



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF BIOMEDICAL ENGINEERING

MAPOVÁNÍ POHYBOVÝCH ARTEFAKTŮ VE FMRI

MAPPING OF MOTION ARTEFACT IN FMRI

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. MARIE NOVÁKOVÁ

VEDOUCÍ PRÁCE

SUPERVISOR

prof. Ing. JIŘÍ JAN, CSc.

BRNO 2013



**VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ**

**Fakulta elektrotechniky
a komunikačních technologií**

Ústav biomedicínského inženýrství

Diplomová práce

magisterský navazující studijní obor
Biomedicínské inženýrství a bioinformatika

Studentka: Bc. Marie Nováková

ID: 115108

Ročník: 2

Akademický rok: 2012/2013

NÁZEV TÉMATU:

Mapování pohybových artefaktů ve fMRI

POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši ohledně měření a zpracování dat funkční magnetické rezonance (fMRI). 2) V rešerši se dále především věnujte pohybovému šumu ve fMRI a jeho nežádoucím projevům. 3) Navrhněte vhodnou metodiku pro mapování pohybového artefaktu. Ve fázi předzpracování dat se zaměřte se na funkce "unwarp" a zarovnání. U statistické analýzy dat jednotlivce věnujte pozornost parametrům statistického modelu, jejich prvním a druhým derivacím a možnosti konvoluce s hemodynamickou odezvou. 4) Proveďte analýzu na reálných fMRI datech podle navržené metodiky. 5) Získané výsledky v podobě pravděpodobnostních map a map ukazujících míru projevu diskutujte a zhodnoťte. 6) Vytvořte program v prostředí MATLAB, který bude provádět danou metodiku automaticky vhodným nastavením a voláním dílčích funkcí toolboxu SPM. Program musí umožňovat spouštění dávkového módu, aby bylo možné realizovat analýzy na skupinách osob.

DOPORUČENÁ LITERATURA:

- [1] HUETTEL, S. A., SONG, A. W., MCCARTHY, G. Functional Magnetic Resonance Imaging. 2nd edition. Sunderland: Sinauer Associates, Inc, 2009, p. 542, ISBN 9780878932863.
[2] BUXTON, R. B. Introduction to Functional Magnetic Resonance Imaging. Cambridge University Press, 2009, ISBN-13: 978-0521899956.

Termín zadání: 11.2.2013

Termín odevzdání: 24.5.2013

Vedoucí práce: prof. Ing. Jiří Jan, CSc.

Konzultanti diplomové práce:

prof. Ing. Ivo Provazník, Ph.D.

Předseda oborové rady

Prohlášení

Prohlašuji, že svoji diplomovou práci na téma Mapování pohybových artefaktu ve fMRI jsem vypracovala samostatně pod vedením vedoucího semestrálního projektu a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

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

V Brně dne 20. května 2013

.....
podpis autora

Poděkování

Děkuji vedoucímu diplomové práce prof. Ing. Jiřímu Janovi, CSc. a konzultantovi Ing. Michalu Miklovi, PhD. a Ing. Martinu Lamošovi za účinnou metodickou, pedagogickou a odbornou pomoc při zpracování mé diplomové práce. Dále děkuji pracovní skupině 1. Neurologické kliniky Fakultní nemocnice u sv. Anny v Brně. Na závěr také děkuji mojí matce za podporu po celou dobu mého studia.

V Brně dne 20. května 2013

.....
podpis autora

ABSTRAKT

Tato práce shrnuje princip magnetické rezonance a metodu funkční magnetické rezonance. Je zaměřena na projevy pohybových artefaktů ve fMRI datech a na metody předzpracování snímků, především jejich zarovnání. Zabývá se možností využití pohybových parametrů získaných při procesu zarovnání funkčních skenů k vytvoření map projevu pohybových artefaktů. V práci jsou navrženy, implementovány a testovány tři metody sloužící k vytvoření pravděpodobnostních, výkonových a statistických skupinových map ukazujících místa typicky postižená pohybovým artefaktem.

KLÍČOVÁ SLOVA

Funkční magnetická rezonance, pohybové artefakty, zarovnání, obecný lineární model, regresor, statistická parametrická mapa, pravděpodobnostní mapa, výkonová mapa, statistická skupinová mapa

ABSTRACT

This thesis summarizes a theory of magnetic resonance and the method of functional magnetic resonance. It is focused on the influence of motion artifacts and image preprocessing methods, especially realign. It deals with the possibility of using movement parameters obtained in the process of alignment of functional scans to create maps that show the expression of motion artifacts. In this thesis, three different methods were designed, implemented and tested. These methods lead to the creation of probability, power and statistical group maps showing areas typically affected by movement artifacts.

KEYWORDS

Functional magnetic resonance, movement artifacts, realignment, general linear model, regressor, statistical parametric map, probability map, power map, statistical group map

BIBLIOGRAFICKÁ CITACE

NOVÁKOVÁ, M. *Mapování pohybových artefaktů ve fMRI*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2013. 86 s. Vedoucí diplomové práce prof. Ing. Jiří Jan, CSc..

Obsah

1	Úvod.....	3
2	Teorie magnetické rezonance	4
2.1	Rezonance atomových jader	4
2.2	Relaxační mechanismy	6
2.3	Pulsní sekvence.....	7
2.4	Kódování pozice	9
2.5	Artefakty v MRI datech	10
3	Funkční magnetická rezonance.....	11
3.1	Vznik BOLD signálu	11
3.2	Návrh fMRI experimentu.....	13
3.3	fMRI data.....	14
4	Artefakty ve fMRI datech.....	16
4.1	Nejvýznamnější artefakty postihující fMRI data	16
4.2	Fyziologický šum způsobený srdeční činností a respirací	16
4.3	Pohyb hlavy a s ním spojené artefakty.....	17
5	Předzpracování fMRI dat.....	20
5.1	Korekce akvizčních časů	20
5.2	Korekce zkreslení	20
5.3	Korekce pohybu.....	21
5.4	Koregistrace funkčních a anatomických snímků	25
5.5	Prostorová normalizace.....	25
5.6	Prostorové vyhlazení.....	26
5.7	Filtrace časového průběhu	26
5.8	Globální normalizace intenzity	27
6	Statistická analýza fMRI dat.....	28
6.1	T-test.....	28
6.2	F-test	28
6.3	Korelace a regrese.....	29
6.4	Obecný lineární model.....	29
6.5	Korekce pro mnohonásobné testování	31
6.6	Interpretace výsledných aktivačních map	32
6.7	Analýza jednotlivce jako vstup do skupinové analýzy	32
7	Reprezentace pohybových parametrů v GLM	33
7.1	Zahrnutí pohybových parametrů jako regresorů v GLM	33
8	Návrh metody mapování pohybových artefaktů.....	35
8.1	Navržený postup mapování pohybových artefaktů.....	35
8.2	Programové řešení navržených metod	45
9	Výpočet a interpretace výsledků získaných navrženými metodami.....	56
9.1	Popis použitých dat.....	56

9.2	Interpretace dosažených výsledků	57
9.3	Diskuse	66
10	Závěr.....	70
11	Seznam zkratk	72
12	Seznam obrázků	73
13	Seznam použité literatury.....	75
14	Seznam příloh	78

1 Úvod

Data pořízená zobrazováním funkční magnetickou rezonancí poskytují informace o aktivitě a o lokalizaci jednotlivých funkčních oblastí mozku. Jsou proto velmi užitečným nástrojem pro pokrok v neurovědách a postupně se dostávají i do klinické praxe při předoperačních vyšetřeních. Proto je důležité data kvalitně předzpracovat a korektně statisticky vyhodnotit, aby byla omezena míra falešně pozitivních, ale i falešně negativních výsledků, a tím byla zvýšena specifická a senzitivita této zobrazovací metody. Cílem této práce bylo zabývat se především pohybovými artefakty vznikajícími při akvizici dat a jejich mapováním sloužícím k určení nejobvyklejších lokalit jejich projevu a míry s jakou měřená data ovlivňují.

Počáteční část práce je zaměřena na shrnutí znalostí o principech zobrazování magnetickou rezonancí a úvodu do funkční magnetické rezonance. V další části je pojednáno o předzpracování dat při funkčním zobrazování zejména o procesu vzniku a korekce pohybových artefaktů. Jsou zde vysvětleny základní principy zarovnání série snímků a metody *unwarp*, která slouží k potlačení geometrického zkreslení snímků způsobeného pohybem. Část teoretické práce je věnována statistické analýze dat, která umožňuje vytvoření aktivačních map ukazujících lokalizaci a míru aktivace daných mozkových oblastí.

V rámci práce byly navrženy tři různé metody sloužící k získání prostorových map projevu pohybových artefaktů. Tyto metody byly implementovány v programovém prostředí MATLAB (Matlab2011b) s využitím funkcí toolboxu SPM (spm8 – Statistical Parametrical Mapping) a testovány byly na reálných datech ze třech různých studií. Metody byly zaměřeny na možnost využití pohybových parametrů získaných při procesu zarovnání snímků k vytvoření pravděpodobnostních map zobrazujících lokality, s nejkonzistentnějším výskytem projevu pohybových artefaktů. Dále také výkonových map ukazujících míru projevu pohybového artefaktu v dané lokalitě a nakonec využití pohybových regresorů při skupinové analýze. V rámci práce byla také zvážena možnost konvoluce pohybových parametrů s hemodynamickou odezvou, jejich derivace a druhé mocniny a následné využití jako parametrů ve statistickém modelu.


2 Teorie magnetické rezonance

Magnetická rezonance je moderní tomografická zobrazovací metoda. Signálem je zde elektromagnetické vlnění v radiofrekvenční části spektra. Metoda magnetické rezonance vychází z principu interakce atomových jader majících vlastní magnetický moment s vnějším magnetickým polem. Kromě hlavního magnetického pole je pro akvizici obrazových dat a následnou korektní rekonstrukci obrazu nutná aplikace gradientních magnetických polí ve směru x, y, a z. Základní princip sběru dat vychází z umístění pacienta do magnetu a vybudení protonových jader v pacientově těle pomocí radiofrekvenční energie. K pozičnímu kódování se využívá již zmíněných gradientních magnetických polí. Indukcí v přijímacích cívkách je následně zaznamenán radiofrekvenční signál, vzniklý jako odezva protonových jader na excitační impuls. Výsledný obraz je pak vytvořen zpracováním dat z přijímacích cívek. [1]

2.1 Rezonance atomových jader

Některá jádra atomů vykazující nenulový spin (jedná se o vnitřní moment hybnosti, rotační pohyb, daný magnetickým a mechanickým momentem) se chovají na venek jako magnetické dipóly. Jak je patrné z obr. 1, mimo spinu vykazuje proton umístěný ve vnějším magnetickém poli precesní pohyb na přesně definované frekvenci. Tato frekvence, nazývaná Larmorova, je definována násobkem gyromagnetické konstanty γ , specifické pro každou látku, a velikostí vnějšího magnetického pole B_0 , ve kterém se proton nachází, viz následující vztah [1]


$$\omega_0 = \gamma B_0. \quad (1)$$



Obrázek 1: Precesní pohyb protonu [3]

Protony se mohou nacházet buď ve vysokoenergetickém, nebo nízkoenergetickém stavu. Je-li dipól protonu umístěn proti vnějšímu magnetickému poli, nachází se ve vysokoenergetickém stavu, naopak v klidu je orientován ve směru vnějšího magnetického pole. Přejít mezi těmito dvěma stavy je vždy doprovázen absorpcí nebo vyzářením radiofrekvenční energie na Larmorově frekvenci. [1]


Bez přítomnosti vnějšího magnetického pole se protony (pro lékařské aplikace nejčastěji využívané protony vodíku H^{-1}) v tkáni v důsledku tepelného pohybu orientují svými rotačními osami zcela náhodně a magnetické vlastnosti se tak v makroskopickém měřítku neprojeví. Zavedeme-li však vnější magnetické pole, protony vodíku se uspořádají paralelně s tímto polem a v souladu s Boltzmanovým distribučním zákonem se na vyšší energetické hladině, tedy proti směru magnetického pole (antiparalelní uspořádání), bude nacházet menší počet jader. Tento fakt vede ke vzniku vektoru magnetizace M_z ve směru pole B_0 . Na základě toho, že protony vykonávají precesní pohyb, by se dalo očekávat, že bude měřitelný i jistý magnetický moment v rovině os x a y . V praxi tomu tak však bez dodání radiofrekvenční energie není, jelikož se směr magnetického momentu každého z precedujících protonů v čase mění a protony se tak nacházejí v různých fázích. Tím dochází k vyrušení jejich vlivu na výsledný vektor magnetizace M_{xy} . Dodáme-li protonu radiofrekvenční (RF) energii na frekvenci ω_0 , dojde k sfázování precedujících protonů, což ve výsledku vede ke vzniku příčné složky magnetizace. Dále dochází dodáním RF impulsu k nutačnímu pohybu výsledného vektoru magnetizace M , přičemž úhel vychýlení tohoto vektoru je dán energií aplikovaného RF impulsu. Nutaci vektoru M si je možné představit jako současnou precesi a pohyb vedoucí k vychýlení vektoru M o daný úhel viz obr. 2. [1]



Obrázek 2: Nutací pohyb [3]

Úhel vychýlení vektoru M závisí na integrálu dodané energie, tzn. na velikosti RF impulsu a na délce jeho trvání. Je-li úhel vychýlení 90° , byl aplikován takzvaný 90° RF impuls a vektor M se tak překlápí do roviny os x a y ($M_z \rightarrow M_{xy}$). Tento proces je doprovázen postupným poklesem velikosti složky vektoru M v ose z a naopak nárůstem jeho velikosti v rovině x a y . Dále např. při aplikaci 180° RF impulsu dojde k překlapaní vektoru M o 180° , čili opět do směru osy z , avšak v opačném směru ($M_z \rightarrow -M_z$). Vychýlení vektoru magnetizace do roviny os x a y má praktický význam pro možnost zaznamenání jeho velikosti, jelikož právě


v tomto směru se nachází přijímací cívky detektoru, ve kterých se indukuje napětí úměrné velikosti magnetizace v tomto směru. Tento signál s exponenciálně klesající amplitudou je označován FID (free induction decay) a jeho průběh je znázorněn na obr. 3. [1]



Obrázek 3: Průběh FID signálu [3]

2.2 Relaxační mechanismy


Vlivem interakce rezonujících jader s okolním prostředím dochází po ukončení trvání RF impulsu k tzv. relaxačním mechanismům, které navrací protony do termodynamické rovnováhy, kdy $M_{xy} = 0$ a $M_z = M_0$. Základními relaxačními mechanismy jsou spin-mřížková a spin-spinová interakce. Během spin-mřížkové interakce dochází k podélné relaxaci, při níž se vektor magnetizace navrácí do osy z. Tento proces je způsoben interakcí s magnetickým šumem generovaným termálním pohybem molekul a je závislý na velikosti molekuly, vazbě atomů, teplotě, koncentraci jader a viskozitě. Podélná relaxace je popsána T1 relaxační křivkou exponenciálního tvaru, viz obr. 4. Zde je důležité si povšimnout konstanty T1, která udává čas, kdy dojde k obnovení velikosti M_z na 63% původní velikosti. Díky rozdílům v relaxační době jednotlivých tkání, které způsobují modulaci kontrastu ve výsledném obrazu, je možné rozlišovat na MR snímcích jednotlivé druhy tkání. [1]



Obrázek 4: T1 relaxace

Spin-spinová T2 relaxace je způsobena vlivem vnitřních a vnějších nehomogenit magnetického pole B_0 . Vliv gradientních polí navíc vede k definici T2*. Spin-spinová interakce

vede k příčné relaxaci, tedy ke ztrátě fázové koherence, která je způsobena rozdílnou frekvencí precese jednotlivých protonů v nedokonale homogenním poli. K jejímu popisu se využívá také exponenciální T_2 relaxační křivka viz obr. 5, kde konstanta T_2 určuje čas, v němž dojde k poklesu velikosti příčné magnetizace M_{xy} na 37% původní velikosti. Tím, jak se zmenšuje velikost M_{xy} , dochází také k poklesu FID signálu. U lidských tkání navíc platí, že $T_2^* < T_1$. [1]




Obrázek 5: T_2^* relaxace

2.3 Pulsní sekvence

Jak již bylo zmíněno výše, měří se velikost vektoru magnetizace v rovině xy . V této rovině je měřen FID signál, který je úměrný složce M_{xy} (čili počtu jader v rovině xy) a modulován je ztrátou fázové koherence T_2^* . S ohledem na různé kombinace a časování RF impulsů je možné docílit váhování přijímaného signálu různým primárním parametrem. Tím může být počet vodíkových jader, T_1 , T_2^* časy nebo např. průtok krve. Výsledný kontrast ve snímcích je pak způsoben variabilitou relaxačních časů různých tkání a specifickým uspořádáním budících impulsů a časů snímání signálu. Hlavními parametry budící sekvence jsou energie excitačního pulsu, repetiční čas TR a čas odezvy (echo-time) TE . Velikost energie excitačního pulsu udává velikost sklopení vektoru magnetizace a tím i čas, který je nutný pro jeho návrat do rovnovážného stavu. TR vyjadřuje dobu, po které je opakován excitační puls. Pokud se zkracuje tato doba, omezuje se tak čas potřebný k T_1 relaxaci. Aplikací dalšího RF impulsu je přitom možné docílit, že nedojde k úplné podélné relaxaci a vektor magnetizace je ještě před dosažením rovnovážného stavu naklopen o další zvolený úhel. TE udává čas, za který je od aplikace RF impulsu snímán indukovaný rezonanční signál. Jádra s kratším časem T_2^* , u kterých dojde k rozfázování (ztrátě fázové koherence) rychleji, tak budou pro delší časy TE přispívat k výslednému přijímanému signálu méně. Základními budícími sekvencemi jsou SaturationRecover SR, Stimulated/Hahn Echo STE, InversionRecover IR, Spin Echo SE a Gradient Echo GRE. [1, 2]

Pro aplikace fMRI je podstatný princip GRE stimulačních sekvencí. Tato technika je podobná technice SE, která zde proto bude krátce nastíněna. SE budící sekvence se skládá z 90° RF impulsu a až několika následujících 180° pulsů, viz obr. 6. Nejprve je aplikován 90° impuls, ten překlápí vektor magnetizace do roviny xy

a způsobí jeho sfázování. Soufázovost však vlivem T2 relaxace začne postupně klesat, čím jak protony začnou precedovat na mírně jiných frekvencích. Před plnou T2 relaxací je zaveden další, tentokrát 180° impuls. Ten překlápí jednotlivé spiny v rámci roviny xy o 180° a docílí tak jejich postupného zsfázování. Právě toto sfázování je snímáno přijímací cívkou jako nárůst signálu a je označováno jako ECHO signál. Pokles amplitudy tohoto signálu vůči amplitudě FID signálu je závislý na T2 tkáně (T2* se zde však neuplatňuje). Různých kontrastů obrazu je možné docílit různým nastavením časů TR a TE. [1, 2]



Obrázek 6: SE sekvence


Samotná GRE budící sekvence patrná na obr. 7 začíná taktéž 90° impulsem, po němž však nenásleduje 180° impuls, ale k opětovnému sfázování precedujících protonů se využívá gradientních magnetických polí. Zavedením gradientního pole nejprve dojde ke změně precesních frekvencí jednotlivých protonů a tak i k rozsfázování jejich spinů. Aplikací gradientního pole s opačným znaménkem dojde k opětovnému sfázování a vzniku echo signálu. Amplituda echa je pak závislá na T2* relaxačním čase. Díky kratším TE časům a využití menších nežli 90° velikosti excitačních pulsů je možné zkrácení TR časů a tím docílení rychlejšího zobrazování. [1, 2]



Obrázek 7: GRE sekvence

Technika EPI (echo planar imaging), viz obr. 8, je nejrychlejší akviziční metoda MRI. Spočívá v efektivnějším plnění k-prostoru pomocí velmi rychlého přepínání gradientů. Kompletní 2D data jsou získána po jednom RF pulsu, který slouží pro vybuzení vybrané tomografické roviny. Spolu s tímto pulsem je zaveden gradient G_z , následovaný gradientem v téže směru, ale s opačnou fází, který slouží jako refokusační. Následně záporné gradienty G_x a G_y umístí počátek trajektorie plnění k-prostoru do limitní hodnoty v dolním levém rohu,

odkud jejich následným přepínáním bude postupně zaplňován k-prostor. Plnění probíhá tak, že po skončení gradientu G_x je na krátký okamžik zaveden gradient G_y , který přemístí trajektorii plnění prostoru o řádek výše. Následuje další gradient G_x , ovšem s opačným znaménkem nežli ten předcházející. Tento postup je opakován, dokud není vyplněn celý k-prostor v daném řezu. [2, 3]



Obrázek 8: EPI sekvence (vlevo) a způsob plnění k-prostoru

2.4 Kódování pozice

Aby bylo možné vytvoření obrazu, jenž by zachycoval prostorovou distribuci primárního parametru (nikoliv hodnotu pp z celého objemu), je nutné zavést poziční kódování. Tím je myšleno kódování v ose z, které určuje pozici a tloušťku tomografické vrstvy a taktéž kódování pozice v rámci vybrané tomografické roviny. Kódování tomografické roviny je docíleno pomocí zavedení přídavného gradientního magnetického pole paralelně s hlavním magnetickým polem B_0 . Na základě velikosti sklonu gradientu tohoto pole je pak určena šířka tomografické vrstvy, která je vybudena RF impulsem obsahujícím daný rozsah frekvencí odpovídající velikosti magnetického pole v dané vrstvě (dochází k tzv. selektivní excitaci). [1]

Pro kódování pozice v rámci vybrané vrstvy se používá frekvenční a fázové kódování. V ose x je zavedeno další gradientní magnetické pole, které zajistí frekvenční kódování. Zatímco v ose y je pomocí krátké aplikace gradientního magnetického pole, ihned po aplikaci RF pulzu, docíleno kódování fázového. Po krátkém zavedení gradientu totiž dojde k rozfázování jednotlivých spinů podél osy y. [1]

Měřený signál reprezentuje spektrum projekce v k-prostoru a tím tedy prostorovou distribuci vektoru magnetizace M_{xy} . Pro rekonstrukci obrazu se využívá Fourierova 2D rekonstrukční metoda. Postupně je zaplněn celý ortogonální datový k-prostor, který tak reprezentuje 2D Fourierovo spektrum snímané scény. Prostorová distribuce vektoru magnetizace, která nám na základě vybrané budící sekvence reprezentuje např. počet vodíkových jader či T1 (resp. T2) časy tkáně, je získána zpětnou Fourierovou transformací k-prostoru. [1]

2.5 Artefakty v MRI datech

MRI data bývají postižena mnoha různými artefakty. Tyto artefakty vznikají v důsledku fyzikálních procesů probíhajících při měření a jejich výskyt značně znesnadňuje analýzu rekonstruovaných snímků. Stručný přehled nejvýznamnějších MRI artefaktů je uveden níže. [1, 2]

Artefakt z chemického posunu – Tento artefakt se projevuje na rozhraní voda/tuk a vyplývá z interakce jejich lokálních magnetických polí s hlavním magnetickým polem, což ovlivňuje hodnotu Larmorovi frekvence a tím zavádí nepřesnosti při frekvenčním kódování pozice. Při rekonstrukci obrazu dochází ke zkreslení prostorové informace ve směru frekvenčního kódování a na rozhraní vzniká inverzní lem.

