



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

VIZUALIZACE FMRI DAT SE ZAMĚŘENÍM NA HODNOCENÍ KVALITY DAT

VISUALIZATION OF FMRI DATA WITH RESPECT TO DATA QUALITY ASSESSMENT

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Petra Podhorná

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Michal Mikl, Ph.D.

BRNO 2026

Diplomová práce

magisterský navazující studijní program **Bioinženýrství**

Ústav biomedicínského inženýrství

Studentka: Bc. Petra Podhorná

ID: 240548

Ročník: 2

Akademický rok: 2025/26

NÁZEV TÉMATU:

Vizualizace fMRI dat se zaměřením na hodnocení kvality dat

POKYNY PRO VYPRACOVÁNÍ:

1) Provedte literární rešerši metody funkčního zobrazování pomocí magnetické rezonance (fMRI) s ohledem na způsoby porovnání/hodnocení kvality dat. 2) Seznamte se s nástroji pro zpracování fMRI dat (zejména se softwarem SPM v prostředí Matlab) a s praktickými postupy zpracování dat na datech dodaných laboratoří MAFIL, CEITEC MU. 3) Vyberte vhodné nástroje/postupy využitelné ke srovnání kvality fMRI dat a navrhnete způsob vizualizace fMRI dat a dalších odvozených parametrů souvisejících s hodnocením kvality dat. 4) Vytvořte software (v Matlabu s grafickým uživatelským rozhraním) který bude realizovat navržené výpočty a vizualizace dat a umožní tak např. identifikovat data se sníženou kvalitou (zvýraznit problematické voxely a/nebo časové body a umožnit blíže prozkoumat naměřená data v jednotlivých místech) nebo porovnat kvalitu dat v závislosti na provedeném měření či zpracování. 5) Ve spolupráci s pracovištěm MAFIL CEITEC MU otestujte funkčnost navržených nástrojů a postupů na vhodných vzorcích fMRI dat.

DOPORUČENÁ LITERATURA:

- [1] HUETTEL, Scott A, SONG, Allen W, MCCARTHY, Gregory. Functional Magnetic Resonance Imaging. Second Edition. Sunderland: Sinauer Associates, Inc, 2009. ISBN 978-0-87893-286-3
- [2] BIRN, Rasmus M. Quality control procedures and metrics for resting-state functional MRI. Frontiers in Neuroimaging, 2023, vol. 2:1072927. doi: 10.3389/fnimg.2023.1072927

Termín zadání: 9.2.2026

Termín odevzdání: 27.5.2026

Vedoucí práce: Ing. Michal Mikl, Ph.D.

doc. Ing. Radim Kolář, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

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

ABSTRAKT

Tato diplomová práce se zabývá kontrolou kvality (QC) dat funkční magnetické rezonance (fMRI). Vzhledem k nízkému poměru signálu k šumu a citlivosti BOLD signálu na pohybové, fyziologické a technické artefakty je detekce nekvalitních dat nezbytná pro validní interpretaci výsledků. Cílem práce bylo navrhnout a implementovat interaktivní softwarový nástroj v prostředí MATLAB pro vizualizaci a hodnocení kvality fMRI dat. S využitím knihovny SPM bylo vytvořeno grafické uživatelské rozhraní, které kombinuje interaktivní anatomické řezy, časové průběhy BOLD signálu, grafy metrik FD a DVARS, prostorové mapy tSNR a SNS, binární masku mozku a souhrnnou QC mapu. Funkčnost nástroje byla ověřena na datech poskytnutých laboratoří MAFIL CEITEC MU ve čtyřech scénářích zaměřených na vliv předzpracování, pohybové artefakty, technický artefakt v multi-echo datech a metriku SNS. Výsledky ukázaly, že nástroj umožňuje identifikovat problematické časové body, lokalizovat oblasti se sníženou kvalitou signálu a porovnávat kvalitu dat v různých fázích zpracování. Navržené řešení představuje praktický prostředek pro interaktivní kontrolu kvality fMRI dat v MATLABu.

KLÍČOVÁ SLOVA

fMRI, kvalita dat, artefakty, vizualizace, MATLAB, SPM, Framewise Displacement, DVARS, tSNR, BOLD signál, SNS, Carpet plot

ABSTRACT

This diploma thesis focuses on quality control (QC) of functional magnetic resonance imaging (fMRI) data. Due to the low signal-to-noise ratio and the sensitivity of the BOLD signal to motion, physiological, and technical artifacts, the detection of low-quality data is essential for valid interpretation of results. The aim of this thesis was to design and implement an interactive software tool in MATLAB for visualization and quality assessment of fMRI data. Using the SPM toolbox, a graphical user interface was developed that combines interactive anatomical slices, BOLD signal time courses, FD and DVARS metric plots, spatial maps of tSNR and SNS, a binary brain mask, and a summary QC map. The tool was evaluated on data provided by the MAFIL CEITEC MU laboratory in four scenarios focused on the effect of preprocessing, motion artifacts, a technical artifact in multi-echo data, and the SNS metric. The results showed that the tool enables the identification of problematic time points, localization of regions with reduced signal quality, and comparison of data quality across different processing stages. The proposed solution represents a practical tool for interactive fMRI data quality control in MATLAB.

KEYWORDS

fMRI, data quality, artifacts, visualization, MATLAB, SPM, Framewise Displacement, DVARS, tSNR, BOLD signal, SNS, Carpet plot

PODHORNÁ, Petra. *Vizualizace fMRI dat se zaměřením na hodnocení kvality dat*. Diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2026. Vedoucí práce: Ing. Michal Mikl, Ph.D.

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Bc. Petra Podhorná
VUT ID autora: 240548
Typ práce: Diplomová práce
Akademický rok: 2025/26
Téma závěrečné práce: Vizualizace fMRI dat se zaměřením na hodnocení kvality dat

Prohlašuji, že svou závěrečnou práci jsem vypracovala samostatně pod vedením vedoucí/ho závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce. V souvislosti s vytvořením závěrečné práce jsem neporušila zásady a doporučení VUT k využívání generativní umělé inteligence.

Jako autorka uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědoma následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno
.....
podpis autorky*

*Autor podepisuje pouze v tištěné verzi.

PODĚKOVÁNÍ

Ráda bych poděkovala vedoucímu diplomové práce panu Ing. Michalovi Miklovi, Ph.D. za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Obsah

Úvod	13
1 Princip funkční magnetické rezonance	14
1.1 Základy magnetické rezonance	14
1.1.1 Jaderný spin	14
1.1.2 Precese a Larmorova frekvence	15
1.1.3 Relaxace (T_1 , T_2 a T_2^*)	17
1.2 BOLD efekt	19
1.2.1 Magnetické vlastnosti hemoglobinu	19
1.2.2 Vznik BOLD signálu	19
1.2.3 Hemodynamická odezva	20
1.3 fMRI experiment	21
1.3.1 Echo Planar Imaging (EPI)	21
1.3.2 Časové a prostorové rozlišení	22
1.3.3 Struktura fMRI dat	23
1.3.4 Typy experimentálního designu	23
2 Zpracování fMRI dat	25
2.1 Datové formáty fMRI dat	25
2.2 Typická pipeline	26
2.2.1 Korekce akvizičních časů	26
2.2.2 Korekce pohybu	27
2.2.3 Korekce distorzí	28
2.2.4 Koregistrace	29
2.2.5 Normalizace	30
2.2.6 Prostorové vyhlazení	30
2.3 Přehled používaných softwarových nástrojů	31
2.3.1 SPM (Statistical Parametric Mapping)	31
2.3.2 FSL (FMRIB Software Library)	32
2.3.3 AFNI (Analysis of Functional NeuroImages)	33
3 Hodnocení kvality fMRI dat	35
3.1 Faktory ovlivňující kvalitu dat	35
3.1.1 Pohyb hlavy	35
3.1.2 Fyziologické faktory	35
3.1.3 Přístrojové faktory	36
3.1.4 Susceptibilní artefakty	37

3.2	Metriky pro hodnocení kvality dat	38
3.2.1	Metriky pohybu	38
3.2.2	Metriky globální změny intenzity	39
3.2.3	SNR metriky	39
3.2.4	Prostorové metriky	40
3.2.5	Carpet plot	41
3.3	Stávající nástroje pro kontrolu kvality	42
3.3.1	MRIQC	42
3.3.2	fMRIPrep	44
3.3.3	QC možnosti ve standardních neurovizuálních balících	45
3.3.4	Limitace existujících řešení	45
4	Praktická část	47
4.1	Použité nástroje, metodika a architektura	47
4.1.1	Vývojové prostředí a použité knihovny	47
4.1.2	Metodika vývoje	48
4.1.3	Architektura softwaru	50
4.2	Návrh a implementace vizualizačního nástroje	52
4.2.1	Rozvržení a struktura uživatelského rozhraní	53
4.2.2	Správa a načítání dat	55
4.2.3	Prostorová vizualizace a mapování souřadnic	56
4.2.4	Analýza BOLD signálu	58
4.3	Implementace metrik kvality dat	60
4.3.1	Výběr metrik pro implementaci	60
4.3.2	Vytvoření masky mozku	61
4.3.3	Implementace časových metrik	62
4.3.4	Implementace prostorových metrik	64
5	Testování nástroje	67
5.1	Testovací data	67
5.2	Metodika testování	67
5.3	Vliv preprocessingu na kvalitu dat	68
5.3.1	Interpretace výsledků	68
5.3.2	Carpet plot	71
5.4	Detekce pohybových artefaktů	72
5.4.1	Interpretace výsledků	72
5.4.2	Carpet plot	75
5.4.3	QC mapa	76
5.5	Detekce technického artefaktu na multi-echo datech	77

5.5.1	Interpretace výsledků	77
5.6	Demonstrace metriky SNS	81
5.6.1	Interpretace výsledků	81
5.7	Shrnutí výsledků	85
5.7.1	Omezení a možná rozšíření	87
	Závěr	89
	Literatura	91
	Seznam symbolů a zkratk	98
6	Obsah elektronické přílohy	99

Seznam obrázků

1.1	Orientace magnetických momentů: náhodně – bez přítomnosti vnějšího mag. pole (vlevo), podél siločar vnějšího mag. pole (vpravo) [5]	15
1.2	Precesní pohyb protonu [6]	15
1.3	Překlopení vektoru magnetizace do roviny xy po aplikaci RF pulzu [7]	16
1.4	Schéma podélné relaxace – návrat vektoru magnetizace do směru osy z [4]	17
1.5	Schéma příčné relaxace – zánik vektoru magnetizace v rovině xy [4]	18
1.6	Hemodynamická odezva [10]	20
1.7	Standardní vyplňování k-prostoru zleva doprava (vlevo), vyplňování k-prostoru cik-cak trajektorií (vpravo) [13]	21
2.1	Jednotlivé kroky předzpracování fMRI dat[25]	27
2.2	Parametry translace a rotace ve 3D datech[24]	28
2.3	Ukázka uživatelského rozhraní SPM	32
2.4	Ukázka uživatelského rozhraní FSL [28]	33
2.5	Ukázka uživatelského rozhraní AFNI [30]	34
3.1	Drift MR signálu [4]	36
3.2	Typický projev spike artefaktu v obraze [34]	37
3.3	Typický projev Nyquist ghostingu v obraze [36]	37
3.4	Výpadek signálu ve výsledném obraze [37]	38
3.5	Projev pohybu hlavy v carpet plotu [46]	42
3.6	Ukázka individuálního reportu MRIQC [44]	43
3.7	Ukázka skupinového reportu MRIQC [45]	44
4.1	Diagram všech 4 fází vývoje vlastního nástroje	49
4.2	Diagram toku dat	51
4.3	Náhled vizualizačního panelu	53
4.4	Náhled panelu pro kontrolu kvality	54
4.5	Náhled kompletního uživatelského rozhraní softwaru	54
4.6	Náhled správce dat jako vedlejšího okna	55
4.7	Ukázka BOLD grafů s rozložením 3x3	58
4.8	Ukázka BOLD grafů po odečtení střední hodnoty	60
4.9	Ukázka možností kontextového menu	60
5.1	Porovnání tSNR map před a po prostorovém vyhlazení	69
5.2	Porovnání průběhu metriky DVARS u subjektu 2 pro varianty w , wr a sur	70
5.3	FD křivky po korekci pohybu a vyhlazení	71
5.4	Porovnání carpet plotu pro surová data (nahore) a data po kompletním zpracování (dole).	72

