

České vysoké učení technické v Praze

Fakulta elektrotechnická

Katedra teorie obvodů



Bakalářská práce

**Detekce a charakterizace ustálených zrakových evokovaných
potenciálů pro výzkum vědomí**

Detection and characterization of steady-state visual evoked
potentials for consciousness research

Autor: Lucián Čadan

Vedoucí práce: prof. Ing. Roman Čmejla, CSc.

Vedoucí práce – specialista: Ing. Vlastimil Koudelka, Ph.D.

Studijní program: Lékařská elektronika a bioinformatika

Praha 2022

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Čadan** Jméno: **Lucián** Osobní číslo: **491833**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra teorie obvodů**
Studijní program: **Lékařská elektronika a bioinformatika**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Detekce a charakterizace ustálených zrakových evokovaných potenciálů pro výzkum vědomí

Název bakalářské práce anglicky:

Detection and characterization of steady-state visual evoked potentials for consciousness research

Pokyny pro vypracování:

Cílem bakalářské práce je návrh, implementace a validace pokročilé metody detekce ustálených zrakových evokovaných potenciálů (SSVEP).

1. Proveďte rešerši literatury zabývající se metodami detekce SSVEP.
2. Vyberte a implementujte referenční a pokročilou metodu s ohledem na přímé využití ve výzkumu vědomí.
3. Porovnejte a statisticky vyhodnoťte pokročilé metody s referenční metodou na jednom subjektu.
4. Porovnání a vyhodnocení obou metod proveďte také na reálných elektroencefalografických datech od dvaceti subjektů.

Seznam doporučené literatury:

- [1] COHEN, Michael X.; GULBINAITE, Rasa. Rhythmic entrainment source separation: Optimizing analyses of neural responses to rhythmic sensory stimulation. *Neuroimage*, 2017, 147: 43-56.
- [2] TSUCHIYA, Naotsugu, et al. No-report paradigms: extracting the true neural correlates of consciousness. *Trends in cognitive sciences*, 2015, 19.12: 757-770.
- [3] JAMISON, Keith W., et al. SSVEP signatures of binocular rivalry during simultaneous EEG and fMRI. *Journal of neuroscience methods*, 2015, 243: 53-62.

Jméno a pracoviště vedoucí(ho) bakalářské práce:

prof. Ing. Roman Čmejla, CSc. katedra teorie obvodů FEL

Jméno a pracoviště druhé(ho) vedoucí(ho) nebo konzultanta(ky) bakalářské práce:

Ing. Vlastimil Koudelka, Ph.D. Národní ústav duševního zdraví, Klecany

Datum zadání bakalářské práce: **02.02.2022** Termín odevzdání bakalářské práce: **20.05.2022**

Platnost zadání bakalářské práce: **30.09.2023**

prof. Ing. Roman Čmejla, CSc.
podpis vedoucí(ho) práce

doc. Ing. Radoslav Bortel, Ph.D.
podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Student bere na vědomí, že je povinen vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

Datum převzetí zadání

Podpis studenta

Poděkování

Děkuji Ing. Vlastimilu Koudelkovi, Ph.D. za odborné rady, trpělivost a vstřícný přístup při vedení této práce. Chtěl bych také poděkovat prof. Ing. Romanu Čmejlovi, CSc. za cenné rady a poskytnuté konzultace, které mi pomohly při kompletaci této práce. V neposlední řadě bych chtěl poděkovat své rodině a přátelům, kteří mě po celou dobu studia podporují.

Prohlášení

Prohlašuji, že jsem předloženou práci vypracoval(a) samostatně a že jsem uvedl(a) veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

V Praze,

Podpis autora práce

Abstrakt

Ustálené zrakové evokované potenciály představují oscilující signály v mozku, které jsou vyvolány pravidelně se opakujícím či blikajícím vizuálním stimulem. Tyto evokované potenciály se využívají ve výzkumu vědomí a v systémech BCI, kde se využívá jejich vysokého odstupu signálu od šumu.

V této práci byly porovnány metody JD a RESS, což jsou dvě metody pro prostorovou filtraci signálu, které dokážou izolovat SSVEP aktivitu. Jejich efektivita byla porovnána na pětadvaceti osobách, které podstoupily experiment, při kterém zažívaly binokulární rivalitu. Jedná se o jev, kdy dochází k náhodným fluktuacím vědomí, pokud ve stejném okamžiku promítneme do každého oka rozdílný stimul.

Metody JD a RESS byly vyhodnoceny jako úspěšné při rekonstrukci SSVEP signálu v trénovací části experimentu. Hlavním cílem této části bylo detekovat frekvenci promítnutého stimulu ze zrekonstruovaného SSVEP signálu, který zvýrazňoval aktivitu obou frekvencí stimulů, přičemž metoda RESS vykazovala lepší výsledky jak v detekci, tak v odstupu signálu od šumu. Funkčnost metod v rivalitní části byla silně ovlivněna úzkopásmovou filtrací, která potlačila dynamiku zrekonstruovaného SSVEP signálu a nebylo tak možné detekovat rychlé fluktuace amplitudy SSVEP, ke kterým docházelo při binokulární rivalitě.

Klíčová slova: SSVEP, RESS, JD, prostorová filtrace, binokulární rivalita

Abstract

Steady-state visually evoked potentials are neural oscillations evoked by repeating or blinking visual stimuli. One of the possible uses of these evoked potentials is in experiments with consciousness and BCI systems because of the high signal-to-noise ratio.

This thesis will compare two spatial filtering methods JD and RESS. These two methods are used for isolating SSVEP activity. The effectiveness of these methods was tested on twenty-five subjects who underwent an experiment in which they experienced a paradigm called binocular rivalry. During this paradigm, subjects experienced random consciousness fluctuations while different stimuli were projected into each eye separately.

During the training part of this experiment, both methods had satisfying results in SSVEP reconstruction. In the training part, the main task was to detect stimuli frequency from the reconstructed SSVEP signal combined with both stimuli frequencies. The RESS method was more successful than JD in the detection task and the signal-to-noise ratio. In the rivalry part of the experiment, both methods' performance was strongly influenced by narrowband filtering, which suppresses the reconstructed SSVEP dynamics. Because of this suppression, it was impossible to detect fast fluctuations of SSVEP amplitude during binocular rivalry.

Keywords: SSVEP, RESS, JD, spatial filtering, binocular rivalry

Seznam použitých zkratk

RESS		Rhythmic entrainment source separation
JD		Joint-decorelation
BCI		Brain-computer interface
PCA	Analýza hlavních komponent	Principal component analysis
ICA	Analýza nezávislých komponent	Independent component analysis
SNR	Odstup signálu od šumu	Signal-to-noise ratio
EEG	Elektroencefalografie	Electroencephalography
OCD	Obsedantně-kompulzivní porucha	Obsessive-compulsive disorder
SSVEP	Ustálený zrakový evokovaný potenciál	Steady-state visually evoked potential
VEP	Vizuálně evokovaný potenciál	Visually evoked potential
ERP	Kognitivní evokovaný potenciál	Event-related potential
NCC	Nervový korelát vědomí	Neural correlate of consciousness
CNN	Konvoluční neuronová síť	Convolutional neural network
GED	Zobecněný rozklad na vlastní čísla	Generalized eigendecomposition

Obsah

1 Úvod	1
1.1 Motivace	2
1.2 Evokované potenciály	2
1.2.1 Ustálené zrakové evokované potenciály (SSVEP)	4
1.3 Nervové koreláty vědomí	5
1.4 Paradigmata	6
1.4.1 Binokulární rivalita	6
1.4.2 Potlačení záblesku	7
1.5 Úvod do metod pro registraci SSVEP signálu	7
1.5.1 Metody využívané jako prostorové filtry	9
2 Metodika	15
2.1 Návrh experimentu	15
2.1.1 Autoři experimentu	16
2.1.2 Návrh stimulů	16
2.1.3 Trénovací blok	16
2.1.4 Rivalitní blok	17
2.1.5 Záznam událostí	18
2.1.6 Použité přístroje	18
2.2 Předzpracování EEG signálu	19
2.2.1 Redukce počtu elektrod	19
2.2.2 Předzpracování dat	19
2.3 Implementace metod použitých v experimentu	20
2.3.1 Data k výpočtu	20
2.3.2 Implementace RESS	21
2.3.3 Implementace JD	22
2.4 Způsob vyhodnocení metod v trénovacím bloku	23
2.5 Způsob vyhodnocení metod v rivalitním bloku	24
2.6 Topografická vizualizace	24
3 Výsledky	25
3.1 Úspěšnost metod RESS a JD v trénovacím bloku	25
3.2 Úspěšnost metod JD a RESS v rivalitním bloku	31
4 Diskuze	33
5 Použitá literatura	34
Příloha A	41
Příloha B	43

1 Úvod

Vizuálně evokované potenciály mají využití v mnoha oblastech, a to jak ve výzkumu, tak v klinické praxi. Například v medicíně lze pomocí vyhodnocení signálu vizuálně evokovaného potenciálu diagnostikovat optickou neuritidu (zánět zrakového nervu) [1], [2]. Z výzkumů je také známo, že se signály vizuálně evokovaných potenciálů u pacientů se schizofrenií liší od signálů evokovaných potenciálů zdravých osob. Konkrétně se jedná o pokles amplitudy první pozitivní výchylky zhruba 100 ms po prezentaci stimulu [3]. Další výzkum ukázal, že u lidí diagnostikovaných s OCD je prodleva mezi stimulem a první pozitivní výchylkou evokovaného potenciálu kratší, než u zdravých osob [4].

Z vyhodnocení signálu evokovaných potenciálů můžeme také získat informaci o somatosenzorických cestách a jejich abnormalitách, či detekovat místo narušení somatosenzorických cest [5].

Další velice užitečnou oblastí využití evokovaných potenciálů jsou systémy BCI (Brain-Computer interface). BCI je rozhraní, které převádí aktivitu mozku na určitou externí aktivitu [6], například na pohyb protetické ruky [7].

Cílem práce je porovnat metody zpracování dat s využitím ve výzkumu vědomí a vědomích zkušeností. K těmto účelům je potřeba přizpůsobit předzpracování dat. Jeden z možných způsobů předzpracování dat je prostorová filtrace (spatial filtering). Pomocí prostorové filtrace nalezneme takové váhy jednotlivých elektrod, aby bylo možno identifikovat aktivitu mozku (evokované potenciály), která je těžko identifikovatelná v nefiltrovaných datech [8]. Existují různé druhy prostorových filtrů. V této práci se zaměřím na RESS filtr [9] a na metodu filtrace zvanou JD [10]

1.1 Motivace

Experiment si klade za cíl najít co nejlepší EEG korelát dobrovolníkovy odpovědi. Tyto koreláty budou porovnávány s ruční odpovědí dobrovolníka joystickem. Naším cílem je vyloučit aktivaci spojenou s reportováním joystickem, aby byl zkoumaný EEG korelát co nejlépe nervovému korelátu vědomí a eliminován se vliv aktivace spojené s odpovědí joystickem.

Metoda RESS je filtrační metoda, která je využívána k analýze SSVEP v různých výzkumech [11], [12], [13]. Podle nejlepšího vědomí autora této práce nebyla metoda RESS doposud použita k analýze SSVEP signálu při binokulární rivalitě na více subjektech. Proto byla metoda RESS v této práci zvolena jako pokročilá metoda.

Metoda JD byla zvolena jako referenční metoda, se kterou budou porovnány výsledky metody RESS.

1.2 Evokované potenciály

Evokované potenciály jsou elektrické potenciály, které lze získat nahráváním signálu z různých částí nervového systému v reakci na podnět vyvolaný určitým stimulem. Většinou se využívají stimuly vizuální a zvukové. Nejčastěji využívanými typy evokovaných potenciálů využívaných v medicíně jsou vizuálně evokované potenciály (VEP), sluchové evokované potenciály (AEP) a somatosenzorické evokované potenciály (SEP). [14]

Evokovaný potenciál se jeví jako přechodová vlna jejíž vlastnosti závisí na typu a intenzitě stimulu, na poloze elektrod, nebo také na duševním stavu subjektu (například únava). Jejich amplituda se pohybuje mezi 0.1 až 10 μV . Signál evokovaného potenciálu je většinou špatně detekovatelný v nahraných EEG datech. Na aktivitu EEG, která nesouvisí se signálem SSVEP, je nahlíženo jako na šum a při analýze se snažíme minimalizovat jeho vliv, aby bylo možno přímo zkoumat signál evokovaného potenciálu. [5]

Kognitivní evokované potenciály (ERP)

Kognitivní evokovaný potenciál (ERP) může být evokován nějakým vnějším stimulem při nějakém rozhodnutí, nebo vyvolání reakce. Pro popis signálu ERP se používá terminologie související s jeho polaritou a trváním jednotlivých výchylek jeho amplitudy. Například P100 značí maximální pozitivní výchylku amplitudy po čase 100 ms od vyslání konkrétního stimulu. [15]

Nejčastěji jsou tyto signály nahrávány při odezvě na samostatný diskretní stimul. Jednotlivé ERP jsou od sebe odděleny dlouhou prodlevou, aby došlo k oddělení jednotlivých ERP. [16]


ERP můžeme rozdělit do dvou kategorií. První kategorie ERP jsou exogenní, nebo také senzorycké ERP dosahující maxima během prvních 100 ms po stimulu. Tyto ERP jsou závislé hlavně na vlastnostech stimulu. Druhou skupinou stimulu jsou endogenní stimuly, nebo také kognitivní ERP, které jsou generovány později a souvisí hlavně se zpracováním informací mozkiem. [17]. Příklad vizuálně evokovaného potenciálu ukazuje Obrázek 1.