Aliasing (wrap-around artefakt) – Vzniká v případě, kdy je FOV menší nežli vyšetřovaná oblast těla, a dochází k podvzorkování v k-prosor. Část těla ležící mimo FOV se ve výsledném obrazu zobrazí na opačné straně ve směru kódování.

Susceptibilní artefakt – Je způsoben mikroskopickými odchylkami v homogenitě magnetického pole vznikajícími na rozhraní struktur s rozdílnou magnetickou susceptibilitou. Vzniklé nehomogenity vedou k rychlejšímu rozfázování spinů v okolních tkáních, čímž způsobí snížení intenzity signálu v daných místech a prostorové zkreslení obklopujících tkání. Nepřesnosti související s tímto artefaktem jsou přítomné především při dlouhých TE a při gradient-echo sekvencích.

Black boundary artefakt – Artefakt projevující se černým lemem na okrajích mezi vodou a tukem způsobený obsahem vody i tuku v zobrazovaném hraničním voxelu.

Phase-encoded pohybový artefakt (ghost artefakt) – Vzniká pohybem během akvizice dat a projevuje se v celém snímku jako světlý šum či světlé pruhování ve směru kódování fáze. Je způsoben tím, že pohybující se objekty získají chybnou pozici ve snímku ve směru fázového kódování a jsou tak zduplikovány na nepatřičná místa v obraze.

Gibbsův artefakt – Gibbsův artefakt se projevuje paralelními liniemi sousedícími s oblastí s velkou změnou intenzity a je způsobený konečným počtem prostorových frekvencí při Fourierově rekonstrukci obrazu.

Partial volume artefakt – Vzniká v důsledku omezené velikosti voxelu. Dochází při něm k průměrování signálu z více odlišných tkání přítomných v jednom voxelu.

3 Funkční magnetická rezonance

Jednou z aplikací teorie magnetické rezonance je funkční zobrazování mozku. Funkční magnetická rezonance (fMRI) patří spolu např. s EEG a PET k metodám, které dokážou lokalizovat mozkovou aktivitu a sledovat komunikaci mezi jednotlivými mozkovými centry. Tím se tato metoda stává dominantní metodou v neurovědách, kde vědci a lékaři jsou s její pomocí schopni vyšetřovat aktivitu jednotlivých mozkových center a zkoumat vztahy mezi nimi. fMRI tedy neslouží na rozdíl od klasického MRI zobrazování k zobrazení morfologie, ale k zobrazení funkčních parametrů tkáně. [4]

fMRI lze provádět dvěma základními způsoby. Prvním je zobrazování změn prokrvení zkoumané tkáně, takzvané perfuzní fMRI. Druhá, častěji používaná metoda je tzv. BOLD fMRI (blood oxygenation level dependent). BOLD fMRI využívá k zobrazení aktivních center změny v poměru oxygenované a neoxxygenované krve během mozkové činnosti. Během každého experimentu je pomocí MR tomografu nasnímáno mnoho obrazů objemu dané části mozku vyšetřované osoby v po sobě jdoucích časových intervalech. Během tohoto snímání se střídají předem důkladně promyšlené experimentální podmínky, jejichž vhodným uspořádáním je možné sledovat změny v činnosti konkrétních mozkových center (např. motorických, kognitivních...). Výsledný získaný časový průběh signálu z každého nasnímaného voxelu je vyhodnocován zvláště porovnáním s předpokládaným průběhem odezvy BOLD signálu v případě aktivace. V případě, že je statisticky vyhodnocena shoda mezi těmito signály, může být dané místo označeno za aktivní při dané činnosti. Výsledkem fMRI bývá aktivační mapa, ze které je možné vyčíst lokalizaci jednotlivých mozkových center a jejich participaci na daných motorických, senzitivních, kognitivních či jiných procesech. [2, 3, 4]

Funkční magnetická rezonance má své místo nejen v neurovědním výzkumu, ale stává se důležitou i pro klinickou praxi v oblasti předoperačních vyšetření. Je využívána k lokalizaci mozkových funkcí, například lokalizaci řečových center před resekci tumorů, lateralizaci jazykových funkcí při chirurgickém léčení epilepsie, lokalizaci spontánní mozkové aktivity nebo sledování mozkové plasticity při zraněních nebo nemocech. Právě při těchto aplikacích fMRI je velmi důležité, aby výsledky byly co nejméně ovlivňovány arteficiálním signálem nebo alespoň, aby byl brán zřetel na fakt, že data mohou být různými artefakty ovlivněna. [5]

3.1 Vznik BOLD signálu

3.1.1 Šíření informace neuronovou sítí

Základním článkem přenosu informací v lidském těle jsou neurony. Jejich vzájemným spojením mohou být předávány a uchovávány získané informace. Vedení vzruchu, který kóduje danou informaci, je dosaženo převodem akčního potenciálu neuronovou sítí. Akční potenciál se šíří jako změna membránového potenciálu neuronu ve smyslu její depolarizace

a následné opětovné repolarizace. Přenos informace z jednoho neuronu na druhý probíhá přes synaptická spojení. V nich se depolarizací presynaptické membrány uvolní neurotransmitery, které na postsynaptické membráně druhého neuronu způsobí změny její propustnosti následované její depolarizací a tím umožní další postup akčního potenciálu. K tomu, aby bylo možné pomocí iontových pump obnovit klidový membránový potenciál a aby mohlo dojít k vylití a zpětnému načerpání neurotransmiterů, je potřebná energie. Energie ve formě ATP je pro neurony získávána primárně z glukózy a kyslíku. Tyto metabolity jsou k cílovým buňkám dopravovány vaskulárním systémem. Hlavním a pro fMRI nejdůležitějším důsledkem vaskulární odezvy na neuronální aktivitu je zvýšení zásobování aktivní tkáně kyslíkem a tím způsobená změna v poměru oxyhemoglobinu a deoxyhemoglobinu. [2, 6]

3.1.2 Vliv lokálního poměru oxygenace krve na T2* signál


Sledování mozkové aktivity na základě rozdílných vlastností oxyhemoglobinu a deoxyhemoglobinu je základním principem pro BOLD (blood oxygenation level dependend) fMRI. Molekula hemoglobinu totiž vykazuje rozdílné magnetické vlastnosti v závislosti na tom, zda na ní je či není navázaná molekula kyslíku. Zatímco oxygenovaný hemoglobin je diamagnetický, deoxygenovaný hemoglobin vykazuje vlastnosti paramagnetické. Celkově deoxygenovaná krev tak má o 20% vyšší magnetickou susceptibilitu nežli dokonale oxygenovaná krev. Paramagnetické látky dokážou zkreslovat magnetické pole, které je obklopuje, čímž mění intenzitu vnějšího magnetického pole, které působí na zobrazované protony. Tím mění jejich precesní frekvenci, což vede k rychlejšímu poklesu příčné magnetizace a tím i kratšímu T2* času. Při fMRI zobrazování to tedy znamená zvýšení T2* signálu v aktivních oblastech, kde je větší zastoupení oxyhemoglobinu. Budící sekvencí používanou pro BOLD fMRI je gradientní echo a to právě díky jeho vlastnosti reagovat na pokles T2* signálu. [2, 3]

3.1.3 Průběh hemodynamické odezvy

Změna časového průběhu MR signálu daného voxelu, která je odezvou na aktivaci v dané oblasti, se označuje jako hemodynamická odezva (hemodynamic response function = HRF), viz obr. 9. Její tvar je závislý především na velikosti a době trvání stimulu, nicméně se mírně liší i s ohledem na rozdílné mozkové oblasti. Větší neuronální aktivita vede k zvýšení amplitudy HRF a delší trvání stimulu vede k jejímu širšímu průběhu. HRF je za neuronálními událostmi, které jí vyvolali, vždy o krátký časový úsek zpožděná (zhruba 2 sekundy). Průběh HRF lze rozdělit na několik dílčích částí. Prvním je malý iniciační pokles MR signálu, po zhruba 2 sekundách začne signál postupně narůstat, tím jak se do aktivované oblasti začne dostávat více oxyhemoglobinu nežli je tkáň schopná spotřebovat. Svého maxima HRF dosahuje po zhruba 5 sekundách a celková doba je okolo 20 s. [2, 3]

Pro vytvoření modelu signálu sloužícího ke srovnání s naměřenými daty, je nutné modelovat průběh HRF. V této souvislosti předpokládáme linearitu HRF. Což znamená, že

změny v relativní amplitudě neuronální aktivity jsou úměrné změnám v amplitudě HRF, a že platí princip superpozice v krátkém intervalu následujících HRF. [2]



Obrázek 9: Modelový průběh hemodynamické odpovědi [7]

3.2 Návrh fMRI experimentu

Pro tvorbu správného fMRI experimentu je nutné nejprve stanovit hypotézu, která se má ověřovat. Dále musí být určeny experimentální podmínky, jejichž pomocí je možné tuto hypotézu potvrdit či vyvrátit. Základním problémem při funkčním zobrazování mozku je, že není možné kvantifikovat klidovou úroveň signálu. Tím, že neexistuje informace o základním stavu, je nutné vždy fMRI experiment vytvářet tak, aby byly proti sobě srovnávány minimálně dva různé stavy. Jeden z nich uvažovaný jako klidový (ačkoliv vyšetřovaná osoba může při tomto stavu vykazovat velkou míru mozkové činnosti) a druhý stav, kdy dochází ke specifické aktivitě. Klidový stav je označován za klidový proto, že je ve stejné míře zastoupen jak při „klidu“, tak i během vykonávání experimentální činnosti. Dalším omezením, se kterým je nutné se vypořádat, je velmi malá změna signálu při změně experimentálních podmínek. V důsledku toho je nutné pro vyhodnocování dat získat jejich velké množství a vyhodnocení provádět statisticky. Nakonec je kvůli fluktuacím a driftu snímaného signálu důležité střídat experimentální stimulační stavy v přiměřeně dlouhých časových intervalech (problém při dlouhém trvání bloků v blokovém designu). Typy experimentů lze rozdělit do tří základních kategorií. Jedná se o blokový design, event-related design a smíšený design. [2, 3, 4]

3.2.1 Blokový design


Jak je patrné z obr. 10, v blokovém designu jsou sledované osobě prezentovány série stimulů v časově souvislých úsecích, přičemž se v jednotlivých blocích střídají odlišné experimentální podmínky. Vyhodnocovány jsou pak relativní změny mezi jednotlivými bloky. [2, 3, 4]

3.2.2 Event-related design

Druhým typem je event-related design. V něm jsou měřeny odezvy na jednotlivé události. Díky tomu, že jednotlivý stimul trvá pouze krátkou dobu, je možné, pokud je dodržena jistá minimální vzdálenost mezi stimuly (zhruba 20 s), sledovat průběh HRF. Nicméně statistická výkonnost tohoto typu experimentu je nižší nežli při blokovém designu. Periodické uspořádání jednotlivých stimulů je v tomto typu experimentu výhodné, chceme-li mít informaci o klidovém stavu, nicméně jejich statistická síla je malá. Výhodnější tedy je, zavádět jednotlivé stimuly v různých časových intervalech, čímž se statistická účinnost zvýší. [2, 3, 4]

3.2.3 Smíšený design

Smíšený design využívá kombinaci jak bloků, tak i jednotlivých stimulů, a využívá se pro odlišení dlouhotrvajících aktivací od těch přechodných. [2, 3, 4]



Obrázek 10: Blokový a event-related design

Stimulace může být jak přímá, při níž pacient reaguje na nějaký např. vizuální, zvukový, čichový či bolestivý podnět, nebo nepřímá, kdy experimentátor udává pacientovi povely k činnosti. Stimuly mohou být cíleny na různé funkce: zrak a zraková percepce, emoce, paměť, kognitivní funkce, řečové funkce, senzomotorické funkce apod. [2, 3, 4]

3.3 fMRI data

Naměřená data se vždy sestávají ze série funkčních snímků, strukturálních snímků a informací o průběhu a časování experimentálních podmínek. Funkční snímky se sestávají z jednotlivých session. Termínem session je myšlen soubor funkčních snímků, tzv. skenů (celkových objemů mozku), které jsou nasnímány během experimentu bez přerušení. Funkční skeny, které se nejčastěji získávají pomocí EPI sekvencí, jsou snímány s repetiční dobou mezi

jednotlivými skeny v rozmezí 1,5 až 3 sekundy, časem snímání echa TE v řádech několika desítek milisekund a používaným úhlem sklopení $FA = 90^\circ$. Velikost voxelu v těchto snímcích bývá $3 \times 3 \times 3$ mm a jejich rozměr bývá 64×64 pixelů (případně 128×128 pixelů). Pro snímání strukturálního skenu se používá T1 váhování s repetiční dobou okolo 2 s, TE rámcově 4 ms a FA okolo 15° . Velikost voxelu bývá $1 \times 1 \times 1$ mm a rozměr 256×256 pixelů. Prostorové rozlišení fMRI snímků je dáno velikostí voxelu, zorným polem, velikostí matice voxelů, šířkou řezu a vlastnostmi vaskulárního systému. Časové rozlišení fMRI snímků je limitováno dobou trvání HRF vyplývající z vlastností vaskulárního systému. Je v řádech několika sekund a umožňuje tak vzájemné odlišení událostí, které po sobě následují minimálně s touto časovou prodlevou. Není proto možné dosáhnout až řádově sto milisekundového časového rozlišení (při snímání omezené části mozku) měřených dat, které umožňuje hardware a použitá pulsní sekvence. Čím je repetiční doba mezi snímáním skenů nižší, tím lépe je možné vzorkovat průběh HRF. Negativním důsledkem je však menší získaný echo signál. Běžně se proto využívá doba okolo 2 sekund. [2]

Data je nutné před samotnou statistickou analýzou předzpracovat. Základními kroky předzpracování jsou data upravena tak, aby byly minimalizovány artefakty spojené se snímáním a aby data byla co nejlépe připravena pro statistickou analýzu, která bude následovat. V rámci ní je vytvořen model průběhu signálu a je zkoumáno, jak jednotlivé části tohoto modelu vysvětlují variabilitu v naměřených datech. Nakonec mohou být prováděna skupinová srovnání a ROI (region of interest) analýza. Výsledkem jsou trojdimenzionální aktivační mapy zobrazující aktivní mozková centra, hemodynamické odpovědi nebo kauzální modely. [2, 3, 4]

4 Artefakty ve fMRI datech

4.1 Nejvýznamnější artefakty postihující fMRI data

Základní předpoklady při funkčním zobrazování mozku jsou: neměnná poloha zobrazovaných voxelů v průběhu měření, snímání celého 3D objemu mozku ve stejný čas, paradigma experimentu tvořící jediný zdroj variability v datech, identická morfometrie všech mozků a přesná korespondence obrazu s anatómií snímané oblasti. Tyto předpoklady zpravidla bývají během snímání porušeny v důsledku působení různých fyzikálních principů souvisejících s měřením, čímž v datech vznikají závažné artefakty komplikující analýzu. [2]

Veškerá naměřená data bývají postižena tepelným šumem lidského těla a radiofrekvenčních cívek, šumem předzesilovačů a kvantizačním šumem A/D převodníků. Závažná část šumu je způsobena nehomogenitami vnějšího magnetického pole způsobenými nedokonalým *shimmingem*, nelinearitami a nestabilitou gradientních polí či nepřesnostmi vysílacích a přijímacích cívek. Nepřesnosti do měření také zavádí pomalý drift scanneru, tedy pomalá změna statického magnetického pole. Data dále bývají zkreslena pohybovým šumem. Tím je především myšlen pohyb pacientovi hlavy, očí a jazyka. Kromě toho jsou data zkreslena fyziologickým šumem, způsobeným především srdeční činností a dýcháním, ale mimo jiné také spontánní neuronální činností, vaskulárními fluktuacemi, výkyvy metabolismu mozku či změnami chování a myšlení osoby během experimentu. [2]

Tepelný a systémový šum, přičemž oba jsou náhodné, prostorově nezávislé a nezávislé na experimentu, rostou se zvyšující se intenzitou magnetického pole lineárně a dominantní složkou šumu ve fMRI datech se tak stává pohybový a fyziologický šum, které rostou kvadraticky. V práci proto bude věnována pozornost především možnostem potlačení a mapování výskytu pohybového šumu. [2]

Projevy pohybových artefaktů jsou vzájemně úzce provázány a jejich kategorizace a určení, jakým způsobem se jednotlivé procesy budou projevovat je složitou problematikou. Za vznikem pohybových artefaktů stojí složité fyzikální procesy, které vedou k různým typům zkreslení snímků. Určit přesně, jakým způsobem bude měřený signál ovlivněn nějakým typem pohybu, je komplexní a velmi složitý problém, jelikož každý pohyb vede rovnou k několika fyzikálním procesům, které do měřených dat vnáší mnoho nepřesností a vedou k jejich zkreslení. Následující kapitoly jsou věnovány artefaktům spojeným s pohybem pacienta a to především s pohybem hlavy. [2]

4.2 Fyziologický šum způsobený srdeční činností a respirací

Šum způsobený srdeční činností se projevuje dvěma základními způsoby. Jednak krevní tok způsobuje, že přicházející spiny, které neobdrželi (s ohledem na jejich předchozí pozici

mimo excitovanou vrstvu) RF impuls, falešně zvyšují hodnotu signálu. Dále některé spiny putují tak rychle, že buď RF impuls ani neobdrží, nebo jsou krevním tokem posunuty mimo snímanou oblast dříve, než je provedena akvizice, což v důsledku způsobí úbytek signálu. Nakonec v souvislosti s pulsací cév dochází k posunu ve snímané rovině, což vede k získání dalšího fázového posunu a tím ke zkreslení signálu. Dýchání způsobuje především změny susceptibility vedoucí na změny v homogenitě B_0 a tím i příslušně intenzitní zkreslení snímků. Srdeční aktivita a dýchání se projevují jako periodické děje a pokud je obraz snímán s dostatečně rychlou vzorkovací frekvencí je možné tento pohyb minimalizovat během předzpracování pomocí filtrace signálu. Bohužel ve většině fMRI studií nebývá splněn předpoklad dostatečně rychlého vzorkování a dochází tak k aliasingu vlivem podvzorkování těchto periodických pohybů. Tím dochází ke zkreslení v obraze a zhoršuje se tak hrubý SNR. [2]

4.3 Pohyb hlavy a s ním spojené artefakty

Artefakty spojené s pohybem hlavy závisí především na čase, kdy k pohybu došlo, použité pulsní sekvenci, typu pohybu a amplitudě pohybu. Pohyb během akvizice jednotlivého řezu, který způsobuje *ghost* artefakt je zanedbatelný v důsledku velmi krátkého trvání doby snímání při využití EPI sekvencí. Díky tomu nedochází příliš ke zhoršování hrubého SNR, ale zhoršuje se s pohybem především funkční SNR. Většina vědeckých prací se tak zabývá především korekcí pohybů vzniklých mezi jednotlivými skeny. [2]

Pomineme-li pohybem způsobený samotný posuv obrazu, který je možné regulovat pomocí zarovnávacích metod, existuje několik základních mechanismů, jakými je snímáný objekt ovlivňován v důsledku jeho pohybu. V první řadě jsou to změny spojené se vzniklou nehomogenitou magnetického pole. *Shimming* se totiž upravuje pouze před každým měřením, nikoliv v jeho průběhu. Při pohybu subjektu ve skeneru tak vznikají nehomogeneity magnetického pole, které nejsou nijak korigovány. V důsledku to pak způsobuje susceptibilní artefakty, které je těžké z dat eliminovat. Dalším mechanismem je *spin-history* artefakt, vznikající v důsledku závislosti signálu na aktuální i předešlé pozici subjektu. [2, 8, 9]

Pokud je rozsah pohybu velký ($> 3\text{mm}$) a je spojen se stimulací, jsou výsledkem oblasti s falešně pozitivními výsledky aktivace. Bylo zjištěno, že i velmi jemný pohyb ($< 1\text{ mm}$) slabě spojený se stimulací může způsobovat falešně pozitivní aktivace. Navíc pohybové artefakty mohou navíc i zastírat aktivní oblasti, což ústí na falešně negativní detekci. [10, 11, 12]

4.3.1 Spin history artefakt

Ve fMRI je aktuálně snímáný signál funkcí jak aktuální pozice, tak i všech předešlých pozic během předchozích skenů. Tím posun během experimentu mění intenzitu v následujících skenech, a to i když tyto části nejsou sami zobrazovány (pohybem se dostanou mimo

zobrazovaný prostor). Vliv pozice předešlých skenů se do snímání zavádí přes tzv. *spin-history* artefakt. *Spin-history* artefakt se objevuje především ve voxelech, kde se nachází tkáň s $T_1 \gg TR$ a obsažené spiny tak nemohou dosáhnout před dalším excitačním pulsem rovnovážného stavu. Pokud by všechny spiny byly v rovnovážném stavu před akvizicí daného objemu, žádný *spin-history* artefakt by nebyl pozorovatelný. Avšak tím, že jednotlivé spiny jsou opětovně buzeny během velmi krátkého intervalu, nemůže docházet k jejich úplnému návratu do rovnovážného stavu a dostávají se tak pouze do ustáleného stavu. Změna pozice subjektu vůči skeneru způsobí, že posunutý objem obdrží RF impuls v jiném okamžiku než by měl a ve výsledku je pak vektor magnetizace vychýlen o jiný sklápěcí úhel, než je pro použitou budící sekvenci charakteristické. Intenzita signálu se v posunutých místech mění a tím zavádí artefakt do snímaných dat. Změna pozice je doprovázena přechodovou dobou, nutnou k nastolení nového ustáleného stavu. Přechodný stav může trvat po dobu několika skenů od změny pozice. [13, 14]

$$M_{zi} = M_0 - k[M_0 - M_{zi-1}(1 - \mu_{i-1})] \quad (1)$$

Rovnice č. 1 ukazuje vztah velikosti vektoru podélné magnetizace M_{zi} v čase skenu i na jeho předchozí pozici v čase skenu $(i-1)$ a na stupni excitace μ vyvolaném RF impulsem. M_0 vyjadřuje rovnovážný stav magnetizace a proměnná $k = \exp(-TR/T_1)$ vyjadřuje míru spinů navracených do rovnovážného stavu. [14]

Spin-history artefakt se projevuje při pohybu subjektu v rámci osy hlavního magnetického pole. To znamená, že obraz je tímto artefaktem zkreslen v případech, kdy dochází k translaci v ose z , nebo rotacím okolo os x a y . Pohyb v rámci snímaného řezu v rovině xy nemá vliv na změnu vychýlení vektoru magnetizace. [13, 14]

