonásobnej lineárnej regresie v obecnom lineárnom modeli (GLM, *general linear model*). Ten má rovnicu (3.1). Hlavnou myšlienkou regresie je, že sa dá nameraný signál y rozložiť na lineárnu kombináciu n zdrojov a šumu. Lineárnu zmes modelových signálov tzv. regresorov x_i každý s vlastnými váhami β_i . Jednotlivé váhy udávajú akou veľkosťou ich regresor prispieva k celkovej variabilite signálu. Zvyšným signálom je reziduálny šum respektíve chyba merania ϵ . Váha β_0 obsahuje všetky zložky signálu, ktoré boli v meraní konštantné. GLM počíta β_i váhy pre každý voxel tak aby sa minimalizoval výkon reziduálneho šumu ϵ [27][31].

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon \quad (3.1)$$

Dáta fMRI majú 4D rozmer, v podobe 3D priestorovej matice s časovým priebehom BOLD signálu pre každý voxel matice. Preto sa pri ich použití v GLM 2D maticovom zápise (3.2), musí ich podoba upraviť. Voxeli 3D priestoru sú konkatenáciou rozložené vedľa seba a tvoria stĺpce v matici $\mathbf{Y}$ kde riadky predstavujú čas. Tým vyjadruje každý riadok celkové dáta získané behom jednej akvizície. Šumová matica ϵ reprezentuje v rovnakých rozmeroch šum v meraní. Matica regresorov $\mathbf{X}$ má za stĺpce jednotlivé regresory s ich časovým priebehom v riadkoch. Matica β váh má za riadky indexy regresorov s ich konkrétnymi váhami pre každý voxel v odpovedajúcom stĺpci [32].

$$\mathbf{Y} = \mathbf{X}\beta + \epsilon \quad (3.2)$$

Grafické vyobrazenie maticového zápisu rovnice (3.2) je na obrázku (3.1).



Obr. 3.1: Maticový zápis obecného lineárneho modelu [32]

Na ukončenie výpočtu pri nájdení minima šumovej matice ϵ sa štandardne používa váhovaná metóda najmenších štvorcov (wLMS - *weighted least mean square method*). Rovnica (3.3) popisuje výpočet maticového zápisu GLM metódou wLMS [29].

V nej $\sum_{\epsilon}$ predstavuje kovariačnú maticu reziduálnej matice ϵ . Algoritmus wLMS sa odhaduje optimalizačným ReML algoritmom [41].

$$\beta = (X^T \sum_{\epsilon}^{-1} X)^{-1} X^T \sum_{\epsilon}^{-1} Y \quad (3.3)$$

Hodnoty v získanej matici β váh predstavujú akou mierou je každý regresor časťou celkových dát, pre každý voxel, po manipulácii IV [27]. Na interpretáciu výsledkov je potrebné previesť test štatistickej významnosti pre individuálny voxel. Nulová hypotéza je že voxel nie je korelovaný s regresorom. Hladina štatistickej významnosti je daná prahom p . Voxel, u ktorého je zamietnutá nulová hypotéza (nad prahová hodnota), je označený ako štatisticky významná aktivácia na záujmový regresor. Farebne vyznačené aktivované voxeli tvoria aktivačnú mapu štatisticky významných aktivácií. Používajú sa dva druhy testov F-test a t-test. F-test sa používa pre zložitejšie modely s viac než jedným regresorom. Táto BP bude využívať t-test kde sa hodnota štatistickej významnosti pre voxel počíta v rovnici (3.4). Tá sa skladá zo súčinu transponovaného vektora kontrastu c^T , definujúci regresory záujmu a vzťah medzi nimi, s hodnotami β váh voxelu z GLM, vydelený rozptylom chyby σ_{ϵ} , v matici reziduálneho šumu ϵ [32][31].

$$t = \frac{c^T \beta}{\sigma_{\epsilon}} \quad (3.4)$$

3.2 Výpočet regresorov na fúziu dát z EEG

Jeden z variantov fúzie simultánnych EEG-fMRI dát je založený na využití EEG regresorov pre GLM. Predspracované EEG dáta sú segmentované na epochy o dĺžke TR. Následne sú epochy signálu transformované do spektrálnej oblasti diskretnou Fourierovou transformáciou (DFT)(3.5) [4]. V nej X_k predstavuje k -tý prvok epochy v spektrálnej oblasti, x_n je n -tý prvok epochy v časovej oblasti, N je počet prvkov epochy.

$$X_k = \sum_{n=0}^{N-1} x_n \cdot e^{\frac{-i2\pi kn}{N}} \quad (3.5)$$

Vyberie sa záujmové frekvenčné pásmo a zvyšné frekvenčné zložky sú odfiltrované nulovaním spektrálnych čiar mimo frekvenčné pásmo záujmu. Podľa vzťahov (3.6)(3.7) sú vypočítané absolútne a relatívne výkony frekvenčného pásma každej epochy. Vektor $\mathbf{F}_{\text{zero}}$ je filtrovaná epocha v spektrálnej oblasti a vektor $\mathbf{F}$ je nevyfiltrovaná. $\mathbf{F}_k$ a $\mathbf{F}_{k-\text{zero}}$ sú hodnoty výkonu spektrálnych čiar na k -tej frekvencii. k má frekvenčný rozsah záujmového pásma od 0 do 40 Hz (0 do N) [4][31].

$$P_{abs} = \frac{\sum_{k=1}^N |\mathbf{F}_{k-\text{zero}}|^2}{N} \quad (3.6) \quad P_r = \frac{P_{abs} \cdot N}{\sum_{k=1}^N |\mathbf{F}_k|^2} \quad (3.7)$$