Jelikož je šum často větší oproti ERP signálu, bylo by velmi těžké analyzovat ERP pouze z jedné vlny (jedno promítnutí stimulu). Nejpoužívanější metodou pro zlepšení odstupu signálu od šumu je zprůměrování signálu. Průměrování signálu se provádí přes úseky, kdy přesně známe čas opakujícího se stimulu. [15]

Zprůměrování je pak možné provést, pokud jsou splněny tyto tři podmínky [18]:

- Nahraný signál ERP je lineárním součtem šumu a čistého ERP signálu
- Průběh signálu ERP je stejný pro každé opakování stimulu
- Signál odpovídající šumu je dostatečně nepravidelný, aby mohl být brán jako statisticky nezávislý náhodný signál

Potlačení šumu je v přímé úměrnosti s druhou odmocninou z počtu použitých úseků signálu (opakování stimulu) [15].



Obrázek 1: Průběh signálu vizuálně evokovaného potenciálu. Převzato z [59].

1.2.1 Ustálené zrakové evokované potenciály (SSVEP)

Exogenní ERP mohou být generovány jako odezva na stimul opakující se s konstantní frekvencí [16]. Díky tomu, že odezvy na tento druh stimulu mohou být velice stabilní v amplitudě i ve fázi, byly nazvány ustálené zrakové evokované potenciály (SSVEP) [19].

Signál SSVEP vykazuje stacionární, periodické oscilace. Spektrum SSVEP signálu je stabilní v čase. [20]

SSVEP může být vyvolán několika druhy vizuálních stimulů. Hlavní myšlenkou je vyvolat pohybem, nebo blikáním stimulu na určité frekvenci je mozkovou odezva na frekvenci stejné. [20]


Je-li frekvence stimulu nad 10 Hz, signál SSVEP se blíží sinusovému průběhu [16].

Vlastnosti SSVEP

Signál SSVEP je možné detekovat elektrodami v okcipitální části mozku [21]. Výsledky studie [21] ukazují, že v závislosti na frekvenci stimulu lze SSVEP detekovat i v centrech mozku vzdálených od primárního vizuálního kortexu.

Autoři v další studii [22] píší, že signál SSVEP nelze modelovat pouze jedním zdrojem v okcipitální oblasti mozku, jelikož tento model dostatečně nevystihuje distribuci SSVEP signálu na skaplu.

Existuje více teorií, jak SSVEP vzniká a jak se šíří. Společným znakem těchto teorií je, že SSVEP signál se šíří od primárního vizuálního kortexu a obsahuje více než jen jeden zdroj mozkové aktivity [20]. Šíření SSVEP ukazuje Obrázek 2.




Obrázek 2: SSVEP signál je generován více mozkovými zdroji. Signál je distribuován od primárního vizuálního kortexu ve směru šípek. Každý kruh představuje jeden dipól. Převzato z [20].

Využití SSVEP

Jednou z největších výhod SSVEP je možnost zaznamenávání většího počtu vizuálních procesů díky využití různých stimulačních frekvencí. Vycházíme z toho, že známe-li frekvence stimulů, známe také frekvenci evokovaného potenciálu a metodami zpracování signálu můžeme zrekonstruovat jednotlivé reakce mozku na konkrétní stimuly. [16]

Tento přístup je využíván v metodách BCI (brain-computer interface). Jedním z příkladů využití může být ovládání autíčka (Obrázek 3), které se pohybuje do třech směrů (doprava, doleva, dopředu). Subjekt se zaměřuje na panely problikávající na určité frekvenci podle toho, kam má zrovna autíčko zatočit. [23]



Obrázek 3: Na levém obrázku se nachází tři panely, díky kterým je možné řídit pohyb autíčka. Na pozadí se nachází obraz z kamery, která snímá scénu před autíčkem. Převzato z [23].


1.3 Nervové koreláty vědomí

Jako nervový korelát vědomí je označována minimální neuronová aktivita, potřebná k prožití konkrétní vědomé události (cítím, že se mě někdo dotknul, napadne mě myšlenka, emoce, nálada). Problém zabývající se touto otázkou se nazývá obtížný problém vědomí (the hard problem of consciousness) [24].

Obrázek 4 zobrazuje aktivace nervového korelátu vědomí. (Aktivace části mozku spojená se spatřením psa.)

Ke zkoumání nervových korelátů vědomí jsou využívána různá paradigmata. Nejčastěji se používají metody, kdy se udržuje konstantní vstupní vjem a sleduje se fluktuace (změny) vědomí [25].

Často je k nervovému korelátu přidáno rušení (nechtěná aktivita mozku) z toho důvodu, že nejsme přesně schopni rozlišit mechanickou odpověď člověka a minimální neuronovou aktivitu (nervový korelát). Tento problém řeší paradigmata bez nutnosti mechanické odpovědi subjektu, která se snaží tato rušení minimalizovat. [25]



Obrázek 4: Nervový korelát vědomí je minimální mozková aktivita potřebná k prožití vědomé události. Převzato z [58].

1.4 Paradigmata

Jednou z nejučinnějších metodik pro zkoumání NCC je udržovat vizuální stimul konstantní, zatímco u subjektu pozorujeme fluktuace vědomí. Tato metodika může být aplikována například s využitím maskovacích stimulů, kdy subjekt rozpoznává vlastnosti maskovaného stimulu (stimul je/není přítomen, je vpravo, vlevo,...). Předpokládá se, že korelováním reportů dobrovolníka indikujících změny vědomí se signálem mozkové aktivity mohou být izolovány NCC. Tato strategie značně závisí na reportu subjektu. [25]

U paradigmát s nutnou mechanickou odpovědí a bez nutné mechanické odpovědi hrozí, že k NCC bude přidána nějaká mozková aktivita, která nebude představovat NCC. U reportovacích paradigmát existuje několik způsobů, jak omezit tyto artefakty způsobené reportem člověka. Místo reportování verbálně nebo tlačítkem lze použít třeba mrkání, ukázání prstem nebo pohyb očí. [25]

Výhodou nereportovacích paradigmát je možnost využití v situacích, kdy je obtížné získat přímý report od subjektu. (Subjekt může být malé dítě, nebo třeba zvíře.) Jejich nevýhodou je naopak to, že k snímanému signálu bude přidáno rušení z nevědomé mozkové činnosti. [25]

V této práci jsou využívána paradigmata s mechanickou odpovědí, jelikož subjekt odpovídal ovladačem, jaký stimul zrovna vnímá.

1.4.1 Binokulární rivalita

Binokulární rivalita je paradigma, kdy jsou člověku promítnuty dva rozdílné obrázky, a to do každého oka jeden. Člověk subjektivně vnímá nedobrovolné změny obsahu vědomí, střídavě vnímá jeden nebo druhý obrázek. [26]

Binokulární rivalita je populární nástroj ke zkoumání vnímání a vědomí, jelikož fyzický stimul zůstává stejný, ale vnímání se mění [27].

Bylo dokázáno, že když člověk reportuje, vnímá jeden obrázek problikávající na jedné frekvenci. V tu chvíli se v EEG na této frekvenci vyskytují oscilace s vyšší amplitudou, než je amplituda oscilací druhého obrázku [28].

Binokulární rivalita je subjektivní paradigma. Jediný, kdo přesně ví o změně vnímání, je právě subjekt [20].

Bloku s binokulární rivalitou, kdy subjekt zažívá fluktuaci vědomí, může předcházet tzv. trénovací (replay) blok, který slouží jako trénink reportování vnímání stimulů. V tomto bloku je do pravého i levého oka promítnut stejný stimul a subjekt nezažívá fluktuaci vědomí (rivalitu).

1.4.2 Potlačení záblesku

Potlačení záblesku (anglicky Flash suppression) je paradigma, kdy je subjektu nejdříve promítnut pouze jeden stimul. Po krátké časové prodlevě (stovky milisekund) je subjektu promítnut stimul druhý, který bude naplno dominovat ve vědomí dotyčného, zatímco vnímání prvního stimulu bude plně potlačeno [29]. Obrázky popisující tyto paradigmaty jsou k nahlédnutí v kapitole 2.1.

1.5 Úvod do metod pro registraci SSVEP signálu

Jeden z možných přístupů při separaci zdrojů mozkové aktivity je analyzovat každou elektrodu zvlášť. Tento přístup považuje každou elektrodou za jedno nezávislé měření. [30]

V tomto přístupu se snažíme vybrat „nejlepší elektrodu“ tak, že spočteme určité charakteristiky či parametry každé elektrody a k analýze vybereme tu elektrodu, která bude vykazovat parametry nejlepší. Tyto parametry mohou být například SNR, výkon konkrétních frekvencí (hledám-li například nejlepší elektrodu k rekonstrukci SSVEP signálu). K výpočtu parametrů může být využita Fourierova transformace, vlnková transformace a další metody. [31]

Lze říci, že jedna elektroda zachycuje signál z více než jednoho zdroje mozkové aktivity. Tím dochází k míchání signálu mezi elektrodami a zdroji a jednotlivé elektrody tak zaznamenávají vážený součet těchto aktivit, zatímco každý zdroj přispívá signálem více elektrodám najednou. [10]

Toto míchání zdrojů znamená, že jedna elektroda je nedostačující pro rozlišení rozdílných zdrojů mozkové aktivity. [8]

K detekci SSVEP signálů jsou využívány také konvoluční neuronové sítě (CNN), jejichž využití představuje několik výhod oproti metodám nezaložených na strojovém učení.

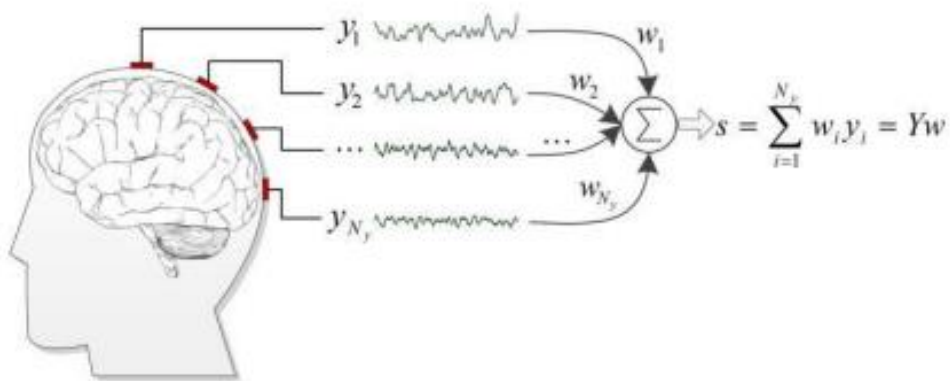
Díky využití CNN není nutné ručně vybírat příznaky (features), či provádět manuální předzpracování dat, jelikož je signál v konvoluční vrstvě konvolován za účelem vytvoření

příznakových map [32], a díky tomu mohou být na vstup sítě přivedena nepředzpracovaná EEG data. [33]

Nevýhodou použití CNN v analýze EEG dat je horší interpretace příznaků extrahovaných neuronovou sítí, avšak existují postupy, jak tyto příznaky lépe interpretovat. [34]

Další skupinou metod, které jsou využívány k analýze SSVEP, jsou lineární prostorové filtry. Tyto filtry využívají lineárního mixování zdrojů mozkové aktivity [35] a mohou být velmi úspěšné při izolování statisticky či anatomicky rozdílných zdrojů. Myšlenkou prostorových filtrů je najít takovou lineární kombinaci elektrod (Obrázek 5) aby byla zvýrazněna aktivita, která je v původních datech špatně detekovatelná. [8]

Prostorové filtrační metody se liší způsobem výpočtu vah elektrod [10]. Jejich výhodou je jednoduchá implementace a dobrá interpretovatelnost. A díky své vlastnosti vylepšovat odstup signálu od šumu jsou využívány často [36]



Obrázek 5: Myšlenka prostorových filtrů je najít ke každé elektrodě takovou váhu, aby při lineární kombinaci elektrod vznikla časová řada (ne nutně jedna), která bude představovat signál našeho zájmu. Převzato z [60].

1.5.1 Metody využívané jako prostorové filtry

Analýza hlavních komponent (PCA)

PCA je lineární transformace dat, jejíž cílem je najít takovou ortogonální bázi, aby byl zachován co největší rozptyl původních dat [37]. Jednotlivé prvky nově nalezené báze se nazývají hlavní komponenty a jsou seřazeny podle rozptylu (první hlavní komponenta má takový směr, aby obsahovala nejvíce rozptylu původních dat). Jelikož PCA provádí rozklad dat do ortogonální báze, není tato metoda optimální pro analýzu mozkových signálů, jelikož ty obecně ortogonální nejsou [8].

Analýza nezávislých komponent (ICA)

ICA řeší tzv. cocktail-party problem. Například budou-li se v místnosti nacházet dva mikrofony a dvě mezi sebou diskutující osoby, mikrofony budou nahrávat směs signálu mluvení obou těchto osob. Z mikrofonů získáme signály $x_1(t)$ a $x_2(t)$ (viz rovnice (1) a (2)), kde t je čas. Každý z těchto signálů je váhovaným součtem signálů diskutujících osob, které označíme jako $s_1(t)$ a $s_2(t)$. Koeficienty a_{11} , a_{12} , a_{21} a a_{22} jsou závislé na vzdálenosti mluvící osoby od mikrofonů. ICA se snaží o zrekonstruování signálů $s_1(t)$ a $s_2(t)$. [38]

$$x_1(t) = a_{11}s_1(t) + a_{12}s_2(t) \quad (1)$$

$$x_2(t) = a_{21}s_1(t) + a_{22}s_2(t) \quad (2)$$

Obecně se předpokládá, že nahrávaná EEG data jsou lineárními součty nezávislých zdrojů mozkové aktivity, které mají neměnnou polohu (analogie s cocktail-party problémem). Díky tomu se ICA často používá k detekci zdrojů mozkové aktivity, a vykazuje lepší výsledky než metoda PCA. [39]

Pro analýzu nezávislých komponent existuje více algoritmů jako třeba FastICA [40], nebo Infomax [41].