4.3.2 Susceptibilní artefakt

Susceptibilní artefakty se vyskytují jako důsledek mikroskopických gradientů magnetického pole, které vznikají na rozhraních tkání s různou magnetickou susceptibilitou. Tyto gradienty způsobují rozfázování spinujících protonů a změny v precesní frekvenci přilehlé tkáně. Výsledkem jsou pak světlé a tmavé lokality v okolí předmětu či tkáně s rozdílnou susceptibilitou a prostorové zkreslení okolí. V mozku se nachází mnoho přechodů oblastí s vysokým rozdílem v jejich magnetických susceptibilitách. Jedná se především o přechody vzduch/měkká tkáň a měkká tkáň/kost. Změny v rozsahu a prostorové distribuci MR signálu, které vznikají v důsledku nehomogenit magnetického pole, tak nezávisí pouze na parametrech sekvence, síle statického magnetického pole a orientaci v gradientním magnetickém poli, ale také na orientaci regionů s rozdílnou magnetickou susceptibilitou s ohledem na hlavní magnetické pole B_0 . V důsledku pohybu se tak na daných pozicích v mozku mění velikost součtu nehomogenit pole B_0 a nehomogenit na rozhraní tkání B_{roz} . Daná lokalita je tak během měření ovlivňována vždy jinou velikostí výsledné nehomogenity což vede k proměnnému

zkreslení snímků. Mikroskopické nehomogenity vedou ke změnám v $T2^*$ váženém signálu a způsobují jeho zeslabení. Změnu $T2^*$ signálu lze popsat následovně vztahem č. 2 [15]

$$\frac{1}{T2^*} = \frac{1}{T1} + \frac{\gamma}{2}(\Delta B_{bold} + \Delta B_{roz}), \quad (2)$$

kde ΔB_{roz} zahrnuje lokální změny pole závislé na reorientaci pozice rozhraní. Součet změn magnetických indukcí pak způsobuje na dané pozici v prostoru rozfázování. [15, 16]

Dále dochází ke změně precesních frekvencí přilehlých protonů a tedy ke zkreslení trajektorie k-prostoru. Po zpětné rekonstrukci obrazu tak dochází ke geometrickému zkreslení přilehlých oblastí. Toto zkreslení se snaží potlačit metoda unwarp, která z pohybových parametrů postupně odhaduje změnu mapy zkreslujícího pole, na jejímž základě se snaží eliminovat geometrické zkreslení z výsledných snímků. [8, 9, 15, 16, 17]

4.3.3 *Phase-encoded* pohybový artefakt

S pohybem souvisí také *phase-encoded* pohybový artefakt, který vzniká pohybem během akvizice dat, a který byl již zmíněn výše. S ohledem na velmi krátký časový okamžik snímání jednotlivých řezů je však zanedbatelný. [1]

5 Předzpracování fMRI dat

Získaná data je nutné před jejich statistickou analýzou nejprve co možná nejlépe zbavit nepřesností vzniklých během jejich akvizice, normalizovat je pro jejich možné porovnávání a předzpracovat tak, aby byla možná jejich přesnější a lépe interpretovatelná analýza. Základními kroky předzpracování jsou korekce pohybu, transformace do standardního prostoru, koregistrace funkčních a anatomických snímků, prostorové vyhlazení a filtrace časových řad signálu z jednotlivých voxelů. [2, 4]

5.1 Korekce akvizičních časů

Při vyhodnocování výsledků předpokládáme, že celý objem mozku je sejmut v jediném krátkém časovém okamžiku. Ve skutečnosti však akvizice jednoho skenu trvá s ohledem na repetiční čas TR 1,5 až 3 sekundy. Pokud je snímáno například 30 řezů, každý z řezů je sejmut v odlišnou dobu jednou za TR. Dochází tedy k tomu, že v různých vrstvách je v době akvizice HRF v odlišné fázi svého průběhu. Pro potlačení tohoto vlivu se využívá tzv. *slice-timing* neboli časová interpolace signálu na referenční okamžiky. Při některých experimentech je možné tuto korekci zanedbat a vyhnout se tak nepřesnostem pramenícím z interpolačních metod. [2]

5.2 Korekce zkreslení

Naměřená data mohou být postižena geometrickým či intenzitním zkreslením, které nejčastěji bývají způsobeny nehomogenitami pole. Nehomogenity statického pole obvykle způsobují geometrické zkreslení, avšak v některých případech mohou vést i ke ztrátě signálu. Nehomogenity excitačního pole způsobují intenzitní zkreslení signálu. Nehomogenity pole se běžně korigují *shimmingem*. To se provádí přidáním gradientních cívek vytvářejících magnetické gradienty vyšších řádů. I přes to však některé nehomogenity přetrvávají a zavádí tak proměnné zkreslení snímků v případě pohybu snímaného subjektu. [2]


Jiný způsob korekce představuje mapování magnetického pole, při němž je snaha o získání přesných znalostí o magnetickém poli. Mapa hlavního magnetického pole se získává srovnáním fází signálu dvou obrazů sejmutých s mírně odlišným TE. Fázový rozdíl v obrazech je přímo úměrný síle pole v daném místě. Pokud by v magnetickém poli nebyly přítomny žádné nehomogenity, výsledný obraz by byl po odečtení dílčích obrazů ve všech místech homogenní. Tyto mapy je možné vypočítat na základě snímání fantomu simulujícího lidský mozek a poté je zahrnout do procesu rekonstrukce obrazu. Obdobně se korigují i nehomogenity excitačních polí. [2]

5.3 Korekce pohybu

Jak již bylo zmíněno, pohyb způsobuje nejzávažnější typ šumu ve fMRI datech. K potlačení pohybů hlavy se využívá fixace pacienta ve skeneru. I přes to však dochází k jemným pohybům hlavy. [2]

5.3.1 Zarovnání

Zanedbáme-li vliv pohybu na vznik s ním spojených artefaktů, je stále nutné před samotnou analýzou provést zarovnání snímků tak, aby si jednotlivé oblasti v čase vzájemně odpovídali. Posunutí hlavy i o velmi malý úsek v rovině xy má za následek posun v obraze, který by se především na okrajích mozku projevil falešnou aktivací, viz obr. 11, pokud by nebyl korigován zarovnáním. Zarovnání se zabývá potlačením pohybu v rovinách x, y a z. Provádí však pouze zarovnání jednotlivých skenů vůči sobě, nikoliv korekci geometrického a intenzitního zkreslení, které je způsobeno daným pohybem. [2, 14]



Obrázek 11: Pohyb hlavy způsobující falešnou aktivaci [2]

Posunutí a natočení skenů v důsledku pacientova pohybu se koriguje šesti parametrickou rigidní transformací (3 translace a 3 rotace) tak, aby si po jejím provedení jednotlivé voxely ve skenech vzájemně odpovídaly. Zarovnání snímků se provádí vždy vůči referenčnímu objemu, kterým nejčastěji bývá první sken v sérii (příp. průměrný sken). Ostatní snímky jsou vždy brány jako pohyblivé a upravují (při rigidní transformaci - posouvají či rotují) se tak, aby co nejlépe odpovídaly pozici referenčního snímku. Po interpolaci pohyblivého snímku se vypočítá kritériální funkce a určí se, jak spolu dané obrazy korespondují. Optimalizací se pak hledá ideální sada parametrů tak, aby spolu obrazy co nejvíce korespondovaly. [2, 14]

Postup transformace vychází z předpokladu, že každý obraz $\Omega(\mathbf{x})$ je spojený rigidní transformací s referenčním obrazem $\tau(\mathbf{x})$. Transformace je popsána $\mathbf{q}(\mathbf{x}, \gamma)$ s parametry $\gamma = [\gamma_1 \dots \gamma_6]$. Transformace pohyblivého obrazu k referenčnímu obrazu v případě, že pohyb je malý s ohledem na prostorové vyhlazení snímku, je popsána následujícím vztahem [14]

$$\beta \cdot \tau(\mathbf{x}) \approx \Omega(\mathbf{q}(\mathbf{x}, \gamma)), \quad (3)$$

kde β popisuje šalovací konstantu. Při aproximaci prvního řádu rovnice č. 3, je možné najít řešení γ pomocí metody nejmenších čtverců. Výraz $\mathbf{q}(\mathbf{x}, \gamma)$ může být rozšířen jako funkce šesti vektorů $\partial \mathbf{q}(\mathbf{x}, \gamma) / \partial \gamma_k$ proměnné $\mathbf{x}$, kde $k = 6$, což odpovídá 6 parametrům rigidní transformace. Tento vztah popisují následující rovnice [14]

$$\mathbf{q}(\mathbf{x}, \gamma) \approx \mathbf{x} + \sum_k \gamma_k \partial \mathbf{q}(\mathbf{x}, \gamma) / \partial \gamma_k \quad (4)$$

$$\beta \cdot \tau(\mathbf{x}) \approx \Omega(\mathbf{x} + \sum_k \gamma_k \partial \mathbf{q}(\mathbf{x}, \gamma) / \partial \gamma_k) \quad (5)$$

Pokud je $\Omega(\mathbf{x})$ prostorově vyhlazený, účinek malých transformací $\gamma_k \partial \mathbf{q}(\mathbf{x}, \gamma) / \partial \gamma_k$ nebude velký a vztah č. 5 může být rozšířen Taylorovým rozvojem se zanedbáním vyšších řádů, viz vztah č. 6 [14]

$$\beta \cdot \tau(\mathbf{x}) \approx \Omega(\mathbf{x}) + \sum_k \gamma_k \nabla_{\mathbf{x}} \Omega(\mathbf{x}) \cdot \partial \mathbf{q}(\mathbf{x}, \gamma) / \partial \gamma_k \approx \Omega(\mathbf{x}) + \sum_k \gamma_k \partial \Omega(\mathbf{q}(\mathbf{x}, \gamma)) / \partial \gamma_k \quad (6)$$

Ze vztahu č. 6 vyplývá, že rozdíl mezi transformovaným a referenčním obrazem může být vyjádřen jak součet změn v transformovaném obrazu, pro každý parametr transformace, násobeno hodnotou tohoto parametru. Vztah č. 6 [14] lze převést do maticového zápisu jako

$$\Omega \approx \mathbf{G} [b\gamma]^T, \quad (7)$$

kde

$$\mathbf{G} \approx [\tau - \partial \Omega / \partial \gamma]. \quad (8)$$

Vypočteno je šest sloupců $\partial \Omega / \partial \gamma$ pomocí aplikování malých translací a rotací na $\Omega(\mathbf{x})$ a měření změn hodnot voxelů. Parametr b udává odhad proměnné β . Šest prvků řádkového vektoru γ odpovídá vyhodnoceným translacím a rotacím a může být vypočítáno ve smyslu metody nejmenších čtverců podle vztahu č. 9 [14]

$$[b\gamma]^T = (\mathbf{G}^T \cdot \mathbf{G})^{-1} \cdot \mathbf{G}^T \cdot \Omega. \quad (9)$$

Prakticky je každá transformace provedena ve třech dimenzích, výsledkem pak je celkem 6 parametrů. Jedná se o tři parametry určující posun v osách x , y a z a 3 parametry rotací podél těchto základních os. Translace bodu x do bodu y může být vyjádřena maticově podle vztahu č. 10 [3]

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & a_1 \\ 0 & 1 & 0 & a_2 \\ 0 & 0 & 1 & a_3 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ 1 \end{bmatrix}. \quad (10)$$

Rotace o q radiánů okolo osy x , y a z (v tomto pořadí) jsou maticově popsány vztahem č. 11. [3]

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & \cos(q_1) & \sin(q_1) & 0 \\ 0 & -\sin(q_1) & \cos(q_1) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos(q_2) & 0 & \sin(q_2) & 0 \\ 0 & 1 & 0 & 0 \\ -\sin(q_2) & 0 & \cos(q_2) & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos(q_3) & \sin(q_3) & 0 & 0 \\ -\sin(q_3) & \cos(q_3) & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ 1 \end{bmatrix} \quad (11)$$

Celková změna pozice daného bodu je pak násobkem translací a rotací.

Aby mohl být obraz upraven na základě vypočtených parametrů, je nutné provést jeho převzorkování a interpolaci hodnot na nových souřadnicích z okolních hodnot. Interpolace pohyblivého obrazu do nových souřadnic podle vypočtených pohybových parametrů velmi ovlivňuje výslednou kvalitu procesu zarovnání. Nejjednodušší metoda interpolace nejbližším sousedem je sice výpočetně velmi snadná, do dat však zanáší značné chyby. Při interpolaci nejbližším sousedem je hodnota nového voxelu odvozena přesně z hodnoty voxelu, který je mu svojí polohou nejbliž. Vhodnější je lineární interpolace, která přiřazuje konkrétnímu pixelu hodnotu podle hodnot jeho sousedů váhovaných jejich vzdáleností od vypočítávaného pixelu. V tomto případě se jedná o trilineární interpolaci. Hodnota voxelu je pak dána váhovaným průměrem sousedních voxelů. Další možností je B-spline interpolace, která pro svůj nultý a první řád vede na interpolaci nejbližším sousedem a na lineární interpolaci. Obecná B-spline interpolace n -tého stupně je popsána vztahem č. 12 [18]

$$\beta^n(x) = \sum_{j=0}^n \frac{(-1)^j (n+1)}{(n+1-j)! j!} \max\left(\frac{n+1}{2} + x - j, 0\right)^n \quad (12)$$


K identifikaci optimálních parametrů transformací se využívá podobnostních kritérií. Rozdílné fitness funkce jsou přitom citlivé na rozdílné aspekty obrazu. Nejjednodušší fitness funkcí je suma absolutních hodnot intenzitních rozdílů mezi voxely v zarovnávaném a referenčním objemu. Optimalizace probíhá nejčastěji Newtonovou metodou, která využívá k hledání optimálních parametrů kvadratickou aproximaci kritériální funkce pomocí prvních tří členů Taylorova rozvoje. Pokud jsou pohyblivý a referenční obraz dokonale zarovnány a nejsou mezi nimi žádné jiné změny v důsledku artefaktů, vyjde suma čtverců rozdílu mezi obrazy nulová. Při optimalizaci však postačí dostat se co nejbližší tomuto optimálnímu stavu a optimalizace tam může skončit již na jisté předem nastavené hodnotě shody. Další možností je srovnávání kvality zarovnání na základě vzájemné informace obrazů. Zarovnávací algoritmy

v rámci urychlení výpočtů využívají iterační algoritmy, kdy je nejprve provedeno hrubé zarovnání a pak teprve je iteračně dosaženo jemnějšího zarovnání. [3]

5.3.2 Metoda UNWARP

Unwarp se snaží potlačit prostorové zkreslení snímků způsobené pohybem subjektu. Vychází z toho, že při EPI zobrazování jsou pořízené snímky postiženy poměrně závažným geometrickým zkreslením, a to především na rozhraních tkáň/vzduch a rozhraních různých druhů tkání. V těchto oblastech je pozorovaný obraz deformovaný v důsledku změny homogenity magnetického pole vyvolané pohybem subjektu. [16, 17]

K modelování zkreslení jednoho obrazu lze využít deformační pole. FMRI data jsou ale časovou posloupností, kde pohyb interaguje se zkreslením. Deformace se tedy mění s ohledem na pozici objektu, viz obr. 12. Metoda *unwarp* se snaží korigovat zbytkové odchylky signálu způsobené právě touto interakcí tak, že zjišťuje odchylky deformací s ohledem na pohyb subjektu.



Obrázek 12: Vliv pohybu na změnu deformace obrazu objektu [19]

Předpokládáme-li, že známe odchylky po zarovnání a disponujeme vypočtenými pohybovými parametry, je možné odhadnout, jak se deformační pole mění s pohybem, a díky tomu vytvořit pole vektorů na každé pozici v prostoru, ukazující jak se každá daná pozice odchýlila.

Pole B_0 , které je funkcí změny pozice $\Delta\theta$, $\Delta\varphi$ může být modelováno prvními dvěma řády Taylorovy expanze, jak popisuje rovnice č. 13 [19]


$$B_0(\theta, \varphi) = B_0(\Delta\theta, \Delta\varphi) + [(\delta B_0 / \delta \varphi) \Delta\varphi + (\delta B_0 / \delta \theta) \Delta\theta], \quad (13)$$

kde první část součtu popisuje statické deformace pole, které je ve všech časech stejné. A druhá část vyjadřuje iteračně počítané změny v deformačním poli související s pohybem. Využití druhého řádu Taylorovy expanze dovoluje zahrnout parametry rychlosti změny pohybových parametrů z vypočtení jejich druhých derivací. [17, 20]

Pomocí těchto polí je možné částečně odstranit variabilitu způsobenou pohybovým susceptibilním artefaktem a zachovat experimentálně vyvolanou odezvu. [19,20]

5.4 Koregistrace funkčních a anatomických snímků

Jelikož funkční snímky poskytují pouze velmi špatnou představu o anatomii (jedná se o snímky s poměrně malým rozlišením, kde jsou patrné pouze cévy a hranice šedé hmoty), viz obr. 13, využívá se pro získání neuroanatomické informace jejich spojení s anatomickými snímky vysokého rozlišení pořízenými pomocí T1 váhovaných sekvencí. Aby bylo možné oba snímky spojit, je nutné provést jejich vzájemnou koregistraci. Koregistrace se provádí pomocí šesti parametrické rigidní transformace a následné minimalizace související kritériální funkce. S ohledem na odlišné kontrasty funkčních a anatomických snímků je výhodné neuvažovat jako kritériální funkci metodu nejmenších čtverců, ale zvolit využití vyhodnocování vzájemné informace. [2]



Obrázek 13: Funkční snímek (vlevo) a anatomický snímek [2]


5.5 Prostorová normalizace

Dalším krokem, který je využíván především pro skupinovou analýzu, je prostorová normalizace. Jedná se o transformaci snímků do standardního (stereotaktického) prostoru. Tento krok je nutný, pokud je třeba vzájemně porovnávat snímky více lidí mezi sebou či s anatomickými atlasy, jelikož mozky různých lidí se od sebe vzájemně liší jak velikostí, tak i tvarem. V klinické praxi není tento krok nutný. Pro koregistraci se využívají afinní lineární transformace (posun, otáčení, zoom a zkosení) i nelineární transformace tak, aby se mozkové struktury vzájemně co nejvíce přiblížily. V zásadě se využívají dva standardní prostory. Jedná se o Talaraichův souřadný systém a MNI (Montreal Neurological Institute) systém. Talaraichův

souřadný systém vychází ze stereotaktického rámce, který byl vytvořen na základě snímku mozku konkrétní osoby. Počátek souřadného systému je umístěn uprostřed přední komisury s osami x a y umístěnými horizontálně tak, že propojují přední a zadní komisury. Lepší a častěji používaný souřadný systém je MNI prostor, který je průměrem z více než sta anatomických snímků mozku různých jedinců. MNI prostor byl škálován tak, aby odpovídal Talaraichovu prostoru. Další možností je normalizace povrchových obrazů mozku, které vzniknou procesem pomyslného nafouknutí mozkových závitů. Tato metoda má výhody při odlišení mozkové aktivity, která si je sice prostorově blízká, ale je umístěna v různých částech neurálního prostoru (jiné sulky). [2]

5.6 Prostorové vyhlazení

K prostorovému vyhlazení se využívá filtrace dolní propustí, která ze snímků odstraňuje vysokofrekvenční složky. Nejčastěji se využívá filtrace Gaussovským filtrem, který má tvar normálního rozložení ve 3D prostoru, viz obr. 14. Filtrací pomocí dolní propusti je intenzita konkrétního voxelu rozložena mezi hodnoty intenzity sousedních voxelů. Šířka filtru, která se popisuje parametrem FWHM (full width a half maximum) určuje rozsah okolí, ve kterém budou intenzity obsažených voxelů vzájemně ovlivněny. Používaná šířka filtru vychází z obvyklého prostorového rozsahu oblasti aktivity a pohybuje se standardně okolo 6 až 10 mm. Hlavní výhodou prostorového vyhlazení je potlačení šumu ve snímcích. Další výhodou je, že vyhlazená data lépe vyhovují požadavku normality rozložení, což je významné pro jejich následnou statistickou analýzu. [2]




Obrázek 14: Gaussův filtr

5.7 Filtrace časového průběhu

Tato filtrace se provádí na časovém průběhu signálu z jednotlivého voxelu. Odfiltrováním nízkých frekvencí se odstraňuje drift a pomalé kolísání signálu způsobené především srdeční činností a dýcháním a odfiltrováním vysokých frekvencí se potlačuje

vysokofrekvenční šum. Frekvenční rozsah signálu je daný dobou trvání repetičního času TR, která určuje vzorkovací frekvenci. Přičemž podle Nyquistova teorému tak maximální možná korektně zachycená frekvence signálu odpovídá polovině vzorkovací frekvence, čili polovině trvání TR. Všechny vyšší frekvence než je Nyquistův limit se v signálu projeví nežádoucím aliasingem. Frekvence BOLD signálu se pohybuje v závislosti na typu experimentu okolo 0,01 až 0,05 Hz s maximem okolo 0,025 Hz, viz obr. 15. Frekvence dýchání se pohybuje okolo 0,25 Hz a lze ji odfiltrovat pásmovou zádrží. Srdeční činnost se projevuje na frekvencích 1 až 1,5 Hz a aliasingem je tak přenášena na ostatní frekvence.