5.5	Porovnání křivek FD (nahore) a DVARS (dole) v datech s výrazným pohybem.	73
5.6	Porovnání průběhu FD křivek u subjektu s nízkým (modrá) a vysokým (fialová) pohybem	74
5.7	Porovnání průběhu DVARS a BOLD křivek u subjektu s nízkým (modrá) a vysokým (fialová) pohybem	75
5.8	Carpet ploty subjektů s výrazným pohybem.	76
5.9	Porovnání QC map u subjektů s tSNR limitem 50.	77
5.10	Porovnání masek mozku pro jednotlivá echa.	78
5.11	Porovnání tSNR map pro jednotlivá echa.	79
5.12	Průběh DVARS křivek při přítomnosti technického artefaktu	80
5.13	Porovnání anatomických řezů pro jednotlivá echa.	81
5.14	Porovnání SNS map subjektu 1 při různém nastavení prahu masky.	82
5.15	Porovnání QC mapy a BOLD grafů pro voxel s nízkými hodnotami obou metrik a pro voxel bez detekovaného problému.	84
5.16	Porovnání SNS mapy a BOLD grafů pro oblasti s vyšší a nízkou hodnotou SNS.	85

Seznam tabulek

5.1	Souhrn intenzitních metrik kvality pro jednotlivé varianty zpracování	68
5.2	Pohybové metriky po kroku korekce pohybu	70
5.3	Souhrn hodnot metriky FD u testovaných subjektů	73
5.4	Hodnoty velikosti masky a průměrného tSNR pro jednotlivá echa . .	77
5.5	Statistiky metriky SNS pro testované subjekty	82

Úvod

Funkční magnetická rezonance (fMRI) představuje jednu z nejvýznamnějších neinvazivních metod pro studium aktivity lidského mozku. Díky schopnosti zobrazovat hemodynamické změny související s neuronální činností s vysokým prostorovým rozlišením se stala důležitým nástrojem v klinické praxi i v základním neurovědeckém výzkumu. Současně však jde o metodu velmi citlivou na rušivé vlivy. BOLD signál představuje pouze malou změnu intenzity signálu, a proto může být výrazně ovlivněn například pohybem hlavy, fyziologickým šumem, technickými nestabilitami nebo artefakty vznikajícími při akvizici a zpracování dat. Hodnocení kvality dat (angl. *Quality Control*, QC) by proto mělo být nezbytnou součástí každé fMRI studie.

V současné praxi existuje řada nástrojů zaměřených na automatizovanou kontrolu kvality, mezi nejrozšířenější patří například MRIQC a fMRIPrep. Tyto nástroje poskytují standardizované výstupy a umožňují výpočet řady užitečných metrik, jejich reporty však mají převážně statickou povahu. Uživatel proto často nemůže přímo propojit detekovanou odchylku s odpovídajícím časovým snímkem, prostorovým řezem nebo lokálním průběhem BOLD signálu. Zavedené softwarové balíky pro zpracování fMRI dat, jako jsou SPM, FSL nebo AFNI, naopak poskytují možnosti vizuální inspekce, ale obvykle nesjednocují kvantitativní QC metriky a interaktivní prohlížení dat do jednoho prostředí. V praxi tak vzniká mezera mezi automatizovaným výpočtem metrik kvality a jejich přímou vizuální interpretací.

Cílem této diplomové práce je navrhnout a implementovat softwarový nástroj v prostředí MATLAB, který na tuto potřebu reaguje. Vyvíjený nástroj propojuje výpočet vybraných metrik kvality s interaktivní vizualizací fMRI dat v jednom uživatelském rozhraní. Umožňuje současné porovnání více datových sad a poskytuje uživateli možnost plynule přecházet mezi časovými průběhy metrik, prostorovými řezy a detailní inspekci konkrétních problematických voxelů nebo časových bodů. Návrh nástroje byl koncipován ve spolupráci s laboratoří MAFIL CEITEC MU tak, aby navazoval na zavedené pracovní postupy založené na softwaru SPM.

Práce je strukturována do pěti kapitol. První kapitola shrnuje fyzikální principy magnetické rezonance, mechanismus vzniku BOLD signálu a charakteristiku fMRI experimentu. Druhá kapitola popisuje standardní postupy zpracování fMRI dat a přehled používaných softwarových nástrojů. Třetí kapitola se věnuje hodnocení kvality fMRI dat, klasifikaci zdrojů šumu, kvantitativním metrikám pro detekci artefaktů a zhodnocení stávajících QC nástrojů. Čtvrtá kapitola popisuje návrh a implementaci vyvinutého softwaru. Pátá kapitola se věnuje testování funkčnosti nástroje na reálných fMRI datech ve čtyřech experimentálních scénářích.

1 Princip funkční magnetické rezonance

Funkční magnetická rezonance (angl. functional Magnetic Resonance Imaging, fMRI) je neinvazivní zobrazovací metoda umožňující sledovat aktivitu mozku in vivo s vysokým prostorovým rozlišením. Na rozdíl od strukturální magnetické rezonance, která poskytuje informace o anatomii mozku, je fMRI zaměřena na detekci změn souvisejících s neuronální aktivitou. Nejčastěji využívaným mechanismem je tzv. BOLD kontrast (angl. Blood Oxygen Level Dependent), který je založen na nepřímém vztahu mezi neuronální aktivitou a lokálními změnami v okysličení krve. [1][2]

V této kapitole jsou nejprve shrnuty základní fyzikální principy magnetické rezonance, dále je popsán BOLD efekt jako klíčový mechanismus fMRI a nakonec je uveden přehled typického průběhu fMRI experimentu.

1.1 Základy magnetické rezonance


Zobrazování pomocí magnetické rezonance (angl. Magnetic Resonance Imaging, MRI) je neinvazivní tomografická metoda, která využívá magnetických vlastností atomových jader k vytvoření detailního obrazu vnitřních struktur organismu [3]. Pro pochopení principů fMRI a následného hodnocení kvality dat je nezbytné nejprve definovat fyzikální podstatu vzniku signálu magnetické rezonance.

1.1.1 Jaderný spin

Základním stavebním prvkem pro MRI je atom vodíku, konkrétně jeho jádro – proton (1H). Vodík je ideálním prvkem pro zobrazování biologických tkání díky svému hojnému zastoupení v lidském těle, především v molekulách vody a tuku, a díky svým magnetickým vlastnostem. Protony v jádře vodíku se vyznačují vlastností zvanou spin. Ačkoliv jde o kvantově-mechanický jev, pro pochopení principu MRI si lze protony zjednodušeně představit jako malé tyčové magnety, které kolem sebe vytvářejí mikroskopické magnetické pole. Za běžných podmínek - bez přítomnosti vnějšího silného magnetického pole, jsou magnetické momenty těchto protonů orientovány náhodně všemi směry, jak lze vidět na Obr. 1.1 vlevo. Jejich účinky se tedy vzájemně vyruší a výsledná magnetizace tkáně je nulová. [3][4]

Situace se mění v okamžiku, kdy je pacient umístěn do silného statického magnetického pole skeneru, které označujeme vektorem $\vec{B}_0$ (jednotka Tesla, [T]). V tomto prostředí mají jaderné spiny tendenci se orientovat podél siločar tohoto vnějšího pole, viz Obr. 1.1 vpravo. Mohou zaujmout dva energetické stavy:

1. Paralelní (nízkoenergetický): Orientace souhlasná se směrem $\vec{B}_0$.
2. Antiparalelní (vysokoenergetický): Orientace proti směru $\vec{B}_0$.




Obr. 1.1: Orientace magnetických momentů: náhodně – bez přítomnosti vnějšího mag. pole (vlevo), podél siločar vnějšího mag. pole (vpravo) [5]

Podle Boltzmannova rozdělení je vždy mírný nadbytek protonů v energeticky výhodnějším - paralelním stavu. Ačkoliv je tento rozdíl velmi malý (v řádu jednotek na milion protonů), je dostatečný k vytvoření makroskopického vektoru podélné magnetizace $\vec{M}_0$, který je orientován ve směru osy z – směr hlavního magnetického pole. [3][4]

1.1.2 Precese a Larmorova frekvence

Vlivem vnějšího magnetického pole $\vec{B}_0$ spiny nejenže zaujmou určitou orientaci, ale začnou také vykonávat specifický pohyb, který nazýváme precese. Jeho znázornění lze pozorovat na Obr. 1.2. Osa rotace protonu opisuje plášť kužele kolem směru magnetického pole $\vec{B}_0$, podobně jako se kolébá roztočená dětská káča v gravitačním poli Země. [4][8]



Obr. 1.2: Precesní pohyb protonu [6]


Rychlost tohoto pohybu, neboli frekvence precese, je pro MR zobrazování zásadní a je definována Larmorovou rovnicí:

$$\omega_0 = \gamma B_0, \quad (1.1)$$

kde ω_0 je úhlová frekvence precese [rad/s], B_0 je magnetická indukce [T], která vyjadřuje velikost vnějšího magnetického pole, a γ je gyromagnetický poměr, který je pro každé jádro konstantní. Pro vodík ^1H platí $\gamma/2\pi \approx 42,58 \text{ MHz/T}$. Tato rovnice ukazuje, že frekvence precese je přímo úměrná velikosti magnetického pole. Například u 3T skeneru, který se běžně používá pro fMRI, odpovídá Larmorova frekvence protonů přibližně 127,7 MHz. [4]

Samotná podélná magnetizace $\vec{M}_0$ není přímo měřitelná, protože je orientována ve směru hlavního magnetického pole $\vec{B}_0$ a její detekce by byla v porovnání s tímto polem prakticky zanedbatelná. Aby bylo možné získat měřitelný MR signál, je nutné vychýlit magnetizaci z rovnovážného stavu. Toho se dosahuje krátkým radiofrekvenčním (RF) pulzem. [4]

RF pulz musí mít frekvenci odpovídající Larmorově frekvenci protonů, aby došlo k rezonanci, tedy k účinnému ovlivnění spinového systému. Působením RF pulzu je makroskopická magnetizace, původně orientovaná podél osy z , sklopena směrem do roviny xy . Velikost tohoto sklopení se označuje jako úhel sklopení (angl. flip angle), a závisí zejména na amplitudě a délce trvání RF pulzu. Například ideální 90° pulz sklopí podélnou magnetizaci M_z do příčné roviny, čímž vzniká příčná, neboli transverzální, magnetizace M_{xy} . Tento jev lze pozorovat na Obr. 1.3. [3]



Obr. 1.3: Překlopení vektoru magnetizace do roviny xy po aplikaci RF pulzu [7]

Z mikroskopického hlediska RF pulz ovlivňuje rozložení spinů mezi energetickými hladinami a zároveň vytváří fázovou koherenci mezi precesními pohyby jednotlivých protonů. Před aplikací RF pulzu mají jednotlivé spiny různé fáze, takže se jejich příspěvky k příčné magnetizaci navzájem ruší. Po RF pulzu jsou však jejich precese částečně sfázovány, což umožňuje vznik měřitelné koherentní příčné magnetizace.