Detekce SSVEP signálu metodou ICA může vypadat následovně. Jedním z ICA algoritmů rozložíme původní data na jednotlivé nezávislé komponenty. Z těchto komponent vybereme ty, které budou mít výraznější výkon na frekvenci stimulu, kterým byl vyvolán SSVEP. Z vybraných komponent můžeme zrekonstruovat nová data, ve kterých bude oproti původnímu EEG signálu zvýrazněna SSVEP aktivita. [42]

Povrchový Laplaceův filtr


Povrchový Laplaceův filtr (jinak nazýván CSD nebo SCD) je filtr (existují různé varianty), který aplikovaný na EEG data představuje odhad hustoty proudu, který směřuje kolmo přes lebku na skalp. K jeho výpočtu musí být definován model skalpu, na který bude tento filtr aplikován. Tradičně se k výpočtu povrchového Laplaceova filtru využívají hodnoty z EEG promítnuté na sférický povrch pro usnadnění výpočtu povrchových prostorových derivací. [43]

Tento filtr zvyšuje senzitivitu EEG na zdroje mozkové aktivity, které se s největší pravděpodobností nacházejí blízko elektrod, a redukuje citlivost EEG na zdroje nacházející se hlouběji v mozku [21].

Existuje mnoho metod pro výpočet povrchového Laplaceánu. První publikovaná metoda je založena na metodě konečných prvků [44].

Povrchový Laplaceův využívá druhé derivace k detekci náhlých změn proudu ve směru kolmém na skalp (skalp je definovaný modelem). [45]

Obrázek 6 ukazuje výsledek filtrace Laplaceovým filtrem.




Obrázek 6: Obrázek vlevo ukazuje zkruslenou SSVEP aktivitu. Prostřední a pravý obrázek ukazují výpočet povrchového Laplaceova filtru dvěma rozdílnými algoritmy. Převzato z [43].

Metody využívající zobecněný problém vlastních čísel (GED)

Prostorové filtry, vypočteny pomocí GED, jsou vypočteny tak, aby byl maximalizován rozdíl mezi dvěma různými vlastnostmi zkoumaných dat. Těmito daty jsou úseky signálu, které se snažíme zvýraznit a úseky signálu sloužící jako reference. Zkoumanou dvojicí signál-reference mohou tvořit například: časový úsek před stimulem a časový úsek po stimulu, signál zprůměrovaný přes více úseků dat a signál z jednoho úseku dat, nebo filtrovaná a nefiltrovaná data. Z tohoto pohledu je GED metoda učení s učitelem, na rozdíl od PCA a ICA, které spadají do kategorie učení bez učitele. [30]

Mezi tyto metody patří metody RESS a JD zkoumané v této práci. Způsob výpočtu je naznačuje Obrázek 8.



Obrázek 8: Výpočet vah (matice W) pomocí spektrálního rozkladu matice $R^{-1}S$, kde matice R je kovarianční matice referenčního signálu (nefiltrovaný signál) a matice S je kovarianční matice signálu našeho zájmu (filtrovaný signál). Upraveno z [8].

Rhythmic entrainment source separation (RESS)

Všechny poznatky z této sekce jsou čerpány z [9].

Metoda RESS je prostorový filtr sestávající se z několika již existujících metod ([46], [47], [10], [48], [49]). Hlavní myšlenkou je nalézt prostorový filtr, který po vynásobení s EEG daty vytvoří jednodimenzionální časovou řadu, která může být analyzována namísto dat ze samostatných elektrod. Tato časová řada je reprezentována lineární kombinací všech použitých EEG elektrod. Jednotlivé prostorové filtry jsou reprezentovány jako vlastní vektory, získané zobecněným spektrálním rozkladem dvou kovariančních matic.

Pro optimalizaci filtru pro specifickou aplikaci je důležité správné zvolení dat pro vytvoření “signálové” a “referenční” kovariančních matic. Matice S je reprezentována kovarianční maticí, která je vypočtena z dat vyfiltrovaných pásmovou propustí na frekvenci SSVEP (každá elektroda je filtrována zvlášť). Referenční matice R může být vypočtena z původních nefiltrovaných, nebo ze dvou zprůměrovaných kovariančních matic, vypočtených z dat vyfiltrovaných pásmovou propustí na frekvencích sousedících s frekvencí SSVEP.


Výpočtem spektrálního rozkladu matice $\mathbf{R}^{-1}\mathbf{S}$ získáme matici \mathbf{W} a \mathbf{L} . Sloupce matice \mathbf{W} obsahují vlastní vektory, kde každý vektor náleží jednomu vlastnímu číslu v matici \mathbf{L} . Vlastní vektor náležící největšímu vlastnímu číslu v matici \mathbf{L} použijeme jako RESS filtr. Složky RESS filtrů (sloupce matice \mathbf{W}) na rozdíl od PCA nejsou navzájem ortogonální. Je tomu tak proto, jelikož matice $\mathbf{R}^{-1}\mathbf{S}$ obecně není symetrická a vlastní vektory nesymetrické matice obecně nejsou ortogonální. To představuje výhoda, jelikož metody předpokládající ortogonalitu signálu mozkové aktivity mají horší výsledky než metody, které předpokládají nezávislost zdrojů jednotlivých aktivit [50]. Spektrální rozklad matice $\mathbf{R}^{-1}\mathbf{S}$ zobrazuje rovnice (3).

$$\mathbf{SW} = \mathbf{RLW} \quad (3)$$

Metoda RESS využívá Gaussovské okno (Obrázek 9) pro filtraci ve spektrální oblasti, které je reprezentováno průměrem (frekvencí zájmu) a maximální šířkou pásma při polovině maxima amplitudy (FWHM). Signál je vyfiltrován ve frekvenční oblasti, kdy je využíváno konvolučního teorému dle rovnice (4), kde značka $*$ představuje konvoluci, $FT\{\}$ je Fourierova transformace, $f(k)$ a $g(k)$ jsou časové signály a $F(k)$, $G(k)$ jsou jim náležící frekvenční spektra. Konvoluční teorém říká, že konvoluce dvou signálů v časové oblasti může být nahrazena vynásobením jejich frekvenčních spekter bod po bodu ve spektrální oblasti [51].

$$FT\{f(x) * g(x)\} = F(k)G(k) \quad (4)$$

Výhodou filtrace ve spektru Gaussovským oknem je rychlá implementace a hladké hrany, které při filtrování nezpůsobují artefakty [9].



Obrázek 9: Normované Gaussovské okno pro frekvenci zájmu $f = 5$ Hz a $\text{FWHM} = 2.5$ Hz.

Joint Decorelation (JD)

Všechny poznatky z této sekce jsou převzaty z [10].

Joint-Decorrelation je kombinace několika metod, která se snaží maximalizovat SNR chtěné aktivity, kde se signál a šum specifikuje bias filtrem. Bias filtr se volí v závislosti na tom, jakého výsledku chceme docílit (rozlišitelnost mezi jednotlivými podmínkami, redukce šumu, atd).

Algoritmus

Mějme matici \mathbf{X} s T řádky a D sloupci, kde T je délka signálu (počet vzorků) a D je počet elektrod. Kromě více zdrojů aktivity mozku může matice \mathbf{X} obsahovat také šum. Šum může být způsoben například pohybem očí, síťovým rušením nebo svalovou aktivitou. Cílem bude získat matici \mathbf{Y} s T řádky a K sloupci, kde K je počet nezávislých komponent. Matici \mathbf{Y} získáme vynásobením matice \mathbf{X} maticí \mathbf{W} s rozměry $D \times K$, kde matice \mathbf{W} je matice vah, které budou optimalizovány. Vztah vyjadřuje rovnice (5).

$$\mathbf{Y} = \mathbf{XW} \quad (5)$$

Sloupce matice \mathbf{Y} budou obsahovat nezávislé komponenty, kde první komponenta vykazuje největší poměr energie mezi aktivitou filtrovanou bias filtrem a energií nijak nezpracovaných dat. Na tuto první komponentu budeme nahlížet jako na SSVEP.

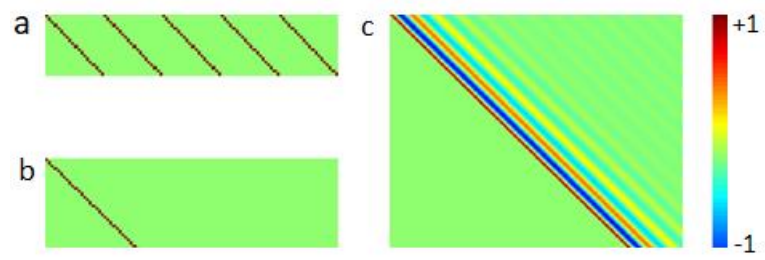
Výpočet matice \mathbf{W} probíhá následovně:

- 1) Použitím PCA na matici \mathbf{X} získáme matici vlastních vektorů \mathbf{P} a matici vlastních čísel \mathbf{D} . Matice \mathbf{P} ortogonalizuje data tak, že sloupce matice \mathbf{XP} jsou nezávislé.
- 2) Matici \mathbf{XP} vynásobíme maticí \mathbf{N} , čímž docílíme jednotkového (sférického) rozptylu. Matici \mathbf{N} získáme tak, že odmocníme inverzní matici vlastních čísel \mathbf{D}^{-1} .
- 3) Aplikujeme bias filtr \mathbf{L} na matici \mathbf{XPN} , čímž zvýšíme energii u chtěné aktivity a zároveň dojde k potlačení šumu.
- 4) Aplikujeme PCA na filtrovaná data \mathbf{LXPN} , čímž získáme matici vlastních vektorů \mathbf{Q} a matici vlastních čísel.
- 5) Matici vah získáme vynásobením matic z předchozích kroků (viz rovnice (6))

$$\mathbf{W} = \mathbf{PNQ} \quad (6)$$

Cílená filtrace

Metoda JD využívá tzv. bias filtr, který je podle [10] definovaný jako jakákoliv operace kombinující vzorky signálu v čase aplikovaná na všech kanály (elektrody) nezávisle na sobě. Této definici odpovídá operace násobení signálové matice \mathbf{X} maticí \mathbf{L} (bias filtr) zleva. Matice \mathbf{L} může vypadat různě v závislosti na tom, jakého výsledku chceme docílit. Obrázek 10: Typy bias filtrů (matice \mathbf{L}). (a) Průměr přes trialů (tady konkrétně přes 5 trialů). (b) Výběr intervalu. (c) Pásmová propust. Převzato z [10] ukazuje některé druhy bias filtrů.



Obrázek 10: Typy bias filtrů (matice \mathbf{L}). (a) Průměr přes trialů (tady konkrétně přes 5 trialů). (b) Výběr intervalu. (c) Pásmová propust. Převzato z [10].


2 Metodika

V této kapitole bude blíže popsán návrh experimentu, postup implementace metod JD a RESS, dále budou také popsány použité funkce z toolboxu FieldTrip [52], způsob výpočtu topografických map a předzpracování EEG signálu.

Data pro tuto práci byla naměřena v Národním ústavu duševního zdraví (NUDZ) v Klecanech na celkovém počtu dvaceti pěti subjektů (12 žen; 13 mužů; průměrný věk 29 let; rozsah 18 – 38). Experiment byl schálen etickou komisí. Autor této práce se nepodílel na měření těchto dat.

2.1 Návrh experimentu

Subjekt byl usazen na pohodlnou židli, na které setrval po celou dobu experimentu. Před subjektem se nacházel monitor, na kterém byly promítány dva různé stimuly. Na tyto stimuly subjekt odpovídal pomocí ovladače. Stlačení páčky ovladače směrem od subjektu bylo signalizováno vnímání domečku, směrem k subjektu pak vnímání obličeje. Stimuly byly promítány ve dvou rozdílných časových blocích. Subjektu byly nasazeny speciální brýle, které zaručily překrytí obou stimulů. V ose mezi subjektem a monitorem byla vložena deska. Sestavení experimentu ukazuje Obrázek 11.



Obrázek 11: Experiment při kterém byla nahrána data. Obrázek byl pořízen v NUDZ.


2.1.1 Autoři experimentu

Stimuly pro tento experiment vytvořil tým zabývající se výzkumem vědomí v NUDZ Mgr. Kozáková Eva, Mgr. Grygarová Dominika, Ph.D., Mgr. Havlík Marek, Ph.D. a Mgr. Adámek Petr. Ze stejného týmu připravovali a implementovali experiment Ing. Jakub Šebek, Ing. Jan Hubený a Ing. Jan Rydlo.