Signál je navíc časově autokorelovan což snižuje statistickou účinnost. K minimalizaci tohoto efektu se využívá *prewhitening* algoritmů, které z dat odfiltrovávají tu část BOLD signálu, která je odvoditelná z předchozích vzorků. Jiným přístupem může být *precoloring*, který je účinnější, pokud není možné úspěšně zjistit míru časové autokorelace signálu. [2]



Obrázek 15: Časový průběh MR signálu (vlevo) a jeho výkonové spektrum [2]

5.8 Globální normalizace intenzity

Časový průběh signálu z jednotlivého voxelu může v důsledku driftu vykazovat pomalé změny intenzity. Tyto změny jasu jednotlivých snímků mohou způsobovat problémy při detekci aktivace a je vhodné je eliminovat. Proto se provádí normalizace globální intenzity snímků na předem stanovenou hodnotu. Ne vždy je však vhodné tuto normalizaci provádět. Jistou alternativou je tedy metoda *Grand mean scaling*, při které se vypočte průměrná hodnota úrovně signálu, a ta je pak upravována na požadovanou hodnotu tak, aby bylo dosaženo srovnatelné úrovně signálu v jednotlivých měřeních. [2, 4]

6 Statistická analýza fMRI dat

Základem statistického hodnocení fMRI dat je vytvoření obecného lineárního modelu (GLM), kterým se snažíme co nejlépe vysvětlit variabilitu dat. GLM může realizovat odlišné statistické metody, jako je korelace, t-testy, F-testy, ANOVA apod. Jelikož všechny tyto metody jsou parametrické, je při analýze kladen důraz na požadavek normality použitých dat. [2, 3, 4]

6.1 T-test

T-test při hodnocení dat fMRI slouží ke srovnávání rozdílů průměrů hodnot během aktivace a mimo ní. Rozdíl průměrů je vážen směrodatnou odchylkou, čímž je do výpočtu zahrnuta i variabilita dat. T-test vychází ze Studentova rozdělení $t(n-1)$ dat o rozsahu hodnot n , které popisuje předpokládaný rozdíl mezi dvěma náhodnými vzorky ze stejného rozložení, přičemž průměr t -rozložení je nulový. Vycházející hodnota t -statistiky je vypočítána podle rovnice č. 14 [2]

$$t = \frac{\bar{x} - \bar{y}}{\sigma_{xy}} = \frac{\bar{x} - \bar{y}}{\sqrt{\sigma_x^2 + \sigma_y^2}}, \quad (14)$$

kde $\bar{x}$ a $\bar{y}$ jsou průměry v jednotlivých skupinách a σ_x, σ_y jsou jejich směrodatné odchylky. Hodnotu t -statistiky je pomocí stupňů volnosti možné přepočítat na pravděpodobnost. Počet stupňů volnosti je daný počtem časových vzorků signálu minus 1. Nulová hypotéza o shodnosti průměrů je zamítnuta pokud platí vztah č. 15. [21]

$$|T| > t_p(n-1) \quad (15)$$

6.2 F-test

F-test vychází z testování rozdílnosti dvou rozptylů. Je při něm testována nulová hypotéza o shodnosti obou rozptylů. Jsou-li dány dva výběry o rozsazích n_1 a n_2 s rozptyly S_1^2 a S_2^2 , vybrané ze dvou souborů majících rozdělení $N(\mu_1, \sigma_1^2)$ a $N(\mu_2, \sigma_2^2)$, pak je testovací kritérium dáno vztahem č. 16. [21]

$$F = \frac{\sigma_1^2}{\sigma_2^2} = \frac{n_1(n_2-1) \cdot S_1^2}{n_2(n_1-1) \cdot S_2^2} \quad (16)$$

Testovací kritérium má Fisherovo-Snedecorovo rozdělení $F(n_1-1, n_2-1)$. Nulová hypotéza o shodnosti obou rozptylů je zamítnuta pokud platí vztah č. 17. [21]

$$F > F_{\frac{p}{2}}(n_1 - 1, n_2 - 1) \quad (17)$$

6.3 Korelace a regrese


Korelace a regrese vychází ze srovnání předpokládaného průběhu signálu s naměřeným signálem. Míra korelace se určuje pomocí hodnoty korelačního koeficientu (pro parametrické testy se jedná o Pearsonův korelační koeficient) r podle vztahu č. 18 [21]

$$r = \frac{1}{n-1} \cdot \frac{\sum (x - \bar{x})(y - \bar{y})}{\sigma_x \sigma_y}, \quad (18)$$

kde n určuje počet vzorků signálu. Hodnota korelačního koeficientu se vyskytuje v intervalu $\langle -1, 1 \rangle$, přičemž 1 značí úplnou korelaci (shodu) signálů, 0 značí, že mezi signály není žádný vztah a -1 poukazuje na negativní korelaci. Statistická významnost regresního koeficientu může být vypočtena z tabulek pomocí znalosti o stupních volnosti. [21]

6.4 Obecný lineární model

Obecný lineární model je jistým zobecněním lineární regresní analýzy. Různým sestavením modelu, následným testováním a interpretací, je možné z GLM odvodit t-test, F-test či ANOVU. Podle obr. 16 je výsledný signál, tvořený maticí Y , kde řádky tvoří n časových vzorků a sloupce tvoří V jednotlivých voxelů, násobkem matice návrhu (design matrix) obsahující M regresorů (každý dlouhý n vzorků), s maticí parametrů β (skládající se z M sloupců a V řádků), k čemuž je přičtena matice reziduí, mající taktéž jako Y rozměr $n \times V$. [2, 22]



Obrázek 16: Maticový zápis obecného lineárního modelu

GLM předpokládá, že časová posloupnost signálu z daného voxelu je tvořena lineárním součtem modelových signálů, jak je patrné z obr. 16 a dále popsáno rovnicí č. 19 [2].

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (19)$$

Z rovnice vyplývá, že naměřený signál je součtem faktorů, které jsou během experimentu konstantní β_0 , váhovaných regresorů $\beta_1 x_1$ až $\beta_n x_n$ (modelových signálů) a rezidua ε (zbytkové variability). Jednotlivé modelové signály x_i tvoří sloupce matice návrhu. Váhy β určují, jak moc daný regresor ovlivňuje data. Jeden typ modelových signálů jsou regresory modelující odezvu na stimulaci. Tyto signály jsou dané konvolucí průběhu stimulace s HRF. Další typ regresorů, které pomáhají vysvětlit variabilitu v datech, jsou ty, modelující artefakty související s fMRI zobrazem (sem patří pohybové artefakty). Zahrnutí pohybových parametrů jako regresorů do matice návrhu vede ke konzervativnějšímu statistickému testu s méně stupni volnosti, zároveň však zlepšuje validitu vytvořeného GLM. Běžně se jako kovariáty využívají parametry translací a rotací získané během procesu zarovnání. [2, 3, 4]

Rovnice č. 20 vyjadřuje vztah pro výpočet parametrů obecného lineárního modelu. Řešením této rovnice je sada optimálních vah tak, aby bylo dosaženo co nejmenší hodnoty zbytkové nevysvětlené variability ε . [3]

$$Y = X \cdot \beta + \varepsilon \quad (20)$$

Analyticky se tato rovnice řeší metodou nejmenších čtverců, viz rovnice č. 21, kde β určuje prostorové mapy účinků jednotlivých regresorů. [3]

$$\beta = (X^T X)^{-1} X^T Y \quad (21)$$

Výsledný statistický obraz neboli statistická parametrická mapa (SPM), je získána použitím takto odhadnutých parametrů a následným výpočtem testové statistiky. Pro t-statistiku platí vztah č. 22, kde vektor c je vektor kontrastních vah a σ značí rozptyl, [3]

$$T = \frac{c^T \beta}{\sigma \sqrt{c^T (X^T X)^{-1} c}}, \quad (22)$$

jehož úpravou se určuje lineární kombinace odhadnutých parametrů určených k testování.

V rámci analýzy je nutné stanovení nulové a alternativní hypotézy, jejichž platnost v rámci statistické analýzy testujeme. Nulová hypotéza H_0 se vždy uvažuje ve smyslu, že stimulace nemá žádný efekt. Nejjednodušší případ nastane, pokud stimulujeme subjekt pouze jedním typem stimulační podmínky. Potom zjednodušíme vztah do tvaru, viz následující rovnice [2]

$$y = \beta_0 + \beta_1 x_1 + \varepsilon, \quad (23)$$

kde je nulová hypotéza $H_0: \beta_1 = 0$ a alternativní hypotéza H_a je $|\beta_1| > 0$. Pokud existuje více, než jedna stimulační podmínka, platí vztah č. 16, kde $H_0: c^T \beta = 0$ a H_a je $|c^T \beta| > 0$. V tomto případě je navíc možné vzájemně porovnávat odezvu na jednotlivé stimulační podmínky. Běžně se během testování snažíme vyvrátit či potvrdit platnost nulové hypotézy, čímž přímo určíme, zda platí či neplatí hypotéza alternativní. Nejčastěji se platnost hypotéz testuje pomocí T-testu o β

parametrech viz rovnice č. 14. T-test přitom musí být proveden pro každý voxel z celého objemu mozku. Výsledná statická parametrická mapa ukazuje v každém svém bodě hodnotu statistiky vypočtené dle příslušného rozdělení. Na základě zvolení hodnoty hladiny významnosti získáme pro test mezní hodnotu T_{krit} . Voxely, kde absolutní hodnota T statistiky vyjde vyšší nežli zvolená T_{krit} , jsou následně označeny za aktivní. V těchto voxelech je totiž testovaný efekt statisticky významný na dané hladině významnosti. Jedná se o proces prahování, přičemž hladina významnosti je pravděpodobnost s jakou ještě je možné připustit, že bude zamítnuta nulová hypotéza v případě, že je ve skutečnosti pravdivá (chyba 1. druhu).

Požaduje-li se testování dvou variant modelů, využívá se pro testování F-test. Oba testované modely přitom mohou mít rozdílný počet regresorů. Hodnota F testu je pak dána vztahem č. 24 [2]

$$F = \frac{\sigma_{res1} - \sigma_{res2}}{\sigma_{res2}}, \quad (24)$$

kde σ_{res1} a σ_{res2} jsou směrodatné odchylky reziduí 1. a 2. modelu. F-testem se testuje hypotéza, zda model s více regresory vysvětluje variabilitu dat lépe, než model s méně regresory. To lze využít ke zjištění, zda pohybové parametry pomáhají ve vysvětlení variability dat či ne. Také lze pomocí něj testovat efekt stimulace v případě, že je k dispozici více bazových funkcí pro modelování HRF. [2, 3, 22]

6.5 Korekce pro mnohonásobné testování

S ohledem na veliký počet současně prováděných testů (pro každý voxel celého objemu mozku) je nutné provádět korekci pro mnohonásobné testování. Tato korekce upravuje hodnotu hladiny významnosti, na které se testování provádí. Pokud by totiž byla použita obvyklá hodnota hladiny významnosti, čili hodnota 0,05, připouštěli bychom výslednou chybu pro celý objem mozku tolikrát větší, kolik voxelů se v objemu nachází (a bylo tedy testováno). Je proto důležité snížit hodnotu hladiny významnosti úměrně počtu zahrnutých voxelů. Běžně se využívají dvě základní metody korekce, a to FWE (family wise error) a FDR (false discovery rate). [2, 22]

Při FWE korekci se pro všechny testované voxely kontroluje pravděpodobnost výskytu falešně pozitivních voxelů. Skutečná hodnota hladiny významnosti je pak vypočtena pomocí jedné z implementací. Pro FWE to může být Bonferroniho korekce či pomocí teorie náhodných polí, přičemž vždy je použita méně přísná z obou vypočtených hodnot. Při použití FDR korekce se kontroluje poměrné množství falešně pozitivních výsledků. [2, 22]

6.6 Interpretace výsledných aktivačních map

V závěru jsou výsledné aktivační mapy vyhodnocovány z hlediska lokalizace aktivovaných oblastí v rámci daných funkčních anatomických oblastí mozku. Srovnávají se statistické hodnoty mezi jednotlivými oblastmi a je možné také zjišťovat časové návaznosti v aktivaci oblastí. Pomocí metod funkční konektivity je tak ve výsledku možné získat přehled o postupném zapojování jednotlivých mozkových oblastí aktivovaných experimentální stimulací. [4]

6.7 Analýza jednotlivce jako vstup do skupinové analýzy

Pokud je cílem analýzy dat usuzování obecných závěrů platných pro celou populaci je nutné provádět populační analýzu na 2. stupni. Zatímco na 1. úrovni je vyhodnocována variabilita dat v rámci každého subjektu zvlášť, na 2. úrovni je zkoumána variabilita dat mezi subjekty. V takovém případě se provádí dané výpočty pro všechny subjekty ve vzorku populace a zkoumá se, kde je efekt přítomný pro celou populaci. Vstupem do skupinové analýzy jsou data z analýzy jednotlivců. Aby bylo možné provádět skupinové testování, je podstatné, aby na úrovni jednotlivce byla pro všechny subjekty využita totožná matice návrhu. Do skupinové analýzy pak vstupují soubory dat vyjadřující efekt zkoumaných regresorů v daných voxelech. Pro každý voxel se jedná o souhrnnou hodnotu vah regresorů násobených kontrastní maticí, čímž je získán součet všech relevantních vah. Na skupinové úrovni je opět možné provádět jednovýběrové testy, dvouvýběrové testy nebo ANOVU. V případě, kdy se vyhodnocuje vliv různých faktorů na výsledná data, se využívá full-factorial analýza. [2, 20, 21]

Zatímco řádky v matici návrhu na úrovni jednotlivce jsou tvořeny časovou posloupností měřeného signálu (a vyjadřují tak variabilitu v signálu), řádky matice návrhu při skupinové analýze jsou tvořeny výsledky analýzy 1. úrovně jednotlivých subjektů (a vyjadřují tak variabilitu mezi subjekty). Sloupce matice návrhu vyjadřují při analýze jednotlivce experimentální podmínky a při skupinové analýze specifické účinky podmínek, které jsou při analýze zkoumány. Na skupinové úrovni je možné zkoumat hlavní účinky jednotlivých podmínek a také jejich interakce. [20]

Každá popisná proměnná (tzv. faktor) se skládá ze dvou či více úrovní. ANOVA testuje hypotézu, že populační průměry na každé úrovni jsou shodné oproti alternativní hypotéze, že průměr z alespoň jedné úrovně je odlišný. ANOVA může testovat simultánně několik faktorů s několika úrovněmi. Hlavní efekt změny hladiny faktoru je rozdíl mezi průměrem daného faktoru a „grand meanem“. Velikosti účinků ukazují, který faktor má nejvýznamnější vliv na výsledky. Analýza určuje významnost každého faktoru s ohledem na výpočet těchto účinků. Kromě určování hlavního efektu každého faktoru je možné sledovat interakce mezi jednotlivými faktory. Interakcí je přitom myšlen stav, kdy jeden faktor ovlivňuje výsledky závislé i na druhém faktoru. [2, 3, 21]

7 Reprezentace pohybových parametrů v GLM

7.1 Zahrnutí pohybových parametrů jako regresorů v GLM


Odchyly signálu způsobené pohybem mohou být v porovnání s amplitudou skutečných aktivací značně velké. Intenzitní změny v signálu daného voxelu, přetrvávající i po zarovnání snímků, způsobují falešně pozitivní aktivace v důsledku toho, že jim příslušející variabilita je chybně přisouzena aktivacím. To jak tyto artefakty ovlivňují BOLD signál je patrné z obr. 17. Kde obrázek C ukazuje absolutní změnu BOLD signálu z obrázku A. Na obrázku D je patrná změna pozice hlavy vypočtená jako součet absolutních diferencí pohybových parametrů patrných na obrázku B. Z obrázků C a D je jasně patrné, že při zvýšené míře pohybu pacienta dochází k nárůstu amplitudy změny BOLD signálu, což může být chybně detekováno jako mozková aktivita dané oblasti. [23]

Jedním z možných řešení tohoto problému je zahrnutí pohybových parametrů jako regresorů do matice návrhu, jak je patrné ze vztahu 25

$$Y = \beta \cdot X + \gamma M + \varepsilon, \quad (25)$$

kde γ udává váhy pohybových regresorů M . Váhy pohybových regresorů jsou násobeny nulovým vektorem kontrastních vah. Tím je možné potlačit vliv pohybových artefaktů na vznik falešně pozitivních aktivací díky tomu, že pohybové parametry pomáhají vysvětlit variabilitu dat a minimalizovat tak hodnotu zbytkové variability ε . Zpravidla bývá do GLM zahrnuto 6 pohybových parametrů popisujících pohyb hlavy během experimentu. [2, 11, 12, 23]


Problematické je zahrnutí těchto parametrů v případě, kdy je pohyb korelovaný s časovým průběhem experimentální stimulace. V takovém případě zahrnutí pohybových parametrů vede ke snížení významnosti skutečných aktivací, jelikož pohybové regresory ubírají variabilitu náležící regresorům modelujícím skutečnou hemodynamickou odpověď. [11]



Obrázek 17: Efekt ovlivnění BOLD signálu pohybovými artefakty [23]

Na obr. 18 je ukázka aktivačních map, na kterých je možné pozorovat vliv zahrnutí pohybových parametrů do GLM. Je zde patrný mírný úbytek aktivací, způsobený přisouzením části variability signálu pohybovým artefaktům.

Z výše uvedených poznatků vyplývá, že modelování průběhu arteficiálních změn signálu spojených s pohybem je možné právě s využitím průběhu transformačních parametrů translací a rotací. Tohoto teoretického předpokladu bylo dále využíváno při tvorbě map projevu pohybových artefaktů.



Obrázek 18: Ukázka matice návrhu a výsledné statistické mapy s využitím pohybových parametrů jako regresorů v GLM ($p = 0,001$, bez korekce)

8 Návrh metody mapování pohybových artefaktů

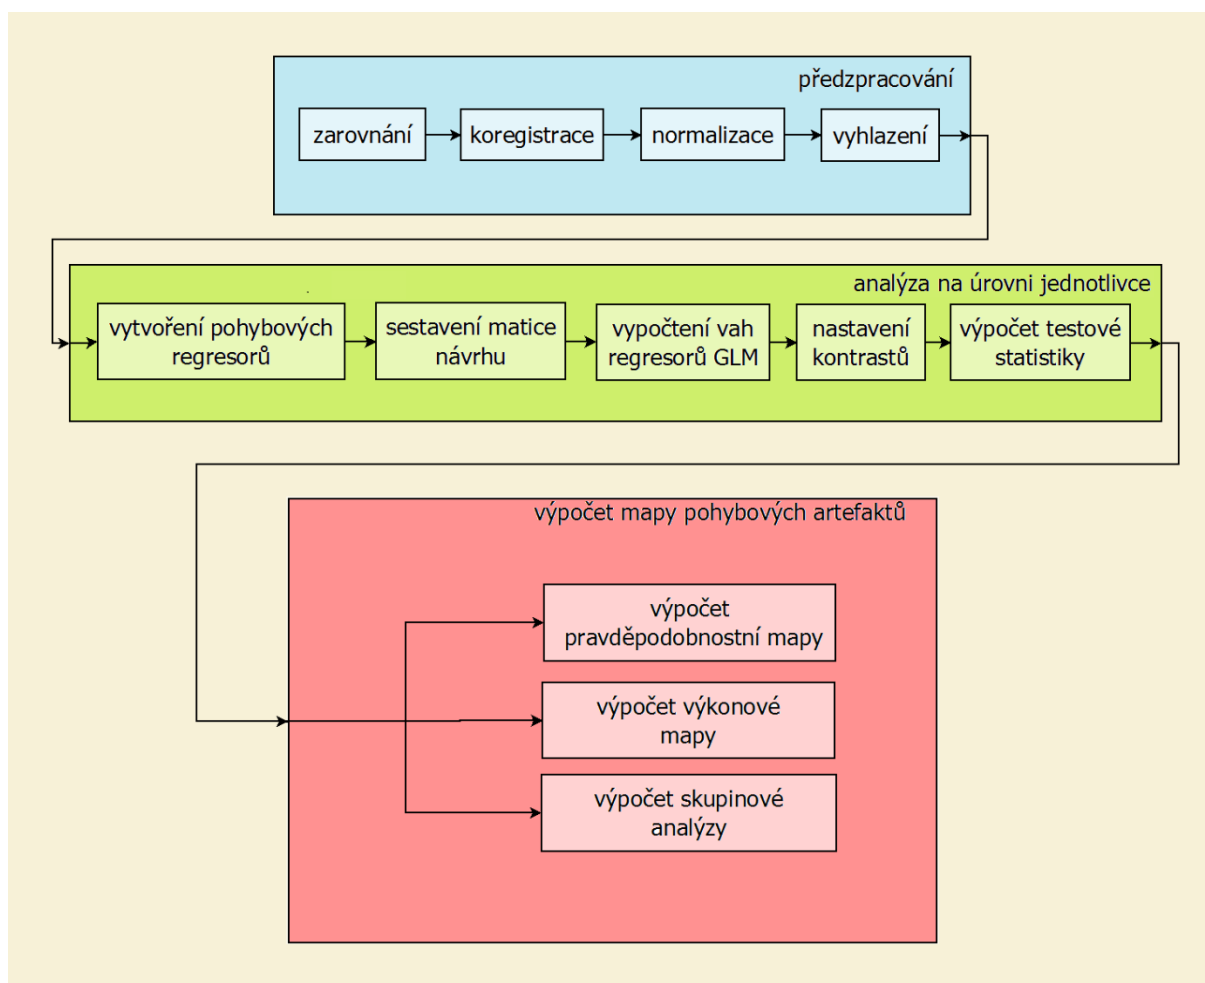
Mapování pohybových artefaktů vychází z předpokladu, že pohyb ovlivňuje data v lokalitách, které bývají u většiny subjektů obdobné. Jak vyplývá z dříve uvedených teoretických předpokladů v kapitole 4, pohybem jsou nejvíce ovlivněna místa, kde se nachází tkáň s rozdílnou susceptibilitou, rozhraní tkáň/kost a tkáň/vzduch. V těchto místech dochází k největšímu projevu susceptibilního artefaktu spojeného s pohybem. Dále tkáň s dlouhým T1 časem jsou značně postiženy *spin-history* artefaktem. Tyto oblasti jsou u všech pacientů lokalizovány na obdobných místech a dá se tedy předpokládat, že projev pohybových artefaktů bude u většiny subjektů lokalizován podobně, pouze s různou mírou projevu na základě rozsahu pohybu.

Mapování lokalit ovlivněných pohybovými artefakty je užitečné ke dvěma hlavním účelům. Tyto mapy tvoří pomocnou informaci při vyhodnocování výsledků statistické analýzy. Díky vytvořeným mapám je možné při interpretaci aktivačních map brát v úvahu nejistotu při interpretaci zdánlivých aktivací, které zasahují do míst častého projevu pohybových artefaktů. Dále tyto mapy mohou sloužit při simulacích fMRI dat. Na jejich základě je možné pro každý voxel z objemu mozku určit míru s jakou se ve změřeném signálu projevuje arteficiální signál a tento arteficiální signál pak s daným výkonem modelovat a přidat do uměle vytvořených dat.

Následující kapitoly popisují vytvořený návrh metod, sloužících k mapování projevů pohybových artefaktů ve fMRI datech, a jejich realizaci v programovém prostředí MATLAB s využitím toolboxu SPM.

8.1 Navržený postup mapování pohybových artefaktů


V rámci práce byly navrženy a vyzkoušeny tři přístupy mapování pohybových artefaktů. Ačkoliv každý z použitých přístupů nahlíží na problematiku mapování pohybových artefaktů z jiného úhlu, základní kroky pro vytvoření výsledných map jsou identické. Přehled základních kroků shodných u jednotlivých metod ukazuje schéma na obr. 19. Ve všech metodách je nejprve nutné data předzpracovat a provést jejich statistickou analýzu na úrovni jednotlivce. Dále již každá z navržených metod pracuje odlišně. Společné kroky budou popsány v následujících kapitolách.




Obrázek 19: Schéma základních kroků vytvořených metod

8.1.1 Předzpracování

Zvolený proces předzpracování naměřených fMRI dat lze rozdělit do čtyř základních bloků. Nejprve je nutné provést zarovnání jednotlivých skenů. Jako referenční se používá první sken. Ostatní skeny jsou zarovnány šestiparametrickou rigidní transformací k referenčnímu skenu. Pro převzorkování výsledných snímků je zvolena B-spline interpolace. Vypočtené transformační parametry, vyjadřující míru translací a rotací musí být uloženy, aby bylo možné jejich následné využití v GLM. Obr. 20 znázorňuje možný průběh pohybových parametrů popisujících posun v osách x, y a z. Na obr. 21 jsou znázorněny pohybové parametry příslušející rotacím okolo os x (*pitch*), y (*roll*) a z (*yaw*). [20]



Obrázek 20: Ukázka průběhu parametrů translací



Obrázek 21: Ukázka průběhu parametrů rotací

Dále je pomocí afinních transformací provedena koregistrace anatomického skenu s průměrným funkčním skenem. Optimální transformace je vyhodnocena na základě metody vzájemné informace.