Vzniklá příčná magnetizace rotuje v rovině xy na Larmorově frekvenci. Protože se jedná o časově proměnný magnetický moment, indukuje podle Faradayova zákona elektromagnetické indukce v přijímacích cívkách střídavé elektrické napětí. Toto indukované napětí představuje surový MR signál. [3, 4]

1.1.3 Relaxace (T_1 , T_2 a T_2^*)

Po vypnutí excitačního RF pulzu se systém snaží vrátit zpět do původního rovnovážného stavu. Tento proces se nazývá relaxace a probíhá současně ve dvou nezávislých směrech, které jsou charakterizovány časovými konstantami T_1 a T_2 . [3]

Podélná relaxace (T_1 , spin-mřížková)

Podélná relaxace popisuje obnovu podélné magnetizace M_z ve směru hlavního magnetického pole, tedy ve směru osy z , jak znázorňuje Obr. 1.4. Po excitačním RF pulzu je magnetizace vychýlena z rovnovážného stavu a složka M_z je snížena. Během T_1 relaxace protony předávají přebytečnou energii okolní tkáni, a podélná magnetizace se postupně vrací ke své rovnovážné hodnotě. Časová konstanta T_1 udává dobu, za kterou se obnoví přibližně 63 % původní podélné magnetizace. Různé tkáně mají různé T_1 časy, což je základem kontrastu u anatomických snímků (např. rozlišení šedé a bílé hmoty). [3]




Obr. 1.4: Schéma podélné relaxace – návrat vektoru magnetizace do směru osy z [4]

Příčná relaxace (T_2 , spin-spinová)

Příčná relaxace popisuje zánik příčné magnetizace M_{xy} v rovině xy , schéma tohoto jevu lze vidět na Obr. 1.5. Po RF pulzu jsou spiny částečně sfázované, a jejich společná rotace vytváří měřitelnou příčnou magnetizaci. Postupem času však jednotlivé spiny ztrácejí fázovou synchronizaci, takže se jejich příspěvky v rovině xy začnou

vzájemně rušit. Výsledkem je pokles velikosti vektoru příčné magnetizace M_{xy} . Časová konstanta T_2 udává dobu, za kterou klesne příčná magnetizace na 37 % své počáteční hodnoty. [3]



Obr. 1.5: Schéma příčné relaxace – zánik vektoru magnetizace v rovině xy [4]

Relaxace T_2^*

V reálném prostředí experimentu je zánik příčné magnetizace mnohem rychlejší než teoretická hodnota T_2 . K rozfázování spinů totiž nepřispívají jen interakce mezi spiny navzájem (T_2), ale také nehomogenity vnějšího magnetického pole ΔB_0 . Tyto nehomogenity mohou být způsobeny nedokonalostí magnetu nebo rozdílnou magnetickou susceptibilitou tkání (např. rozhraní kost/vzduch nebo přítomnost paramagnetických látek v krvi). [8]

Výsledná efektivní relaxace se označuje jako T_2^* (T2-star) a platí pro ni vztah:

$$\frac{1}{T_2^*} = \frac{1}{T_2} + \frac{1}{T_{2,nehomog}} \quad (1.2)$$

Právě tento parametr T_2^* je pro funkční magnetickou rezonanci zásadní. BOLD efekt, který využíváme pro měření mozkové aktivity, je založen na změnách lokální nehomogenity magnetického pole v okolí cév, což se projevuje změnou času T_2^* a následně intenzitou signálu v obraze. Citlivost na T_2^* je však zároveň zdrojem častých artefaktů (např. výpadky signálu v blízkosti dutin/v oblasti orbitofrontálního kortexu), které jsou předmětem hodnocení kvality dat v této práci. [1][2]

Prostorové rozlišení obrazu je pak dosaženo pomocí gradientních magnetických polí, která způsobují prostorově závislé změny Larmorovy frekvence. Kombinací RF pulzů, gradientních polí a vhodného zpracování signálu je možné rekonstruovat dvou- rozměrné nebo trojrozměrné obrazy zobrazující rozložení signálu v tkáních. [4]

1.2 BOLD efekt

Zatímco strukturální MRI zobrazuje anatomii mozku na základě rozdílných relaxačních časů T_1 a T_2 v různých typech tkání (šedá hmota, bílá hmota, likvor), funkční MRI má za cíl mapovat neuronální aktivitu v čase. Protože však MRI skener nedokáže přímo měřit elektrickou aktivitu neuronů, využívá se nepřímého měření založeného na hemodynamických změnách. Tento fenomén, který v roce 1990 popsal Seiji Ogawa, se nazývá již dříve zmiňovaný BOLD efekt. [1]

Základním předpokladem fMRI je těsné spojení mezi neuronální aktivitou a cévním zásobením, označované jako neurovaskulární vazba. Když se určitá populace neuronů stane aktivní, např. v reakci na vizuální podnět nebo při motorickém úkolu, dojde v dané oblasti ke zvýšení metabolické poptávky. Neurony pro obnovení svých membránových potenciálů a recyklaci neurotransmiterů spotřebovávají energii ve formě ATP, což vede ke zvýšené spotřebě kyslíku a glukózy. Na tento lokální pokles koncentrace kyslíku a hromadění metabolitů (např. CO_2 , NO) reaguje cévní systém vazodilatací. Klíčovým fyziologickým mechanismem pro fMRI je skutečnost, že toto zvýšení průtoku krve je výrazně vyšší než samotný nárůst spotřeby kyslíku. Do aktivované oblasti je tedy přiváděno nadměrné množství okysličené krve, což vede k paradoxnímu jevu - v místě zvýšené neuronální spotřeby kyslíku jeho koncentrace v cévách (kapilárách a venulách) neklesá, ale naopak roste. [4][9]

1.2.1 Magnetické vlastnosti hemoglobinu

BOLD kontrast je fyzikálně umožněn rozdílnými magnetickými vlastnostmi přenašeče kyslíku – hemoglobinu, v jeho okysličené a neokysličené formě. Oxyhemoglobin (Hb) je molekula hemoglobinu s navázaným kyslíkem. Je diamagnetická, což znamená, že nemá žádné nepárové elektrony a nevykazuje významný magnetický moment. V magnetickém poli se chová neutrálně, podobně jako voda nebo okolní tkáň, a nezpůsobuje lokální nehomogenity pole. Deoxyhemoglobin (dHb) je hemoglobin, který odevzdal kyslík. Je paramagnetický díky přítomnosti nepárových elektronů železa v hemu. V silném magnetickém poli se chová jako mikroskopický magnet, který deformuje okolní magnetické pole a vytváří lokální gradienty. Přítomnost deoxyhemoglobinu v krvi tedy funguje jako endogenní kontrastní látka, která narušuje homogenitu magnetického pole. Jak bylo vysvětleno v kapitole 1.1, nehomogenita pole urychluje rozfázování spinů a zkracuje relaxační čas T_2^* . [4]

1.2.2 Vznik BOLD signálu


Mechanismus vzniku signálu lze shrnout do následující sekvence událostí. V cévním řečišti existuje rovnovážný poměr mezi oxyhemoglobinem a deoxyhemoglobinem.

Deoxyhemoglobin způsobuje určitou míru nehomogenity pole, což tlumí MR signál (kratší T_2^*). Neuronální činnost spouští neurovaskulární vazbu. Dochází k masivnímu přísunu čerstvé arteriální krve. Tento přísun vyplaví deoxyhemoglobin z venózního řečiště. Koncentrace paramagnetického deoxyhemoglobinu klesá a magnetické pole v daném voxelu se stává homogennějším. To vede k prodloužení času T_2^* a nárůstu intenzity naměřeného signálu. Zjednodušeně řečeno – aktivní oblast mozku se na T_2^* -vážených snímcích zobrazí jasněji než oblast neaktivní. [1][2][4]

1.2.3 Hemodynamická odezva

Velice důležitým aspektem pro zpracování dat je časový průběh BOLD signálu. Zatímco neuronální aktivita probíhá v řádu milisekund, cévní změny jsou mnohem pomalejší. Časový profil změny BOLD signálu po krátkém stimulu se nazývá hemodynamická odezva a má charakteristický průběh, který lze pozorovat na Obr. 1.6. [4]

Krátce po stimulu může dojít k mírnému poklesu signálu (angl. initial dip), který je způsoben okamžitou spotřebou kyslíku před příchodem zvýšeného průtoku krve; tento jev je však v běžných fMRI datech často obtížně detekovatelný. Následně signál začíná růst přibližně 2 sekundy po stimulu a dosahuje maxima kolem 5.–6. sekundy. Po odeznění stimulu signál klesá a často se dostává pod svou původní výchozí úroveň (angl. post-stimulus undershoot). K návratu na klidovou úroveň dochází typicky po 12–20 sekundách. [4]



Obr. 1.6: Hemodynamická odezva [10]

Z hlediska hodnocení kvality dat, které je předmětem této práce, je důležité zdůraznit několik vlastností BOLD signálu. První vlastností je, že změna intenzity signálu při aktivaci je velmi malá, u 3T skeneru se pohybuje typicky v rozmezí

1–5 % oproti klidovému stavu. Druhou je nízký poměr signálu k šumu (angl. Signal-to-Noise Ratio, SNR). Vzhledem k malé amplitudě je BOLD efekt snadno překryt šumem. Pohyb hlavy pacienta o pouhý 1 milimetr může způsobit změnu intenzity signálu o 10–20 % (na hranách tkání), což je řádově více než hledaný fyziologický signál [11]. BOLD signál je také ovlivněn nejen neuronální aktivitou, ale i dýcháním a srdečním tepem, které rovněž modulují okysličení krve a CO_2 [12]. Právě tyto vlastnosti činí fMRI data náchylná k artefaktům a podtrhují nutnost pokročilých metod vizualizace a kontroly kvality, aby bylo možné odlišit skutečnou mozkovou aktivitu od falešně pozitivních výsledků způsobených šumem.


1.3 fMRI experiment

Předchozí podkapitoly popisovaly fyzikální a fyziologickou podstatu signálu, tato kapitola se zaměřuje na technickou realizaci měření – tedy jakým způsobem MR skener zaznamenává data v čase a prostoru.

1.3.1 Echo Planar Imaging (EPI)

Pro fMRI je kritickým parametrem čas. Vzhledem k tomu, že hemodynamická odezva probíhá v řádu sekund, je nutné snímat celý objem mozku dostatečně rychle, aby bylo možné tento proces adekvátně časově vzorkovat. Konvenční anatomické sekvence, jejichž akvizice trvá řádově minuty, jsou proto pro účely fMRI nevhodné. [4]

Standardem pro fMRI se stala ultrarychlá akviziční sekvence Echo Planar Imaging (EPI). Princip EPI spočívá v nasnímání celého řezu mozku po jediném excitacním RF pulzu, čehož je dosaženo velmi rychlým přepínáním čtecích gradientů a zaplněním k-prostoru (frekvenční domény obrazu) během jednoho cyklu pomocí charakteristické cik-cak trajektorie. Vyobrazení těchto dvou odlišných trajektorií lze vidět na Obr. 1.7.