2.1.2 Návrh stimulů

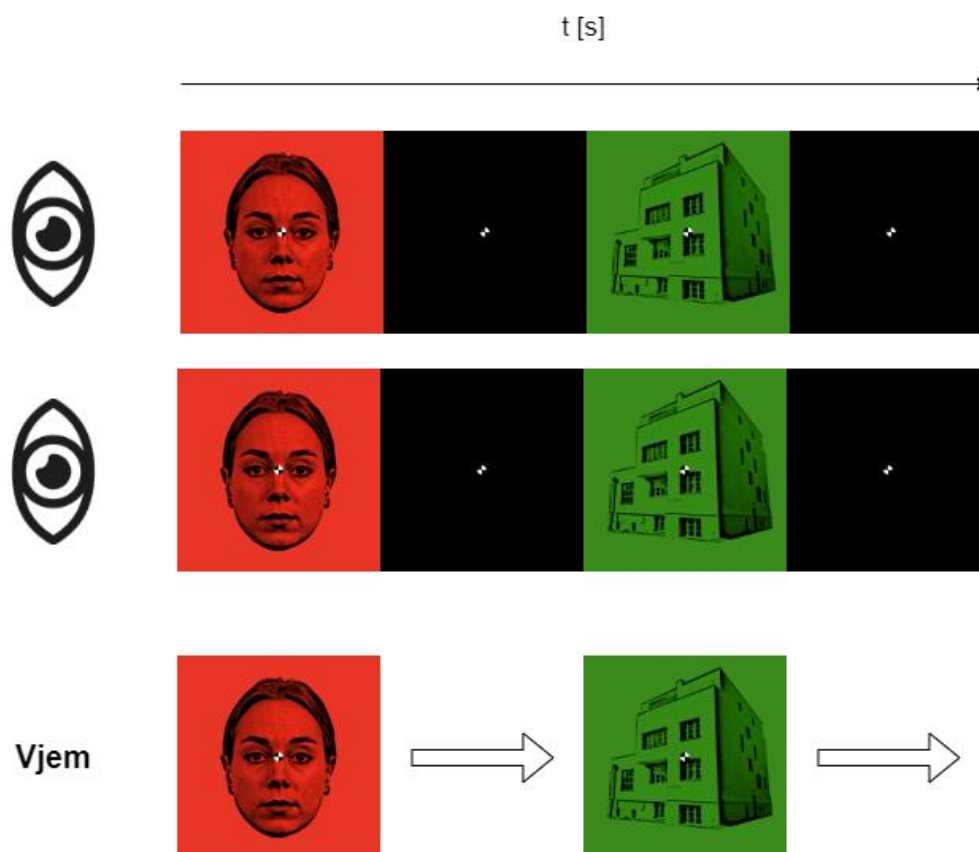
V tomto experimentu byly využívány dva stimuly (Obrázek 12). Tyto Stimuly byly reprezentovány dvěma obrázky, kde každý obrázek problikával na konkrétní frekvenci. Prvním stimulem byl domeček, který blikal na frekvenci 6.67 Hz. Druhým stimulem byl pak obličej s frekvencí 8.57 Hz. Fixační terčík neproblikával a byl promítán mezi dvěma hlavními stimuly (domečkem a obličejem).

2.1.3 Trénovací blok



Obrázek 12: Stimuly použité při experimentu (domeček, fixační terčík a obličej). Pro domeček byla zvolena frekvence blikání 6,67 Hz pro obličej pak 8,57 Hz. Fixační terčík neproblikával. Obrázky upraveny z [61].


První časový blok experimentu byl trénovací blok. V trénovacím bloku byl subjektu do pravého i levého oka promítán stejný stimul. Tento blok sloužil k tomu, aby se subjekt naučil rychle reagovat na promítnuté stimuly. Po absolvování tohoto bloku je subjekt naučený rychle reagovat na promítnuté stimuly bez dlouhých prodlev, což se hodí v binokulární rivalitě, kde je zapotřebí rychle reagovat. Trénovací blok byl rozdělen na 80 úseků. Jeden úsek sestával ze dvou částí, kdy v prvních pěti sekundách byl promítnut stimul (domeček nebo obličej), následovaný promítnutím fixačního terčíku po dobu čtyř sekund. Jeden úsek v trénovacím bloku tedy trval devět sekund. Celý trénovací blok trval dvanáct minut. Průběh trénovacího bloku s vnímáním stimulu subjektem ukazuje Obrázek 13



Obrázek 13: Průběh trénovacího bloku. Do pravého i levého oka je promítán vždy stejný stimul. Náhodně se střídá domeček a obličej. Obrázky stimulů převzaty z [61]

2.1.4 Rivalitní blok

Po trénovacím bloku následoval blok, kde byla aplikována paradigma binokulární rivality a potlačení záblesku Obrázek 14. Rivalitní blok byl rozdělen do 50 úseků. Každý úsek začínal promítnutím fixačního terčíku po dobu čtyř sekund. Následně byl subjektu promítnut jeden stimul pouze do jednoho oka po dobu dvou sekund. Po těchto dvou sekundách byl do druhého oka promítnut druhý rozdílný stimul (toto je paradigma potlačení záblesku). Poté, co je do každého oka promítán rozdílný stimul, se začne projevovat binokulární rivalita a subjekt zažívá náhodné změny vnímání dvou stimulů s tím, že vnímá buď domeček, obličej, či směs obou stimulů (páčka v neutrální poloze). Rivalitní blok trval celkem 1300 sekund (necelých 22 minut).



Obrázek 14: Průběh paradigmat potlačení záblesku a binokulární rivality. Nejdříve je promítnut stimul do jednoho oka, po promítnutí druhého stimulu dojde k potlačení vnímání prvního stimulu a nastává náhodné vnímání obou stimulů. Obrázky stimulů upraveny z [61]

2.1.5 Záznam událostí

V průběhu experimentu byly zaznamenávány jednotlivé události. Každá událost měla svůj popis a byla označena vzorkem v signálu. Tabulka značek je k nahlédnutí v příloze (Příloha B).

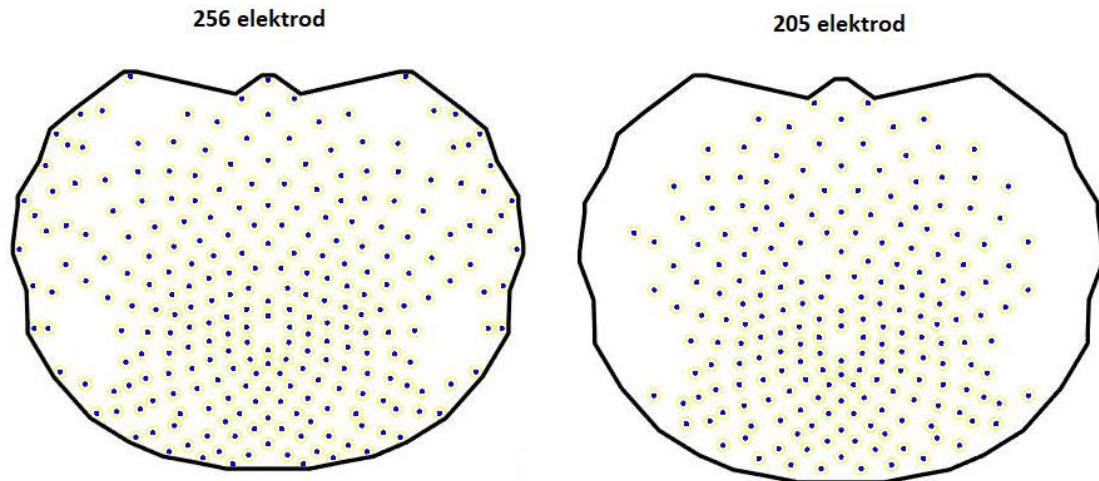
2.1.6 Použité přístroje

Pro získání EEG dat byla použita senzorická síť EGI HCGSN s 256 kanály. Data byla vzorkována frekvencí 1000 Hz a zaznamenána zesilovačem Net Amps 400. Pro prezentování stimulu byl použit software Opensesame.

2.2 Předzpracování EEG signálu

2.2.1 Redukce počtu elektrod

Z původních 257 elektrod bylo odstraněno 51 elektrod z důvodu zlepšení kvality získaného SSVEP signálu (Obrázek 15). Byla odstraněna spodní řada elektrod, stejně tak jako elektrody z tváří. V těchto místech nebyla očekávána SSVEP aktivita. Naopak, tato místa jsou často spojována se zdroji rušivých signálů.



Obrázek 15: Na levém obrázku jsou vyznačeny všechny elektrody, se kterými bylo nahráno EEG. Na pravém obrázku jsou elektrody použité pro výpočet vah prostorových filtrů. Obrázek je z galerie autora.

2.2.2 Předzpracování dat

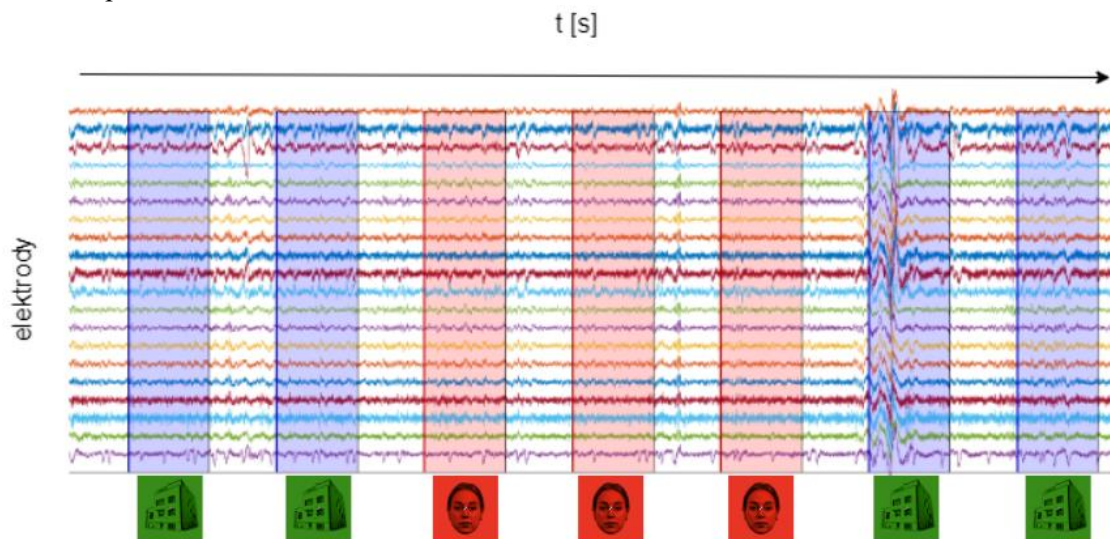
Původním úmyslem bylo odstranit a interpolovat kanály vykazující rušivou aktivitu, následně aplikovat metodu ICA a odstranit složky vykazující rušení jako například signál svalové aktivity, či očního pohybu. Výsledky tohoto předzpracování nebyly dostačující pro potřeby této práce. V rámci udržení konzistence a urychlení práce s daty byla v této práci použita data již předzpracovaná pokročilými metodami [53].

2.3 Implementace metod použitých v experimentu

Tato práce byla naimplementována v prostředí MATLAB s využitím doplňku pro práci s EEG a MEG daty, FieldTrip [46]. Jeho obsahem jsou funkce umožňující předzpracování, vykreslování a statistické zpracování dat. Data každého subjektu byla reprezentována strukturou, obsahující kromě samotných dat informace o časové ose, poloze a popisu elektrod a definovaných rozsahů jednotlivých úseků na které byla data rozdělena.

2.3.1 Data k výpočtu

Pro výpočet vah prostorových filtrů RESS a JD byla využita data z trénovacího bloku. Obrázek 16 ukazuje část dat, které byly použity k výpočtu vah prostorových filtrů. Modrý a červený úsek začíná vždy značkou, kdy byl subjektu promítnut konkrétní stimul, a tento každý blok má přesně 5 s.



Obrázek 16: Data, která byla použita k výpočtu vah prostorových filtrů JD a RESS. Pro ilustraci bylo použito méně elektrod. Obrázky stimuly upraveny z [61].

2.3.2 Implementace RESS

Kovarianční matice potřebné k výpočtu prostorového filtru byly vypočteny následovně. Máme-li data, reprezentovaná maticí \mathbf{X} s J řádků (počet elektrod) a L sloupců (délka signálu), kde od každého řádku bude odečten jeho průměr, můžeme vypočítat kovarianční matici \mathbf{C} podle rovnice (7) a bude mít rozměry $J \times J$

$$\mathbf{C} = \frac{1}{L} \mathbf{X}^T \mathbf{X} \quad (7)$$

Matice \mathbf{R} byla vypočtena z původních spojitých nefiltrovaných dat. Matice \mathbf{S} byla vypočtena jako průměr dvou kovariančních matic \mathbf{S}_D a \mathbf{S}_O . Pro ilustraci bude popsán výpočet matice \mathbf{S}_D . Princip výpočtu \mathbf{S}_O je analogický. Mějme matici \mathbf{X} , která má m řádků a n sloupců. Nejprve vypočteme matici \mathbf{X}_D tak, že přenásobíme každý řádek matice \mathbf{X} Hammingovým oknem, abychom zamezili prosakování ve spektru, a poté vyfiltrujeme každý řádek matice \mathbf{X} Gaussovým oknem ve spektrální oblasti se středem okna na frekvenci stimulu domečku (6.67 Hz). Od každého řádku filtrované matice odečteme jeho průměr. Matici \mathbf{S}_D vypočteme jako průměr kovariančních matic ze všech bloků, jejichž začátek je definován značkou promítnutí domečku. Každý blok trvá 5 s. Matici \mathbf{S}_D vypočteme podle rovnice (7). Analogicky vypočteme kovarianční matici \mathbf{S}_O (data pouze z úseků, kde byl promítnut obličej, Gaussovské okno se středem 8.57 Hz). Výslednou matici \mathbf{S} získáme podle rovnice (8)

$$\mathbf{S} = \frac{\mathbf{S}_D + \mathbf{S}_O}{2} \quad (8)$$


Dále použijeme funkci *eig* z prostředí MATLAB k výpočtu vlastních vektorů kovariančních matic. Podle rovnice (3) je spočten spektrální rozklad kovarianční matice $\mathbf{R}^{-1} \mathbf{S}$, ze kterého získáme matici vlastních vektorů a vlastních čísel. Vlastní vektor náležící největšímu vlastnímu číslu je prostorový filtr, který použijeme v rekonstrukci SSVEP signálu z původních nefiltrovaných dat.