Pre presnejšie hodnoty výkonu môže mať signál časové okno na výpočet výkonu menšie než TR. Výkon epochy je nakoniec vypočítaný ako vážený priemer výkonov z týchto okien. Táto operácia ale nemá podstatný vplyv na zmenu finálnych skupinových výsledkov fúzie [4][32]. Zloženým hodnôt z jednotlivých epoch signálu vzniká výsledný vektor fluktuácií výkonu záujmového frekvenčného pásma v celkovom signále. Tento vektor vstupuje do konvolúcie (3.8) s kanonickou HRF, $\mathbf{P}$ je vektor zmien výkonu a $\mathbf{g}$ je kanonická HRF. Kanonická HRF je idealizovaným výstupom na hemodynamickom modeli (2.1) ako odpoveď na záujmový podnet. Vo fyzikálnej rovine to predstavuje idealizovaný priebeh BOLD signálu, vzťahujúci sa na zmenu v magnetickom poli, priamo úmernú zmene pomeru okysličenej krvi, v mieste vyvolanej neurálnej aktivácie na záujmový podnet. V konvolúcii sa podľa vektoru fluktuácií $\mathbf{P}$ namodeluje cez vektor HRF v podobe $\mathbf{g}$, hľadaný modelový signál - EEG regresor. Sú odstránené hodnoty o dĺžke impulznej charakteristiky mínus jeden vzorok, zo začiatku signálu, ktoré vznikli ako následok konvolúcie. A regresor je ešte normalizovaný výrazom (3.9) kde je $\mathbf{P}_{N(0,1)}$ regresor po normalizácii, hodnota regresoru $\mathbf{P}$, priemer regresoru $\mu \mathbf{P}$ a $\sigma \mathbf{P}$ smerodajná odchýlka regresoru [4][31].

$$(\mathbf{P} * \mathbf{g})(t) = \int_{-\infty}^{\infty} P(t)g(\tau - t)d\tau \quad (3.8) \quad \mathbf{P}_{N(0,1)} = \frac{\mathbf{P} - \mu \mathbf{P}}{\sigma \mathbf{P}} \quad (3.9)$$

3.3 Skupinová analýza dát

Na porovnanie dát každého subjektu sa použije jednovýberový t-test. V jeho rovnici 3.10 predstavuje $\mathbf{c}^T$ transponovaný vektoru kontrastu, $\hat{\beta}$ odhadované hodnoty váh voxelu a $\sigma_{(\mathbf{c}^T \hat{\beta})}$ je smerodajnou odchýlkou prvých dvoch premenných. Testuje sa u každého subjektu 3D aktivačná mapa štatistickej významnosti sledovanej korelácie EEG regresoru voči BOLD signálu. Výsledkom je jedna 3D aktivačná mapa pre všetky subjekty experimentu, zobrazujúca štatisticky významné sledované korelácie EEG regresoru voči BOLD signálu [27][4].

$$t = \frac{\mathbf{c}^T \hat{\beta}}{\sigma_{(\mathbf{c}^T \hat{\beta})}} \quad (3.10)$$

3.4 Metodika porovnávania podobností viacrozmerých signálov

Na kvantitatívne vyhodnotenie podobnosti 3D aktivačných máp, sú používané podobnostné kritéria. Pre túto BP budú použité kovariancia (3.11), Pearsonov korelačný koeficient (3.12), euklidovská vzdialenosť (3.14) a kosínove kritérium (3.13). Aktivačné skupinové 3D mapy z rôznych nastavení parametrov fúzie EEG-fMRI dát,

sú prevedené do 1D vektorov, ktoré sú v dvojiciach porovnané, variantom podobnostného kritéria, pre dva 1D vektory. Kvantifikovaná bude hlavne rozdielnosť pre nastavenia analýzy bez a s použitím potlačenia mrkania zo surových EEG dát. V rovniciach predstavujú $\mathbf{x}$ a $\mathbf{y}$ 1D vektory, x_i a y_i ich i -té prvky, $\bar{x}$, $\bar{y}$ priemeru a $\sigma_{\mathbf{x}}\sigma_{\mathbf{y}}$ ich smerodajné odchýlky.

$$cov(\mathbf{x}, \mathbf{y}) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) \quad (3.11) \qquad R = \frac{cov(\mathbf{x}, \mathbf{y})}{\sigma_{\mathbf{x}}\sigma_{\mathbf{y}}} \quad (3.12)$$

$$K_{cos} = \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} \sqrt{\sum_{i=1}^n y_i^2}} \quad (3.13) \qquad E_d = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.14)$$

4 METÓDY

4.1 Simultánne EEG-fMRI dáta

Boli merané zo skupiny subjektov predstavujúcu 42 zdravých individuálov, zloženej z 24 mužov (2 ľaváci) a 18 žien. Vekový priemer skupiny bol 25 ± 5 rokov. Jedinci podstúpili sémantickú blokovú úlohu.

4.1.1 Semantic decision úloha

Cieľom úlohy bolo vyvolať silnú aktiváciu v oblastiach súvisiacich so spracovávaním jazyka. Úloha mala blokový návrh so striedajúcimi sa medzi tzv. "baseline" (izolínia) blokmi a aktívnymi blokmi. Stimul aktívneho bloku bol prezentovaný vizuálnou scénou, ktorá obsahovala vetu. Vety buď mali, alebo nemali v sebe významový nonsens, ktorý zároveň znel foneticky približne ako významovo správna veta (Nesprávne - cat was chased by a fog, Správne - cat was chased by a dog). Stimulom izolínneho bloku boli reťazce písmen X alebo O (Xxxx xxx xx xxxx, Ooo ooooo oo). Každý blok trval 24 s a mal 6 stimulov, ktoré trvali 3,5 s v bielom fonte na čiernom pozadí a zakončením stimulu bolo 0,5 s čiernej obrazovky. Subjekt mal pozorne si prečítať stimul a pri nonsense alebo reťazcoch O stlačiť tlačidlo v pravej ruke [34][35][36].

4.1.2 Akvizícia EEG dát a ich čiastočné predspracovanie

Dáta boli snímané vzorkovacou frekvenciou 5 kHz, pomocou 30 elektródového MR kompatibilného 10/20 EEG systému (Brain-Products, Nemecko). Referenčná hodnota bola priemer z Fz a Cz elektród. Ďalšími piatimi elektródami sa merali elektrookulografia (EOG), EKG (1 unipolárna, 2 bipolárne) a signál z akcelometru (sníma pohyb v 3D priestore) na hrudníku subjektu. Rozlíšenie EEG elektród bolo 0,5 μ V a zvyšných 10 μ V. Dáta boli predspracované nasledovne: artefakt gradientu sa odstránil metódou kumulačnej subtrakcie [15], dáta boli podvzorkované na 250 Hz a EKG artefakt bol odstránený pomocou signálu z EKG elektród, metódou subtrakcie pulzného artefaktu [33]. Na toto predspracovanie bol použitý softvér *BrainVision Analyser 2.0* (BrainProducts, Nemecko) [34][35][36].