Zpracovávaná data je dále nutné normalizovat do standardního stereotaktického prostoru, aby bylo možné následné porovnávání výsledků v rámci skupin. Nejprve je provedena normalizace anatomického skenu k templátovému T1 váženému snímku (šabloně) příslušejícímu MNI šabloně. Poté jsou normalizovány všechny funkční skeny podle parametrů vyhodnocených v předchozím kroku. Funkční skeny jsou nakonec prostorově vyhlazeny Gaussovským jádrem, což vede ke zlepšení hrubého SNR a k vyšší normalitě dat pro následnou statistickou analýzu.

Jednou z možností při předzpracování snímků je také úprava jejich geometrického zkreslení pomocí metody *unwarp*. Tato metoda nebyla v navržených postupech aplikována. Jedním z důvodů je, že v případě, kdy dochází pouze k malému pohybu, nedochází ke zkreslení, které by metoda mohla zaznamenat. Dále při jejím použití dochází k dalšímu zavádění nepřesností do snímků, jelikož výsledná úprava je pouze odhadem skutečného vzhledu snímku. [12, 20]

V poslední řadě je pro účel mapování pohybového artefaktu metoda unwarp nevhodná s ohledem na fakt, že má za úkol odstranit variabilitu dat spojenou s pohybem, zatímco pro účely mapování je naopak žádoucí tuto variabilitu vysvětlit pohybem a ukázat místa jejího projevu.

8.1.2 Analýza na úrovni jednotlivce

Předzpracované snímky mohou vstoupit do 1. level analýzy. Na úrovni jednotlivce je pro každý subjekt vypočtena statistická parametrická mapa ukazující místa, kde pohyb statisticky významně přispěl k vysvětlení variability v datech. Tato analýza probíhá zvlášť pro každý voxel snímaného objemu. K získání výsledných hodnot F-statistiky vede několik dílčích kroků.

Vytvoření pohybových regresorů

Jak znázorňuje schéma na obr. 19, aby bylo možné mapovat pohybové artefakty, je důležité vhodně zvolit regresory, pomocí nichž je v rámci GLM snaha vysvětlit variabilitu dat související s pohybem. Na základě procesu zarovnání snímků je možné získat poměrně přesný odhad průběhu pohybu subjektu ve třech hlavních osách. Výsledné transformační parametry ukazují posun a rotaci subjektu a dávají tak informaci o míře pohybu v daném čase.


Jak je zmíněno v [12, 14, 16, 24], vhodným sestavením pohybových regresorů je možné postihnout část signálu příslušející pohybovým artefaktům. Již v dřívějších studiích [2, 11, 12, 23] se ukázalo, že při zahrnutí pohybových parametrů, získaných jako transformační parametry při procesu zarovnávání, do matice návrhu v GLM, je těmto parametrům přisouzená část zbytkové variability, což vede ke zvýšení testové statistiky. V případě korelace mezi aktivací a pohybem snižuje zahrnutí pohybových regresorů do modelu riziko falešně pozitivních výsledků. V případě silných korelací však naopak hrozí riziko falešně negativních výsledků. Studie [12, 14, 16, 24] navíc navrhuje využití Volterrova rozvoje šesti základních pohybových parametrů, čímž je získáno celkem 24 pohybových regresorů. Volterrov rozvoj modeluje nelineární chování systému a na rozdíl od Taylorova rozvoje zahrnuje i efekt paměti systému viz rovnice 26 [25]

$$y(k) = w_{o0} + \sum_{l_1=0}^{\infty} w_{o1}(l_1)x(k-l_1) + \sum_{l_1=0}^{\infty} \sum_{l_2=0}^{\infty} w_{o2}(l_1, l_2)x(k-l_1)x(k-l_2) \quad (26)$$


kde je popsán vliv prvních dvou řádů rozvoje. První dva řády rozvoje zahrnují lineární a kvadratický vliv systému. Rozvoj modeluje průběhy, kde současný stav systému je funkcí nejen jeho aktuálních parametrů, ale také všech předchozích. Zahrnutím efektu paměti systému použitím prvních dvou řádů Volterrova rozvoje je modelován vliv *spin-history* artefaktu. Využití druhých mocnin pohybových parametrů i jejich diferencí modeluje nelineární vztahy mezi pohybem a změnou intenzitního signálu. [25] Samotný vliv prvních diferencí je možné chápat také jako zrychlení. Jelikož pohybové parametry vyjadřují míru pohybu – rychlost, tak jejich první derivace pak modeluje efekt zrychlení.

Výsledkem tedy je 24 pohybových regresorů – 6 regresorů modelujících translaci a rotace v hlavních osách, 6 regresorů příslušejících jejich časovým diferencím a 12 regresorů příslušejících jejich mocninám.

Na obrázcích č. 22 a 23 jsou znázorněny ilustrační časové průběhy translací v jednotlivých osách, jejich diferencí a druhých mocnin.



Obrázek 22: Ukázkové časové průběhy translací a jejich diferencí (ose x – červeně, v ose y – zeleně, v ose z - modře)



Obrázek 23: Ukázkové časové průběhy druhých mocnin translací a jejich diferencí (ose x – červeně, v ose y – zeleně, v ose z - modře)

Sestavení matice návrhu a vypočtení vah regresorů GLM


Matice návrhu X obsahuje souhrn všech regresorů sloužících k vysvětlení co největšího podílu variability v datech. Pro mapování pohybových artefaktů tato matice obsahuje regresory modelující aktivace a vypočtené pohybové regresory. Regresory modelující aktivace jsou získány konvolucí průběhu experimentálních stimulací s hemodynamickou odezvou. Pohybové regresory jsou vypočteny v předchozím kroku a jsou pro další práci centrovány na střední hodnotu. Celkově tedy matice návrhu obsahuje příslušný počet regresorů modelujících aktivace

(počet závisí na typu úkolu, tedy počtu různých modelovaných typů reakcí na stimuly), jeden regresor modelující konstantní člen a 24 pohybových regresorů.

Váhy β jednotlivých regresorů jsou počítány metodou nejmenších čtverců podle rovnice č. 21. Pro každý regresor je tak vypočítána objemová matice dat obsahující hodnoty vah daného regresoru. [20]

Nastavení kontrastů a výpočet testové statistiky

Jak je uvedeno v [2], při mapování pohybových artefaktů se využívá výpočtu F statistiky souhrnného efektu všech pohybových regresorů. Výsledná kontrastní matice má na pozicích odpovídajícím regresorům aktivací nuly a jednotlivým pohybovým regresorům přiřazuje kontrast jedna, viz obr. 24, ukazující použitou kontrastní matici pro úkol označený jako vizuální *oddball*. Takto sestavenou kontrastní matici je vynásobena matice vah regresorů, čímž je získána jejich lineární kombinace a testuje se, zda vybrané regresory statisticky významně přispívají k vysvětlení variability.



Obrázek 24: Nastavení kontrastní matice pro testování souhrnného vlivu všech pohybových regresorů pro úkol typu vizuální *oddball* se třemi regresory pro experimentální stimulaci.

Je také možné testovat vliv jednotlivých pohybových regresorů zvlášť pomocí t-testu nebo vliv jednoho typu pohybu (např. translace v ose x) F-testem jako souhrnný účinek pohybového parametru, jeho difference a jejich mocnin.

8.1.3 Pravděpodobnostní mapy

Pravděpodobnostní mapy ukazují konzistentnost výskytu pohybového artefaktu v populaci pro daný experiment. K jejich vytvoření slouží jako vstup výsledky analýzy na úrovni jednotlivce.

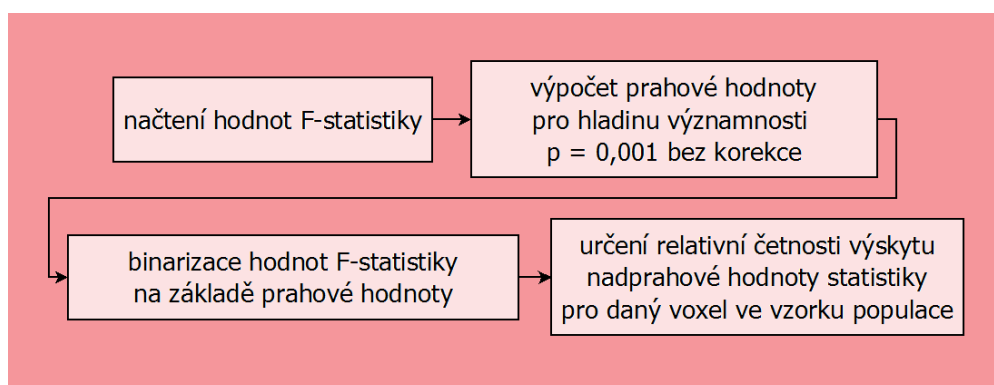
Proces jejich výpočtu znázorňuje schéma na obr. 25. Pro jejich tvorbu se využívají vypočtené hodnoty F statistiky získané při výpočtu na úrovni jednotlivce. Tyto hodnoty jsou pro každý subjekt binarizovány prahováním F hodnotou Fisher-Sneydecorova rozložení odpovídající hladině významnosti 0,001 pro tvar rozložení při daných stupních volnosti. Stupně volnosti, které určují tvar rozložení, přísluší sledovanému signálu a reziduálnímu signálu. Korekce pro mnohonásobné testování není využíváno, jelikož při mapování artefaktu je žádoucí mapovat všechny pozice, kde je možné, že se pohyb vyskytnul.

Binarizované hodnoty pak určují, zda byla na dané pozici pro daný subjekt pozorována statisticky významná změna signálu související s pohybem. Nakonec je vypočtena relativní četnost výskytu pohybového artefaktu na dané pozici jakožto průměr získaných hodnot přes všechny subjekty.

Relativní četnost C výskytu pohybu na pozici dané indexy m, n, p v objemu mozku je tedy dána vztahem č. 27

$$C_{m,n,p} = \frac{\sum_{i=1}^{Nsub} A_{m,n,p}(i)}{Nsub}, \quad (27)$$

kde A je binární hodnota vyjadřující výskyt či nevýskyt pohybového artefaktu na dané pozici u daného subjektu a $Nsub$ je počet subjektů.



Obrázek 25: Proces výpočtu pravděpodobnostní mapy

8.1.4 Výkonové mapy

Výkonové mapy jsou počítány z poměru energie signálu příslušícího pohybu k celkovému změřenému signálu. Na obr. 26 je patrný zjednodušený průběh celého procesu výpočtu výkonové mapy. Změřený signál je nejprve vyfiltrován filtrem pro odstranění nízkých frekvencí. Následně je filtrován bělicím filtrem sloužícím k odstranění autokorelací sousedních

vzorků signálu. Pohybový signál je získán jako suma násobku jednotlivých pohybových regresorů (24 regresorů v modelu slouží k modelování pohybu, tyto jsou také vyfiltrovány stejnými filtry jako měřený signál) s jejich váhami β , které byly získány při analýze na úrovni jednotlivce a byly vynásobeny kontrastní maticí c nastavenou tak, aby zdůrazňovala pohybové regresory, viz vztah č. 27, který vychází ze vztahu č. 19 [2].

$$sig_{pohyb} = \sum_{reg=1}^{24} X(reg) \cdot \beta \cdot c \quad (27)$$

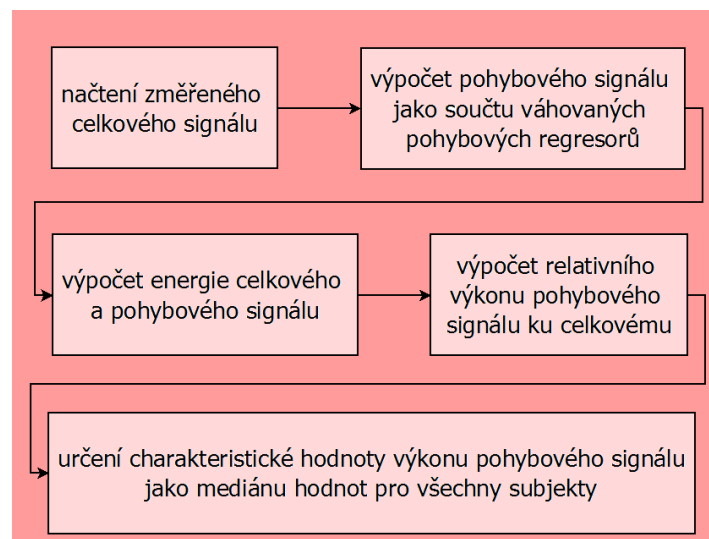
Energie signálu je pak vypočtena jako rozptyl signálu podle vztahu č. 28 [26]

$$energie = \frac{1}{n} \sum_{i=1}^n (x_i - E(x))^2 \quad (28)$$

kde n značí délku signálu a $E(x)$ jeho střední hodnotu. Procentuální výkon pohybového artefaktu v daném voxelu je dán poměrem energie pohybového signálu k celkovému signálu, viz rovnice č. 29.

$$procent_vykon = \frac{energie_{pohybovy}}{energie_{mereny}} \cdot 100 \quad (29)$$

Výsledné výkonové mapy jsou počítány souhrnně přes všechny subjekty v dané studii. Jelikož rozložení procentuálního výkonu ve výběru subjektů jeví log-normální rozdělení, bylo pro získání reprezentativní hodnoty každého voxelu využito výpočtu mediánu z hodnot všech subjektů. Hodnota v každém voxelu objemu tedy ve výsledku reprezentuje předpokládanou hodnotu výkonu arteficiálního signálu u daného typu studie.

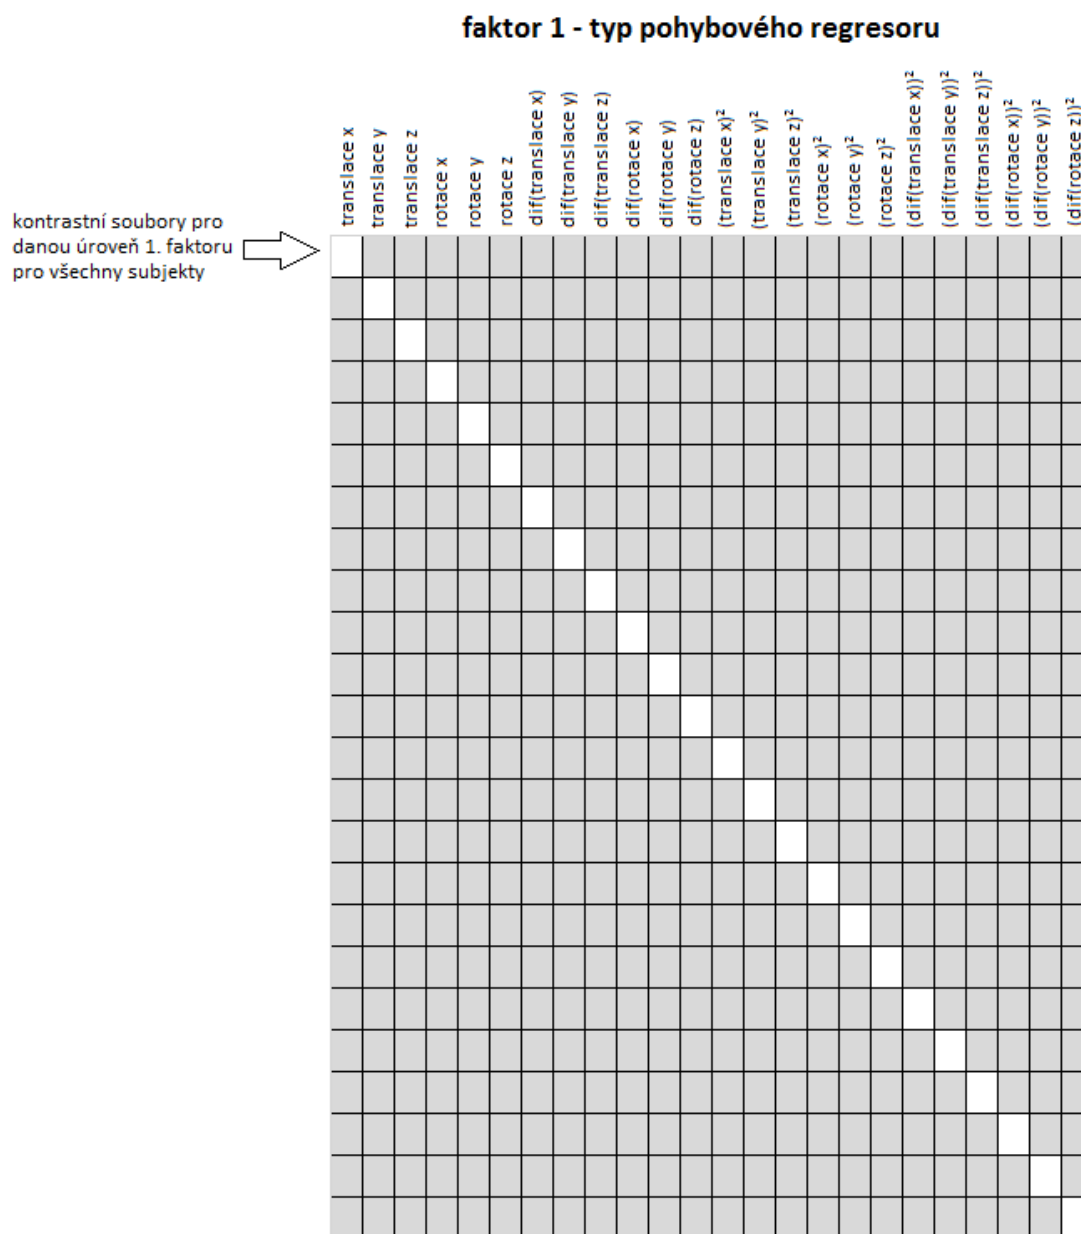


Obrázek 26: Proces výpočtu výkonové mapy

8.1.5 Skupinová analýza

Do skupinové analýzy vstupují kontrastní soubory určující lineární kombinaci vah regresorů, na které je vložen kontrast. Pro hledání souhrnného vlivu všech 24 pohybových regresorů byly využity hodnoty T kontrastů nastavených vždy na jeden z pohybových

regresorů. Každý z pohybových regresorů byl považován za jednu z celkových 24 hladin 1. faktoru full-factorial analýzy (1. faktor - typ pohybového regresoru). Pro testování, na jakých pozicích v objemu mozku se významně projeví alespoň jeden z uvažovaných pohybových regresorů u všech osob v populaci, byl nastaven kontrast, znázorněný na obr. 27. Jednotlivé hladiny 1. faktoru jsou považovány za závislé, jelikož jednotlivé typy pohybových regresorů spolu souvisí. Rozptyl hodnot úrovní je v analýze považován za nestejný.




Obrázek 27: Nastavení matice návrhu pro skupinovou analýzu

Tímto způsobem jsou získány statistické mapy určující místa projevu jednotlivých úrovní daného faktoru. Je možné sledovat hlavní efekt jednotlivých hladin, nebo průměrný efekt daného faktoru. Využitím nastavení kontrastu podle obr. 27 je zkoumán vliv všech pohybových regresorů.

8.1.6 Srovnání mezi studiemi

V rámci práce byl také testován vliv daného typu studie na možnost sledování projevů pohybových artefaktů. K tomuto účelu bylo využito full-factorial analýzy se dvěma faktory. Prvním faktorem byl typ pohybového regresoru a druhým faktorem typ studie. Jednotlivé hladiny druhého faktoru byly považovány za nezávislé a jejich rozptyl za nestejný. Nastavení kontrastní matice pro testování projevu pohybových artefaktů souhrnně ve všech studiích byla využita kontrastní matice, znázorněná na obr. 28.



Obrázek 28: Nastavení matice návrhu pro testování vlivu typu studie a jednotlivých pohybových regresorů

8.1.7 Možnost využití konvoluce pohybových parametrů s hemodynamickou odezvou

Pokud by se získané pohybové parametry konvolovaly s průběhem HRF a byly by zahrnuty jako regresory do matice návrhu, mohlo by být teoreticky možné získat informaci o lokalitách zodpovědných za tento pohyb. Teoreticky by aktivní místa (v případě volního pohybu) měla příslušet motorickým centřům. V rámci práce byl tento předpoklad testován, avšak nebyly získány žádné relevantní výsledky. Navíc se během práce ukázalo, že pro tvorbu map projevů pohybových artefaktů nemá tato metodika smysl. V práci jí tedy nebyla věnována další pozornost.

8.1.8 Možnost využití druhých diferencí pohybových parametrů

Pohybové parametry získané jako transformační parametry při procesu zarovnání vyjadřují míru pohybu v daném směru. Jejich první derivace určuje strmost změny daného parametru – zrychlení. Druhé difference tedy již nemají žádný interpretovatelný význam a při tvorbě map nebyly využívány. Naopak byly do modelu přidány druhé mocniny reprezentující nelineární vztahy.

8.2 Programové řešení navržených metod

V rámci práce byl vytvořen toolbox sloužící pro výpočet zmíněných druhů map popisujících projevy pohybových artefaktů. Program byl vytvořen v programovacím prostředí MATLAB s využitím funkcí toolboxu SPM. Program umožňuje zadávání dat v dávkovém módu. Vizualizace výsledků byla prováděna pomocí programů *xjview2* (modifikace originálního kódu dostupného na <http://www.alivelearn.net/xjview8/>) a *mask_explorer3_2_EN* [27].

8.2.1 Spouštěcí skript: mapovani_pohybovych_artefaktu

Analýza je spouštěna skriptem *mapovani_pohybovych_artefaktu.m*. V tomto spouštěcím skriptu je nutné zadat cesty k datům, názvy adresářů, parametry dat a typ mapy, která má být počítána. Uživatel zadává proměnné, viz tabulka č. 1 v sekci příloh. Dále je ve skriptu definována proměnná popisující názvy 24 pohybových regresorů viz tabulka č. 2 v sekci příloh, kterou uživatel již nemění.

Skript poté volá vytvořené funkce. Nejprve volá funkci *preprocessing*, sloužící k předzpracování snímků. Následně funkci *vypocet_statistiky*, která provede výpočet statistiky na úrovni jednotlivce. Dále skript v případě zvolení skupinové analýzy (proměnná regresors nastavená na ‘skupinova’) volá funkci *skupinova_statistika*, která vypočítá statistiku na 2. level úrovni. V opačném případě volá funkce *pravdepodobnostni_mapa* pro výpočet pravděpodobnostních map a *vykonova_mapa* pro výpočet výkonových map. Pokud je uživatelem zvolen typ výpočtu map pro všechny pohybové regresory dohromady (proměnná regresors nastavená na ‘dohromady’), je vypočítána pravděpodobnostní a výkonová mapa

s využitím všech pohybových regresorů. Pokud je uživatelem zvolen výpočet vlivu zvolených kombinací regresorů (proměnná regersors nastvená na 'zvlast'), jsou vypočteny pravděpodobnostní a výkonové mapy pro souhrnný efekt daného typu pohybu, jeho difference a jejich mocnin.