2.3.3 Implementace JD

Mějme matici \mathbf{X} s m řádky a n sloupce, která vznikla spojením pětisekundových bloků se stimuly. Pro přehlednost bylo uvažováno, že signál z jednotlivých elektrod bude ve sloupcích matice \mathbf{X} . Po provedení prvního PCA získáme matici vlastních vektorů \mathbf{P} a matici vlastních čísel \mathbf{D} s rozměry $n \times n$, kde každé vlastní číslo představuje rozptyl dat promítnutých na vlastní vektor náležící tomuto vlastnímu číslu. Z matice \mathbf{P} bylo využito prvních 35 vektorů náležejících prvním 35 největším vlastním číslům. Po vynásobení matice \mathbf{XP} maticí $\mathbf{D}^{-\frac{1}{2}}$ zleva získáme matici \mathbf{Z} . Pro zvýraznění signálu našeho zájmu (signál vyvolaný dvěma stimuly) byly naimplementovány dva filtry pro filtraci v časové oblasti (Obrázek 17). Pro signál evokovaného potenciálu platí, že jeho aktivita může být zvýrazněna zprůměrováním stejně dlouhých úseků (viz kapitola 1.2). Každý z těchto filtrů provedl zprůměrování úseků s konkrétním stimulem v matici \mathbf{Z} . Výsledkem byly dvě matice $\tilde{\mathbf{Z}}_D$ a $\tilde{\mathbf{Z}}_O$. Výpočet ukazují rovnice (9) a (10), kde prvky na diagonálách v matici \mathbf{L}_D a \mathbf{L}_O mají hodnotu $\frac{1}{N}$, kde N je počet bloků signálu, které mají být zprůměrovány. Jedná se o řídkou matici (kromě diagonál jsou všechny ostatní prvky rovny nule).

$$\tilde{\mathbf{Z}}_D = \mathbf{L}_D \mathbf{Z} \quad (9)$$

$$\tilde{\mathbf{Z}}_O = \mathbf{L}_O \mathbf{Z} \quad (10)$$



Obrázek 17: Dva filtry v časové oblasti \mathbf{L}_O a \mathbf{L}_D , které po vynásobení matice dat zleva provedou zprůměrování bloků signálu.

V posledním kroku byly vypočteny dvě kovarianční matice z dat v maticích $\tilde{\mathbf{Z}}_O$ a $\tilde{\mathbf{Z}}_D$, jejichž zprůměrováním byla vypočtena matice \mathbf{C} , na kterou bylo aplikováno PCA, čímž byla získána matice vlastních vektorů \mathbf{Q} . Matice vah \mathbf{W} byla poté vypočtena podle rovnice (6). Poslední vektor matice \mathbf{W} byl použit jako prostorový filtr.

2.4 Způsob vyhodnocení metod v trénovacím bloku

Výstupem každé metody byl sloupcový vektor vah \mathbf{v} , jehož počet řádků odpovídal počtu elektrod. Tyto váhy byly aplikovány na nefiltrovaná data v matici \mathbf{X} s jednotlivými kanály v řádcích matice, která byla sestavena z pětisekundových částí signálu, kdy byl subjektu promítán stimul. Vynásobením podle rovnice (11) získáme jednorozměrnou časovou řadu reprezentovanou vektorem \mathbf{s} , která byla vytvořena jako lineární kombinací jednotlivých elektrod. Tento výpočet byl proveden stejným způsobem pro metodu RESS a JD. Výsledný signál není signál SSVEP o jedné frekvenci, nýbrž signál, který zvýrazňuje aktivitu na frekvencích 6.67 Hz i 8.57 Hz.

$$\mathbf{s} = \mathbf{v}^T \mathbf{X} \quad (11)$$

Metody byly porovnány z hlediska úspěšnosti detekce signálu o frekvenci, na které blikal stimul promítaný subjektu. Signál byl detekován pouze v pětisekundových blocích, kdy byl tento stimul promítnut. K tomuto vyhodnocení byla použita funkce *ft_freqanalysis* z toolboxu FieldTrip umožňující výpočet výkonového spektra signálu rozdělený na bloky. Každý blok byl přenásoben Hanningovým oknem a byl doplněn nulami pro lepší rozlišení spektra. Poté bylo pro každý blok vypočteno výkonové frekvenční spektrum jako kvadrát koeficientů rychlé Fourierovy transformace. V každém bloku bylo zkoumáno, je-li spektrální výkon frekvence promítnutého stimulu větší, než spektrální výkon frekvence nepromítnutého stimulu. Výsledkem byl relativní počet správně detekovaných frekvencí stimulů.

Dále bylo pro každý subjekt provedeno srovnání mezi dvěma výkonovými spektry vypočtené zvlášť z průměru bloků, kde byl promítnut stejný stimul.

Porovnat metody lze také podle toho, jak velký má odstup signál našeho zájmu od šumu. Dle rovnice (12) byl vypočten odstup signálu od šumu zvlášť pro každé zprůměrované výkonové spektrum.

$$SNR_f = \frac{nP(f)}{\sum_{i=1}^{i=n/2} (P(f + i\Delta f) + P(f - i\Delta f))} \quad (12)$$

Hodnoty byly zvoleny: $\Delta f = 0.005 \text{ Hz}$, $n = 150$, $f = \{6.67 \text{ Hz}, 8.57 \text{ Hz}\}$, kde Δf značí rozlišení rychlé Fourierovy transformace, f značí frekvence použitých stimulů, n ovlivňuje šířku pásma šumu a $P(f)$ značí výkonové spektrum. SNR bylo vypočteno způsobem podle [54].

2.5 Způsob vyhodnocení metod v rivalitním bloku

V trénovacím bloku byly využity časové úseky dat, ve kterých byly promítnuty jednotlivé stimuly. V této části budou aplikovány váhy vypočtené z dat z trénovacího bloku na spojitá nefiltrovaná data z rivalitního bloku. Tímto byl získán jednorozměrný signál zvýrazňující aktivitu obou frekvencí. Dále bylo potřeba oddělit aktivitu dvou stimulů. Toho bylo docíleno filtrací Gaussovským filtrem ve frekvenční oblasti tak, že zrekonstruovaný signál byl filtrován na frekvenci těchto dvou stimulů zvlášť. Filtrací byly získány dva signály \mathbf{s}_D a \mathbf{s}_O , reprezentované jako jednorozměrný vektor. Pro každý z těchto signálů byla vypočtena komplexní obálka. Uvažujeme-li absolutní hodnotu této komplexní obálky, získáme dva reálné signály $\tilde{\mathbf{S}}_D$ a $\tilde{\mathbf{S}}_O$.

V rivalitním bloku bylo zkoumáno, zda je detekovatelný signál o frekvenci toho stimulu, na který zrovna subjekt reaguje tlačítkem. Z literatury je známo, že je obtížné detekovat amplitudu SSVEP signálu pro odpovědi subjektu kratší než 1 s [55]. Z tohoto důvodu byla detekce prováděna na odpovědích subjektu, které byly delší než 1 s.

K detekci byl vypočten pomocný signál \mathbf{r} podle rovnice (13)

$$\mathbf{r} = \tilde{\mathbf{S}}_D - \tilde{\mathbf{S}}_O \quad (13)$$

Signál \mathbf{r} měl kladnou hodnotu, pokud byla amplituda signálu $\tilde{\mathbf{S}}_D$ větší, než amplituda signálu $\tilde{\mathbf{S}}_O$. Signál byl považován za správně detekovaný, pokud amplituda signálu po celou dobu trvání odpovědi subjektu byla větší než nula v případě detekce signálu $\tilde{\mathbf{S}}_D$, menší než nula pak při detekci signálu $\tilde{\mathbf{S}}_O$.

2.6 Topografická vizualizace


Váhy prostorových filtrů nelze obecně interpretovat tak, že elektrody, nacházející se blíž oblasti našeho zájmu budou mít větší váhu než elektrody dál od této oblasti [56].

U JD i u RESS byly topografické mapy zobrazeny pomocí nových vah. Každá nová váha odpovídala koeficientu, který byl vypočten jako skalární součin zrekonstruovaného SSVEP signálu se signálem každé elektrody zvlášť. (Předpoklad byl, že SSVEP signál i signál elektrod měl stejný počet vzorků a začínal ve stejném čase.) Od obou signálů byl odečten jejich průměr a jejich výsledný skalární součin byl vydělen součinem směrodatných odchylek obou signálů. Výsledkem této operace je vektor se stejným počtem složek jako je počet vah prostorových filtrů vypočtených metodami RESS a JD a lze ho interpretovat jako odhad energie v daném místě na skalpu [10].

3 Výsledky

3.1 Úspěšnost metod RESS a JD v trénovacím bloku

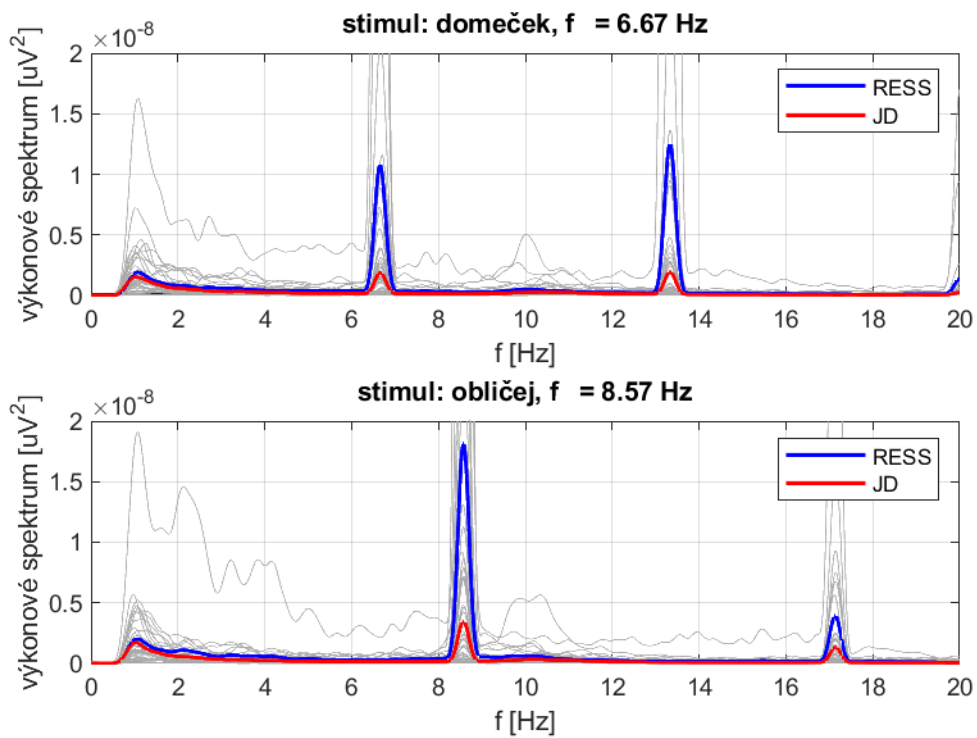
Porovnání metod RESS a JD podle úspěšnosti detekce frekvencí promítnutých stimulů v úsecích v trénovacím bloku ukazuje Obrázek 18. Medián chyby detekce frekvencí stimulů metodou RESS je 1.25 % pro úseky signálu s promítnutím domečku a 0 % pro úseky s promítnutým obličejem. Medián úspěšnosti detekce metodou JD je 2.5 % pro úseky s promítnutým domečkem a 0 % pro úseky s promítnutým obličejem.



Obrázek 18: Vyhodnocení detekce v trénovacím bloku pro obě metody. Úsek signálu byl prohlášen za správně detekovaný, pokud výkon frekvence promítnutého stimulu byl větší, než výkon frekvence nepromítnutého stimulu. Toto vyhodnocení bylo provedeno pro každý pětisekundový úsek trénovacího bloku.

Porovnání metod JD a RESS ve spektrální oblasti ukazuje Obrázek 19. V grafech jsou zobrazeny první a druhé harmonické frekvence pro každý stimul. Z obrázku je patrné, že frekvence stimulů detekovaných v signálu, který byl získán metodou JD, mají mnohem menší výkon než frekvence signálu zrekonstruovaných metodou RESS.


průměrná výkonová spektra pro oba stimuly



Obrázek 19: Porovnání průměrných výkonových spekter zprůměrovaných bloků podle promítnutých stimulů. Světle šedé křivky vyznačují výkonová spektra každého subjektu. Červená a modrá křivka představují průměrná výkonová spektra zprůměrovaná přes všechny subjekty.