4.1.3 Akvizícia fMRI dát a ich predspracovanie

Na meranie fMRI dát bol použitý 1,5T *Siemens Symphony* MR tomograf. Bola použitá pulzná sekvencia GE s technikou snímania dát EPI. Parametre akvizície funkčných snímkov boli 230 funkčných snímkov, 20 tranzverzálnych rezov na 1 3D sken, TR = 1850 ms, TE = 40 ms a veľkosť voxelu 3,9 x 3,9 x 6 mm³. Parametre


anatomických T_1 vážených snímkov boli 160 snímkov sagitálneho rezu, $TR = 1700$ ms, $TE = 3,96$ ms a hrúbka rezu 1,17 mm. Dáta boli kompletne predspracované na princípe metód popísaných v podkapitole 2.4 [34][35][36].

4.2 Návrh metodiky analýzy dát

4.2.1 MATLAB spracovanie

EEG dáta s hlavičkou obsahujúcou informácie o elektródach sú načítané do toolboxu EEGLab z formátu .dat a .vhdr [40]. Na načítanie dát sa použije *BrainVision* rozšírenie pre EEGLab toolbox [37]. Načítajú sa iba dáta z EEG elektród. Potom sú potlačené filtráciou v spektrálnej oblasti frekvenčné pásma pod 0,1 Hz a nad 40 Hz. Dolná medzná frekvencia je zvolená tak, aby sa zachovalo záujmové δ pásmo [38]. Zároveň sa odstráni nízko-frekvenčná zložka kolísania izolínie. Následne sú dáta normalizované podľa vzťahu (1.1). Tieto procesy sú spravené vlastným naprogramovaným skriptom SubjektspracGUI v MATLABe [1]. Na potlačenie artefaktu bol zvolený ICA variant algoritmus SOBI (*Second order blind inference*) [39][14]. Spraví sa prvý výpočet ICA komponentov. Časový priebeh signálu elektród je zobrazený a vizuálne skontrolovaný. Vyradia sa signály, ktoré vykazujú známky zlého kontaktu danej elektródy a skalpu. A zároveň sa manuálne vyradia signály elektród, ktoré vykazujú izolovanú abnormálnu aktivitu pri topografickom zobrazení, u viacerých komponentov. Na ich miesto je dointerpolovaný signál z okolitých elektród. Odstránia sa komponenty izolovaných nebiologických artefaktov. Následne sa spraví druhý výpočet ICA komponentov. V tejto fáze predspracovania sa uloží kópia EEG dát. Vizuálnou kontrolou časového priebehu komponentov a ich topografických máp, zobrazujúcich výkonové rozloženie komponenty na skalpe, sa manuálne odstránia komponenty artefaktu mrkania a EEG dáta sú spätne reštaurované do priestoru elektród bez komponentov obsahujúcich variabilitu mrkania. Tieto procesy sú robené v grafickom rozhraní EEGLab toolboxu s využitím jeho funkcií. Z výsledných predspracovaných dát a ich kópie s nepotlačeným artefaktom, sú vypočítané EEG regresori. Regresori potom vstupujú spolu s predspracovanými dátami fMRI do fúzie v GLM. Tým sa získa aktivačná mapa záujmového EEG regresoru jedného subjektu pre jedno konkrétne nastavenie analýzy. Zo získaných aktivačných máp všetkých subjektov sa spraví skupinová analýza jednovýberovým t-testom, ktorej výstupom je spoločná aktivačná mapa subjektov. Na výpočet regresorov je použitý EEG Regressor Builder rozhranie s využitím SPM8 knižníc pre fúziu a SPM12 knižníc pre skupinovú analýzu [4][32]. Podobnostné kritéria sú použité na vyhodnotenie rozdielu získaných spoločných aktivačných máp záujmových EEG regresorov s ICA a bez ICA odstránenia artefaktov. Vyhodnotenie je spravené vlastnými naprogramovanými skriptami.

movanými skriptmi v MATLABe. Bloková schéma celkového spracovania dát je na obrázku (4.1).



Obr. 4.1: Blokový diagram EEG-fMRI analýzi s zameraním na predspracovanie EEG

4.2.2 Naprogramované funkcie a skripty

Skript `SubjektspracGUI` umožňuje užívateľovi pri načítaní dát do EEGLab toolboxu ich vyfiltrovať a normalizovať. Skript zdefinuje známu vzorkovaciu frekvenciu 250 Hz a vypočíta z nej spolu s načítanými dátami frekvenčnú os. Tá spolu s dátami slúži ako vstupy pre funkcie. Všetky signály z 30 elektród sú vyfiltrované nulovaním spektrálnych čiar mimo záujmového pásma 0,1 až 40 Hz. Potom sú signály normalizované (vzťah 1.1) a uložené naspäť do dát EEGLab toolboxu. Kód skriptu je na výpise (4.1).

Skript `set2mat` uloží dáta z ALLEEG štruktúry EEGLabu, obsahujúce EEG signály všetkých načítaných datasetov. To spraví pomocou premennej `Sindex` predstavujúcu stĺpec riadkov char premenných obsahujúcich štvorčíslica indexu jednotlivých

Výpis 4.1: Kód skriptu SubjektspracGUI v prostredí Matlab.

```

1 Fs=250;
2 f_os = linspace(0,Fs,size(EEG.data,2));
3 for i=1:30
4     sch=fft(EEG.data(i,:));
5     sch(f_os<0.1|f_os>40)=0;
6     EEG.data(i,:)=real(iffth(sch));
7     EEG.data(i,:)=(EEG.data(i,:)-mean(EEG.data(i,:)))...
8         /sqrt(var(EEG.data(i,:)));
9 end

```

subjektov, podľa ktorých nazve súbory ukladajúce sa do .mat formátu.

Výpis 4.2: Kód skriptu set2mat v prostredí Matlab.

```

1 for i=1:length(Sindex)
2     savename=['S',Sindex(i,:), 'data.mat']
3     udata=ALLEEG(i).data;
4     save(savename, 'udata')
5 end

```

Funkcia Podkrit kvantifikuje rozdiel medzi aktivačnými mapami skupinovej analýzy, v podobe hodnôt podobnostných kritérií. Jej vstupmi sú adresáre zložiek dvoch porovnávaných výsledkov skupinovej analýzy. Z týchto zložiek sú načítané skupinové mapy do MATLABu a skonkatenované do 1D vektorov. Dva vektory sú vzájomne porovnané podobnostnými kritériami a výsledky porovnania predstavujú výstup funkcie.