V dalších kapitolách budou popsány vytvořené dílčí funkce.

8.2.2 preprocessing

Celý název funkce:

preprocessing(nazvy_dat,nazvy_session,cesta_k_datum,lomitko,cesta_k_templatuT1)

Tato funkce slouží k předzpracování vybraných snímků. Proměnné tvořící její vstupy jsou popsány v tabulce č. 1 v sekci příloh. Funkce nemá žádné přímé výstupy. Jejím výsledkem jsou vytvořené zpracované snímky opatřené předponou 'swr*' uložené do adresáře k původním snímkům.

Funkce provádí předzpracování snímků voláním dílčích funkcí toolboxu *spm8* přes Batch editor, který tvoří rozhraní mezi uživatelem zadávanými proměnnými a voláním jednotlivých funkcí pro potřebné výpočty. Nejprve jsou definovány parametry určující vstupní parametry zadávané do Batch editoru, který již dále volá jednotlivé dílčí funkce *spm8*.

Celá funkce pracuje ve *for* cyklu, ve kterém provádí dané úpravy pro data postupně vybíraná od každého subjektu. Nejprve je provedeno vyhodnocení transformačních parametrů pro zarovnání snímků. Funkce načte naměřené funkční snímky, které mají být zarovnány. Snímky jsou zarovnány k prvnímu skenu v sérii šestiparametrickou rigidní transformací. Pro hledání optimálních transformačních parametrů jsou snímky nejprve vyhlazeny filtrem s FWHM 5 mm a je provedeno jejich převzorkování se separačním koeficientem mezi sousedními vzorky 4 mm. Pro zjištění optimálních transformačních parametrů jsou snímky průběžně interpolovány B-spline interpolací 2. řádu. Zarovnání snímků se provádí do docílení kvality zarovnání dané parametrem 0,9 (na škále od nuly do jedné). Každý sken je nakonec transformován pomocí vypočtených optimálních transformačních parametrů a interpolován B-spline interpolací 4. řádu do nových souřadnic. Výsledné vypočtené transformační parametry jsou uloženy jako textový dokument do adresáře s funkčními daty. Zarovnané snímky jsou uloženy do adresáře k původním snímkům a jsou opatřeny předponou 'r*'.

V dalším kroku je funkcí do Batch editoru zadáno vypočtení koregistrace anatomického skenu s průměrným funkčním skenem. Optimální transformace je vyhodnocena na základě metody vzájemné informace.

Data jsou poté normalizována do standardního stereoskopického prostoru afinní nelineární transformací. Nejprve je provedena normalizace anatomického skenu k templátovému T1 váženému snímku. Poté jsou normalizovány všechny funkční skeny podle parametrů vyhodnocených v předchozím kroku. Velikost voxelu po normalizaci je nastavena

na 3x3x3 mm. Snímky jsou interpolovány trilineární interpolací. Normalizované skeny získají předponu 'w*' a jsou uloženy do adresáře k ostatním snímkům.

Zpracované skeny jsou nakonec prostorově vyhlazeny 3D Gaussovským jádrem s FWHM 8 mm a jsou uloženy s předponou 's*'.

Po předzpracování mají upravené snímky předponu 'swr*' a jsou uloženy v adresáři s původními naměřenými daty.

8.2.3 vypocet_statistiky

Celý název funkce:

vypocet_statistiky(nazvy_dat,nazvy_session,cesta_k_datum,TR,lomitko,nazvy_cond,nazvy_regresoru,regresors,nazev_adresare,aktivace,trvani)

Tato funkce slouží k analýze skupiny jednotlivců na první úrovni. Proměnné tvořící její vstupy jsou popsány v tabulce č. 1 v sekci příloh. Funkce si sama načítá podle vstupních parametrů názvy dat předzpracované snímky uložené v adresáři každého pacienta zahrnutého do analýzy. Funkce nemá žádné přímé výstupy. Její výsledky jsou uloženy do nově vytvořeného adresáře s názvem, který je definován uživatelem jako vstupní proměnná. Do tohoto adresáře je uložena vytvořená SPM.mat struktura obsahující veškeré informace o datech a analýze. Dále jsou do adresáře uloženy, pro další výpočty potřebné, vypočtené 3D objemy vah jednotlivých regresorů ve formátu beta_00*.img (a příslušející hlavičkový soubor beta_00*.hdr), kde * nahrazuje číslo dané váhy. Váhy regresorů jsou číslovány postupně nejprve pro váhy stimulačních podmínek, dále váhy pro 24 pohybových regresorů a nakonec váha pro konstantní člen. Dalším výstupem, který je potřebný pro další zpracování, je mask.img (a příslušný mask.hdr) soubor, obsahující implicitně stanovenou objemovou masku. Tato maska je nastavena tak, aby její hodnota pro daný voxel byla nula, pokud je nulový signál daného voxelu v jakémkoliv skenu. Do adresáře jsou také uloženy con_00*.img (a příslušející con_00*.hdr) soubory obsahující hodnotu součtu vah regresorů násobených kontrastní maticí. Počet těchto souborů odpovídá počtu definovaných kontrastů. Nakonec jsou uloženy soubory spmF_00*.img (a příslušející spmF_00*.hdr) obsahující objemová data hodnot F statistiky pro každý voxel.

Celá funkce pracuje ve *for* cyklu, ve kterém provádí dané výpočty pro data postupně vybíraná od každého subjektu. Funkce nejprve z předdefinovaného adresáře načte předzpracované snímky a průběhy 6 transformačních parametrů získaných při procesu zarovnání. Dále jsou ve funkci definovány parametry určující vstupní parametry zadávané do Batch editoru, který již dále volá jednotlivé dílčí funkce spm8. Jako jednotky měření jsou definovány skeny, repetiční čas je nastaven na hodnotu definovanou uživatelem, časování stimulů je načteno z proměnných definovaných uživatelem. Perioda filtru typu horní propust pro odstranění pomalých frekvencí ze signálu je nastavena na 128 s. Bělení signálu je provedeno bělícím autokorelačním filtrem, který bere v úvahu sousední vzorky signálu.

Pohybové regresory, které jsou zahrnuty do modelu, se vypočítají z transformačních parametrů získaných při procesu zarovnání. Z původních 6 pohybových parametrů jsou vypočteny jejich zpětné difference podle vztahu č. 30

$$dif - p_{k,i} = p_{k,i} - p_{k,i-1}, \quad (30)$$

kde $p_{k,i}$ je k-tý pohybový regresor ($k = 1$ až 6) a i značí daný časový okamžik. Pro první časový okamžik jsou difference každého regresoru nastaveny na nulu. Z celkových 12 regresorů jsou v dalším kroku vypočítány jejich druhé mocniny podle vztahu č. 31

$$sq - p_{k,i} = (p_{k,i})^2, \quad (31)$$

kde $p_{k,i}$ je k-tý pohybový regresor ($k = 1$ až 12) a i značí daný časový okamžik. Tímto způsobem je získáno celkem 24 pohybových regresorů.

Po vypočtení hodnot GLM jsou ve funkci definovány kontrastní matice. Tento krok se dělí podle typu pohybové mapy, jaká má být počítána. Pokud je uživatelem na počátku zvolen výpočet pro všechny pohybové regresory dohromady (parametr regresors na 'dohromady'), je zadáno 5 kontrastních matic nastavených jako souhrnný vliv pohybových parametrů ve všech směrech dohromady, viz tabulka č. 1.

Tabulka 1: Nastavení kontrastních matic pro účinky všech pohybových regresorů

Číslo F kontrastu	Nastavení účinků regresorů
1	6 základních pohybových parametrů
2	difference 6 základních pohybových parametrů
3	12 pohybových parametrů
4	druhé mocniny 12 pohybových parametrů
5	24 pohybových parametrů

Pokud je uživatelem na počátku zvolen výpočet jednotlivých kombinací dílčích regresorů (parametr regresors jako 'zvlast'), je vytvořeno 6 kontrastních matic nastavených jako souhrnný vliv jednoho z 6 pohybových parametrů, jeho difference a jejich druhých mocnin, viz tabulka č. 2.

Tabulka 2: Nastavení kontrastních matic pro účinky jednotlivých pohybových regresorů

Číslo F kontrastu	Nastavení účinků regresorů
1	translace v ose x, její difference a jejich druhé mocniny
2	translace v ose y, její difference a jejich druhé mocniny
3	translace v ose z, její difference a jejich druhé mocniny
4	rotace v ose x, její difference a jejich druhé mocniny
5	rotace v ose y, její difference a jejich druhé mocniny
6	rotace v ose z, její difference a jejich druhé mocniny

Nakonec, v případě že je uživatelem na počátku zvolen výpočet skupinové statistiky, parametr regresors jako ‘skupinova’ je vytvořeno 24 kontrastních matic nastavených jako vliv každého z 24 pohybových parametrů zvlášť (tzv. T kontrast).

Takto zadané kontrastní matice v dalším kroku slouží k výpočtu F-statistiky (T-statistik v případě počítání vlivu jednotlivých pohybových parametrů zvlášť pro účely skupinové analýzy). Výsledné statistické mapy jsou vypočteny voláním funkce `spm8` přes Batch editor.

8.2.4 pravdepodobnostni_mapa

Celý název funkce:

pravdepodobnostni_mapa (nazvy_dat,cesta_k_datum,regresors,nazev_adresare)

Tato funkce slouží k výpočtu pravděpodobnostních map. Proměnné tvořící její vstupy jsou popsány v tabulce č. 1 v sekci příloh. Funkce nemá žádné přímé výstupy. Jejím výsledkem jsou vypočtené pravděpodobnostní mapy uložené do adresáře obsahujícím složky patientských dat určených k analýze. Vypočtené pravděpodobnostní mapy jsou uloženy ve formátu *.img (s hlavičkou v příslušném *.hdr souboru). Funkce vypočítá odlišné pravděpodobnostní mapy na základě uživatelem zadané proměnné určující, zda má být počítán souhrnný vliv všech 24 regresorů či jejich jednotlivých kombinací. Pokud je uživatelem zvolen výpočet souhrnného vlivu všech regresorů, jsou vypočteny pravděpodobnostní mapy jmenované v tabulce č. 3.

Tabulka 3: Názvy pravděpodobnostních map počítaných pro souhrnný vliv všech pohybů

Název pravděpodobnostní mapy	Číslo odpovídajícího F kontrastu (viz tabulka č. 2)
PSTni_mapa_pohybu.img	1
PSTni_mapa_pohybu_diff.img	2
PSTni_mapa_pohybu_all.img	3
PSTni_mapa_pohybu_squared.img	4
PSTni_mapa_pohybu_24.img	5


Pokud uživatel zvolí výpočet kombinací dílčích regresorů, jsou vypočteny pravděpodobnostní mapy jmenované v tabulce č. 4.

Tabulka 4: Názvy pravděpodobnostních map počítaných pro vliv jednotlivých pohybů

Název pravděpodobnostní mapy	Číslo odpovídajícího F kontrastu (viz tabulka č. 3)
PSTni_mapa_pohybu_t1.img	1
PSTni_mapa_pohybu_t2.img	2
PSTni_mapa_pohybu_t3.img	3
PSTni_mapa_pohybu_r1.img	4
PSTni_mapa_pohybu_r2.img	5
PSTni_mapa_pohybu_r3.img	6

V obou případech je průběh funkce obdobný a liší se pouze proměnnou délkou cyklu pro výpočet všech nastavení kontrastů a načtením odlišných kontrastů. Průběh funkce

schematicky znázorňuje vývojový diagram na obr. 29. Ze schématu je patrné, že hlavní části funkce pracují ve dvou vnořených *for* cyklech. První z nich je pro všechny zvolené kontrasty a druhý pracuje přes všechny zahrnuté subjekty. V každém cyklu jsou načtené příslušné hodnoty F kontrastů. Dále jsou pomocí načtené masky vynulovány hodnoty voxelů, kde nejsou přítomny výsledky pro všechny subjekty v analýze. Poté je pomocí funkce z toolboxu spm8 vypočtena mezní hodnota F statistiky pro hladinu významnosti 0,001 a dané stupně volnosti. Touto hodnotou jsou v dalším kroku prahovány hodnoty F statistiky ve všech voxelech objemu. Nakonec je pro voxely, kde se vyskytuje nadprahová hodnota, inkrementována hodnota proměnné četnost o 1. Pro provedení daných výpočtů pro všechny subjekty je vypočtena pravděpodobnost výskytu statisticky významného projevu pohybu pro každý voxel a výsledky jsou uloženy jako soubor *.img do adresáře. Tento proces je proveden pro všechny zvolené kontrasty.



Obrázek 29: Blokový diagram funkce pro výpočet pravděpodobnostních map


8.2.5 vykonova_mapa

Celý název funkce:

vykonova_mapa(typ,nazvy_dat,cesta_k_datum,regresors,nazev_adresare,nazvy_cond,nazvy_session)

Tato funkce slouží k výpočtu výkonových map. Proměnné tvořící její vstupy jsou popsány v tabulce č. 1 v sekci příloh. Funkce nemá žádné přímé výstupy. Jejím výsledkem jsou vypočtené výkonové mapy uložené do adresáře obsahujícím složky dat subjektů určených k analýze. Vypočtené pravděpodobnostní mapy jsou uloženy ve formátu *.img (a příslušný *.hdr). Funkce vypočítá odlišné pravděpodobnostní mapy na základě proměnné regresors obdobně jako funkce pro počítání pravděpodobnostních map.

V obou případech je průběh funkce obdobný a liší se pouze proměnnou délkou cyklu pro výpočet všech nastavení kontrastů a načtením odlišných kontrastů. Průběh funkce schematicky znázorňuje vývojový diagram na obr. 30. Ze schématu je patrné, že hlavní části funkce pracují ve dvou hlavních vnořených *for* cyklech. První z nich je pro všechny zvolené kontrasty a druhý pracuje přes všechny zahrnuté subjekty. Pro každý subjekt jsou načteny změřené signály a je provedena jejich filtrace horní propustí a bělení autokorelačním filtrem. Dále je načtena kontrastní matice příslušící danému kontrastu a jsou načteny vektory vah regresorů. Dále je vnořený další *for* cyklus, který probíhá přes všechny voxely. V každém voxelu je vybrán jemu příslušející změřený signál. Poté je vybrán příslušející vektor vah a je vynásoben kontrastní maticí. Pohybový signál příslušící danému voxelu je vypočten jako suma váhovaných regresorů po filtraci a bělení (použity stejné filtry jako pro filtraci změřeného signálu). V dalších krocích je vypočtena energie obou signálů jako hodnota jejich rozptylu. Tato hodnota je počítána ze signálů po odstranění přechodových jevů na okrajích vzniklých během jejich filtrace. Nakonec je pro každý voxel určena hodnota výkonu pohybového signálu jako poměr jeho energie k energii změřeného signálu. Po dokončení cyklu pro všechny subjekty jsou hodnoty výkonu vynásobeny stem, aby byla získána procentuální hodnota výkonu. Nakonec je pro každý voxel vypočítán medián hodnoty procentuálního výkonu přes všechny subjekty. Výsledná mapa je uložena do adresáře. Tento postup je zopakován pro všechny zvolené kontrasty.



Obrázek 30: Blokový diagram funkce pro výpočet výkonových map

8.2.6 skupinova_statistika

Celý název funkce:

skupinova_statistika(nazev_adresare,nazvy_dat,cesta_k_datum,lomitko)

Tato funkce slouží k výpočtu skupinové statistiky v rámci dané studie. Proměnné tvořící její vstupy jsou popsány v tabulce č. 1 v sekci příloh. Funkce si sama načítá podle vstupních parametrů názvů dat soubory con_00*.img vytvořené během analýzy na úrovni jednotlivce. Funkce nemá žádné přímé výstupy. Jejím výsledkem jsou vypočtené statistické mapy uložené v adresáři, který funkce založí. Funkce načítá vždy pro každý z 24 pohybových regresorů pro všechny pacienty příslušný con_00*.img soubor, ve kterém jsou hodnoty vypočtené váhy daného regresoru násobené kontrastní maticí. Tyto skupiny souborů všech pacientů pro každý pohybový regresor tvoří 24 úrovní jednoho faktoru. Jednotlivé úrovně jsou považovány za závislé, jelikož jednotlivé pohybové parametry spolu úzce souvisí. Jejich variance je různá. Voláním Batch editoru funkce vypočítá matici návrhu pro daný model. V dalším kroku je definována kontrastní matice nastavená jako jednotková matice o velikosti 24x24 prvků, čímž je uvažován souhrnný vliv všech úrovní faktoru. Voláním Batch editoru je vypočtena skupinová statistika. Funkce vypočítá hlavní efekty každé z úrovní a také průměrný efekt všech úrovní. Jelikož účelem je zobrazení oblastí, kde se projeví alespoň jeden z pohybových regresorů u všech osob, je pro analýzu důležitá statistická mapa spmF_0027.img, která obsahuje příslušné statistické hodnoty.

8.2.7 Skript: skupinova_srovnani_studii

Tento skript slouží k výpočtu skupinové statistiky mezi vybranými studii. Na jeho začátku je nutné zadat cesty k jednotlivým adresářům všech studií, názvy dat ve studiích, cestu kam budou ukládány výsledky a název adresáře, ve kterém jsou uloženy výsledky z analýzy na úrovni jednotlivce obsahující vypočítané t-statistiky pro každý z pohybových regresorů. Výsledkem skriptu jsou vypočtené statistické mapy uložené v daném adresáři.

Skript si sám načítá podle vstupních parametrů názvů dat soubory con_00*.img vytvořené během analýzy na úrovni jednotlivce. Jejím výsledkem jsou vypočtené statistické mapy uložené v adresáři, který funkce vytvoří. Funkce načítá vždy pro každý z 24 pohybových regresorů pro všechny pacienty příslušný con_00*.img soubor, ve kterém jsou hodnoty vypočtené váhy daného regresoru násobené kontrastní maticí. Tyto skupiny souborů všech pacientů pro každý pohybový regresor tvoří 24 úrovní prvního faktoru. Takto jsou načtena data z každé ze studií, čímž je vytvořeno n úrovní druhého faktoru (pro n zahrnutých studií). Jednotlivé úrovně prvního faktoru jsou považovány za závislé, jelikož jednotlivé pohybové parametry spolu úzce souvisí. Jejich variance je různá. Úrovně druhého faktoru jsou považovány za nezávislé a rozptyl jejich hodnot je různý. Voláním Batch editoru funkce vypočítá matici návrhu pro daný model. V dalším kroku je definována kontrastní matice nastavená podle obr. 28, čímž je uvažován souhrnný vliv všech úrovní prvního faktoru u všech

studií. Voláním Batch editoru je vypočtena skupinová statistika. Funkce vypočítá hlavní efekty každé z úrovní každého faktoru, průměrný efekt všech úrovní prvního faktoru u každé z úrovní druhého faktoru a také průměrný efekt všech úrovní prvního faktoru pro současně všechny úrovně druhého faktoru. Jelikož účelem je zobrazení oblastí, kde se projeví alespoň jeden z pohybových regersorů u všech pacientů ve všech studiích je pro analýzu důležitá statistická mapa `spmF_0077.img`, která obsahuje příslušné statistické hodnoty.

9 Výpočet a interpretace výsledků získaných navrženými metodami

9.1 Popis použitých dat

Pro testování navržených metod byla využita data ze tří různých studií. Jednalo se o dva blokové experimenty a jeden event-related design. Z každé studie bylo do analýzy zahrnuto 50 pacientů.

9.1.1 Studie VOBd2

Jedná se o data z vizuálního *oddball* experimentu. Při tomto typu experimentu jsou vyšetřované osobě promítány tři typy stimulů. Frekventní (frekvent), vyskytující se velmi často, poté cílový (target) a rušivý (distraktor). Stimulace byla typu event-related. Do studie byli zahrnuti pouze zdraví dobrovolníci ve věku mezi 22 a 31 lety.

Data byla snímána magnetickým tomografem s magnetickou indukcí 1,5 Ts čas skenů byl 1,66 s, TE = 45 ms, FA (sklápěcí úhel) = 80°. FOV bylo 250x250 mm. Pro každou session (Cekem byly změřeny čtyři session. V rámci práce bylo počítáno pouze s daty z první session.) bylo získáno 256 skenů s rozlišením 64 x 64 bodů v rovině řezu a počtem 17 transverzálních řezů na objem o tloušťce 6 mm.

9.1.2 Studie VSMT

Jedná se o data z vizuálního experimentu s jedním typem stimulační podmínky. Stimulace měla blokové schéma. Do studie byli zahrnuti zdraví dobrovolníci i pacienti ve věku mezi 49 a 88 lety.

Data byla snímána magnetickým tomografem s magnetickou indukcí 1,5 T. Pro funkční skeny byla použita gradientní-echo EPI sekvence. Repetiční čas skenů byl 2,05 s, TE = 50 ms, FA (sklápěcí úhel) = 90°. FOV bylo 240x240 mm. Bylo získáno 260 skenů s rozlišením 64 x 64 bodů v rovině řezu a počtem 20 transverzálních řezů na objem o tloušťce 5 mm.

9.1.3 Studie VFTv

Jedná se o data z vizuálního experimentu s jedním typem stimulační podmínky. Stimulace měla blokové schéma. Do studie byli zahrnuti zdraví dobrovolníci i pacienti ve věku mezi 23 a 49 lety.

Data byla snímána magnetickým tomografem s magnetickou indukcí 1,5 T. Pro funkční skeny byla použita gradientní-echo EPI sekvence. Repetiční čas skenů byl 4,52 s (zahrnuje 1000 ms pauzu mezi akvizicemi), TE = 40 ms, FA (sklápěcí úhel) = 90°. FOV bylo 220x220 mm.


Bylo získáno 71 skenů s rozlišením 64 x 64 bodů v rovině řezu a počtem 32 transversálních řezů na objem o tloušťce 3,5 mm.

9.2 Interpretace dosažených výsledků

Výsledkem jsou jednotlivé mapy (uložené ve formátu obsahujícím data *.img a formátu obsahujícím hlavičku souboru *.hdr) popisující projevy pohybových artefaktů v měřeném signálu. Jednotlivé mapy byly vizualizovány na subjektivně určených hodnotách prahu, které vedly k tomu, aby zobrazení byla co nejvíce přehledná a vypovídající. Při interpretaci výsledků tak musí být k tomuto faktu přihlédnuto. Pro vizualizaci pravděpodobnostních a výkonových map byla použita barevná škála *Hot* a barevná škála *HSV*, viz obr. 9 v sekci příloh. Pro vizualizaci výsledků skupinových analýz byla využita také teplotní barevná škála.