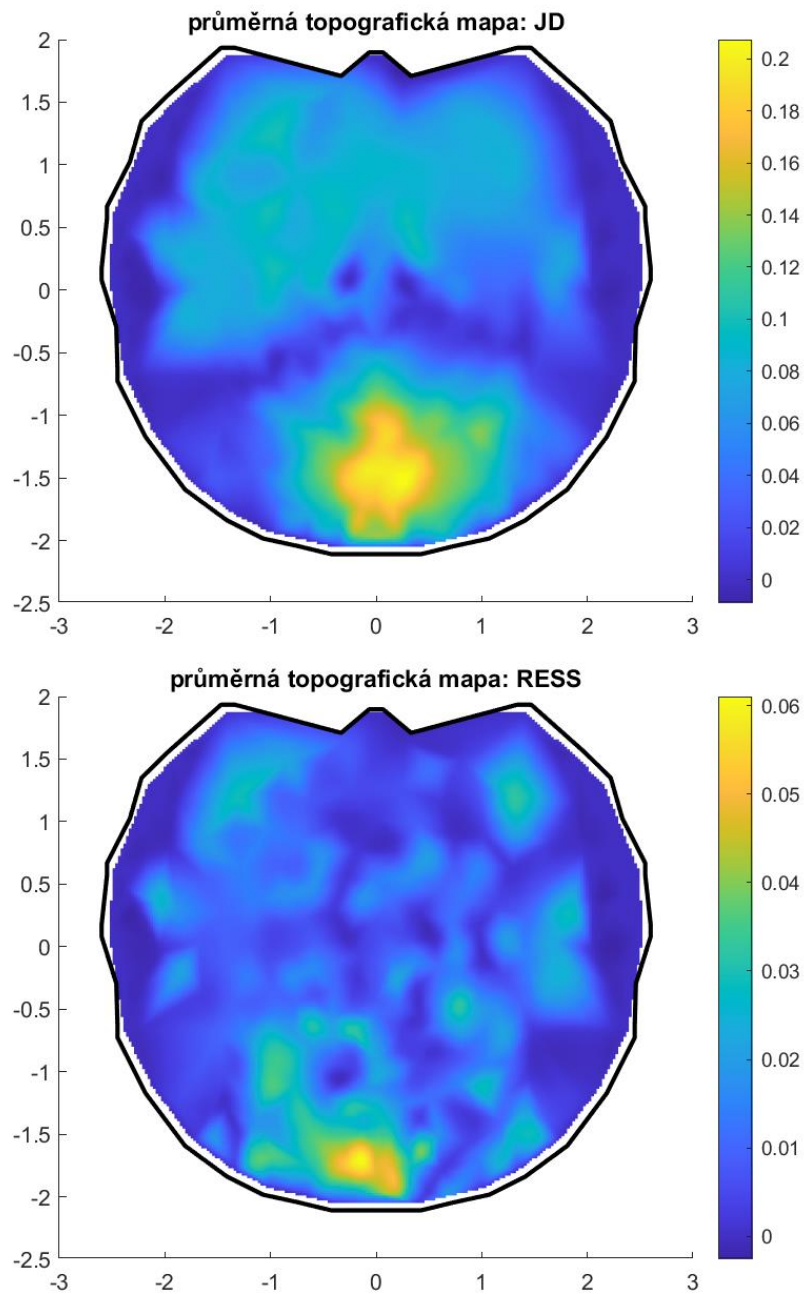
Dále byl porovnán odstup signálu od šumu u obou metod (postup výpočtu viz kapitola 2.4). Toto porovnání ukazuje Obrázek 20. Poměr SNR je zobrazen pro první a druhé harmonické frekvence obou stimulů. V tomto porovnání vykazoval signál zrekonstruovaný metodou RESS větší odstup signálu od šumu, než signál zrekonstruovaný metodou JD pro první i druhou harmonickou frekvenci obou stimulů.

Odstup signál-šum průměrných výkonových spekter



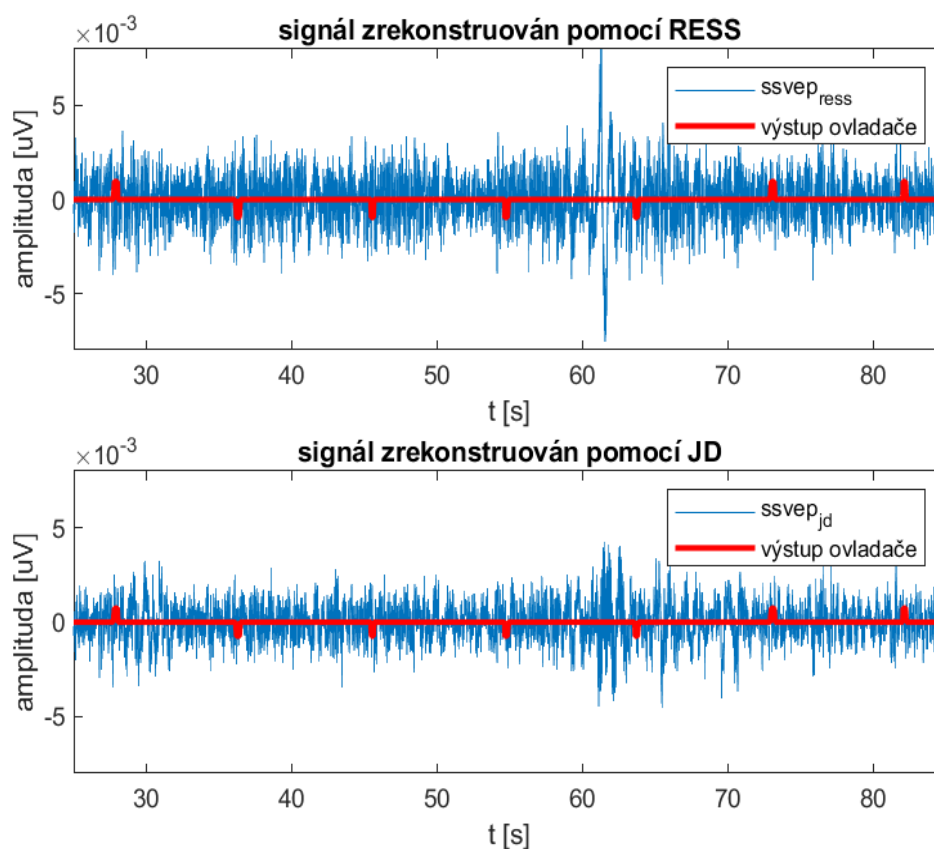
Obrázek 20: Výpočet odstupu signálu od šumu z průměrných výkonových spekter zprůměrované přes všechny subjekty. Zobrazen je poměr SNR pro první a druhé harmonické frekvence pro bloky signálu s rozdílnou frekvencí stimulu.

Podle teorie můžeme při detekci SSVEP očekávat zvýšenou aktivitu v okcipitální oblasti (konkrétně primární vizuální kortex). To potvrzují dvě průměrné topografické mapy, které ukazuje Obrázek 21. Topografické mapy pro každý subjekt jsou k nahlédnutí v příloze (Příloha A).



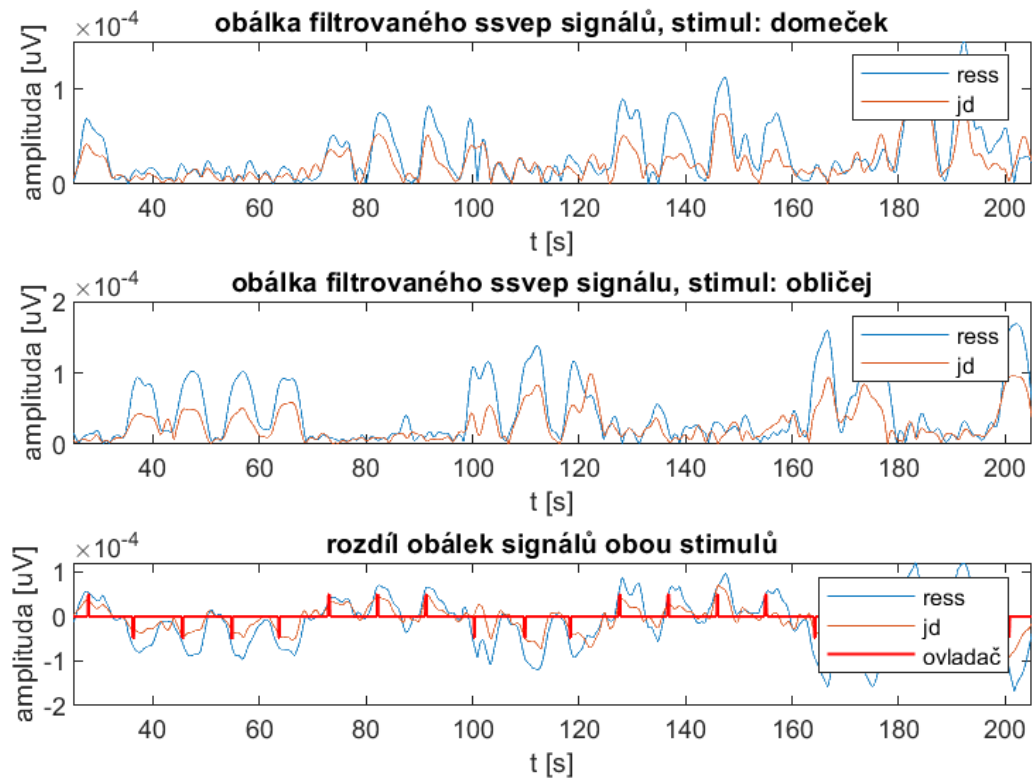
Obrázek 21: Topografické mapy zprůměrované přes všechny subjekty pro metodu JD a RESS. Obrázek nahoře ukazuje interpolované váhy popisující aktivitu signálu získaného metodou JD, dole pak analogicky obrázek pro aktivitu signálu získaného metodou RESS

Prostorově filtrovaný signál získaný aplikací vah vypočtených metodami RESS a JD na původní EEG data ukazuje Obrázek 22. Způsob, jakým byl prostorově filtrovaný signál dále filtrován úzkopásmovými Gaussovskými filtry je popsán v kapitole 2.5. Obrázek 23 ukazuje Absolutní hodnoty komplexních obálek pro signály filtrované na frekvencích jednotlivých stimulů a rozdíl komplexních obálek (obálka náležící obličejovému stimulu je odečtena od obálky náležící domečkovému stimulu). Rozdíl absolutních hodnot komplexních obálek je proložený křivkou signalizující odpověď subjektu ovladačem. Při kladné výchylce odpovídal subjekt ovladačem, že vnímal domeček, při záporné pak obličej. Obrázek 23 také ukazuje silnou závislost mezi rozdílem komplexních obálek a odpovědí subjektu ovladačem.



Obrázek 22: Signál vypočtený prostorovou filtrací původních EEG dat metodami JD a RESS (zrekonstruované prostorovým filtrem odpovídající vlastnímu vektoru náležící největšímu vlastnímu číslu).

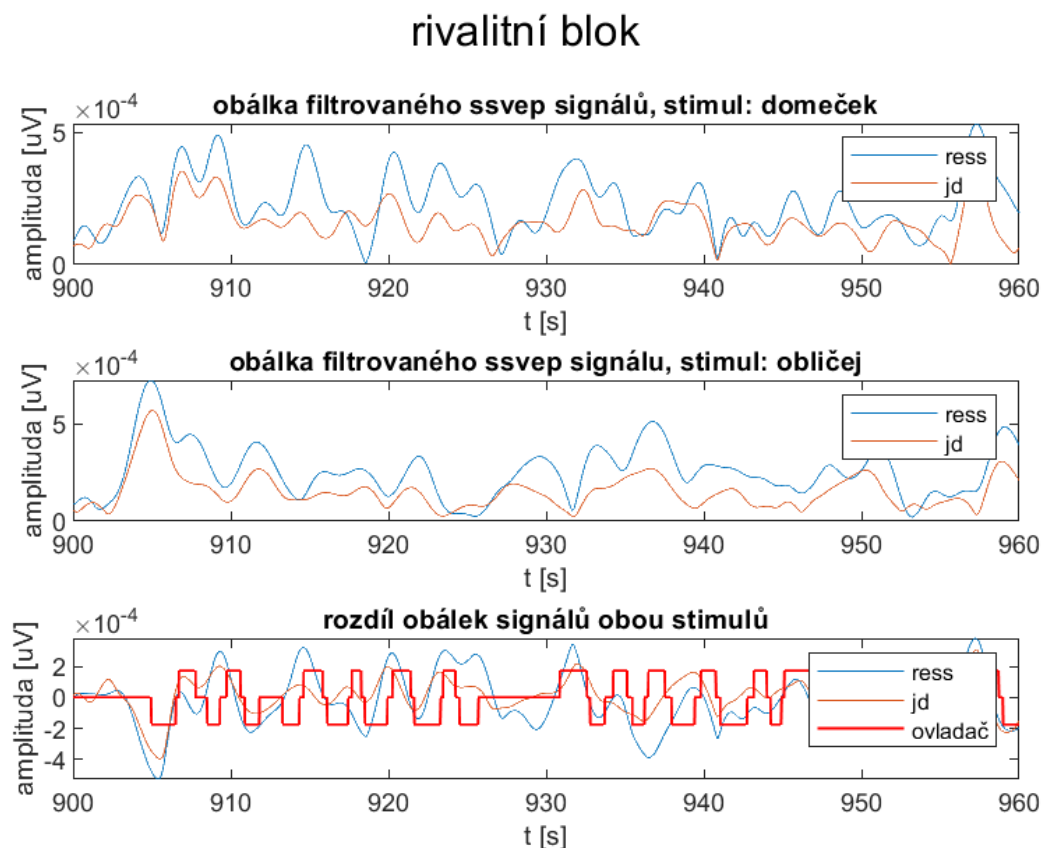
trénovací blok



Obrázek 23: Horní a prostřední graf ukazují absolutní hodnoty komplexních obálek signálů zrekonstruovaných metodami JD a RESS. Tyto signály jsou úzkopásmově filtrovány na frekvencích 6.67 Hz pro domečkový stimul a 8.57 Hz pro obličejový stimul. Průběh křivky na spodním grafu zobrazuje rozdíl absolutních hodnot komplexních obálek společně s proloženou červenou křivkou, která odpovídá reakcím (zmáčknutí tlačítka) subjektu na jednotlivé stimuly. Kladná výchylka u této křivky znamená že subjekt vnímá domeček, záporná pak vnímání obličej.

3.2 Úspěšnost metod JD a RESS v rivalitním bloku

V rivalitním bloku byly subjektu promítány dva rozdílné stimuly najednou. Subjekt zažíval střídavé vnímání jednotlivých stimulů. Toto střídavé vnímání ukazuje červený obdélníkový signál, kde kladná část ukazuje vnímání domečku a záporná vnímání obličeje. Zatímco v trénovacím bloku byla dobře znatelná závislost mezi amplitudou rozdílu komplexních obálek a signálem reprezentující odpověď subjektu, v rivalitním bloku je již tato závislost hůře znatelná. Průběhy jednotlivých signálů ukazuje Obrázek 24.