4.2.3 Použité funkcie iných knižníc

Z knižnice EEGLab je použitých celkovo 10 funkcií. Funkcia eeglab na spustenie GUI EEGLabu. Funkcia pop_loadbv() na načítanie EEG dát. Jej vstupmi sú cesta a názov zložky s dátami s možným nastavením výberu konkrétnych kanálov a časti signálu. A výstupom je štruktúra s EEG dátami a informáciami k nim nazývaná dataset. Funkcia pop_newset() slúži na editáciu údajov štruktúry, pri načítaní dát vyzve užívateľa k názvu datasetu konkrétnych dát. Funkcia pop_runica() spraví ICA dekompozíciu na dátach datasetu. Má možnosť voľby ICA algoritmu vrátane parametrov jeho prevedenia a možnosť výberu signálu konkrétnych elektród na ICA dekompozíciu. Funkcia pop_interp() dointerpoluje EEG signál jednej elektródy z ostatných elektród. EEGLab má na výber intepoláciu planárnu a sférickú. Funkcia eegplot() zobrazuje

Výpis 4.3: Kód funkcie Podkrit v prostředí Matlab.

```
1 function [cov,PKK,Eu,Ks] = Podkrit(dir1,dir2)
2 OldFolder=cd(dir1)
3 V1 = niftiread('spmT_0001.nii');
4 Vektor=[];
5 for o=1:size(V1,3)
6     for i=1:size(V1,2)
7         Vektor=[Vektor,V1(:,i,o)'];
8     end
9 end
10 x=Vektor;
11 cd(dir2)
12 V2 = niftiread('spmT_0001.nii');
13 Vektor=[];
14 for o=1:size(V2,3)
15     for i=1:size(V2,2)
16         Vektor=[Vektor,V2(:,i,o)'];
17     end
18 end
19 y=Vektor;
20 cd(OldFolder)
21 cov=sum((x-mean(x)).*(y-mean(y)))/length(x);
22 PKK=cov/(std(x)*std(y));
23 Eu=sqrt(sum((x-y).^2));
24 Ks=sum(x.*y)/(sqrt(sum(x.^2))*sqrt(sum(y.^2)));
25 end
```


časový priebeh signálov alebo komponenty. Funkcia `pop_spectopo()` zobrazí amplitúdové spektrum signálu alebo komponenty. Funkcia `pop_topoplot()` zobrazí mapy výkonového rozloženia signálu alebo komponenty na skalpe. Funkcia `pop_subcomp()` umožňuje odstrániť vybrané komponenty, zároveň má možnosť výberu ktoré komponenty uchovať, v prípade, že by sa odstraňovali skupiny komponentov. Funkcia `pop_saveset` uloží dataset v `.set` formáte [40].

Zo základných MATLAB funkcií sa používa `mean()`, `var()`, `sqrt()` na výpočet normalizácie. A `fft()` s `ifft()` na získanie spektra signálu a jeho spätnú reštauráciu pri nulovaní nezáujmových zložiek spektra.

Z SPM8 knižnice boli využité funkcie na fúziu dát v GLM. Funkcie boli použité v EEGRegressor Builder rozhraní [41].

Z SPM12 knižnice bola využitá funkcia `spm_jobman` na skupinovú analýzu dát. Táto funkcia má na starosti kompatibilitu medzi SPM a `matlabbatch` formátom, v ktorom sú načítané aktivačné mapy subjektov [42].

4.3 Predspracovanie dát

Pred použitím dát v práci boli dáta už predspracované (fMRI) alebo čiastočne predspracované (EEG). Spravené kroky sú popísané v 4.1.3 a 4.1.2. EEG dáta sú predspracované podľa 4.2.1. Vypočíta sa ICA s nastavením SOBI algoritmu, a tým sa získa ICA mixovacia matica $\mathbf{A}$. To umožňuje získanie matice komponentov $\mathbf{S}$, po vynásobení matice dát $\mathbf{X}$ inverznou maticou $\mathbf{A}$, podľa vzťahu 1.2. Algoritmus má parametre nastavené na default hodnoty, pričom parameter 'Extended' je defaultne nastavený na hodnotu 1, a tým sa bude algoritmus snažiť nájsť subgausovské komponenty. Odstráni sa komponenty nebiologické pre EEG. A sféricky sa dointerpolujú zlé signály na jednotlivých elektródach. Sférická interpolácia bola zvolená oproti planárnej lebo dosahovala interpolácie podobnejšej biologickému EEG signálu. Pri veľmi rozsiahlom znehodnotení dát sa vyradí dataset subjektu z analýzy. Následne sa s rovnakým nastavením zopakuje na dátach ICA SOBI dekompozícia. Tento proces sa spraví pre dataset každého subjektu. V tomto stave sa jednotlivé datasety subjektov obsahujúce mixovacie matice na získanie komponentov uložia ako `.set` súbor. Vytvorí sa sada kópií súborov datasetov. V jednej z dvoch identických sád datasetov sa odstráni komponenty artefaktu mrkania. Do premennej `Sindex` sa uložia indexy subjektov ktorých datasety boli použité. V skripte `set2mat` sa táto premenná použije na získanie predspracovaných EEG dát jednotlivých subjektov vo formáte `.mat`, obsahujúcich iba signál z 30 elektród. Tento krok sa spraví pre obe sady datasetov.