9.2.1 Pravděpodobnostní mapy

Pravděpodobnostní mapy ukazují konzistentnost projevu pohybového artefaktu na dané pozici v objemu mozku. Rozsah hodnot je v rozmezí od nuly do sta, přičemž výsledná hodnota vždy udává procento výskytu artefaktu na dané pozici v rámci vybraného vzorku měřených subjektů. Obr. 31 ukazuje výsledné pravděpodobnostní mapy pro zahrnuté studie.




Obrázek 31: Srovnání pravděpodobnostních map mezi studiemi (rozmezí hodnot 0 až 100, barevná škála HSV)


9.2.2 Výkonové mapy

Výkonové mapy graficky znázorňují míru projevu pohybových artefaktů v různých oblastech mozku. Hodnoty jsou v rozmezí od nuly do sta a vyjadřují, jaké procento výkonu celkového změřeného signálu představuje pohybový arteficiální signál. Ten byl získán na základě toho, kolik variability signálu bylo připsáno pohybovým regresorům při analýze na první úrovni. Výkonové mapy ukazují hodnoty výkonu reprezentativní pro danou studii. Na obr. 32 je patrné srovnání výskytů a hodnot výkonů u třech sledovaných studií. Nejnižší procento výkonu bylo pozorováno u VOBd2 studie. S ohledem na to, že do studie byli zahrnuti pouze zdraví a mladí dobrovolníci, dá se předpokládat, že u nich nedocházelo k pohybu tak často jako u pacientů ostatních studií. Pohybový signál tedy netvořil tak značnou část celkového signálu. Naopak u studie VFTv, kde byli zahrnuti pacienti starší a také nemocní, docházelo k pohybu během snímání více a výsledný signál tak obsahoval větší podíl pohybových artefaktů. Lokality, kde se pohybové artefakty projevovaly, jsou totožné.

Na obr. 33 je patrné log-normální rozložení výskytu daných hodnot výkonu u subjektů studie VSMT v oblastech nejvíce postižených pohybovými artefakty. Za nejvíce postižené oblasti mozku, byly považovány oblasti, kde medián výkonů přes všechny subjekty ve studii byl vyšší nežli 25 %.




Obrázek 32: Srovnání výkonových map mezi studiemi (rozmezí hodnot 0 až 100, barevná škála *Hot*)




Obrázek 33: Histogram četnosti výskytu výkonu pro pohybovémi artefakty nejvíce postižené oblasti

9.2.3 Lokalizace projevu pohybových artefaktů pomocí pravděpodobnostních a výkonových map


Na obr. 34 zobrazujícím sagitální řezy pravděpodobnostními a výkonovými mapami je ukázán projev pohybového artefaktu v oblasti kalózního tělesa a na okrajích mozku. Následující obr. 35 a 36 zobrazují koronální řezy ukazující projevy artefaktů v oblastech předních a zadních mozkových komor, na okrajích mozku a v oblasti podélného mozkového zářezu.



Obrázek 34: Lokalizace projevu pohybových artefaktů – sagitální řezy vedené středem (rozmezí hodnot 0 až 100, barevná škála HSV-nahoře, barevná škála Hot - dole)




Obrázek 35: Lokalizace projevu pohybových artefaktů – koronální řezy pravděpodobnostními mapami (rozmezí hodnot 0 až 100, barevná škála HSV)



Obrázek 36: Lokalizace projevu pohybových artefaktů – koronální řezy výkonovými mapami (rozmezí hodnot 0 až 100, barevná škála Hot)

9.2.4 Interpretace statistických map skupinové analýzy

Statistické mapy získané při skupinové analýze vyjadřují, zda v daném voxelu bylo u všech subjektů ve studii zaznamenáno statisticky významné vysvětlení variability změřeného signálu pomocí libovolné kombinace 24 pohybových regresorů. Tento typ zobrazení výskytu pohybového artefaktu tedy ukazuje místa, kde se pohyb nějakým způsobem projevoval u všech pacientů při dané studii. Výsledky byly zobrazovány na hladině významnosti $p = 0,001$ s odpovídající hodnotou $F = 2,159$. Na následujícím obr. 37 je zobrazen výběr několika řezů výslednou mapou pro každou studii. Kompletní statistické mapy všech studií je možné nalézt v sekci příloh.




Obrázek 37: Srovnání výsledných map skupinové statistiky mezi studiemi, prahování na hladině $p=0,001(F>2,159)$

Na obr. 37 je patrné, že projev pohybových artefaktů se v rámci jednotlivých studií lišil. Nejméně míst spojených s pohybem na hladině významnosti $p = 0,001$ u všech osob ve studii bylo nalezeno u studie VFTv. Lokality, které byly pohybovému artefaktu přisouzeny, se zdají být v souladu s teoretickými předpoklady. Malá míra variability přisouzená artefaktům může být spojena s velmi dlouhým časem TR. Je možné, že mnoho pohybů, které daly vzniknout pohybovým artefaktům, nebylo postihnuto pohybovými regresory, které vychází z transformačních parametrů. Ty totiž odhadují průběh pohybu pouze v časech snímání

a veškeré pohyby mezi jednotlivými skeny nejsou těmito parametry zaznamenány. Dále, jelikož je touto metodou sledováno, kde se pohyb projeví u všech subjektů, je možné chápat sníženou míru „aktivací“ v důsledku pohybových artefaktů jako nekonzistentnost výsledků mezi pacienty. Zajímavé je, že u této studie nebyl na hladině významnosti $p = 0,001$ pozorován statisticky významný projev pohybových artefaktů na okrajích mozku, ale pouze v oblasti mozkových komor. Na nižší hladině významnosti již byl pozorován výskyt pohybového artefaktu i na okrajích mozku. U druhých dvou studií je patrný největší projev pohybových artefaktů v oblastech na okrajích mozku a v blízkosti mozkových komor.

9.2.5 Interpretace dílčích částí pohybů

Obr. 38 znázorňuje konzistentnost statisticky významného výskytu souhrnného vlivu daného typu pohybu (3 translační a 3 rotační), jeho difference a jejich druhých mocnin.




Obrázek 38: Pravděpodobnostní mapy výskytu projevu jednotlivých typů pohybů (rozmezí hodnot 0 až 100, barevná škála *Hot*)

Pohybové parametry a jejich druhé mocniny spolu vykazují jistou míru korelace a v některých voxelech mohou být odhadnuty váhy těchto regresorů s opačným efektem, což vede k výsledným antikorelacím mezi vzniklými signály (násobek průběhu daného regresoru a jeho váhy. Tento efekt vede ve výsledném modelovaném signálu ke vzájemnému vyrušení vlivů některých dílčích signálů. Maximální výchylka měřeného signálu pak může v těchto případech být nižší, nežli amplituda pouze některých vybraných dílčích signálů. Tento efekt vede k nepřiměřeně vysokým hodnotám procentuálního výkonu v takto postižených voxelech. Jedná se především o voxely na okraji mozku, ve kterých je celkový měřený signál tvořen převážně pohybovým signálem. S ohledem na toto zjištění se navržená metoda zdá pro sledování dílčích vlivů jednotlivých regresorů nevhodná. Jelikož tento problém nastává pouze výjimečně

u některých subjektů a ojedinělých voxelů, ve výsledné hodnotě výkonu, určené jako medián přes subjekty, se tyto odchylky na první pohled neprojeví. Pro sledování výkonu dílčích pohybů je vhodnější vytvoření modelů obsahujících pouze zainteresované regresory, čímž by se vzniklým nepřesnostem dalo předejít.


Obr. 39 ukazuje míru projevu jednotlivých pohybů – translací ve 3 hlavních osách a rotací okolo těchto hlavních os. Výsledky jsou však pouze ilustrační s ohledem na možnosti vzniku nepřesností, jak bylo uvedeno výše.




Obrázek 39: Výkonové mapy vlivu jednotlivých typů pohybů (translací v hlavních osách a rotací okolo nich) (rozmezí hodnot 0 až 100, barevná škála *Hot*)

9.2.6 Interpretace vlivů diferencí a druhých mocnin

Obr. 40 ukazuje srovnání konzistentnosti výskytu statisticky významného vlivu základních 6 pohybových parametrů, jejich diferencí, vzniklých 12 pohybových parametrů, druhých mocnin 12 parametrů a všech 24 parametrů.



Obrázek 40: Pravděpodobnostní mapy vlivu diferencí a druhých mocnin pohybových parametrů pro studii VSMT (rozmezí hodnot 0 až 100, barevná škála HSV)




Obrázek 41: Výkonové mapy vlivu diferencí a druhých mocnin pohybových parametrů pro studii VSMT (rozmezí hodnot 0 až 100, barevná škála Hot)


Na obr. 41 jsou znázorněny výkonové mapy popisující vliv diferencí a druhých mocnin pohybových parametrů. Model byl odhadnut pro 24 regresorů. Na obrázcích je patrná nižší míra výkonu při zahrnutí více pohybových parametrů. Vyšší výkon u map s menším počtem regresorů je důsledkem antikorelací mezi vysvětlenými signály využívajícími základní pohybovémi parametry a vysvětlenými signály, využívajícími druhé mocniny. Při hodnocení všech regresorů naráz se antikorelované signály vzájemně tlumí a výkon je nižší, než když je zahrnuta pouze část regresorů a chybí k nim jejich antikorelované protějšky.

9.2.7 Srovnání využití modelů s různým počtem pohybových regresorů

V rámci práce se ukázalo, že využití vyššího počtu regresorů v modelu nepřináší žádnou nové informace o lokalizaci výskytu pohybového artefaktu. Výsledný výkon přisouzený pohybovému signálu je sice vyšší, viz obr. 43, ale samotná lokalizace artefaktu je totožná, viz obr. 42. Rozdíl mezi modelem se zahrnutými diferencemi a modelem uvažujícím i druhé mocniny pohybových parametrů a jejich diferencí je sice statisticky prokazatelný, ale není již příliš velký.




Obrázek 42: Srovnání modelů s různým počtem zahrnutých pohybových regresorů (studie VSMT)
(rozmezí hodnot 0 až 100, barevná škála *Hot*)



Obrázek 43: Kvantitativní srovnání modelů s různým počtem zahrnutých pohybových regresorů (studie VSMT)

9.2.8 Srovnání výsledků mezi jednotlivými studiemi

Následující statistická mapa na obr. 44 ukazuje místa projevu pohybových artefaktů u všech subjektů přes všechny zahrnuté studie. Tato mapa ukazuje lokality, kde byla přisouzena statisticky významná část variability alespoň jednomu z pohybových regresorů u všech osob ve všech studiích. Opět je možné pozorovat největší výskyt pohybových artefaktů v teoreticky předpokládaných lokalitách.



Obrázek 44: Mapa projevu pohybových artefaktů mezi studiemi, prahování na hladině $p = 0.001$, ($F > 1.801$)

9.3 Diskuse

9.3.1 Lokalizace projevu pohybových artefaktů

Bylo prokázáno, že pohybové artefakty se projevují především v místech rozhraní různých tkání. Pro všechny výsledné pohybové mapy je charakteristický výskyt pohybových artefaktů na okraji mozku, v oblastech předních a zadních mozkových komor, v oblasti kalózního tělesa a v oblasti podélného mozkového zářezu mezi hemisférami. Jak ukazují výkonové mapy, tyto lokality vykazovaly nejvyšší výkon signálu, který odpovídal pohybovým artefaktům. Zároveň se v těchto lokalitách, jak je patrné z pravděpodobnostních map, vyskytoval statisticky významný vliv pohybových artefaktů nejkonzistentněji přes všechny osoby. Mapy skupinových statistik také ukazují výskyt artefaktů v rámci osob dané studie na obdobných lokalitách. Analýza v rámci jednotlivých studií ukázala, že u všech studií se lokality nejvíce postižené pohybovými artefakty shodují.

V úvahu však musí být vzato, že na sebe pohybové regresory mohly v některých místech navázat variabilitu spojenou s aktivací daných mozkových center, ať už tato aktivace byla výsledkem experimentální stimulace či nikoliv.

9.3.2 Srovnání modelů s různými počty zahrnutých pohybových regresorů

V rámci práce se ukázalo, že rozšíření 6 základních pohybových parametrů na celkový počet 24 je pro lokalizaci pohybových artefaktů nevýznamné. Zahrnutí diferencí a druhých mocnin do modelu nepřináší nové informace o výskytu pohybových artefaktů. Tento postup vede k přisouzení větší části variability dat pohybovým artefaktům a tedy i ke zvýšené míře projevu výkonu arteficiálního signálu. Pro zmapování lokalit nejvíce postižených pohybovými artefakty tedy rozšířený počet pohybových regresorů nepřináší nové poznatky, ale pro zjištění míry projevu pohybových artefaktů v těchto lokalitách, udává přesnější informace.

9.3.3 Srovnání uplatnění pohybových regresorů mezi studii

Z pravděpodobnostních a skupinových map projevu pohybových artefaktů je patrné, že ve studii VFTv bylo uplatnění pohybových regresorů mezi osobami nejvíce odlišné. Pravděpodobnostní mapy ukazují na velmi nízkou konzistentnost projevu artefaktů v odpovídajících si lokalitách. Obdobně na skupinových mapách příslušejících této studii je patrné, že pohybové regresory statisticky významně ovlivnily variabilitu dat u všech osob na méně místech a s menší statistickou významností nežli u ostatních studií. Možným vysvětlením je dlouhý repetiční čas použitý u této studie. Mnoho pohybů tak nemuselo být zaznamenáno a odhad průběhu pohybu z transformačních parametrů procesu zarovnání tak byl velmi nepřesný. Dalším možným vysvětlením může být výběr osob v této studii. Ačkoliv výsledky projevu pohybových artefaktů se v rámci studie nezdály konzistentní, výkon v místech, kde došlo k jejich výskytu, byl vysoký.

9.3.4 Zhodnocení možnosti zkoumání dílčích vlivů jednotlivých regresorů a jejich kombinací

V rámci práce se ukázalo, že zkoumání projevů dílčích pohybových parametrů – posunů a rotací v hlavních osách, stejně jako zkoumání vlivu diferencí a druhých mocnin pohybových parametrů, by bylo metodologicky správnější provádět při použití modelu obsahujícím pouze tyto dílčí regresory. Metody by bylo vhodné rozšířit o výpočty statistické analýzy na prvním stupni s modely pro každý ze zkoumaných pohybových parametrů, či jejich kombinací. Na tuto práci bych ráda navázala v doktorském studiu, kdy bych v prvních fázích chtěla implementovat tento poznatek a testovat ho na reálných datech.

Ryze subjektivním hodnocením konzistentnosti výskytu vlivu jednotlivých pohybů nelze usuzovat o vztahu jednotlivých typů pohybu k specifickým místům projevu souvisejících artefaktů. Dle teoretických předpokladů by posun v ose z (a také rotace okolo os x a y, které vyvolají změny pozice voxelů v ose z) měl představovat největší míru výkonu. Posun v této ose

způsobuje nejen vznik susceptibilních artefaktů, ale také spin-history artefakt. Zajímavé by bylo odhalení lokalit nejvýraznějšího projevu *spin-history* artefaktu modelováním translací v ose z a rotací okolo os x a y . Výsledné srovnání vlivů dílčích regresorů by mělo být prováděno objektivním srovnáním velikostí hodnot na daných pozicích.

9.3.5 Srovnání různých typů navržených map

Pravděpodobnostní a skupinové mapy vypovídají především o lokalizaci projevu pohybových artefaktů. Ze všech tří typů vytvořených map sloužících k popisu projevu pohybových artefaktů proto mají pro další využití největší význam výkonové mapy. Ty se zobrazenými lokalitami shodují s pravděpodobnostními mapami, tedy oblasti s větším výkonem pohybového signálu bývají v populaci častěji spojeny s pohybovým artefaktem. Navíc však tyto mapy přináší informaci o výkonu pohybového signálu v těchto oblastech. Tato informace může být dále využita při simulování pohybových artefaktů v uměle vytvářených datech. Díky znalosti rozložení výkonů v těchto oblastech je možné pro každý voxel uměle simulovaných dat přiřadit hodnotu výkonu pohybového signálu na základě přiřazení náhodné hodnoty dle distribuční funkce vytvořené z histogramu četností výskytu výkonu v dané oblasti.

9.3.6 Zhodnocení navržených metod a možnosti jejich úpravy

Navržené metody vychází z předpokladu, že vypočtené parametry zarovnání funkčních skenů přesně reflektují pohyb subjektu během měření. Tento předpoklad však nemusí být vždy splněn. V případě velmi dlouhého repetičního času akvizice funkčních skenů může docházet ke vzniku pohybových artefaktů vlivem pohybu subjektu, aniž by tyto pohyby byly zaznamenány. Tento problém by bylo možné vyřešit snímáním pohybu sledované osoby pomocí akcelerometru po dobu měření. Prakticky je tento postup však problematický s ohledem na nutnost zajištění kompatibility zařízení s přístrojem magnetické rezonance.

Důležité je si uvědomit, že navržené metody jsou pouze odhadem a nikoliv přesnou informací. Vychází ze statisticky odhadnutých výsledků analýzy jednotlivce, čímž zavádí do výsledků nejistotu. Zvolení hodnoty prahu při striktním prahování mezní hodnotou F statistiky při vytváření pravděpodobnostních map hraje v tomto problému velmi důležitou roli. V navržené metodě je za mezní hodnotu uvažována hodnota bez korekce pro mnohonásobné testování, což na jednu stranu může být poněkud benevolentní přístup. Tato hodnota však byla zvolena s ohledem na snahu o lokalizaci veškerých míst, která by mohla být postižena pohybovými artefakty. V úvahu ale musí být vzato, že se tím do výsledků mohou dostat i lokality, které ve skutečnosti pohybovým artefaktem jsou postiženy jen velmi málo. Výkonové mapy jsou v tomto ohledu přesnější, jelikož k prahování při jejich tvorbě nedochází. Jejich využití při zkoumání dílčích vlivů je omezeno vznikem nepřesností při výskytu antikorelací mezi pohybovými regresory a jejich umocněnými či diferencovanými variantami nebo mezi skutečnými aktivacemi a pohybovými regresory. V takových případech může docházet ke vzniku neúměrně vyšších hodnot výkonu signálu. Tento problém je nevýhodou této

metodologie a odstranit lze zahrnutím pouze zainteresovaných regresorů do modelu a nekorelovaností pohybových regresorů s regresory odpovídajícími experimentální stimulaci.

Dále je při tvorbě map předpokládáno, že jednotlivé voxely si přesně odpovídají. To klade vysoké nároky na kvalitu normalizace použitých skenů.

S ohledem na to, že v této oblasti neexistuje žádný zlatý standard, není možné provést objektivní zhodnocení výsledků navržených metod. Navržené postupy tedy tvoří zcela nový náhled na danou problematiku.

Pro získání informace o lokalizaci pohybových artefaktů, je nejvýhodnější využití pravděpodobnostních nebo výkonových map. Tyto mapy by bylo možné ještě zobecnit zahrnutím většího množství různých studií do testování a následně zkoumat průměrný efekt pohybových artefaktů pomocí pravděpodobnostních a výkonových map přes všechny studie. Tím by mohla být vytvořena obecně platná mapa projevu pohybových artefaktů nezávislá na parametrech měření. Výkonové mapy by navíc v budoucnu mohly být upraveny do podoby, kdy by mapa pro každý voxel obsahovala specifické hodnoty popisující tvar log-normálního rozložení hodnot výkonů pro danou pozici v mozku. Z těchto hodnot by poté bylo pro každou pozici jednoduše zrekonstruovatelné toto rozložení, na jehož základě by byl pro danou pozici uměle generován arteficiální signál při modelování dat.

10 Závěr

V rámci práce bylo prvním úkolem důsledné nastudování principů zobrazování funkční magnetickou rezonancí a souvisejících analýz. Teoretická část práce byla věnována základním principům a technikám zobrazování magnetickou rezonancí a principům funkční magnetické rezonance. Dále se teoretická část zabývala předzpracováním fMRI dat, především procesu zarovnání funkčních snímků s ohledem na úzkou souvislost možnosti využití transformačních parametrů procesu zarovnání snímků k mapování pohybových artefaktů. Pozornost v oblasti předzpracování byla také věnována metodě *unwarp* ačkoliv tato metoda nebyla již pro svou nevhodnost k mapování pohybových artefaktů v práci používána. Metoda *unwarp* totiž slouží k odstranění pohybových artefaktů, zatímco v práci byla věnována pozornost jejich mapování a jejich odstranění z analyzovaných dat by tedy bylo kontraproduktivní. Další část teoretické práce byla věnována popisu artefaktů souvisejících s pohybem pacienta ve skeneru. Fyzikální principy vedoucí ke vzniku jednotlivých pohybových artefaktů jsou velmi komplexní a složitou problematikou. Každý pohyb vyvolává několik odlišných dějů vedoucích ke zkreslení dat. Pohyb během skenu způsobuje *ghost* artefakt, projevující se ve směru kódování fáze a vedoucí ke zhoršení hrubého SNR. Pohyb mezi jednotlivými skeny zhoršuje funkční SNR. Nejvýrazněji se pohyb projevuje na rozhraních tkání s různou susceptibilitou, kde dochází k projevu susceptibilního pohybového artefaktu. Ten se projevuje ztrátou signálu na těchto rozhraních a geometrickým zkreslením signálu v přilehlém okolí. *Spin-history* artefakt vznikající při pohybu v ose hlavního magnetického pole se projevuje intenzitním zkreslením snímků a nejvýrazněji je přítomen v tkáních s dlouhým T1 časem. Pohyb pacienta je zodpovědný za největší část arteficiální variability dat a jeho potlačení a mapování oblastí jeho projevu je tak velmi žádoucí

V rešeršní části práce bylo zmíněno, že je možné využít zahrnutí 6 pohybových parametrů, získaných při zarovnání, jako regresorů GLM a tím snížit počet falešně pozitivních aktivací vzniklých v důsledku chybného přisouzení variability signálu aktivacím na místo pohybovým artefaktům. Tento poznatek byl dále využit při mapování pohybových artefaktů. V práci byly zmíněny studie navrhuující postup rozšíření původních 6 pohybových parametrů o jejich difference a druhé mocniny, čímž je možné získat celkem 24 pohybových parametrů. Využití druhých diferencí pohybových parametrů a jejich konvoluce s hemodynamickou odezvou se ukázalo pro potřeby mapování pohybových artefaktů nevhodné a nebylo proto v práci využíváno.

V práci byly navrženy tři odlišné metody pro zmapování projevu pohybových artefaktů. Tyto navržené metody byly implementovány v programovacím prostředí MATLAB s využitím toolboxu SPM. Vytvořený program provádí navrženou metodiku a umožňuje zadávání v dávkovém módu. Navržené metody byly testovány na reálných datech. Testování probíhalo

na datech ze tří odlišných studií, kde každá byla snímána na stejném přístroji, ale s odlišnými parametry snímání. Z každé studie bylo pro testování vybráno 50 pacientů.