Obrázek 24: Horní a prostřední graf ukazují absolutní hodnoty komplexních obálek vypočtených z filtrovaných signálů zrekonstruovaných metodami RESS a JD na rozdílných frekvencích stimulů. Spodní obrázek ukazuje rozdíl absolutních komplexních obálek s obdélníkovým signálem reprezentující informaci z ovladače, kde kladný obdélník značí vnímání domečkového stimulu. Záporný obdélník pak značí, že subjekt vnímá obličejový stimul.

K vyhodnocení úspěšnosti metod JD a RESS v rivalitním bloku byl zvolen následující postup. V momentech, kdy došlo ke stisknutí tlačítka, bylo zkoumáno, zda došlo k výchylce amplitudy rozdílu komplexních obálek. Amplituda tohoto rozdílu se měnila podle toho, jaký stimul subjekt zrovna vnímal. U každého stisknutí bylo uvažováno časové okno začínající 200 ms před stiskem tlačítka do 500 ms po stisku tlačítka. Aby mohl být úsek, kdy subjekt reagoval tlačítkem na domeček, prohlášen za správně detekovaný musela být amplituda rozdílu obálek v tomto úseku z 80 % kladná.

Pro obličejový stimul bylo použito stejné okno s podmínkou, že amplituda rozdílu obálek musí být v tomto úseku z 80 % záporná. Maximální možný počet správně detekovaných úseků pro konkrétní stimul odpovídal počtu reakcí subjektu na tento stimul v celém rivalitním bloku.

Pro metodu RESS byl medián úspěšnosti detekce signálu náležící reakci na domeček 56.9 %. Pro obličej pak 53.2 %. Pro metodu JD byl medián úspěšnosti detekce reakce na domeček 53.0 %. Pro obličej 51 %. Průměrná doba jakou subjekt reagoval na vnímání domečku byla 1.79 ± 0.66 s. Průměrná doba vnímání obličeje pak byla 2.23 ± 0.86 s. Obrázek 25 ukazuje úspěšnost detekce pro obě metody v rivalitním bloku.



Obrázek 25: Úspěšnost detekce pro obě metody v rivalitním bloku zvlášť pro každý stimul. V čase reakce subjektu na stimul bylo zkoumáno, zda amplituda rozdílu obálek evokovaných potenciálů odpovídá reakci subjektu na stimul.

4 Diskuze

Detekce frekvencí stimulů v trénovacím bloku byla úspěšná pro obě metody, avšak pro metodu JD o něco méně než pro metodu RESS. Proč tomu tak je ukazují výkonová frekvenční spektra, kde výkony frekvencí stimulů v signálu, který byl extrahován metodou JD jsou značně menší než pro signál extrahovaný metodou RESS. Metoda RESS je tedy v tomto pohledu úspěšnější než metoda JD.

V této práci byly k analýze využívány první harmonické složky frekvencí stimulů a o vlivu vyšších harmonických frekvencí nebylo uvažováno. Z literatury zabývající se systémy BCI je známo, že zohlednění vlivu vyšších harmonických frekvencí může zlepšit klasifikaci SSVEP signálů [57].

Pro obě metody se podařilo zrekonstruovat topografické mapy, vykazující aktivitu v okcipitální oblasti. U některých subjektů byla aktivita v okcipitální oblasti znatelně vyšší. U několika subjektů lze vidět vliv rušení, které mohlo být způsobeno špatnou kvalitou dat. Až na výjimky, jsou si topografických mapy JD a RESS velice podobné. Výsledky metody JD předčily očekávání ve smyslu distribuce aktivity na skalpu, jelikož výsledek z literatury [9] ukazuje, že aktivita SSVEP signálů, které jsou zrekonstruované metodou JD se nachází mimo okcipitální oblast.

V rivalitním bloku nebyly metody JD a RESS úspěšné. V tomto bloku bylo zapotřebí detekovat rychlé změny amplitudy signálu. Dynamika SSVEP smohla být potlačena úzkopásmovou filtrací [9], což je při zkoumání rychlých fluktuací amplitudy nevhodné. Použitý úzkopásmový filtr ve spektrální oblasti sice oddělí dvě frekvence stimulů, dojde ovšem k potlačení rychlých změn signálu, které jsou reprezentovány okraji spektra, nikoli vrcholkem ve spektru na frekvenci stimulu [9]. Lepšího výsledku by mohlo být dosaženo vypočtením vah prostorových filtrů pro každou frekvenci stimulu zvlášť, tím bychom získali dva filtry, kde by každý z těchto filtrů zvýraznil pouze jednu frekvenci SSVEP namísto dvou. Po aplikaci vah na původní signál by nebyla potřeba dodatečná úzkopásmová filtrace, jako v našem případě.

5 Použitá literatura

- [1] HALLIDAY, A., W. MCDONALD a J. MUSHIN. Visual Evoked Response in Diagnosis of Multiple Sclerosis. *BMJ* [online]. 1973, **4**(5893), 661-664 [cit. 2022-02-22]. ISSN 0959-8138. Dostupné z: doi:10.1136/bmj.4.5893.661
- [2] HALLIDAY, A.M., W.I. MCDONALD a Joan MUSHIN. DELAYED VISUAL EVOKED RESPONSE IN OPTIC NEURITIS. *The Lancet* [online]. 1972, **299**(7758), 982-985 [cit. 2022-02-22]. ISSN 01406736. Dostupné z: doi:10.1016/S0140-6736(72)91155-5
- [3] BEDWELL, Jeffrey, Christopher SPENCER, Chi CHAN, Pamela BUTLER, Pejman SEHATPOUR a Joseph SCHMIDT. The P1 visual-evoked potential, red light, and transdiagnostic psychiatric symptoms. *Brain Research* [online]. 2018, **1687**, 144-154 [cit. 2022-03-29]. ISSN 00068993. Dostupné z: doi:10.1016/j.brainres.2018.03.002
- [4] TOWEY, James, Gerard BRUDER, Eric HOLLANDER, David FRIEDMAN, Hulya ERHAN, Michael LIEBOWITZ a Samuel SUTTON. Endogenous event-related potentials in obsessive-compulsive disorder. *Biological Psychiatry* [online]. 1990, **28**(2), 92-98 [cit. 2022-03-30]. ISSN 00063223. Dostupné z: doi:10.1016/0006-3223(90)90626-D
- [5] SÖRNMO, Leif a Pablo LAGUNA. *Bioelectrical Signal Processing in Cardiac and Neurological Applications* [online]. Boston: Elsevier, 2005 [cit. 2022-02-28]. ISBN 9780124375529. Dostupné z: doi:10.1016/B978-0-12-437552-9.X5000-4
- [6] MUKESH, T, V JAGANATHAN a M REDDY. A novel multiple frequency stimulation method for steady state VEP based brain computer interfaces. *Physiological Measurement* [online]. 2006, **27**(1), 61-71 [cit. 2022-02-22]. ISSN 0967-3334. Dostupné z: doi:10.1088/0967-3334/27/1/006
- [7] FRIMAN, Ola, Ivan VOLOSYAK a Axel GRASER. Multiple Channel Detection of Steady-State Visual Evoked Potentials for Brain-Computer Interfaces. *IEEE Transactions on Biomedical Engineering* [online]. 2007, **54**(4), 742-750 [cit. 2022-02-22]. ISSN 0018-9294. Dostupné z: doi:10.1109/TBME.2006.889160
- [8] COHEN, Michael X. Comparison of linear spatial filters for identifying oscillatory activity in multichannel data. *Journal of Neuroscience Methods* [online]. 2017, **278**, 1-12 [cit. 2022-02-23]. ISSN 01650270. Dostupné z: doi:10.1016/j.jneumeth.2016.12.016
- [9] COHEN, Michael a Rasa GULBINAITE. Rhythmic entrainment source separation: Optimizing analyses of neural responses to rhythmic sensory stimulation. *NeuroImage*

- [online]. 2017, **147**, 43-56 [cit. 2022-02-23]. ISSN 10538119. Dostupné z: doi:10.1016/j.neuroimage.2016.11.036
- [10] DE CHEVEIGNÉ, Alain a Lucas PARRA. Joint decorrelation, a versatile tool for multichannel data analysis. *NeuroImage* [online]. 2014, **98**, 487-505 [cit. 2022-02-23]. ISSN 10538119. Dostupné z: doi:10.1016/j.neuroimage.2014.05.068
- [11] GULBINAITE, Rasa, Tara VAN VIEGEN, Martijn WIELING, Michael COHEN a Rufin VANRULLEN. Individual Alpha Peak Frequency Predicts 10 Hz Flicker Effects on Selective Attention. *The Journal of Neuroscience* [online]. 2017, **37**(42), 10173-10184 [cit. 2022-04-27]. ISSN 0270-6474. Dostupné z: doi:10.1523/JNEUROSCI.1163-17.2017
- [12] SANCHEZ-LOPEZ, Javier, Caterina PEDERSINI, Francesco DI RUSSO et al. Visually evoked responses from the blind field of hemianopic patients. *Neuropsychologia* [online]. 2019, **128**, 127-139 [cit. 2022-04-27]. ISSN 00283932. Dostupné z: doi:10.1016/j.neuropsychologia.2017.10.008
- [13] GULBINAITE, Rasa, Diane ROOZENDAAL a Rufin VANRULLEN. Attention differentially modulates the amplitude of resonance frequencies in the visual cortex. *NeuroImage* [online]. 2019, **203** [cit. 2022-04-27]. ISSN 10538119. Dostupné z: doi:10.1016/j.neuroimage.2019.116146
- [14] HUSAIN, Aatif. *Illustrated manual of clinical evoked potentials*. New York: Springer Publishing Company, 2017, s. 1-34. ISBN 9781617050107.
- [15] PICTON, Terence, Otávio LINS a Michael SCHERG. The recording and analysis of event-related potentials. *Handbook Neuropsychology*. Elsevier, Amsterdam,: Elsevier Science B.V., 1995, **1995**(10), 3-73, 3-73 s.
- [16] NORCIA, Anthony, L. APPELBAUM, Justin ALES, Benoit COTTEREAU a Bruno ROSSION. The steady-state visual evoked potential in vision research: A review. *Journal of Vision* [online]. 2015, **15**(6) [cit. 2022-03-01]. ISSN 1534-7362. Dostupné z: doi:10.1167/15.6.4
- [17] SUR, Shravani a VK SINHA. Event-related potential: An overview. *Industrial Psychiatry Journal* [online]. 2009, **18**(1) [cit. 2022-04-09]. ISSN 0972-6748. Dostupné z: doi:10.4103/0972-6748.57865
- [18] GLASER, Edmund a Daniel RUCHKIN. *Principles of Neurobiological Signal Analysis*. New York: Academic Press, 1976. ISBN 0122859502, 9780122859502.
- [19] REGAN, D. Some characteristics of average steady-state and transient responses evoked by modulated light. *Electroencephalography and Clinical Neurophysiology* [online]. 1966,

- 20(3), 238-248 [cit. 2022-03-01]. ISSN 00134694. Dostupné z: doi:10.1016/0013-4694(66)90088-5
- [20] VIALATTE, François-Benoît, Monique MAURICE, Justin DAUWELS a Andrzej CICHOCKI. Steady-state visually evoked potentials: Focus on essential paradigms and future perspectives. *Progress in Neurobiology* [online]. 2010, **90**(4), 418-438 [cit. 2022-04-09]. ISSN 03010082. Dostupné z: doi:10.1016/j.pneurobio.2009.11.005
- [21] SRINIVASAN, Ramesh, F. BIBI a Paul NUNEZ. Steady-State Visual Evoked Potentials: Distributed Local Sources and Wave-Like Dynamics Are Sensitive to Flicker Frequency. *Brain Topography* [online]. 2006, **18**(3), 167-187 [cit. 2022-04-13]. ISSN 0896-0267. Dostupné z: doi:10.1007/s10548-006-0267-4
- [22] THORPE, Samuel, Paul NUNEZ a Ramesh SRINIVASAN. Identification of wave-like spatial structure in the SSVEP: Comparison of simultaneous EEG and MEG. *Statistics in Medicine* [online]. 2007, **26**(21), 3911-3926 [cit. 2022-04-13]. ISSN 02776715. Dostupné z: doi:10.1002/sim.2969
- [23] HSIANG-CHIH, Chang, Deng HUA-TING, Lee PO-LEI, Wu CHI-HSUN a Shyu KUO-KAI. *Proceedings of SICE Annual Conference: Real-time control of an SSVEP-actuated remote-controlled car*. 2010, **2010**, 1884-1887.
- [24] KOCH, Christof, Marcello MASSIMINI, Melanie BOLY a Giulio TONONI. Neural correlates of consciousness: progress and problems. *Nature Reviews Neuroscience* [online]. 2016, **17**(5), 307-321 [cit. 2022-03-02]. ISSN 1471-003X. Dostupné z: doi:10.1038/nrn.2016.22
- [25] TSUCHIYA, Naotsugu, Melanie WILKE, Stefan FRÄSSLE a Victor LAMME. No-Report Paradigms: Extracting the True Neural Correlates of Consciousness. *Trends in Cognitive Sciences* [online]. 2015, **19**(12), 757-770 [cit. 2022-03-03]. ISSN 13646613. Dostupné z: doi:10.1016/j.tics.2015.10.002
- [26] JAMISON, Keith, Abhrajeev ROY, Sheng HE, Stephen ENGEL a Bin HE. SSVEP signatures of binocular rivalry during simultaneous EEG and fMRI. *Journal of Neuroscience Methods* [online]. 2015, **243**, 53-62 [cit. 2022-02-22]. ISSN 01650270. Dostupné z: doi:10.1016/j.jneumeth.2015.01.024
- [27] JACK, Bradley N. Binocular Rivalry for Beginners. *I-Perception* [online]. 2012, **3**(8), 503-504 [cit. 2022-03-02]. ISSN 2041-6695. Dostupné z: doi:10.1068/i003ir