Obr. 1.7: Standardní vyplňování k-prostoru zleva doprava (vlevo), vyplňování k-prostoru cik-cak trajektorií (vpravo) [13]

Hlavní výhodou této metody je její vysoká rychlost – jeden řez lze nasnímat přibližně za 50–100 ms, což umožňuje získat celý objem mozku v časovém rozlišení vhodném pro sledování dynamiky BOLD signálu. Nevýhodou EPI sekvencí je jejich vysoká citlivost na nehomogenity magnetického pole. Tyto nehomogenity vedou k typickým geometrickým distorzím obrazu a k výpadkům signálu, zejména v oblastech s výraznými rozdíly magnetické susceptibility, jako jsou rozhraní mezi tkání a vzduchem. Typicky se tyto artefakty vyskytují v orbitofrontální kůře nad nosními dutinami nebo ve spánkových lalocích v blízkosti zvukovodů. [4][14]

Během fMRI experimentu jsou proto obvykle snímány rychlé T2*-vážené obrazy pomocí echo-planární sekvence. Výsledkem akvizice je čtyřrozměrný dataset, který obsahuje trojrozměrné objemy mozku zaznamenané v jednotlivých časových bodech, a který tvoří základ pro další zpracování a hodnocení kvality fMRI dat.

1.3.2 Časové a prostorové rozlišení

Nastavení parametrů fMRI experimentu je vždy hledáním kompromisu mezi prostorovým rozlišením, časovým rozlišením a poměrem signálu k šumu.

Základní jednotkou fMRI dat je voxel. Velikost voxelu určuje, jak jemné prostorové detaily je možné v obraze rozlišit. Typické rozměry voxelů ve fMRI se pohybují v řádu několika milimetrů, např. $3 \times 3 \times 3$ mm. Větší voxel obsahuje větší počet protonů, a poskytuje tak vyšší SNR, avšak za cenu horší prostorové lokalizace aktivity. Tento jev je známý jako partial volume effect, kdy jeden voxel může zahrnovat směs signálů ze šedé hmoty, bílé hmoty a cévních struktur. Naopak menší voxel umožňuje přesnější prostorové určení aktivace, ale vede k výraznému poklesu SNR a často vyžaduje delší dobu snímání nebo jiné kompromisy v nastavení akvizičních parametrů. [4]

Klíčovým parametrem časového rozlišení je repetiční čas (angl. Repetition Time, TR). Je to doba, která uplyne mezi začátkem snímání jednoho objemu mozku a začátkem snímání následujícího. Typická hodnota TR se pohybuje mezi 1 až 3 sekundami. Pokud je mozek rozdělen např. na 40 řezů a nasnímáný jeden trvá 50 ms, minimální TR bude $40 \times 0,05 = 2$ sekundy. [4]

Moderní akcelerační techniky, jako je multiband akvizice (angl. Simultaneous Multi-Slice, SMS), umožňují snímat více řezů současně a výrazně zkrátit TR, často pod hranici 1 sekundy. Tím se zlepšuje časové vzorkování hemodynamické odezvy, avšak za cenu zvýšených nároků na rekonstrukci dat a potenciálního nárůstu artefaktů, což má přímý dopad na hodnocení kvality fMRI dat. [15]

1.3.3 Struktura fMRI dat

Výstupem fMRI je 4D matice, která zahrnuje tři prostorové dimenze a jednu časovou dimenzi. Data si tedy lze představit následovně – jednotlivý řez (angl. slice) lze chápat jako dvourozměrnou matici intenzit signálu, např. o rozměrech 64×64 pixelů. Prostorový objem (angl. volume) vzniká složením několika takových řezů nad sebou, čímž vzniká trojrozměrná matice reprezentující celý mozek, typicky o rozměrech např. $64 \times 64 \times 40$ voxelů. Každý takový objem odpovídá jednomu časovému bodu měření.

Opakovaným snímáním těchto objemů v čase vzniká časová řada (angl. time series), přičemž celý fMRI dataset lze formálně popsat jako čtyřrozměrnou matici o rozměrech $[x, y, z, t]$. Pokud v této matici zafixujeme prostorové souřadnice $[x, y, z]$ a sledujeme vývoj hodnot podél časové osy t , získáme časový průběh signálu v konkrétním voxelu mozku. Právě analýza těchto časových řad, včetně hledání jejich vztahu k experimentálnímu designu nebo spontánním fluktuacím aktivity, tvoří základ statistického zpracování fMRI dat. [16]

1.3.4 Typy experimentálního designu

Způsob, jakým jsou fMRI data snímána, závisí na charakteru úlohy, kterou subjekt během měření vykonává. Volba experimentálního designu má zásadní vliv na vlastnosti naměřených dat, očekávaný průběh BOLD signálu i typy artefaktů, které se mohou v datech vyskytovat. [4]

Resting-state fMRI

Subjekt nevykonává žádnou úlohu, pouze leží v klidu, často se zavřenýma očima. Sledují se spontánní fluktuace BOLD signálu a funkční konektivita, tedy časová synchronizace aktivity mezi vzdálenými oblastmi mozku. V tomto typu experimentu je kontrola kvality dat mimořádně důležitá, protože zde neexistuje explicitní model očekávané neuronální aktivity. Pohybové artefakty nebo fyziologický šum mohou vést k falešné detekci funkční konektivity a významně zkreslit výsledky analýzy. [17]

Task-based fMRI

Subjekt reaguje na externí podněty (např. vizuální či sluchové) nebo vykonává motorickou úlohu. Nejčastěji se používají dva základní typy experimentálního designu: blokový design a event-related design. V blokovém designu dochází ke střídání delších bloků aktivity (např. 20s bubnování prsty) a klidu. Tento přístup poskytuje relativně vysoký kontrast BOLD signálu a je robustní vůči šumu, avšak nabízí omezenou flexibilitu v analýze jednotlivých událostí. Event-related design je založen na

prezentaci krátkých, časově oddělených podnětů. Tento přístup umožňuje detailnější analýzu časového průběhu hemodynamické odezvy a studium odpovědí na jednotlivé události, avšak klade vyšší nároky na kvalitu dat, časové rozlišení a následné zpracování signálu. [4]

2 Zpracování fMRI dat

Zpracování fMRI dat představuje soubor metod a algoritmů, jejichž cílem je připravit naměřená data pro následnou statistickou analýzu a interpretaci mozkové aktivity. Vzhledem k tomu, že fMRI data jsou zatížena různými artefakty, pohybem probanda a technickými omezeními samotné akvizice, je předzpracování nezbytným krokem pro dosažení spolehlivých výsledků. Jednotlivé kroky předzpracování bývají realizovány v rámci specializovaných softwarových balíčků, jako jsou SPM, FSL, AFNI nebo fMRIPrep. [4][18]

2.1 Datové formáty fMRI dat

Primárním výstupem z medicínských zobrazovacích přístrojů je formát DICOM, který představuje standard pro ukládání, přenos a správu medicínských obrazových informací [19]. U fMRI experimentu, kde se snímá např. 30 řezů ve 200 časových bodech, může DICOM export znamenat tisíce samostatných souborů, což je pro následnou analýzu nepraktické.

Tento problém mohou částečně zmírnit alternativní způsoby ukládání, jako je např. mosaic formát, ve kterém je celý objem uložen do jednoho DICOM souboru. I v tomto případě však bývá každý časový bod ukládán samostatně, takže výsledkem mohou být stovky až tisíce souborů pro jedno fMRI měření. Pro následnou analýzu v neurozobrazovacích nástrojích se proto data běžně převádějí z DICOM do formátu NIfTI [20].

Další komplikací práce s DICOM daty je variabilita některých parametrů v hlavici, jejichž interpretace se může lišit mezi jednotlivými výrobci skenerů nebo verzemi softwaru. To komplikuje automatizované zpracování dat a často vyžaduje dodatečné kroky při jejich převodu do analytických formátů. [20][21]

V neposlední řadě je problematická i anonymizace DICOM dat, jelikož citlivé osobní údaje mohou být uloženy nejen ve standardních položkách hlavičky, ale v některých případech také přímo v obrazových datech. Z těchto důvodů se pro následnou analýzu a sdílení dat v neurovědecké komunitě běžně používá konverze do formátu NIfTI, případně organizace dat podle standardu BIDS [21].

NIfTI soubor využívá příponu *.nii nebo komprimované *.nii.gz. Slučuje data do jednoho celku a skládá se ze dvou hlavních částí, často sloučených v jednom souboru:

1. Hlavička: Metadata popisující konkrétní data. Obsahuje informace o dimenzi dat (např. $64 \times 64 \times 40 \times 200$), velikosti voxelu (např. $3 \times 3 \times 3$ mm), datovém typu (např. int16, float32), a transformační matici, která definuje vztah mezi "indexem voxelu" $[i, j, k]$ a reálnou souřadnicí v prostoru $[x, y, z]$ (v milimetrech).

2. Obrazová data: Samotná binární data reprezentující 3D nebo 4D matici intenzit. [18]

Pro správnou vizualizaci a interpretaci fMRI dat je zásadní jednoznačná orientace mozku v prostoru a správné pochopení používaných souřadnicových systémů. Základním souřadnicovým systémem je tzv. voxel space, ve kterém jsou jednotlivé body mozku určeny přímo indexy v datové matici. Souřadnice jsou zde vyjádřeny jako celočíselné indexy odpovídající pozici voxelu v objemu dat. Tento systém je přirozený z hlediska práce s daty v MATLABu, avšak sám o sobě nenese informaci o skutečné fyzické orientaci mozku ani o rozměrech voxelů. [16]

Pro popis reálné geometrie mozku se využívá tzv. world space, ve kterém jsou souřadnice udávány v milimetrech vzhledem k referenčnímu bodu skeneru, typicky k izocentru hlavního magnetického pole. Převod mezi voxely a milimetry je definován afinní transformační maticí uloženou v hlavičce datového souboru. Tento souřadnicový systém umožňuje korektní prostorovou interpretaci dat, měření vzdáleností a správnou orientaci anatomických struktur. [22]


2.2 Typická pipeline

Surová fMRI data jsou zatížena řadou artefaktů, geometrických distorzí a šumu, které ztěžují okamžitou statistickou analýzu. Než je možné hledat v datech neuronální aktivitu, musí projít sérií výpočetních operací, souhrnně nazývaných "pre-processing pipeline", jejichž schéma lze vidět na Obr. 2.1. Cílem předzpracování je snížit variabilitu dat, která nesouvisí s experimentálním úkolem, a připravit data tak, aby splňovala předpoklady obecného lineárního modelu (angl. General Linear Model, GLM). [23]

Následující podkapitoly popisují standardní postup používaný v prostředí SPM (Statistical Parametric Mapping).