4.4 EEG-fMRI analýza

Pre použitie EEG dát na fúziu v EEGRegressor Builder rozhraní, sa vytvorí pre EEG dáta všeobecná hlavička v súbore `hdr.mat`, z ktorej sa pri analýze využije informácia o vzorkovacej frekvencii signálu a označenia jednotlivých elektród. Vytvorenie regresorov EEG pre vybrané pásmo EEG vln a fúzia s fMRI dátami v GLM, sa spraví pre každého subjektu naraz, v batch skripte využívajúci batch mód EEGRegressor Builder rozhrania [32]. A to s nasledujúcimi parametrami, pre 30 záujmových elektród, $TR = 1.85$ sekundy, s konvolúciou pre validný počet prvkov, obdĺžnikové váhové okno, všetky regresory pre všetky pásma záujmu v jednom batch súbore, s nahratím fMRI dát do batch súboru, s vytvorením zložky s výsledkom, spočítaním kompletnej EEG-fMRI analýzy, s názvom zložiek fMRI dát 'FCNI' a fMRI snímky začínajúce na 'swuf', použitie pohybových regresorov, s použitím pozitívneho $[1 \ 0]$ a negatívneho $[-1 \ 0]$ kontrastu, pre absolútny/relatívny výkon, s pásmovou priepustou od 0, 1 do 40 Hz, s časovým oknom na výpočet výkonu $TR/2$. Toto nastavenie výpočtu regresorov frekvenčných pásiem a EEG-fMRI analýzy bolo použité pre všetky samostatné frekvenčné pásma EEG vln (podkapitola 1.2) a pre absolútny aj relatívny výkon. V tomto procese boli EEG dáta subjektov v `.mat` formáte načítané spolu s hlavičkou `hdr.mat` na vytvorenie EEG regresorov podľa podkapitoly 3.2. A to s časovým oknom na výpočet vektoru fluktuácií výkonu $TR = 1.85$ sekundy, s konvolúciou toho to vektoru s kanonickou HRF pre validný počet prvkov, s frekvenčným rozsahom epochy od 1 do 40 Hz pre $\mathbf{F}_k$ a použitím obdĺžnikového okna na filtráciu na získanie $\mathbf{F}_{k-zero}$, zo vzťahov 3.6 3.7. Fúzia v GLM je popísaná v podkapitole 3.1. Použijú sa v nej pohybové regresory, dodané v rámci fMRI dát. A na výpočet aktivácie voxelu podľa vzťahu 3.4, sa použije sa pozitívny $[1 \ 0]$ a negatívny $[-1 \ 0]$ kontrast. Na získanie spoločnej 3D aktivačnej mapy subjektov je dopočítaná skupinová analýza, ktorá je popísaná v podkapitole 3.3. Výsledky jednovýberového t-testu budú prahované na hodnotu $p \leq 0,001$. Skript na výpočet skupinovej analýzy bol dodaný vedúcim tejto BP, Ing. Labounkom.

4.5 Hodnotenie efektu filtrácie mrkania na finálne výsledky


Výsledné skupinové 3D aktivačné mapy pre jednotlivé frekvenčné pásma a druhy výkonov sú kvantitatívne vyhodnotené podobnostnými kritériami podľa podkapitoly 3.4. Na výpočet sa použije funkcia Podkrit.

5 VYHODNOTENIE VÝSLEDKOV ZO SPRACOVANÝCH DÁT

5.1 Predspracovanie EEG dát

5.1.1 Originálne dáta a ich zmena po nulovaní spektrálnych čiar a normalizácií


Načítané EEG dáta 42 subjektov, ktoré boli čiastočné predspracované podľa podkapitoly (4.1.2), majú vynulované spektrálne zložky mimo frekvenčného pásma 0,1 Hz až 40 Hz a sú následne normalizované. Príklad na dátach subjektu 2107 zobrazuje zmeny morfológie dát EEG, počas týchto procesov, obrázky 5.1,5.2) a 5.3.



Obr. 5.1: Originálna podoba načítaných EEG dát, subjekt 2107

5.1.2 Interpolácia znehodnotených elektród, vyradené subjekty a odstránené nebiologické komponenty

Na dátach sa spravila prvá ICA SOBI dekompozícia. Individuálny EEG signál z samostatných elektród majúci v časovom priebehu nebiologický charakter obrázky 5.4, 5.6 alebo abnormálnu výkonovú aktivitu v topografickom zobrazení u viacerých komponentov (obrázok 5.5) bol sférický dointerpolovaný (obrázok 5.7). Interpolované elektródy jednotlivých subjektov sú v tabuľke (5.1).




Obr. 5.2: Podoba EEG dát po vynulovaní spektrálnych zložiek mimo pásma od 0,1 Hz do 40 Hz, subjekt 2107

Komponenty z prvej ICA SOBI dekompozície ktoré obsahovali nebiologický artefakt a mali v sebe minimum užitočného EEG signálu, boli odstránené. Príklad (5.8) na odstránenie komponenty s minimálnym skresľujúcim účinkom u subjektu 2159. Odstránené komponenty jednotlivých subjektov sú v tabuľke (5.1).

Pri veľkom znehodnotený dát boli subjekty z analýzy vyradené. Celkovo sa jednalo o 3 subjekty. Subjekt 1945 (obrázok 5.9) mal rozsiahlo kolísajúcu izolíniu signálu naprieč všetkými elektródami po dobu 110 sekúnd z celého 423 sekundového záznamu. Subjekt 2194 (obrázok 5.10) mal veľký počet nebiologických artefaktov na viacerých elektródach, kde by pri odstránení všetkých nebiologických komponentov došlo k značnej strate EEG signálu, ktorý sa na dané komponenty viaže. Subjekt 2171 (obrázok 5.11) mal viac než 3 signály vykazujúce nebiologické morfológie, ktorých interpolácia by znížila kredibilitu výsledku založenom na dátach získaných z merania.


5.1.3 Potlačenie artefaktu mrkania z EEG dát

Na dátach sa spravila druhá ICA SOBI dekompozícia. U získaných komponentov sa na podľa podkapitoly (1.4.5), určil komponent s artefaktom mrkania. Príklad



Obr. 5.3: Normalizovaná podoba EEG dát, subjekt 2107

(obrázky 5.12, 5.13) podoby topografického zobrazenia získaných komponentov a porovnanie časového priebehu komponenty artefaktu 4 s EEG komponentmi 8 a 12, u subjektu 2028. Na komponente 12 je možné pozorovať zvyškový artefakt mrkania. Kvôli obsahu biologického EEG signálu, nebola odstránená za účelom úplnej eliminácie artefaktu mrkania. Komponenty subjektov klasifikované ako komponenty s artefaktom mrkania, boli následne odstránené (5.14). Poradie odstránených komponentov u jednotlivých subjektov sú v tabuľke (5.1).



Obr. 5.4: Príklad morfológií elektród (Fz,FC2), ktoré boli určené na interpoláciu, subjekt 2201

5.2 Analýza dát subjektu

Z EEG dát sa spravili regresory fluktuácií absolútneho a relatívneho výkonu pre všetky frekvenčné pásma EEG vln. A tie boli použité vo fúzií s fMRI dátami v GLM. Príklad získaných aktivačných máp na obrázkoch (5.15, 5.16). Obrázky boli prahované na $p \leq 0,001$ s T prah hodnotou 3,1326.

5.3 Skupinová analýza dát subjektu


Pre aktivačné mapy bola vypočítaná skupinová analýza pre jednotlivé frekvenčné pásma EEG vln. Výsledky skupinovej analýzy pre absolútny výkon sú na obrázkoch (5.17, 5.18, 5.19, 5.20, 5.21) a pre relatívny výkon na obrázkoch (5.22, 5.23, 5.24, 5.25, 5.26). Obrázky boli prahované na $p \leq 0,001$ s T prah hodnotou 3,319.