- [28] BROWN, Rick a Anthony NORCIA. A method for investigating binocular rivalry in real-time with the steady-state VEP. *Vision Research* [online]. 1997, **37**(17), 2401-2408 [cit. 2022-02-22]. ISSN 00426989. Dostupné z: doi:10.1016/S0042-6989(97)00045-X
- [29] WILKE, Melanie, Nikos LOGOTHETIS a David LEOPOLD. Generalized Flash Suppression of Salient Visual Targets. *Neuron* [online]. 2003, **39**(6), 1043-1052 [cit. 2022-03-21]. ISSN 08966273. Dostupné z: doi:10.1016/j.neuron.2003.08.003
- [30] COHEN, Michael X. A tutorial on generalized eigendecomposition for denoising, contrast enhancement, and dimension reduction in multichannel electrophysiology. *NeuroImage* [online]. 2022, **247** [cit. 2022-04-06]. ISSN 10538119. Dostupné z: doi:10.1016/j.neuroimage.2021.118809
- [31] COHEN, Mike X. *Analyzing Neural Time Series Data* [online]. The MIT Press, 2014 [cit. 2022-05-09]. ISBN 9780262319553. Dostupné z: doi:10.7551/mitpress/9609.001.0001
- [32] GOODFELLOW, Ian, Yoshua BENGIO a Aaron COURVILLE. *Deep Learning*. MIT Press, 2016. ISBN 9780262337373.
- [33] NIK AZNAN, Nik, Stephen BONNER, Jason CONNOLLY, Noura AL MOUBAYED a Toby BRECKON. On the Classification of SSVEP-Based Dry-EEG Signals via Convolutional Neural Networks. In: *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* [online]. IEEE, 2018, s. 3726-3731 [cit. 2022-05-09]. ISBN 978-1-5386-6650-0. Dostupné z: doi:10.1109/SMC.2018.00631
- [34] LAWHERN, Vernon, Amelia SOLON, Nicholas WAYTOWICH, Stephen GORDON, Chou HUNG a Brent LANCE. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of Neural Engineering* [online]. 2018, **15**(5) [cit. 2022-05-09]. ISSN 1741-2560. Dostupné z: doi:10.1088/1741-2552/aace8c
- [35] NUNEZ, Paul a Ramesh SRINIVASAN. *Electric Fields of the Brain* [online]. Druhé vydání. Oxford University Press, 2006 [cit. 2022-04-06]. ISBN 9780195050387. Dostupné z: doi:10.1093/acprof:oso/9780195050387.001.0001
- [36] BLANKERTZ, Benjamin, Ryota TOMIOKA, Steven LEMM, Motoaki KAWANABE a Klaus-robert MULLER. Optimizing Spatial filters for Robust EEG Single-Trial Analysis. *IEEE Signal Processing Magazine* [online]. 2008, **25**(1), 41-56 [cit. 2022-05-09]. ISSN 1053-5888. Dostupné z: doi:10.1109/MSP.2008.4408441
- [37] POURYAZDIAN, S. a A. ERFANIAN. Detection of Steady-State Visual Evoked Potentials for Brain-Computer Interfaces Using PCA and High-Order Statistics. DÖSSEL, Olaf a Wolfgang C. SCHLEGEL, ed., Olaf DÖSSEL, Wolfgang SCHLEGEL. *World Congress on*

- Medical Physics and Biomedical Engineering, September 7 - 12, 2009, Munich, Germany* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, s. 480-483 [cit. 2022-04-06]. IFMBE Proceedings. ISBN 978-3-642-03888-4. Dostupné z: doi:10.1007/978-3-642-03889-1_128
- [38] HYVÄRINEN, A. a E. OJA. Independent component analysis: algorithms and applications. *Neural Networks* [online]. 2000, **13**(4-5), 411-430 [cit. 2022-03-26]. ISSN 08936080. Dostupné z: doi:10.1016/S0893-6080(00)00026-5
- [39] JUNG, T.-P., C. HUMPHRIES, T.-W. LEE, S. MAKEIG, M.J. MCKEOWN, V. IRAGUI a T.J. SEJNOWSKI. Removing electroencephalographic artifacts: comparison between ICA and PCA. In: *Neural Networks for Signal Processing VIII. Proceedings of the 1998 IEEE Signal Processing Society Workshop (Cat. No.98TH8378)* [online]. IEEE, 1998, s. 63-72 [cit. 2022-04-08]. ISBN 0-7803-5060-X. Dostupné z: doi:10.1109/NNSP.1998.710633
- [40] HYVARINEN, A. Fast and robust fixed-point algorithms for independent component analysis. *IEEE Transactions on Neural Networks* [online]. 1999, **10**(3), 626-634 [cit. 2022-05-19]. ISSN 1045-9227. Dostupné z: doi:10.1109/72.761722
- [41] BELL, Anthony a Terrence SEJNOWSKI. An Information-Maximization Approach to Blind Separation and Blind Deconvolution. *Neural Computation* [online]. 1995, **7**(6), 1129-1159 [cit. 2022-05-19]. ISSN 0899-7667. Dostupné z: doi:10.1162/neco.1995.7.6.1129
- [42] KACHENOURA, Amar, Laurent ALBERA, Lotfi SENHADJI a Pierre COMON. Ica: a potential tool for bci systems. *IEEE Signal Processing Magazine* [online]. 2008, **25**(1), 57-68 [cit. 2022-05-19]. ISSN 1053-5888. Dostupné z: doi:10.1109/MSP.2008.4408442
- [43] DENG, Siyi, William WINTER, Samuel THORPE a Ramesh SRINIVASAN. EEG Surface Laplacian using realistic head geometry. *International Journal of Bioelectromagnetism*. 2011, **2011**(13), 173-177.
- [44] HJORTH, Bo. An on-line transformation of EEG scalp potentials into orthogonal source derivations. *Electroencephalography and Clinical Neurophysiology* [online]. 1975, **39**(5), 526-530 [cit. 2022-05-03]. ISSN 00134694. Dostupné z: doi:10.1016/0013-4694(75)90056-5
- [45] CARVALHAES, Claudio a J. DE BARROS. The surface Laplacian technique in EEG: Theory and methods. *International Journal of Psychophysiology* [online]. 2015, **97**(3), 174-188 [cit. 2022-05-04]. ISSN 01678760. Dostupné z: doi:10.1016/j.ijpsycho.2015.04.023


- [46] NIKULIN, Vadim, Guido NOLTE a Gabriel CURIO. A novel method for reliable and fast extraction of neuronal EEG/MEG oscillations on the basis of spatio-spectral decomposition. *NeuroImage* [online]. 2011, **55**(4), 1528-1535 [cit. 2022-04-22]. ISSN 10538119. Dostupné z: doi:10.1016/j.neuroimage.2011.01.057
- [47] CHEVEIGNÉ, Alain a Dorothée ARZOUNIAN. Scanning for oscillations. *Journal of Neural Engineering* [online]. 2015, **12**(6) [cit. 2022-04-22]. ISSN 1741-2560. Dostupné z: doi:10.1088/1741-2560/12/6/066020
- [48] SÄRELÄ, Jaakko, Harri VALPOLA a Michael JORDAN. Denoising source separation. *Journal of machine learning research*. 2005, (63).
- [49] DMOCHOWSKI, Jacek, Alex GREAVES a Anthony NORCIA. Maximally reliable spatial filtering of steady state visual evoked potentials. *NeuroImage* [online]. 2015, **109**, 63-72 [cit. 2022-04-22]. ISSN 10538119. Dostupné z: doi:10.1016/j.neuroimage.2014.12.078
- [50] DELORME, Arnaud, Jason PALMER, Julie ONTON, Robert OOSTENVELD, Scott MAKEIG a Lawrence WARD. Independent EEG Sources Are Dipolar. *PLoS ONE* [online]. 2012, **7**(2) [cit. 2022-03-20]. ISSN 1932-6203. Dostupné z: doi:10.1371/journal.pone.0030135
- [51] DEBNATH, Lokenath a Dambaru BHATTA. *Integral Transforms and Their Applications* [online]. Chapman and Hall/CRC, 2014 [cit. 2022-05-12]. ISBN 9780429162633. Dostupné z: doi:10.1201/b17670
- [52] OOSTENVELD, Robert, Pascal FRIES, Eric MARIS a Jan-Mathijs SCHOFFELEN. FieldTrip: Open Source Software for Advanced Analysis of MEG, EEG, and Invasive Electrophysiological Data. *Computational Intelligence and Neuroscience* [online]. 2011, **2011**, 1-9 [cit. 2022-04-19]. ISSN 1687-5265. Dostupné z: doi:10.1155/2011/156869
- [53] LIU, Quanying, Marco GANZETTI, Nicole WENDEROTH a Dante MANTINI. Detecting Large-Scale Brain Networks Using EEG: Impact of Electrode Density, Head Modeling and Source Localization. *Frontiers in Neuroinformatics* [online]. 2018, **12** [cit. 2022-05-04]. ISSN 1662-5196. Dostupné z: doi:10.3389/fninf.2018.00004
- [54] WANG, Ruiping, Xiaorong GAO a Shangkai GAO. Frequency Selection for SSVEP-based Binocular Rivalry. In: *Conference Proceedings. 2nd International IEEE EMBS Conference on Neural Engineering, 2005* [online]. IEEE, 2005, s. 600-603 [cit. 2022-05-14]. ISBN 0-7803-8710-4. Dostupné z: doi:10.1109/CNE.2005.1419696
- [55] ROY, Abhrajee, Keith JAMISON, Sheng HE, Stephen ENGEL a Bin HE. Deactivation in the posterior mid-cingulate cortex reflects perceptual transitions during binocular rivalry:

- Evidence from simultaneous EEG-fMRI. *NeuroImage* [online]. 2017, **152**, 1-11 [cit. 2022-03-26]. ISSN 10538119. Dostupné z: doi:10.1016/j.neuroimage.2017.02.041
- [56] HAUFE, Stefan, Frank MEINECKE, Kai GÖRGEN, Sven DÄHNE, John-Dylan HAYNES, Benjamin BLANKERTZ a Felix BIEßMANN. On the interpretation of weight vectors of linear models in multivariate neuroimaging. *NeuroImage* [online]. 2014, **87**, 96-110 [cit. 2022-04-24]. ISSN 10538119. Dostupné z: doi:10.1016/j.neuroimage.2013.10.067
- [57] ÇETIN, Volkan, Serhat OZEKES a Hüseyin VAROL. Harmonic analysis of steady-state visual evoked potentials in brain computer interfaces. *Biomedical Signal Processing and Control* [online]. 2020, **60** [cit. 2022-05-04]. ISSN 17468094. Dostupné z: doi:10.1016/j.bspc.2020.101999
- [58] CHRISTOF, Koch. *The Quest for Consciousness: A Neurobiological Approach*. United Kingdom: Roberts & Company Publishers, 2004. ISBN 9781936221042.
- [59] ODOM, J., Michael BACH, Colin BARBER, Mitchell BRIGELL, Michael MARMOR, Alma TORMENE a Graham HOLDER. Visual evoked potentials standard (2004). *Documenta Ophthalmologica* [online]. 2004, **108**(2), 115-123 [cit. 2022-02-22]. ISSN 0012-4486. Dostupné z: doi:10.1023/B:DOOP.0000036790.67234.22
- [60] MATERKA, A. a P. PORYZAŁA. A Robust Asynchronous SSVEP Brain- Computer Interface Based on Cluster Analysis of Canonical Correlation Coefficients. HIPPE, Zdzisław S., Juliusz L. KULIKOWSKI, Teresa MROCZEK a Jerzy WTOREK, ed., Zdzisław HIPPE, Juliusz KULIKOWSKI, Teresa MROCZEK, Jerzy WTOREK. *Human-Computer Systems Interaction: Backgrounds and Applications 3* [online]. Cham: Springer International Publishing, 2014, s. 3-14 [cit. 2022-04-27]. Advances in Intelligent Systems and Computing. ISBN 978-3-319-08490-9. Dostupné z: doi:10.1007/978-3-319-08491-6_1
- [61] LANGNER, Oliver, Ron DOTSCHE, Gijsbert BIJLSTRA, Daniel WIGBOLDUS, Skyler HAWK a Ad VAN KNIPPENBERG. Presentation and validation of the Radboud Faces Database. *Cognition & Emotion* [online]. 2010, **24**(8), 1377-1388 [cit. 2022-05-13]. ISSN 0269-9931. Dostupné z: doi:10.1080/02699930903485076

Příloha A



Obrázek 26: Topografické mapy pro všechny zkoumané subjekty vypočtené jako skalární součiny SSVEP signálu zrekonstruovaného metodou RESS s původními EEG daty.



Obrázek 27: Topografické mapy pro všechny zkoumané subjekty vypočtené jako skalární součiny SSVEP signálu zrekonstruovaného metodou JD s původními EEG daty.

Příloha B

begi	Začátek experimentu nebo bloku
HRep	Prezentace domečku v replay bloku
FRep	Prezentace obličeje v replay bloku
RFix	Fixační kříž v replay bloku
Hous	Report subjektu - vidím domeček
Face	Report subjektu - vidím obličej
Neut	Report subjektu - neurčitý obsah
SFix	Fixační kříž ve flash suppression bloku
SEnd	Konec trialu ve flash suppression bloku
Hrs1	Domeček vpravo jako první stimul
Hrs2	Domeček vpravo jako druhý stimul (flash suppression)
Hls1	Domeček vlevo jako první stimul
Hls2	Domeček vlevo jako druhý stimul (flash suppression)
Frs1	Obličej vpravo jako první stimul
Frs2	Obličej vpravo jako druhý stimul (flash suppression)
Fls1	Obličej vlevo jako první stimul
Fls2	Obličej vlevo jako druhý stimul (flash suppression)

Tabulka 1: Tabulka použitých značek v EEG signálu