2.2.1 Korekce akvizičních časů

Fyzikální princip EPI sekvence neumožňuje nasnímat celý objem mozku v jednom časovém okamžiku. Data jsou proto pořizována postupně po jednotlivých řezech. Je-li také nasnímán celý objem trvá jednu délku TR a mozek je rozdělen do určitého počtu řezů, dochází mezi akvizicí prvního („spodního“) a posledního („horního“) řezu k časovému posunu téměř celé délky TR. Bez další korekce by statistický model fMRI analýzy implicitně předpokládal, že signál ve všech řezech odpovídá stejnému časovému okamžiku. To by vedlo k systematické chybě, protože události zaznamenané v různých částech mozku by byly časově nesprávně zarovnány, a výsledná aktivace by tak mohla být zkreslena. [23]



Obr. 2.1: Jednotlivé kroky předzpracování fMRI dat[25]

Princip korekce akvizičních časů spočívá v časové interpolaci signálu v jednotlivých řezech. Algoritmus odhaduje hodnoty signálu v časech, kdy nebyly řezy skutečně snímány, a data jsou následně matematicky posunuta tak, aby odpovídala jednomu referenčnímu časovému bodu. Tímto referenčním okamžikem bývá nejčastěji čas akvizice prostředního řezu nebo prvního řezu v pořadí snímání. Nejčastěji používanou metodou je sinc interpolace. [26]

Přestože je tento krok z hlediska časové správnosti dat matematicky opodstatněný, je třeba si uvědomit i jeho nevýhodu, kterou je skutečnost, že se jedná o interpolaci, a tedy o operaci, která mění původní naměřená data. Obecně platí, že interpolace by měla být při zpracování zobrazovacích dat používána pouze tehdy, je-li nezbytná. V případě použití této korekce totiž existuje riziko, že lokální artefakty přítomné v jednom objemu dat mohou být interpolací rozšířeny do dalších objemů v časové řadě. Tento efekt je zvláště problematický u dat s výraznějším pohybem hlavy, kde může interpolace zhoršit kvalitu signálu a negativně ovlivnit následnou statistickou analýzu. [23]


I z tohoto důvodu je otázka zařazení korekce akvizičních časů často diskutována a její přínos závisí na konkrétním experimentálním designu, hodnotě TR a následných analytických krocích. V některých pipeline je tedy zcela vynechávána, zejména při použití krátkého TR nebo multiband akvizice. [23]

2.2.2 Korekce pohybu

Z hlediska hodnocení kvality fMRI dat představuje korekce pohybu jeden z nejvýznamnějších kroků celého zpracování. Fyzický pohyb hlavy vyšetřovaného subjektu

patří mezi hlavní zdroje šumu ve fMRI datech. Již milimetrové posuny mohou na rozhraních jednotlivých tkání způsobit změny intenzity signálu v řádu desítek procent, což zcela překrývá vlastní BOLD efekt, jehož amplituda se typicky pohybuje pouze mezi 0,5–5 %. [4][16]

Princip korekce pohybu spočívá v aproximaci hlavy jako tuhého tělesa, což znamená, že poloha hlavy se může měnit, posunem nebo otáčením podél každé ze tří os, ale tvar hlavy se měnit nemůže. Nejprve je zvolen referenční snímek, kterým může být například první objem časové řady nebo průměrný objem ze všech snímků. Každý další objem je následně prostorově zarovnán k tomuto referenčnímu snímku tak, aby byly minimalizovány rozdíly v intenzitách odpovídajících voxelů. K tomuto účelu se používá rigidní transformace se šesti stupni volnosti, zahrnující tři translační posuny v osách x, y a z (udávané v milimetrech) a tři rotační složky α , β a γ , které popisují otočení hlavy kolem jednotlivých os (angl. pitch, roll a yaw) ve stupních nebo radiánech, viz Obr. 2.2. [4][16][23]



Obr. 2.2: Parametry translace a rotace ve 3D datech[24]

Vedlejším, avšak velmi důležitým výstupem tohoto kroku je soubor obsahující odhadnuté parametry pohybu v čase (v prostředí SPM typicky soubor `rp_*.txt`). Tento soubor má podobu matice o N řádcích, kde N odpovídá počtu časových bodů, a šesti sloupcích reprezentujících jednotlivé translační a rotační parametry. Časové průběhy těchto parametrů poté umožňují výpočet metriky pro kontrolu kvality Framewise Displacement (FD), která kvantifikuje míru pohybu mezi sousedními časovými snímky. [23]

2.2.3 Korekce distorzí

Zatímco korekce pohybu se zaměřuje na změny polohy hlavy v průběhu měření, korekce distorzí řeší deformaci samotného obrazu, která vzniká v důsledku neho-

mogenit magnetického pole. Jednotlivé tkáně lidského těla se liší svou magnetickou susceptibilitou, tedy schopností reagovat na magnetické pole. Nejvýraznější rozdíly vznikají na rozhraní tkáně a vzduchu, typicky v oblasti vedlejších nosních dutin a zvukovodů. V těchto lokalitách dochází k lokálním změnám intenzity magnetického pole. Protože prostorové kódování obrazu v MRI je založeno na frekvenci přesního pohybu spinů, změna magnetického pole vede ke změně této frekvence. Rekonstrukční algoritmus pak tuto změnu chybně interpretuje jako posun v prostoru, což se projeví jako geometrická deformace obrazu. [4]

Nehomogenity magnetického pole se na fMRI datech projevují dvěma hlavními typy artefaktů. Prvním z nich jsou geometrické distorze, kdy je obraz v určitých oblastech „natažen“ nebo „stlačen“, nejčastěji ve směru fázového kódování. Důsledkem je nesoulad tvaru funkčních dat s anatomickým snímkem. Druhým typem artefaktu je výpadek signálu (angl. signal dropout). V oblastech s velmi strmým gradientem magnetického pole, například v orbitofrontální kůře nebo ve spánkových lalocích, dochází k tak rychlému rozfázování spinů, že signál zanikne dříve, než může být zaznamenán. Výsledkem jsou oblasti s výrazně sníženým nebo nulovým signálem. [16]

Korekce geometrických distorzí obvykle vyžaduje doplňková měření. Standardním přístupem, podporovaným i v toolboxu SPM, je použití tzv. FieldMap. Při této akvizici je nasnímána speciální sekvence, která umožňuje přímo změřit lokální odchylky magnetického pole ΔB_0 v jednotlivých voxelech. Z této mapy je následně vypočítána tzv. Voxel Displacement Map (VDM), která určuje velikost a směr posunu potřebného k nápravě geometrického zkreslení. [23]

2.2.4 Koregistrace

Funkční fMRI data mají relativně nízké prostorové rozlišení a postrádají dostatek anatomických detailů. Aby bylo možné přesně lokalizovat oblast mozku, ve které došlo k aktivaci, je nutné funkční data prostorově zarovnat k detailnímu strukturálnímu snímku mozku, nejčastěji T_1 -váženému obrazu, který je u téhož subjektu obvykle pořízen na začátku měření. [4]

Princip této registrace spočívá v tom, že T_1 -vážené strukturální snímky a T_2 -vážené funkční snímky mají zásadně odlišný kontrast – struktury, které jsou na jednom typu obrazu světlé, mohou být na druhém tmavé. Z tohoto důvodu nelze pro zarovnání použít jednoduchou minimalizaci rozdílů intenzit voxelů. Místo toho se používají metody založené na maximalizaci vzájemné informace, která měří statistickou závislost mezi intenzitami obou obrazů a je vhodná právě pro registraci obrazů s rozdílným kontrastem. [4]

2.2.5 Normalizace

Každý lidský mozek má jinou velikost a tvar. Aby bylo možné smysluplně porovnávat výsledky mezi různými subjekty, a provádět skupinové analýzy, je nutné převést individuální data do jednotného referenčního souřadnicového systému. Tento proces se označuje jako normalizace do standardního stereotaktického prostoru. [4][16]

De facto standardem v neurovědecké komunitě, který je zároveň výchozím nastavením v softwaru SPM, je prostor definovaný Montreal Neurological Institute (MNI). Nejčastěji používanými šablonami jsou MNI305 a novější MNI152, které vznikly zprůměrováním anatomických snímků velkého počtu zdravých jedinců ($N = 305$, resp. $N = 152$), jež byly předem vzájemně registrovány. Výsledná šablona je oproti individuálnímu mozku méně ostrá, avšak reprezentuje průměrnou anatomii populace a poskytuje jednotný referenční rámec pro srovnání dat mezi subjekty i studii. [4][16]

Proces převodu mozku jednotlivého subjektu do MNI prostoru je výpočetně náročný a v nástrojích, jako je SPM, probíhá typicky ve dvou hlavních fázích. Nejprve je provedena afinní (lineární) transformace, která zajišťuje hrubé zarovnání mozku na šablonu. Ve druhé fázi následuje nelineární transformace (angl. warping), jejímž cílem je lokální deformace tkáně tak, aby jednotlivé anatomické struktury co nejlépe odpovídaly MNI šabloně. V prostředí SPM jsou k tomuto účelu využívány pokročilé algoritmy jako je např. DARTEL. Tyto metody umožňují velmi přesné prostorové přizpůsobení při zachování topologické konzistence mozku. [16][23]

2.2.6 Prostorové vyhlazení

Posledním krokem před vlastní statistickou analýzou fMRI dat je aplikace prostorového vyhlazení (angl. smoothing). V tomto kroku je každý objem dat konvolován s trojrozměrným Gaussovským jádrem, jehož cílem je potlačit vysokofrekvenční složky signálu a zvýraznit prostorově koherentní aktivaci. Míra vyhlazení je určena parametrem FWHM (Full Width at Half Maximum), který vyjadřuje efektivní šířku Gaussovského jádra. Typické hodnoty FWHM používané ve fMRI se pohybují přibližně na úrovni dvojnásobku velikosti voxelu, nejčastěji v rozmezí 6–8 mm. Volba tohoto parametru představuje kompromis mezi zachováním prostorové přesnosti a zvýšením detekovatelnosti signálu. [16]

Existuje několik důvodů pro aplikaci prostorového vyhlazení. Prvním z nich je zvýšení SNR, protože náhodný vysokofrekvenční šum je potlačen průměrováním signálu v okolních voxelech. Druhým významným důvodem je částečná kompenzace drobných anatomických rozdílů mezi jednotlivými subjekty, které nemusely být zcela odstraněny během normalizace do standardního prostoru. Třetím důvodem je metodologický požadavek některých statistických přístupů. Zejména teorie Gaussovských

náhodných polí (angl. Gaussian Random Field Theory), často využívaná pro korekci na mnohonásobné testování, předpokládá určitou míru prostorové hladkosti dat. Z tohoto důvodu je prostorové vyhlazení standardním krokem u většiny skupinových fMRI studií. Přesto existují specifické případy, kdy se pracuje s nevyhlazenými daty, např. v analýzách založených na klasifikaci vzorů (angl. Multivariate Pattern Analysis, MVPA), kde mohou jemné prostorové detaily nést důležitou informaci. [16]

2.3 Přehled používaných softwarových nástrojů


Vzhledem ke komplexitě fMRI dat a algoritmů používaných pro jejich zpracování není možné provádět jednotlivé kroky analýzy manuálně. V průběhu posledních desetiletí se proto v neurovědecké komunitě rozšířilo několik softwarových balíčků, které pokrývají různé fáze práce s neurovizualizačními daty, zejména jejich předzpracování, statistickou analýzu, vizualizaci a interpretaci výsledků. Tyto nástroje jsou zpravidla vyvíjeny na akademických pracovištích, distribuovány jako open-source software a v praxi se často vzájemně doplňují.

Mezi nejpoužívanější softwarové balíky v oblasti funkční magnetické rezonance patří zejména SPM, FSL a AFNI. Každý z nich využívá odlišný přístup ke zpracování dat, liší se podporovaným prostředím, způsobem ovládání i možnostmi integrace do vlastních analytických postupů. Z hlediska této diplomové práce je důležité zejména to, zda daný software umožňuje práci s fMRI daty, poskytuje nástroje pro předzpracování a zda je možné jeho funkce využít nebo napojit na vlastní aplikaci vytvořenou v prostředí MATLAB.