5.4 Vplyv filtrácie mrkania na finálne výsledky

Aktivačné mapy skupinovej analýzy získané z EEG dáta s potlačeným artefaktom boli porovnané s ich variantom bez potlačeného artefaktu. Výsledky vyhodnotenia podobnostnými kritériami je v tabuľke (5.2).

Tab. 5.1: Tabuľka interpolovaných elektród a čísiel odstránených komponentov každého subjektu


ID subjektu	Interpolované elektródy	Odstránené nebiologické komponenty (Prvá ICA SOBI dekompozícia)	Odstránené komponenty artefaktu mrkania (Druhá ICA SOBI dekompozícia)
1928			3
1933	Pz		3
1936			3
1939			6
1942			4
1945			
1948	CP1		3
1953			6
1966	Fz,Cz		7
1973			2
1976			2
1982	Cz		4
1993			5
1996			3
2006	Fz		1,10,12
2017			2
2020		1,8	4
2025			2
2028			4
2034			2
2052			3
2055			2
2064	CP2,Cz,Fz		2
2074			1
2087			3
2094			2
2107			5
2110			5
2116			3
2120		9	9
2132			4
2140			1
2156		2	4
2159		14	1
2171			
2178			4
2194			
2201	Fz, FC2		1
2225			2
2234			6
2244			2
2255			4




Obr. 5.5: Príklad abnormálnej elektródy (Fz) v topografickom zobrazení viacerých komponentov, subjekt 2006

Tab. 5.2: Tabuľka vyhodnotenia podobnostnými kritériami


Pásmo EEG vln	Typ regresoru	Kovariancia	Pearsonov korelačný koeficient	Euklidovská vzdialenosť	Kosinove kritérium
Delta	Absolútny výkon	1.0037	0.9452	149.2409	0.9450
	Relatívny výkon	0.7936	0.9054	164.5625	0.9115
Theta	Absolútny výkon	0.8608	0.9797	81.2095	0.9786
	Relatívny výkon	0.2966	0.9229	95.4512	0.9195
Alfa	Absolútny výkon	0.7375	0.9867	60.1367	0.9844
	Relatívny výkon	0.8331	0.9523	119.4996	0.9567
Beta	Absolútny výkon	1.0073	0.9944	43.8612	0.9938
	Relatívny výkon	0.3324	0.8601	132.3871	0.8572
Gamma	Absolútny výkon	0.8792	0.9938	42.3084	0.9934
	Relatívny výkon	0.4735	0.9037	129.9223	0.9057




Obr. 5.6: Príklad morfológie elektródy (Cz) určenej na interpoláciu, subjekt 1982




Obr. 5.7: Signál z elektródy Cz pred a po sférickej interpolácii, subjekt 1982




Obr. 5.8: Topografické zobrazenie komponenty 14 a EEG signál pred (modrá) a po odstránení (červená) komponenty 14, subjekt 2159




Obr. 5.9: Znehodnotené EEG dáta, subjekt 1945



Obr. 5.10: Topografické zobrazenie komponentov nebiologických artefaktov, subjekt 2194




Obr. 5.11: Znehodnotenén EEG dáta, subjekt 2171




S2028


Obr. 5.12: Komponenty z ICA SOBI dekompozície, subjekt 2028




Obr. 5.13: Časový priebeh komponentov 4,8 a 12, subjekt 2028




Obr. 5.14: Signál z elektródy FP1 pred a po odstránení komponenty 4, subjekt 2028




Obr. 5.15: Aktivačná mapa relatívneho výkonu pre alfa pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne korelácie), subjekt 1973




Obr. 5.16: Aktivačná mapa absolútneho výkonu pre gamma pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie), subjekt 2132




Obr. 5.17: Aktivačná mapa skupinovej analýzy absolútneho výkonu pre delta pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)




Obr. 5.18: Aktivačná mapa skupinovej analýzy absolútneho výkonu pre theta pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)




Obr. 5.19: Aktivačná mapa skupinovej analýzy absolútneho výkonu pre alfa pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)




Obr. 5.20: Aktivačná mapa skupinovej analýzy absolútneho výkonu pre beta pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)




Obr. 5.21: Aktivačná mapa skupinovej analýzy absolútneho výkonu pre gamma pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)




Obr. 5.22: Aktivačná mapa skupinovej analýzy relatívneho výkonu pre delta pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)




Obr. 5.23: Aktivačná mapa skupinovej analýzy relatívneho výkonu pre theta pásmo, bez potlačenia vľavo, s potlačením vpravo. (negatívne korelácie)



Obr. 5.24: Aktivačná mapa skupinovej analýzy relatívneho výkonu pre alfa pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne korelácie)



Obr. 5.25: Aktivačná mapa skupinovej analýzy relatívneho výkonu pre beta pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)



Obr. 5.26: Aktivačná mapa skupinovej analýzy relatívneho výkonu pre gamma pásmo, bez potlačenia vľavo, s potlačením vpravo. (pozitívne a negatívne korelácie)

6 DISKUSIA

Výsledky z tabuľky (5.2) vyhodnotenia odlišnosti podobnostnými kritériami potvrdzujú, že bola zachovaná vysoká podobnosť až totožnosť medzi aktivačnými mapami s a bez potlačenia artefaktu mrkania. Tento fakt platí pre každé frekvenčné pásmo. Medzi výkonmi sa dá vidieť viditeľný vyšší rozdiel medzi mapami pre relatívny výkon než u máp počítaných z fluktuácií absolútneho výkonu. Na základe toho si myslím že mrkací artefakt znehodnocuje mapy fúzie simultánneho EEG-fMRI počítané z relatívneho výkonu EEG vo vyššej miere ako pre mapy počítané z absolútneho výkonu. Výsledok najviac podporujúci tento záver je videný v rozdiel výsledkov medzi výkonmi pre pásmo β (12-20 Hz).

Potlačenie mrkacie artefaktu bolo čiastočné. SOBI variant algoritmu ICA teda nedokázal plne odstrániť artefakt z dát EEG. SOBI nebol schopný úplne izolovať mrkací artefakt do jednej komponenty a zanechával zvyškové časti artefaktu v komponentoch biologickej EEG aktivity. Toto tvrdenie je prezentované v tejto práci na príklade dát subjektu 2028 obrázok (5.13). Týmto spôsobom bol artefakt naďalej obsiahnutý v dátach, ovplyvňujúc výsledky analýzy. Tým sa potvrdzuje nedostatok SOBI algoritmu, pre potlačenie mrkacieho artefaktu spomínaný v článku navrhujúceho SOBI algoritmus, na účel odstraňovania artefaktov z dát EEG [14].