První z navržených metod slouží k vytvoření pravděpodobnostních map. Tyto mapy jsou určeny k vizualizaci míst s nejkonzistentnějším projevem pohybového artefaktu v souboru osob dané studie. Pro každý voxel objemu mozku je vypočtena hodnota určující pravděpodobnost s jakou se v daném místě projeví pohybový artefakt u všech pacientů. Tyto mapy vycházejí z výpočtů statistické analýzy na úrovni jedince a sledují souhrnný projev všech 24 pohybových parametrů. V práci byla navíc věnována pozornost i sledování vlivu zvolených kombinací regresorů. V závislosti na nastavení výběru požadovaného kontrastu je možné v případě zájmu sledovat pravděpodobnost výskytu projevu i pouze 6 základních pohybových parametrů, jejich diferencí nebo jejich mocnin. Vytvořený program také umožňuje zkoumání vlivu daného typu pohybu (daného pohybového parametru, jeho difference a jejich mocnin)

Druhou možností zkoumání pohybového artefaktu je vytvoření výkonových map. Tyto mapy slouží k určení míry projevu pohybových artefaktů v daném voxelu. Vytvořené mapy vychází opět z výsledků statistiky na úrovni jedince a míru projevu artefaktu určují jako procentuální poměr energie pohybového signálu k změřenému signálu. Výpočty jsou prováděny pro všechny osoby a výsledná hodnota je určena jako medián z dat všech osob. I zde program umožňuje v závislosti na nastavení výběru požadovaného kontrastu sledovat výkon i pouze 6 základních pohybových parametrů, jejich diferencí nebo jejich mocnin, případně zkoumání vlivu daného typu pohybu (daného pohybového parametru, jeho difference a jejich mocnin). Při testování použití navržené metodologie tvorby výkonových map pouze z dílčích kombinací regresorů však bylo zjištěno, že je tento přístup pro tvorbu výkonových map nevhodný a korektnějším řešením je počítání map z výsledků modelu, který zahrnuje pouze vybrané regresory.

Poslední možností je provedení skupinové analýzy. Při ní jsou zobrazovány lokality, ve kterých bylo vypočteno statisticky významné vysvětlení variability dat u všech osob, přispěním libovolné kombinace pohybových regresorů.

V práci bylo také testováno skupinovou full-factorial analýzou, ve kterých místech se projevoval jakýkoliv typ pohybu, tedy regresoru, statisticky významně u všech subjektů ve všech studiích. Vytvořená statistická mapa potom zobrazuje lokality projevu pohybových artefaktů, které nejsou ovlivněny parametry snímání a typem experimentu.

Testováním na reálných datech bylo zjištěno, že pohybové artefakty se nejvíce projevují především na okrajích mozku, v oblastech předních a zadních mozkových komor a v oblasti kalózního tělesa.

Tato práce byla zaměřena především na vyzkoušení různých přístupů pro mapování pohybových artefaktů. Bylo zde nastíněno několik různých přístupů, z nich nejvýhodnějším pro další využití se zdá být tvorba výkonových map ukazujících míru projevu artefaktů. V poslední části práce bylo také nastíněno, jakým způsobem může být tato práce v budoucnu rozšířena.

11 Seznam zkratek

RF	radiofrekvenční
MR	magnetická rezonance
fMRI	zobrazování funkční magnetickou rezonancí
TR	repetiční čas
TE	echo-time
GRE	Gradient Echo
SE	Spin Echo
HRF	hemodynamická odezva
SNR	poměr signálu k šumu
GLM	obecný lineární model
MIP	maximal intensity projection
VSMT	název jedné ze zahrnutých studií
VFTv	název jedné ze zahrnutých studií
VOBd2	název jedné ze zahrnutých studií

12 Seznam obrázků

Obrázek 1: Precesní pohyb protonu [3].....	4
Obrázek 2: Nutační pohyb [3].....	5
Obrázek 3: Průběh FID signálu [3]	6
Obrázek 4: T1 relaxace	6
Obrázek 5: T2* relaxace	7
Obrázek 6: SE sekvence.....	8
Obrázek 7: GRE sekvence.....	8
Obrázek 8: EPI sekvence (vlevo) a způsob plnění k-prostoru	9
Obrázek 9: Modelový průběh hemodynamické odpovědi [7].....	13
Obrázek 10: Blokový a event-related design	14
Obrázek 11: Pohyb hlavy způsobující falešnou aktivaci [2].....	21
Obrázek 12: Vliv pohybu na změnu deformace obrazu objektu [19]	24
Obrázek 13: Funkční snímek (vlevo) a anatomický snímek [2]	25
Obrázek 14: Gaussův filtr	26
Obrázek 15: Časový průběh MR signálu (vlevo) a jeho výkonové spektrum [2].....	27
Obrázek 16: Maticový zápis obecného lineárního modelu	29
Obrázek 17: Efekt ovlivnění BOLD signálu pohybovými artefakty [23].....	34
Obrázek 18: Ukázka matice návrhu a výsledné statistické mapy s využitím pohybových parametrů jako regresorů v GLM ($p = 0,001$, bez korekce).....	34
Obrázek 19: Schéma základních kroků vytvořených metod.....	36
Obrázek 20: Ukázka průběhu parametrů translací	37
Obrázek 21: Ukázka průběhu parametrů rotací.....	37
Obrázek 22: Ukázkové časové průběhy translací a jejich diferencí (ose x – červeně, v ose y – zeleně, v ose z - modře).....	39
Obrázek 23: Ukázkové časové průběhy druhých mocnin translací a jejich diferencí (ose x – červeně, v ose y – zeleně, v ose z - modře).....	39
Obrázek 24: Nastavení kontrastní matice pro testování souhrnného vlivu všech pohybových regresorů pro úkol typu vizuální <i>oddball</i> se třemi regresory pro experimentální stimulaci.	40
Obrázek 25: Proces výpočtu pravděpodobnostní mapy	41
Obrázek 26: Proces výpočtu výkonové mapy	42
Obrázek 27: Nastavení matice návrhu pro skupinovou analýzu	43
Obrázek 28: Nastavení matice návrhu pro testování vlivu typu studie a jednotlivých pohybových regresorů.....	44
Obrázek 29: Blokový diagram funkce pro výpočet pravděpodobnostních map	51
Obrázek 30: Blokový diagram funkce pro výpočet výkonových map.....	53

Obrázek 31: Srovnání pravděpodobnostních map mezi studii (rozmezí hodnot 0 až 100, barevná škála <i>HSV</i>)	57
Obrázek 32: Srovnání výkonových map mezi studii (rozmezí hodnot 0 až 100, barevná škála <i>Hot</i>)	58
Obrázek 33: Histogram četnosti výskytu výkonu pro pohybové artefakty nejvíce postižené oblasti	59
Obrázek 34: Lokalizace projevu pohybových artefaktů – sagitální řezy vedené středem (rozmezí hodnot 0 až 100, barevná škála <i>HSV-nahoře</i> , barevná škála <i>Hot - dole</i>).....	59
Obrázek 35: Lokalizace projevu pohybových artefaktů – koronální řezy pravděpodobnostními mapami (rozmezí hodnot 0 až 100, barevná škála <i>HSV</i>).....	60
Obrázek 36: Lokalizace projevu pohybových artefaktů – koronální řezy výkonovými mapami (rozmezí hodnot 0 až 100, barevná škála <i>Hot</i>).....	60
Obrázek 37: Srovnání výsledných map skupinové statistiky mezi studii, prahování na hladině $p=0,001 (F>2,159)$	61
Obrázek 38: Pravděpodobnostní mapy výskytu projevu jednotlivých typů pohybů (rozmezí hodnot 0 až 100, barevná škála <i>Hot</i>)	62
Obrázek 39: Výkonové mapy vlivu jednotlivých typů pohybů (translací v hlavních osách a rotací okolo nich) (rozmezí hodnot 0 až 100, barevná škála <i>Hot</i>)	63
Obrázek 40: Pravděpodobnostní mapy vlivu diferencí a druhých mocnin pohybových parametrů pro studii VSMT (rozmezí hodnot 0 až 100, barevná škála <i>HSV</i>).....	64
Obrázek 41: Výkonové mapy vlivu diferencí a druhých mocnin pohybových parametrů pro studii VSMT (rozmezí hodnot 0 až 100, barevná škála <i>Hot</i>).....	64
Obrázek 42: Srovnání modelů s různým počtem zahrnutých pohybových regresorů (studie VSMT) (rozmezí hodnot 0 až 100, barevná škála <i>Hot</i>)	65
Obrázek 43: Kvantitativní srovnání modelů s různým počtem zahrnutých pohybových regresorů (studie VSMT)	65
Obrázek 44: Mapa projevu pohybových artefaktů mezi studii, prahování na hladině $p = 0.001, (F > 1.801)$	66

13 Seznam použité literatury

- [1] DRASTICH, Aleš. *Tomografické zobrazovací systémy*. 1. vyd. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2004. ISBN 80-214-2788-4.
- [2] HUETTEL, Scott A., SONG, Allen W., MCCARTHY, Gregory. *Functional Magnetic Resonance Imaging*. 2. vyd. Sunderland: Sinauer Associates, Inc, 2009. ISBN 978-0-87893-286-3.
- [3] BUXTON, Richard B. *Introduction to Functional Magnetic Resonance Imaging*. 2. vyd. New York: Cambridge University Press, 2009. ISBN 978-0-521-89995-6.
- [4] MIKL, Michal. *Funkční magnetická rezonance / fMRI Brno* [online]. [cit. 2012-10-20]. Dostupné z: <<http://fmri.mchmi.com>>
- [5] MATTHEWS, P. M.; JEZZARD, P. Functional magnetic resonance imaging. *Journal of Neurology, Neurosurgery & Psychiatry* [online]. Aug. 2003, vol. 75, no. 1: 6-12. [cit. 2012-10-20]. Dostupné z: <<http://jnnp.bmj.com/content/75/1/6.full>>
- [6] ŠIMURDA, J. *Bioelektrické jevy*. Brno, Fakulta elektrotechniky a komunikačních technologií, VUT Brno. 2007. p. 1 - 72.
- [7] HEIJBLUM, Michelle. *Visualising tinnitus with fMRI and EEG*. MS thesis. Technical Medicine University of Twente, Aug. 2009. Dostupné z: <http://www.mst.nl/neurochirurgie/Onderzoek/tinnitus.doc/>
- [8] JEZZARD, P and S CLARE. 1999. Sources of distortion in functional MRI data. *Human Brain Mapping* [online]. roč. 8, č. 2-3, s. 80–85. Dostupné z: <http://www.scopus.com/inward/record.url?eid=2-s2.0-0032883422&partnerID=40&md5=60035245b82f4760cb0afb11da29820e>
- [9] DIEDRICHSEN, Jörn and Reza SHADMEHR. 2005a. Detecting and adjusting for artifacts in fMRI time series data. *NeuroImage* [online]. roč. 27, č. 3, s. 624–34 [vid. 5. April 2013]. Dostupné z: doi:10.1016/j.neuroimage.2005.04.039
- [10] FIELD, A S, Y.-F. YEN, J H BURDETTE and A D ELSTER. 2000. False cerebral activation on BOLD functional MR images: Study of low-amplitude motion weakly correlated to stimulus. *American Journal of Neuroradiology* [online]. roč. 21, č. 8, s. 1388– 1396. Dostupné z: <http://www.scopus.com/inward/record.url?eid=2-s2.0-0033824308&partnerID=40&md5=3167b560d34149cb4eb444b1d498dbf>
- [11] JOHNSTONE, T, K S ORES WALSH, L L GREISCHAR, A L ALEXANDER, A S FOX, R J DAVIDSON and T R OAKES. 2006. Motion correction and the use of motion covariates in multiple-subject fMRI analysis. *Human Brain Mapping* [online]. roč. 27, č. 10, s. 779–788. Dostupné z: <http://www.scopus.com/inward/record.url?eid=2-s2.0-33749487029&partnerID=40&md5=d7c86a9bc0088d19dacd0ea745b62d2a>

- [12] LUND, T E, M D NØRGAARD, E ROSTRUP, J B ROWE and O B PAULSON. 2005. Motion or activity: Their role in intra- and inter-subject variation in fMRI. *NeuroImage* [online]. roč. 26, č. 3, s. 960–964. Dostupné z: <http://www.scopus.com/inward/record.url?eid=2-s2.0-20444456344&partnerID=40&md5=41a7127e8db9fb6e602c412f8bb20df2>
- [13] MURESAN, L, R RENKEN, J.B.T.M. ROERDINK and H DUIFHUIS. 2005. Automated correction of spin-history related motion artefacts in fMRI: Simulated and phantom data. *IEEE Transactions on Biomedical Engineering* [online]. roč. 52, č. 8, s. 1450– 1460. Dostupné z: <http://www.scopus.com/inward/record.url?eid=2-s2.0-23844454758&partnerID=40&md5=2cbb718ca1b7e9820aac5f297d77d375>
- [14] FRISTON, K J, S WILLIAMS, R HOWARD, R S FRACKOWIAK and R TURNER. 1996b. Movement-related effects in fMRI time-series. *Magnetic resonance in medicine : official journal of the Society of Magnetic Resonance in Medicine / Society of Magnetic Resonance in Medicine* [online]. roč. 35, č. 3, s. 346–55. Dostupné z: <http://www.ncbi.nlm.nih.gov/pubmed/8699946>
- [15] WU, D H, J S LEWIN and J L DUERK. 1997. Inadequacy of motion correction algorithms in functional MRI: Role of susceptibility-induced artifacts. *Journal of Magnetic Resonance Imaging* [online]. roč. 7, č. 2, s. 365–370. Dostupné z: <http://www.scopus.com/inward/record.url?eid=2-s2.0-0031400794&partnerID=40&md5=4074b6b2e3885b2250635e1eab295c9d>
- [16] WEISKOPF, N, C HUTTON, O. JOSEPHS, and R DEICHMANN. 2006. Optimal EPI parameters for reduction of susceptibility-induced BOLD sensitivity losses: a whole-brain analysis at 3 T and 1.5 T. *NeuroImage* [online]. roč. 33, č. 2, s. 493–504 [vid. 3. May 2013]. Dostupné z: <<http://dx.doi.org/10.1016/j.neuroimage.2006.07.029>>
- [17] ANDERSSON, J L, C HUTTON, J ASHBURNER, R TURNER and K FRISTON. 2001. Modeling geometric deformations in EPI time series. *NeuroImage* [online]. roč. 13, č. 5, s. 903–19 [vid. 8. March 2013]. Dostupné z: doi:10.1006/nimg.2001.0746
- [18] FRACKOWIAK, Richard S.J; ASHBURNER, John T.; PENNY, William D.; ZEKEI, Semir; FRISTON, Karl J. *Human brain function*. 2. vydání. Hardcover, 2003. 1144 s. ISBN: 10:0-12-264841-2
- [19] ASHBURNER, John. FMRI preprocessing SPM Course [online]. [cit. 2012-11-24]. Dostupné z: <<http://www.fil.ion.ucl.ac.uk/spm/course/slides11-oct/>>
- [20] ASHBURNER, John et al. *SPM8 Manual* [online]. [cit. 2012-10-21]. Dostupné z: <http://www.fil.ion.ucl.ac.uk/spm/doc/manual.pdf>
- [21] MELOUN, M., MILITKÝ, J., HILL, M. *Statistická analýza vícerozměrných dat v příkladech*. Acedemia: Gerstner, 2012. 756 s. ISBN: 978-80-200-2071-0
- [22] FRISTON, Karl J.; ASHBURNER, John T.; KIEBEL, Stefan J.; NICHOLS, Thomas E.; PENNY, William D. *Statistical Parametric Mapping: The Analysis of Functional Brain Images*. Academic Press, 2006. 656 s. ISBN: 978-0123725608

- [23] POWER, Jonathan D, Kelly a BARNES, Abraham Z SNYDER, Bradley L SCHLAGGAR and Steven E PETERSEN. 2012. Spurious but systematic correlations in functional connectivity MRI networks arise from subject motion. *NeuroImage* [online]. roč. 59, č. 3, s. 2142–54 [vid. 3. March 2013]. Dostupné z: doi:10.1016/j.neuroimage.2011.10.018
- [24] SATTERTHWAITE, Theodore D, Mark a ELLIOTT, Raphael T GERRATY, Kosha RUPAREL, James LOUGHEAD, Monica E CALKINS, Simon B EICKHOFF, Hakon HAKONARSON, Ruben C GUR, Raquel E GUR and Daniel H WOLF. 2013. An improved framework for confound regression and filtering for control of motion artifact in the preprocessing of resting-state functional connectivity data. *NeuroImage* [online]. roč. 64, s. 240–56 [vid. 8. March 2013]. Dostupné z: doi:10.1016/j.neuroimage.2012.08.052
- [25]. ALPER, Paul. 1965. A consideration of the discrete Volterra series. *IEEE Trans. Autom. Control*. [online]. roč. 10, č. 3, s. 322-27. Dostupné z: doi: 10.1109/TAC.1965.1098167
- [26] TŮMA, Jiří. *Zpracování signálů získaných z mechanických systémů užitím FFT*. Sdělovací technika, 2008. ISBN: 80-901936-1-7
- [27] GAJDOŠ, M., MIKL, M., MAREČEK, R. Dataset exploration tool for fMRI group analysis 19th International Conference on Systems, Signals and Image Processing, IWSSIP 2012; Vienna. Article number 6208185, Pages 492-495. ISBN: 978-320002328-4

14 Seznam příloh

1	Návod k použití programu.....	79
2	Ukázka časového průběhu rotací.....	80
3	Výsledky skupinové statistiky jednotlivých studií.....	81
4	Vypočtené výkonové mapy.....	83
5	Vypočtené výkonové mapy.....	86
6	Obsah přiloženého CD	86

Přílohy

1 Návod k použití programu

Otevřete skript `mapovani_pohyboveho_artefaktu.m` a zadejte všechny potřebné údaje, viz tabulka č. 1. Do zvoleného adresáře uložte data určená k analýze. Ve skriptu definujte proměnnou `regresors` podle toho, zda je cílem vypočítat pravděpodobnostní mapu, výkonovou mapu nebo skupinovou statistiku. Dále již program pracuje zcela automaticky. Pro výpočet skupinové statistiky mezi studii spusťte skript `skupinova_srovnani_studii.m` a zadejte požadované proměnné.

Tabulka č. 1: Popis proměnných zadávaných uživatelem


Název proměnné	Datový typ	Popis	Příklad
<code>cesta_k_datum</code>	char	Cesta k adresáři obsahujícím data určená k analýze	<code>'C:\Users\Marie\Documents\programy_DP\VOB2d'</code>
<code>cesta_k_programum</code>	char	Cesta k adresáři obsahujícím funkce pro výpočet map	<code>'C:\Users\Marie\Documents\programy_DP'</code>
<code>cesta_k_templatuT1</code>	char	Cesta k adresáři obsahujícím T1 templátový anatomický snímek	<code>'C:\Program Files\MATLAB\spm8\templates\T1.nii'</code>
<code>lomitko</code>	char	Symbol odlišný pro OS windows/UNIX	Pro OS windows: <code>'\'</code> Pro OS UNIX: <code>'/'</code>
<code>nazvy_session</code>	cell	Názvy adresářů jednotlivých session	<code>{'FCNI1'</code> <code>'FCNI2'</code> <code>'FCNI3'}</code>
<code>nazvy_dat</code>	cell	Názvy adresářů jednotlivých pacientů	<code>{'fM00977'</code> <code>'fM00978'</code> <code>'fM00987'}</code>
<code>typ</code>	char	Určuje typ použité studie	<code>'VOBd2'</code>
<code>nazvy_cond</code>	cell	Určuje názvy jednotlivých stimulačních podmínek	<code>{'frekvent'</code> <code>'target'</code> <code>'distraktor'}</code>
<code>aktivace</code>	double/char	Vektor časování aktivací/název složky obsahující SOTs.mat proměnnou obsahující časování (pokud je k dispozici)	<code>[20,40,60]</code> <code>'Timings'</code>

Název proměnné	Datový typ	Popis	Příklad
trvani	double	Popisuje trvání jednotlivých aktivací	[20 20 20 20] 0 (pro event/related experiment)
TR	double	Repetiční čas	1.66
nazev_adresare	char	Název adresáře kam budou ukládány výsledky statistické analýzy	'Mapy_pohybu_24'
regresors	char	Určuje, co má být počítáno	Možnosti: 'dohromady' (výpočet pro všechny pohybové regresory dohromady) 'zvlast' (výpočet pro kombinace zvolených pohybových regresorů zvlášť) 'skupinova' (výpočet skupinové 2. level analýzy)


Tabulka č. 2: Popis pevně definovaných proměnných

Název proměnné	Datový typ	Popis	Příklad
nazvy_regresoru	cell	Názvy jednotlivých pohybových regresorů	{ 'x trans', 'y trans', 'z trans', 'x rot', 'y rot', 'z rot', ... 'dx trans', 'dy trans', 'dz trans', 'dx rot', 'dy rot', 'dz rot', ... 'x2 trans', 'x2 trans', 'y2 trans', 'z2 trans', 'x2 rot', 'y2 rot', 'z2 rot', ... 'dx2 trans', 'dy2 trans', 'dz2 trans', 'dx2 rot', 'dy2 rot', 'dz2 rot' }

2 Ukázka časového průběhu rotací




Obrázek 1: Ukázkové časové průběhy rotací a jejich diferencí




Obrázek 2: Ukázkové časové průběhy druhých mocnin rotací a jich diferencí


3 Výsledky skupinové statistiky jednotlivých studií



Obrázek 3: Skupinová statistika: VSMT, $p=0,001$, $F=2,159$




Obrázek 4: Skupinová statistika: VFTv, $p=0,001$, $F=2,159$




Obrázek 5: Skupinová statistika: VObd2, $p=0,001$, $F=2,159$


4 Vypočtené výkonové mapy



Obrázek 6: Výkonová mapa, VSMT, práh 25%




Obrázek 7: Výkonová mapa, VFTv, práh 30%



Obrázek 8: Výkonová mapa, VOBd2, práh 13%

5 Použitá barevná škála pro zobrazování pravděpodobnostních a výkonových map



Obrázek 9: Použité barevné škály pro zobrazování pravděpodobnostních a výkonových map

6 Obsah přiloženého CD

marie_novakova_DP.pdf

Vypracovaná diplomová práce ve formátu pdf

mapovani_pohyboveho_artefaktu.m

M-file spouštěcího programu pro mapování pohybového artefaktu

preprocessing.m

M-file funkce pro předzpracování analyzovaných dat

vypocet_statistiky.m

M-file funkce pro výpočet statistické analýzy na úrovni jednotlivce

pravdepodobnostni_mapa.m

M-file funkce pro výpočet pravděpodobnostní mapy

vykonova_mapa.m

M-file funkce pro výpočet výkonové mapy

skupinova_statistika.m

M-file funkce pro výpočet skupinové statistiky

skupinova_srovnani_studii.m

M-file skriptu pro výpočet skupinové statistiky srovnávající studie