2.3.1 SPM (Statistical Parametric Mapping)

SPM je jeden z nejstarších a zároveň nejrozšířenějších softwarových balíčků pro analýzu mozkových dat. Je vyvíjen ve Wellcome Centre for Human Neuroimaging v Londýně. Na rozdíl od některých jiných nástrojů, které jsou implementovány převážně v jazycích C nebo C++, je SPM vytvořeno jako sada funkcí a skriptů pro prostředí MATLAB. Tato skutečnost je významná i pro tuto práci, protože umožňuje přímé volání vybraných funkcí SPM z vlastního MATLABového kódu. Mezi tyto funkce patří například načítání a manipulace s daty ve formátu NIfTI nebo práce s výstupy předzpracování. [16]

SPM je založeno především na voxel-wise přístupu ke statistické analýze, kdy je statistický model aplikován nezávisle na každý voxel mozku. Výsledkem jsou statistické parametrické mapy, které popisují vztah mezi naměřeným signálem a experimentálním designem. Software dále podporuje tzv. *batch processing*, tedy automatizované řetězení jednotlivých kroků zpracování. Tímto způsobem lze provádět



Obr. 2.3: Ukázka uživatelského rozhraní SPM

například korekci pohybu, prostorovou normalizaci nebo vyhlazení dat. Ukázku uživatelského rozhraní SPM lze vidět na Obr. 2.3. [23]


Pro tuto práci je SPM důležité zejména kvůli své kompatibilitě s prostředím MATLAB. Navrhovaný nástroj využívá vstupně-výstupní funkce SPM pro práci s fMRI daty a navazuje také na některé výstupy předzpracování, například na pohybové parametry využitelné při výpočtu metrik kvality.

2.3.2 FSL (FMRIB Software Library)

FSL je komplexní knihovna nástrojů pro zpracování a analýzu neurovizuálních dat, vyvíjená na Oxfordské univerzitě v rámci centra FMRIB. Společně s SPM patří mezi nejpoužívanější softwarové balíky v oblasti fMRI. Ukázku uživatelského rozhraní FSL lze vidět na Obr. 2.4. [16]

FSL je primárně navržena pro Unix-like systémy, zejména Linux a macOS, a je implementována převážně v jazyce C++. Díky tomu umožňuje efektivní zpracování rozsáhlých datových souborů, avšak její přímá integrace do aplikace vyvíjené v prostředí MATLAB je méně přímočará než v případě SPM. [18]

Silnou stránkou FSL je široké spektrum nástrojů pro předzpracování, statistickou analýzu a vizualizaci neurovizuálních dat. Významné postavení má také v oblasti difuzního zobrazování a v metodách založených na nezávislé analýze komponent. Nástroj MELODIC umožňuje rozklad fMRI dat na nezávislé komponenty a může být



Obr. 2.4: Ukázka uživatelského rozhraní FSL [28]

využíván například při identifikaci složek souvisejících s pohybem, srdeční činností nebo dýcháním. [16, 27]


Součástí FSL je také prohlížeč FSLeys, který slouží k vizualizaci strukturálních i funkčních dat, kontrole registrace a zobrazení výsledků analýzy. [27]

2.3.3 AFNI (Analysis of Functional NeuroImages)

AFNI je softwarový balík vyvíjený americkým Národním institutem zdraví (angl. National Institutes of Health, NIH). Je určen zejména pro zpracování, analýzu a vizualizaci funkčních neurozobrazovacích dat. Jednou z jeho hlavních předností je důraz na interaktivní práci s fMRI časovými řadami a prostorovou vizualizací dat. Díky tomu je AFNI vhodné pro detailní inspekci průběhu signálu, kontrolu jednotlivých časových bodů a identifikaci možných artefaktů. Ukázka uživatelského rozhraní AFNI je uvedena na Obr. 2.5. [16]

Z hlediska zpracování dat je AFNI silně orientováno na příkazovou řádku a skriptování. Typickým příkladem je nástroj `afni_proc.py`, který umožňuje vytvářet reprodukovatelné preprocessingové pipeline pro rozsáhlejší studie. Tento přístup poskytuje vysokou flexibilitu, ale může být náročnější pro méně zkušené uživatele nebo pro pracoviště preferující graficky orientované prostředí. [29]

Podobně jako FSL je AFNI primárně určeno pro Unix-like systémy, zejména Linux a macOS. To může být nevýhodou v případě, kdy je cílem vytvořit nástroj přímo integrovaný do prostředí MATLAB. V takovém případě by bylo nutné spouštět externí příkazy mimo vlastní aplikaci, což by zvyšovalo technickou náročnost a snižovalo provázanost celého řešení. [29]



Obr. 2.5: Ukázka uživatelského rozhraní AFNI [30]

Z uvedeného přehledu vyplývá, že SPM, FSL i AFNI představují významné nástroje pro práci s fMRI daty. Pro účely této diplomové práce je však nejvhodnějším výchozím prostředím SPM, a to především díky jeho přímé kompatibilitě s MATLABem a možnosti využít jeho funkce při načítání, zpracování a vizualizaci neurovizuálních dat.

3 Hodnocení kvality fMRI dat

Kvalita fMRI dat je kritickým faktorem, který přímo ovlivňuje validitu a spolehlivost výsledků. Vzhledem k tomu, že BOLD signál představuje pouze velmi malou změnu v celkové intenzitě obrazu (řádově jednotky procent), je extrémně náchylný k překrytí šumem [4]. Cílem této kapitoly je klasifikovat zdroje tohoto šumu a definovat metriky, které umožňují jeho kvantifikaci.

3.1 Faktory ovlivňující kvalitu dat

Signál naměřený v každém voxelu lze obecně modelovat jako časovou řadu $y(t)$, která představuje součet skutečné neuronální odezvy a několika složek šumu [4]. Z hlediska kontroly kvality (angl. Quality Control, QC) je klíčové tyto zdroje variability identifikovat a odlišit. Tato práce rozděluje faktory ovlivňující kvalitu fMRI dat na fyziologické, které souvisejí se subjektem měření, a přístrojové, které vyplývají z vlastností MR skeneru a použité akviziční sekvence.

3.1.1 Pohyb hlavy

Pohyb hlavy subjektu je považován za jeden z nejvýznamnějších zdrojů šumu ve fMRI datech a v krajním případě může vést k jejich úplnému znehodnocení. I při použití fixačních pomůcek dochází k mimovolným pohybům hlavy, které ovlivňují naměřený signál. [31]

Pohyb ovlivňuje fMRI data několika mechanismy. Prvním je prostorový posun, kdy voxel, který v jednom časovém bodě odpovídá šedé hmotě, může v následujícím čase zahrnovat bílou hmotu nebo mozkomíšní mok. To způsobuje náhlé změny intenzity signálu, zejména na hranách kontrastních struktur, jako je povrch mozku. Druhým mechanismem je tzv. spin-history efekt, při němž pohyb hlavy během excitace řezu naruší rovnováhu relaxačních procesů T_1 . Spiny v daném objemu neprojdou stejnou sekvencí RF pulzů jako v klidovém stavu, což vede ke změnám intenzity signálu, které nelze odstranit pouhou geometrickou korekcí. Třetím mechanismem je interakce s magnetickým polem, kdy pohybem hlavy dochází ke změně rozložení nehomogenit pole, což vede k časově proměnným distorzím obrazu. [31][32]

3.1.2 Fyziologické faktory

I při absenci makroskopického pohybu hlavy je MR signál ovlivněn fyziologickými procesy probíhajícími v těle subjektu. Mezi hlavní zdroje fyziologického šumu patří srdeční činnost a dýchání. [31]


Srdeční aktivita způsobuje periodické pulsace krve v cévách a pohyb mozkomíšního moku, což vede k rytmickým změnám signálu zejména v okolí velkých tepen a mozkových komor. Vzhledem k tomu, že srdeční frekvence (okolo 1 Hz) je vyšší než vzorkovací frekvence fMRI, kterou určuje TR, dochází k aliasingu, kdy se srdeční šum promítá do nižších frekvencí a může imitovat neuronální aktivitu. [4][31]

Dýchání ovlivňuje fMRI data jak mechanicky, tak magneticky. Mechanický vliv spočívá v přenosu pohybu hrudníku přes páteř na hlavu, což způsobuje pomalý rytmický pohyb. Magnetický vliv je dán rozdílnou magnetickou susceptibilitou vzduchu v plicích oproti tkáním. Změny objemu plic během dýchání vedou ke globálním fluktuacím magnetického pole B_0 , které se projevují jako fázové posuny signálu v mozku. [4][31]

3.1.3 Přístrojové faktory


Další skupinu faktorů ovlivňujících kvalitu dat tvoří nedokonalosti samotného měřicího zařízení. Základní složkou je tepelný šum, který vzniká v elektronice a přijímacích cívkách v důsledku Brownova pohybu elektronů. Tento šum má charakter bílého šumu a určuje teoretický limit SNR. [4]

Během dlouhých skenování se může projevit také drift skeneru, tedy pomalá nízkofrekvenční změna intenzity signálu v čase, kterou lze pozorovat na Obr. 3.1. Tento jev souvisí se zahříváním gradientních cívek a pasivních vyrovnávacích cívek a obvykle se projevuje jako lineární nebo kvadratický trend v časové řadě. [4]




Obr. 3.1: Drift MR signálu [4]

Specifickým typem artefaktů jsou tzv. spikes, tedy krátké a extrémní výkyvy signálu způsobené např. chybou při rekonstrukci k-prostoru. V obraze se často projeví jako pruhy procházející celým snímkem, viz Obr. 3.2. [33]



Obr. 3.2: Typický projev spike artefaktu v obraze [34]

Dalším typickým artefaktem EPI sekvencí je tzv. Nyquist ghosting, který vzniká při nedokonalé synchronizaci čtení sudých a lichých řádků k-prostoru. Projevuje se jako „duch“ obrazu posunutý o polovinu zorného pole (angl. Field of View, FOV) ve směru fázového kódování. Z hlediska kontroly kvality dat je proto důležité sledovat intenzitu signálu v oblastech mimo hlavu subjektu, kde by měl být přítomen pouze náhodný šum. Při výskytu Nyquist ghostingu se však v těchto oblastech objevují strukturované signály odpovídající obrysu mozku, jak lze vidět na Obr. 3.3. [35]




Obr. 3.3: Typický projev Nyquist ghostingu v obraze [36]

3.1.4 Susceptibilní artefakty

Susceptibilní artefakty vznikají v důsledku lokálních gradientů magnetického pole na rozhraních tkáně a vzduchu, zejména v orbitofrontálních a temporálních oblastech

(oblasti vedlejších nosních dutin a spánkových laloků), jak bylo zmíněno v podkapitole 2.2.3. Nejzávažnějším projevem je výpadek signálu, kdy v důsledku silného rozfázování spinů (zkrácení T_2^*) signál zcela vymizí, viz Obr. 3.4. [16]



Obr. 3.4: Výpadek signálu ve výsledném obraze [37]

3.2 Metriky pro hodnocení kvality dat

Kvantifikace kvality fMRI dat vyžaduje převedení vizuálních artefaktů a šumu do objektivních číselných hodnot. Tyto metriky umožňují automatizovanou detekci problematických skenů a slouží jako základ pro rozhodování o vyřazení subjektu nebo specifických časových bodů. Následující přehled definuje klíčové parametry využívané v současné neurovědě a implementované v nástrojích jako MRIQC.