7 ZÁVER

Obsah semestrálnej práce začína literárnou rešeršou z oblasti fúzie EEG-fMRI. V prvých dvoch kapitolách sú vysvetlené princípy akvizície osobitne pre každú modalitu, s ich artefaktami a procesom predspracovania. Venoval som viac priestoru popisu očných artefaktov a metóde ich potlačenia ICA a jej variantu SOBI algoritmu. Tretia kapitola rozoberá fúziu oboch predspracovaných dát v GLM, za využitia spektrálnych zmien EEG signálu. Kapitola končí metodikou analýzy a vyhodnocovania dát podobnostnými kritériami. V štvrtej kapitole som popísal parametre použitých dát, a navrhol riešenie na potlačenie záujmového artefaktu, spolu s dokončením predspracovania a fúzie. Ďalšia časť kapitoly, je popis použitých funkcií, či už naprogramovaných alebo z použitých knižníc rozšírení. Kapitola je zakončená popisom použitého postupu predspracovania dát EEG a EEG-fMRI analýzy.

Piata kapitola zobrazuje jednotlivé fázy predspracovania EEG dáta a aplikáciu navrhutej metódy na dáta EEG za účelom potlačenia mrkacieho artefaktu, spolu s tabuľkou popisujúcou prácu s dátami EEG. Vo výsledkoch sú následne výsledné aktivačné mapy skupín subjektov pre každé nastavenie analýzy. Potom obsahuje tabuľku hodnôt vyhodnotenia rozdielu medzi mapami použitím podobnostných kritérií. Medzi výslednými mapami s potlačeným a bez potlačenia mrkacieho artefaktu bola preukázaná vysoká podobnosť. V šiestej kapitole, diskusií som dospel k dvom záverom. Za prvé mrkací artefakt vplýva na výsledky EEG-fMRI analýzy viac pri výsledkoch počítaných z fluktuácií relatívneho výkonu než z absolútneho výkonu. A za druhé ICA počítaná SOBI algoritmom neizoluje celý obsah mrkacieho artefaktu od dát biologického EEG.

LITERATÚRA

- [1] MATHWORKS, INC. *MATLAB: the language of technical computing. Desktop tools and development environment, version 7*. MathWorks, 2005.
- [2] BĚLE, Václav. *Jednoduchý BCI na bázi ustálených evokovaných potenciálů (SS-VEP)*. 2015.
- [3] KOLÁŘ, Radim. *Lékařská diagnostická technika*. Brno: FEKT Vysoké učení technické v Brně, 2006.
- [4] LABOUNEK, René, et al. *Exploring task-related variability in fMRI data using fluctuations in power spectrum of simultaneously acquired EEG*. Journal of neuroscience methods, 2015, 245: 125-136.
- [5] SUCHOLEIKI, Roy; LOUIS, Sydney. *Normal EEG Waveforms*. 2008.
- [6] SAMMER, Gebhard, et al. *Relationship between regional hemodynamic activity and simultaneously recorded EEG-theta associated with mental arithmetic-induced workload*. Human brain mapping, 2007, 28.8: 793-803.
- [7] KLIMESCH, Wolfgang; SAUSENG, Paul; HANSLMAYR, Simon. *EEG alpha oscillations: the inhibition-timing hypothesis*. Brain research reviews, 2007, 53.1: 63-88.
- [8] HERRMANN, C. S.; DEMIRALP, T. z *Human EEG gamma oscillations in neuropsychiatric disorders*. Clinical neurophysiology, 2005, 116.12: 2719-2733.
- [9] SCHNEIDER, Till R., et al. *Enhanced EEG gamma-band activity reflects multisensory semantic matching in visual-to-auditory object priming*. Neuroimage, 2008, 42.3: 1244-1254.
- [10] BENBADIS, Selim R.; RIELO, Diego. *EEG artifacts*. eMedicine Neurology, Mar, 2010.
- [11] CHIU, Chuang-Chien, et al. *Recovering EEG signals: muscle artifact suppression using wavelet-enhanced, independent component analysis integrated with adaptive filter*. Biomedical Engineering: Applications, Basis and Communications, 2014, 26.05: 1450063.
- [12] OH, Sung Suk, et al. *A pulse artifact removal method considering artifact variations in the simultaneous recording of EEG and fMRI*. Neuroscience research, 2014, 81: 42-50.

- [13] CASSANI, Raymundo, et al. *The effects of automated artifact removal algorithms on electroencephalography-based Alzheimer's disease diagnosis*. Frontiers in aging neuroscience, 2014, 6: 55.
- [14] JOYCE, Carrie A.; GORODNITSKY, Irina F.; KUTAS, Marta. *Automatic removal of eye movement and blink artifacts from EEG data using blind component separation*. Psychophysiology, 2004, 41.2: 313-325.
- [15] ALLEN, Philip J.; JOSEPHS, Oliver; TURNER, Robert. *A method for removing imaging artifact from continuous EEG recorded during functional MRI*. Neuroimage, 2000, 12.2: 230-239.
- [16] JAN, Jiří. *Digital signal filtering, analysis and restoration*. IET, 2000.
- [17] CROFT, Rodney J.; BARRY, Robert J. *Removal of ocular artifact from the EEG: a review*. Neurophysiologie Clinique/Clinical Neurophysiology, 2000, 30.1: 5-19.
- [18] HOFFMANN, Sven; FALKENSTEIN, Michael. *The correction of eye blink artefacts in the EEG: a comparison of two prominent methods*. PLoS One, 2008, 3.8: e3004.
- [19] JUNG, Tzyy-Ping, et al. *Removal of eye activity artifacts from visual event-related potentials in normal and clinical subjects*. Clinical Neurophysiology, 2000, 111.10: 1745-1758.
- [20] CLIFFORD, G. D. *Singular value decomposition and independent component analysis for blind source separation*. HST582J/6.555 J/16.456 J Biomedical Signal and Image Processing Spring, 2005.
- [21] DELORME, Arnaud; SEJNOWSKI, Terrence; MAKEIG, Scott. *Enhanced detection of artifacts in EEG data using higher-order statistics and independent component analysis*. Neuroimage, 2007, 34.4: 1443-1449.
- [22] TROTTER, H. F. *An elementary proof of the central limit theorem*. Archiv der Mathematik, 1959, 10.1: 226-234.
- [23] MONTEFUSCO-SIEGMUND, Rodrigo; MALDONADO, Pedro E.; DEVIA, Christ. *Effects of ocular artifact removal through ICA decomposition on EEG phase*. In: Neural Engineering (NER), 2013 6th International IEEE/EMBS Conference on. IEEE, 2013. p. 1374-1377.
- [24] ONTON, Julie, et al. *Imaging human EEG dynamics using independent component analysis*. Neuroscience and Biobehavioral Reviews, 2006, 30.6: 808-822.