3.2.1 Metriky pohybu

Pohyb hlavy je, jak bylo zmíněno v kap.3.1.1, hlavním zdrojem šumu. Pro jeho kvantifikaci se standardně využívá metrika Framewise Displacement (FD), kterou popularizovala práce Power et al. v roce 2012 [11]. FD vyjadřuje okamžitou změnu polohy hlavy mezi dvěma po sobě jdoucími časovými body (objemy). Vychází ze šesti parametrů pohybu (3 translační, 3 rotační) získaných během procesu korekce pohybu. Vzorec pro výpočet FD v čase t je definován jako součet absolutních hodnot diferencí těchto parametrů:

$$FD_t = |\Delta d_{x,t}| + |\Delta d_{y,t}| + |\Delta d_{z,t}| + |\Delta \alpha_t| + |\Delta \beta_t| + |\Delta \gamma_t| \quad (3.1)$$

Kde Δd představuje změnu translace (posunu) v osách x, y, z oproti předchozímu snímku ($t - 1$). $\Delta \alpha, \Delta \beta, \Delta \gamma$ představují změnu rotace. Aby bylo možné sčítat

milimetry (posun) a stupně/radiány (rotace), je nutné rotace převést na vzdálenost na povrchu hlavy. Standardně se předpokládá, že hlava je sféra o poloměru $r = 50$ mm, a převod se provádí vztahem:

$$\text{posun} = \alpha[\text{rad}] \times 50[\text{mm}] \quad (3.2)$$

Hodnoty $FD > 0,2$ mm nebo $0,5$ mm (v závislosti na přísnosti studie) indikují výrazný pohyb, který pravděpodobně znehodnotil data v daném časovém bodě. [11]

3.2.2 Metriky globální změny intenzity

Zatímco FD měří fyzický pohyb hlavy, metrika DVARS (Derivative of VARIance over voxelS/RMS variance over voxels) měří důsledek tohoto pohybu, ale i jiných artefaktů, přímo na intenzitě obrazu. DVARS kvantifikuje, jak moc se mění intenzita signálu v celém mozku mezi dvěma po sobě jdoucími snímky. Počítá se jako odmocnina z prostorového průměru druhých mocnin časových diferencí intenzit signálu přes celý mozek:

$$DVARS_i = \sqrt{\langle [I_i(\vec{x}) - I_{i-1}(\vec{x})]^2 \rangle} \quad (3.3)$$

Kde $I_i(\vec{x})$ je intenzita signálu ve voxelu na prostorové souřadnici $\vec{x}$ v časovém bodě i , $I_{i-1}(\vec{x})$ je intenzita téhož voxelu v předchozím časovém bodě. Výraz v hranaté závorce představuje změnu intenzity mezi snímky (časová derivace). Symbol $\langle \dots \rangle$ značí operátor prostorového průměrování přes všechny voxely uvnitř masky mozku. [11]

3.2.3 SNR metriky

Pro posouzení schopnosti detekovat BOLD signál je nutné znát poměr užitečného signálu k šumu na pozadí. Základní metrika pro fMRI časové řady je tSNR (Temporal Signal-to-Noise Ratio). V každém voxelu je definována jako poměr průměrné intenzity signálu v čase k jeho směrodatné odchylce:

$$tSNR = \frac{\mu_{\text{signál}}}{\sigma_{\text{signál}}} \quad (3.4)$$

Vyšší tSNR znamená stabilnější signál. Mapa tSNR (zobrazená jako 3D objem) je vynikajícím nástrojem pro vizualizaci oblastí s výpadky signálu nebo vysokým fyziologickým šumem, například v oblastech kolem velkých cév nebo mozkových komor. [38]

V literatuře se objevují i sofistikovanější přístupy, které se snaží lépe oddělit neuronální fluktuace od šumu. Jedná se o SNS (Signal to Noise Separation) a SFS (Signal Fluctuation Sensitivity). SNS metriku navrhli Shirer et al. v roce 2015 [39]. Využívá prostorové nezávislosti signálu a šumu a snaží se kvantifikovat, jak dobře lze oddělit

skutečné neuronální sítě (na základě atlasu) od artefaktů. SFS metriku představili DeDora et al. v roce 2016 [40], která hodnotí citlivost na fluktuace signálu v konkrétních frekvenčních pásmech relevantních pro BOLD signál, čímž lépe reflektuje "fyziologické SNR" oproti prostému tSNR.

3.2.4 Prostorové metriky

Pro komplexní hodnocení se využívají i metriky popisující prostorové vlastnosti jednotlivých objemů.

První zmíněnou je FWHM, neboli míra hladkosti obrazu. FWHM vyjadřuje plnou šířku v polovině maxima prostorového rozložení hodnot intenzity obrazu, měřenou v jednotkách voxelů. V kontextu této implementace jsou nižší hodnoty považovány za lepší, zatímco vyšší hodnoty indikují rozmazanější obraz (např. vlivem pohybu). Výpočet využívá filtr pro odhad gaussovske šířky, který je implementován ve funkci 3dFWHMx softwarového balíku AFNI. Algoritmus měří změny intenzity signálu nezávisle podél všech tří prostorových os (x, y, z). Výsledná hodnota FWHM je pak kombinací (geometrickým průměrem) těchto tří měření, čímž poskytuje informaci o celkové hladkosti 3D objemu mozku. [30][41]

Druhou metrikou je EFC (Entropy Focus Criterion). Metrika EFC, původně navržena Atkinsonem [43] pro automatickou korekci pohybu, využívá principu Shannonovy entropie k hodnocení ostrosti obrazu. Předpokladem je, že obraz bez artefaktů by měl mít energii koncentrovanou v reálných strukturách, což odpovídá nízké entropii. Naopak přítomnost artefaktů, jako je „ghosting“ nebo rozmazání vlivem pohybu, způsobuje rozptýlení energie do okolních voxelů, čímž se entropie zvyšuje. Výpočet v nástroji MRIQC probíhá ve dvou krocích. Nejprve je vypočtena entropie E normalizovaná celkovou energií obrazu:

$$E = - \sum_{j=1}^N \frac{x_j}{x_{max}} \ln \left[\frac{x_j}{x_{max}} \right] \quad (3.5)$$

Kde x_j je intenzita j -tého voxelu, N je celkový počet voxelů. x_{max} v tomto kontextu neznačí maximální hodnotu, ale L_2 normu obrazu, která slouží k normalizaci jasů:

$$x_{max} = \sqrt{\sum_{j=1}^N x_j^2} \quad (3.6)$$

Aby byla hodnota porovnatelná mezi obrazy s různým rozlišením (různým počtem voxelů N), je výsledné EFC normalizováno maximální možnou entropií systému:

$$\text{EFC} = \left(\frac{N}{\sqrt{N}} \ln(\sqrt{N}^{-1}) \right) \cdot E \quad (3.7)$$

Pro metriku EFC platí, že nižší hodnoty indikují vyšší kvalitu, tedy ostřejší obraz s méně artefakty. Teoretické minimum $EFC = 0$ by nastalo v případě, kdy je veškerá energie soustředěna v jediném voxelu. V reálných fMRI datech se hodnoty typicky pohybují v desetínách, přičemž náhlý nárůst EFC v časové řadě indikuje snímek znehodnocený pohybem. [41]

Poslední zmiňovanou metrikou je FBER (Foreground-Background Energy Ratio). Tato metrika kvantifikuje poměr intenzity signálu uvnitř hlavy vůči šumu v okolním prostoru. V implementaci nástroje MRIQC [41], je FBER definován jako poměr střední energie hodnot voxelů uvnitř masky hlavy ku střední energii hodnot vně této masky (pozadí):

$$FBER = \frac{E[|F|^2]}{E[|B|^2]} \quad (3.8)$$

Kde $E[\cdot]$ značí operátor střední hodnoty (průměru). $|F|^2$ jsou druhé mocniny intenzit voxelů v popředí (Foreground – hlava). $|B|^2$ jsou druhé mocniny intenzit voxelů v pozadí (Background – vzduch). Vyšší hodnoty FBER indikují lepší kvalitu dat s vysokým kontrastem a minimálním šumem v pozadí. Pokles FBER typicky signalizuje přítomnost artefaktů v pozadí.


3.2.5 Carpet plot

Na rozdíl od výše uvedených metrik, jako jsou FD, DVARS nebo tSNR, nepředstavuje Carpet plot samostatnou číselnou metriku kvality. Jedná se o vizualizační metodu, která umožňuje kompaktně zobrazit časové řady velkého množství voxelů současně. V kontextu hodnocení kvality fMRI dat je však velmi užitečná, protože poskytuje rychlý přehled o globální časové struktuře signálu a umožňuje vizuálně identifikovat artefakty, které by v jednotlivých číselných metrikách nemusely být na první pohled zřejmé.

Moderní QC nástroje, včetně MRIQC a fMRIPrep, Carpet plot využívají. Jeho princip podrobně popsal Power et al. v roce 2017 [46]. Jedná se o dvourozměrné maticové zobrazení časových řad, které umožňuje zobrazit velkou část dat v jednom kompaktním obraze. Na ose x je znázorněn čas a na ose y jednotlivé voxely, takže každý řádek představuje časový průběh signálu v jednom voxelu. Intenzita barvy pak odpovídá změně signálu v daném časovém bodě.

Voxely mohou být v Carpet plotu uspořádány podle anatomické nebo signálové příslušnosti, například na šedou hmotu, bílou hmotu a mozkomíšní mok. Na Obr. 3.5 jsou šedá a bílá hmota odděleny zelenou čarou. Toto uspořádání usnadňuje rozpoznání, zda se artefakt projevuje globálně napříč celým mozkem, nebo je omezený pouze na určitý typ tkáně či oblast.

Carpet plot je vhodným nástrojem pro odhalení globálních artefaktů. Například náhlý pohyb subjektu se často projeví jako vertikální pruh procházející napříč velkým počtem voxelů, zatímco pomalejší drift signálu se může projevit jako pozvolná změna intenzity v čase. Díky tomu Carpet plot vhodně doplňuje kvantitativní metriky, jako jsou FD a DVARS, a slouží jako rychlá vizuální kontrola celkové kvality fMRI časové řady.



Obr. 3.5: Projev pohybu hlavy v carpet plotu [46]

3.3 Stávající nástroje pro kontrolu kvality

S rostoucím objemem neurovizuálních dat a zvyšujícím se počtem subjektů ve studiích se manuální kontrola každého datasetu stává časově náročnou a obtížně reprodukovatelnou. Z tohoto důvodu vznikla řada nástrojů zaměřených na automatizované hodnocení kvality dat, výpočet kvantitativních metrik a tvorbu standardizovaných reportů. Tyto nástroje pomáhají odhalit například výrazný pohyb hlavy, změny intenzity signálu, technické artefakty nebo problémy vzniklé při předzpracování dat.

Zatímco obecné softwarové balíky, jako jsou SPM, FSL nebo AFNI, poskytují především nástroje pro zpracování, analýzu a vizuální inspekci dat, specializované QC nástroje se zaměřují přímo na systematické hodnocení kvality. Mezi nejvýznamnější patří zejména MRIQC a fMRIPrep, které jsou popsány v následujících podkapitolách.


3.3.1 MRIQC

Nástroj MRIQC (MRI Quality Control tool), vyvinutý laboratoří Russella Poldracka na Stanfordské univerzitě, patří mezi nejrozšířenější nástroje pro automatizované

hodnocení kvality strukturálních (T_1w , T_2w) i funkčních MRI dat. MRIQC je navrženo jako plně automatická pipeline, jejímž základním požadavkem je organizace vstupních dat podle standardu BIDS. [41]

Cílem MRIQC není provádět kompletní předzpracování dat, ale pouze nezbytné kroky potřebné k výpočtu metrik kvality. U funkčních dat se jedná například o odhad pohybových parametrů nebo výpočet časových charakteristik signálu. Nástroj následně extrahuje řadu parametrů označovaných jako IQMs (angl. *Image Quality Metrics*). Mezi tyto metriky patří například prostorové ukazatele, jako jsou SNR, FWHM nebo EFC, a časové ukazatele, jako jsou DVARS, FD nebo tSNR, viz kap. 3.2.