- [25] TANG, Akaysha C.; LIU, Jing-Yu; SUTHERLAND, Matthew T. *Recovery of correlated neuronal sources from EEG: the good and bad ways of using SOBI*. Neuroimage, 2005, 28.2: 507-519.
- [26] BELOUCHRANI, Adel, et al. *A blind source separation technique using second-order statistics*. IEEE Transactions on signal processing., 1997, 45.2: 434-444.
- [27] HUETTEL, Scott A.; SONG, Allen W.; MCCARTHY, Gregory. *Functional magnetic resonance imaging*. Sunderland: Sinauer Associates, 2004.
- [28] HAVLÍČEK, M.; JAN, J. *Exploring brain network connectivity through hemodynamic modeling*. Brno University of Technology, 2011.
- [29] SANETRŇÍKOVÁ, Dominika; LABOUNEK, ING RENÉ. *Převrácené hodnoty výkonu EEG signálu ve sdružené EEG-fMRI analýze*. In: The proceedings of the 20th conference EEICT 2014. p. 153-155.
- [30] MIKL, Michal. *Stránky brnenské neurovednej skupiny zaoberajúcou sa fMRI* [online]. Dostupné z: <http://www.fmri.mchmi.com/>
- [31] BRIDWELL, David A., et al. *The spatio-spectral characterization of brain networks: fusing concurrent EEG spectra and fMRI maps*. Neuroimage, 2013, 69: 101-111.
- [32] LABOUNEK, René, et al. *Analysis of connections between simultaneous EEG and fMRI data*. In: Systems, Signals and Image Processing (IWSSIP), 2012 19th International Conference on. IEEE, 2012. p. 576-579.
- [33] ALLEN, Philip J., et al. *Identification of EEG events in the MR scanner: the problem of pulse artifact and a method for its subtraction*. Neuroimage, 1998, 8.3: 229-239.
- [34] LABOUNEK, René, et al. *Generalized EEG-FMRI spectral and spatio-spectral heuristic models*. In: Biomedical Imaging (ISBI), 2016 IEEE 13th International Symposium on. IEEE, 2016. p. 767-770.
- [35] LABOUNEK, René, et al. *Stable Scalp EEG Spatio-spectral Patterns Across Paradigms Estimated by Group ICA*. Brain topography, 2017, 1-14.
- [36] MARECEK, R., et al. *What can be found in scalp EEG spectrum beyond common frequency bands. EEG-fMRI study*. Journal of neural engineering, 2016, 13.4: 046026.
- [37] ANALYZER, Brain Vision. *User Manual. 2006. The 41st Research Institute of CETC, China*, 2006.

- [38] KNYAZEV, Gennady G. *EEG delta oscillations as a correlate of basic homeostatic and motivational processes*. Neuroscience and Biobehavioral Reviews, 2012, 36.1: 677-695.
- [39] BRIDWELL, David A., et al. *Spatiospectral Decomposition of Multi-subject EEG: Evaluating Blind Source Separation Algorithms on Real and Realistic Simulated Data*. Brain topography, 2016, 1-15.
- [40] DELORME, Arnaud; MAKEIG, Scott. *EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis*. Journal of neuroscience methods, 2004, 134.1: 9-21.
- [41] ASHBURNER, J., et al. *SPM8 Manual*. Functional Imaging Laboratory Wellcome Trust Centre for Neuroimaging Institute of Neurology. 2009.
- [42] ASHBURNER, John, et al. *SPM12 manual*. London: Wellcome Trust, 2014.

ZOZNAM SYMBOLOV, VELIČÍN A SKRATIEK

1D	jednorozmerný priestor - vektor
2D	dvojmerný priestor - plocha
3D	trojmerný priestor v karteziánskej sústave
4D	časovo premenlivý trojmerný priestor v karteziánskej sústave
AAS	average artifact subtraction
ADHD	hyperaktivita s poruchou pozornosti - attention deficit hyperactivity disorder
BOLD	úroveň závislosti okysličenia krvi - Blood oxygen level dependence
BP	bakalárska práca
BSS	Blinde source separation
C-con	kontrolná podmienka - control condition
CMR	pomer rozdielového zosílenia napätia k súfázovému zosíleniu napätia - Common mode rejection ratio
deox-Hg	deoxyhemoglobin
DV	závislá premenná - dependent variable
EEG	elektroencefalografia
EKG	elektrokardiografia
EOG	elektrookulografia
EPI	echo planárne zobrazovanie - echo planar imaging
ERP	event related potential
Ex-con	experimentálna podmienka - experimental condition
fMRI	funkčná nukleárna magnetická rezonancia - functional magnetic resonance imaging
FWHM	full width half maximum
GE	pulzná sekvencia gradient echo
GLM	obecný lineárny model - general linear model
GUI	grafické užívateľské rozhranie - graphic user interface
HRF	funkcia hemodynamickej odozvy - hemodynamic response function
ICA	analýza nezávislých komponentov - Independent component analysis
IV	nezávislá premenná - independent variable
MI	Mutual information
mm	milimeter, milimetre
MNI	Montreal neurological institute
MRI	zobrazovanie nukleárnou magnetickou rezonanciou - magnetic resonance imaging
ms	milisekunda, milisekundy
OBS	optimal basis set

ox-Hg	oxyhemoglobin
RF	radiofrekvenčný impulz
s	sekunda, sekundy
SE	pulzná sekvencia spin echo
SMP	stacionárne magnetické pole
SNR	pomer signálu k šumu - signal to noise ratio
SOBI	Second order blind interference
T	tesla
TE	snímkovací čas - time of echo
TR	repetičný čas - time of repetition
wLMS	váňovaná metóda najmenších štvorcov - weighted least square method

ZOZNAM PRÍLOH

Príloha č.1

CD s použitými dátami EEG a fMRI. CD obsahuje aj použité kódy pri predspracovaní a analýze dát. Medzi nimi sú vlastné naprogramované kódy a kód dodaný vedúcim práce Ing. René Labounkom. Príloha obsahuje aj výsledky EEG-fMRI analýzy jednotlivcov a skupín.