Výstupem MRIQC jsou dva základní typy reportů. Prvním z nich jsou individuální reporty generované samostatně pro každý dataset. Jejich ukázkou lze vidět na Obr. 3.6. Tyto reporty mají podobu HTML stránky a obsahují souhrnnou tabulku vypočtených metrik, náhledy obrazových dat a doplňkové vizualizace. Součástí jsou také vizuální reporty umožňující rychlé posouzení potenciálně problematických snímků a tzv. *carpet plots*, které zobrazují časový vývoj signálu v jednotlivých oblastech nebo voxelech.




Obr. 3.6: Ukázka individuálního reportu MRIQC [44]

Druhým typem výstupu jsou skupinové reporty, které shrnují metriky kvality pro celou studii, viz Obr. 3.7. Tyto reporty umožňují porovnávat rozdělení jednotlivých QC metrik napříč subjekty a usnadňují identifikaci odlehlých hodnot, například subjektů s výrazně vyšší mírou pohybu hlavy oproti zbytku skupiny. Skupinové reporty tak slouží jako efektivní nástroj pro rychlou detekci datasetů, které mohou vyžadovat detailnější individuální kontrolu.

MRIQC: group anatomical report

Summary

- Date and time: 2017-02-05, 12:27.
- MRIQC version: 0.9.0-rc2.



Obr. 3.7: Ukázka skupinového reportu MRIQC [45]

MRIQC je implementováno v jazyce Python a je distribuováno především jako Docker nebo Singularity kontejner. Tento způsob distribuce podporuje reprodukovatelnost výpočtů, protože software běží ve sjednoceném prostředí nezávisle na konkrétní konfiguraci počítače. Zároveň však může představovat technickou překážku pro uživatele, kteří nejsou zvyklí pracovat s příkazovou řádkou nebo kontejnerizací, případně používají pracovní postupy založené převážně na MATLABu.

3.3.2 fMRIPrep

Dalším významným nástrojem využívaným při zpracování fMRI dat je fMRIPrep. Jedná se o robustní a široce používanou preprocessingovou pipeline, jejímž cílem je standardizovat a automatizovat předzpracování funkčních MRI dat napříč různými studiemi a pracovišti. Stejně jako MRIQC je fMRIPrep navržen pro data organizovaná podle standardu BIDS a integruje osvědčené nástroje z více softwarových balíčků, například FSL nebo AFNI. [47]

Z hlediska kontroly kvality je významné, že fMRIPrep ke každému zpracovanému datasetu generuje vizuální HTML report. Tento report obsahuje náhledy jednotlivých kroků předzpracování, například kontrolu koregistrace funkčních dat se strukturálním obrazem nebo kontrolu normalizace do standardního prostoru. Součástí výstupů jsou také pohybové parametry a další veličiny, které mohou být využity při následném hodnocení kvality dat nebo při regresi nežádoucích složek signálu. [48]

Hlavním účelem fMRIPrep však není samostatná kontrola kvality, ale vytvoření reprodukovatelné a standardizované preprocessingové pipeline. Generované reporty slouží především k ověření správnosti jednotlivých kroků zpracování. Nejsou tedy primárně určeny k interaktivnímu procházení dat, k detailnímu propojení metrik kvality s konkrétními časovými body nebo k prostorové kontrole jednotlivých řežů. Z tohoto důvodu představuje fMRIPrep důležitý referenční nástroj, avšak neřeší plně

potřebu interaktivní vizualizace fMRI dat, na kterou se zaměřuje tato práce. [47]

3.3.3 QC možnosti ve standardních neurovizualizačních balících

Kromě specializovaných nástrojů, jako jsou MRIQC a fMRIPrep, poskytují možnosti kontroly kvality také běžně používané softwarové balíky SPM, FSL a AFNI. Tyto nástroje však nejsou primárně navrženy jako samostatné QC aplikace, ale jejich kontrolní funkce jsou součástí širšího workflow pro zpracování a analýzu neurovizualizačních dat.

V prostředí SPM lze například vizuálně kontrolovat správnost registrace obrazů, výsledky prostorové normalizace nebo výstupy korekce pohybu. FSL nabízí pro vizuální inspekci zejména prohlížeč FSLeyes, který umožňuje zobrazovat strukturální i funkční data, překryvy statistických map a výsledky registrace. AFNI je naopak známé pokročilými možnostmi interaktivní práce s fMRI časovými řadami a prostorovými řezy. [23, 27, 29]

Společným omezením těchto balíků je skutečnost, že kvantitativní metriky kvality, časové průběhy a prostorová vizualizace dat obvykle nejsou propojeny v jednom jednotném prostředí. Uživatel tak často musí kombinovat více výstupů nebo přecházet mezi různými nástroji. To může komplikovat rychlou interpretaci artefaktů, zejména v případech, kdy je potřeba propojit konkrétní hodnotu metriky s odpovídajícím časovým snímkem a prostorovým řezem.

3.3.4 Limitace existujících řešení

Z uvedeného přehledu vyplývá, že existující nástroje poskytují důležitou podporu při kontrole kvality fMRI dat, avšak každý z nich pokrývá pouze určitou část potřebného workflow. Automatizované nástroje, jako je MRIQC, umožňují výpočet rozsáhlé sady kvantitativních metrik a generování přehledných reportů. Ty jsou vhodné pro rychlé zhodnocení kvality jednotlivých datasetů i celé studie. Jejich omezením je však převážně statická povaha výstupů.

Uživatel může například v reportu identifikovat výraznou hodnotu metriky FD nebo DVARS, ale nemůže na tento nález přímo navázat interaktivním zobrazením odpovídajícího časového bodu ve fMRI datech. Pro správnou interpretaci artefaktu je přitom často důležité zjistit, zda se daná odchylka projevuje jako pohybový artefakt, globální změna intenzity signálu, technický problém skeneru nebo lokální odchylka v určité oblasti obrazu.

Opačný přístup představují obecné neurovizualizační balíky, jako jsou SPM, FSL a AFNI. Ty umožňují detailní vizuální inspekci dat, kontrolu prostorového zarovnání nebo procházení jednotlivých řezů a časových snímků. Jejich nevýhodou však je,

že neposkytují jednotné prostředí, ve kterém by byly kvantitativní metriky kvality přímo propojeny s obrazovou informací a časovým průběhem signálu.

V praxi tak vzniká mezera mezi automatizovaným výpočtem metrik a jejich vizuální interpretací. Pokud je například v časovém průběhu DVARS detekována výrazná špička, je pro uživatele užitečné okamžitě zobrazit odpovídající časový snímek a prostorové řezy. Taková přímá vazba mezi číselnou metrikou a obrazovou informací může výrazně usnadnit rozhodnutí, zda je daný časový bod problematický a jaký typ artefaktu se v datech vyskytuje.

Další omezení souvisí se způsobem distribuce a spouštění některých moderních nástrojů. MRIQC i fMRIPrep jsou často provozovány jako kontejnerizované aplikace v prostředí Docker nebo Singularity a ovládají se prostřednictvím příkazové řádky. Tento přístup podporuje reprodukovatelnost výpočtů, ale pro uživatele pracující primárně v prostředí MATLAB nebo na platformě Windows může představovat technickou bariéru. Zároveň komplikuje začlenění kontroly kvality do zavedených MATLABových workflow, například do postupů založených na SPM batch zpracování.

Právě tato kombinace funkčních a technologických omezení tvoří hlavní motivaci pro návrh softwaru vyvíjeného v této diplomové práci. Cílem je vytvořit nástroj, který v prostředí MATLAB propojí výpočet kvantitativních metrik kvality s interaktivním prohlížením fMRI dat. Navržené řešení využívá data a výstupy kompatibilní se SPM a umožňuje uživateli plynule přecházet mezi časovými průběhy metrik, prostorovými řezy a detailní kontrolou konkrétních problematických časových bodů. Tím usnadňuje prostorově-časovou interpretaci detekovaných artefaktů bez nutnosti využití kontejnerových systémů nebo samostatných externích aplikací.

4 Praktická část

4.1 Použité nástroje, metodika a architektura

Tato kapitola popisuje volbu vývojového prostředí, využití externích knihoven pro práci s fMRI daty, postup při vývoji a celkovou vnitřní architekturu navrženého softwaru.

4.1.1 Vývojové prostředí a použité knihovny

Pro realizaci praktické části diplomové práce a vývoj vizualizačního nástroje bylo zvoleno prostředí MATLAB ve spojení s knihovnou SPM12. Tato volba byla motivována především plnou kompatibilitou s pracovními postupy laboratoře MAFIL CEITEC MU, která software SPM standardně využívá pro zpracování fMRI dat. Dalším důvodem byla možnost přímého volání analytických funkcí SPM uvnitř vlastního grafického rozhraní. Odpadla tak nutnost integrace externích nástrojů nebo kompilace C++ kódu, což by bylo při použití jiných softwarových balíčků, jako je např. FSL nebo AFNI, náročnější. Výhodou prostředí MATLAB je rovněž jeho nativní optimalizace pro práci s rozsáhlými vícerozměrnými maticemi, které tvoří základní reprezentaci fMRI dat.

Aplikace je určena pro práci se čtyřrozměrnými daty ve formátu NIfTI, kde první tři dimenze reprezentují prostorové uspořádání voxelů a čtvrtá dimenze odpovídá časové složce měření. Architektura softwaru byla navržena tak, aby se dynamicky přizpůsobovala parametrům načteného datasetu, a to včetně různých prostorových rozlišení, počtu řezů i délky časové řady. Během vývoje bylo dbáno na maximální využití vektorizace výpočtů a takzvané implicitní expanze [51]. Tento přístup umožnil eliminovat výpočetně náročné cykly a zajistil plynulý chod aplikace i při manipulaci s objemnými datovými sadami v reálném čase.

Vzhledem k tomu, že cílem práce nebylo vytvářet vlastní pipeline pro předzpracování obrazu, ale vyvinout nástroj pro vizualizaci a kontrolu kvality již zpracovaných dat, opírá se aplikace o existující infrastrukturu toolboxu SPM12. Z tohoto balíku byly integrovány následující funkce. Pro interakci se souborovým systémem a načítání metadat z NIfTI hlaviček byly využity funkce `spm_select()` a `spm_vol()`, zatímco samotné načtení obrazových dat do paměti zajišťuje funkce `spm_read_vols()`. Pro výpočet metrik kvality byla využita funkce `spm_detrend()`, která odstraňuje lineární trendy a střední hodnotu signálu v čase, čímž kompenzuje nízkofrekvenční drift MRI skeneru [52]. V rámci implementace metriky SNS byla do logiky programu začleněna také funkce `spm_reslice()`. Ta zajišťuje automatické prostorové převzorování externích anatomických atlasů tak, aby svými rozměry exaktně odpovídaly

analyzovaným fMRI datům. [23]


4.1.2 Metodika vývoje

Vývoj nástroje probíhal iterativně, což umožnilo průběžné testování na reálných datech, okamžitou vizuální validaci a postupné rozšiřování funkcionality. Tento přístup usnadnil rychlou identifikaci nedostatků a jejich opravu v navazujících verzích. Celý proces lze rozdělit do čtyř hlavních fází a je shrnut v podobě vývojového diagramu na Obr. 4.1.

V počáteční fázi bylo navrženo základní grafické uživatelské rozhraní. To bylo záměrně implementováno čistě kódově pomocí modulu MATLAB Handle Graphics, aby byla zajištěna maximální kontrola nad rozvržením prvků bez nutnosti spoléhat na vizuální editory typu App Designer. Kód byl od počátku organizován modulárně, tedy rozdělen na logické části s jasně vymezenou odpovědností, zejména pro načítání dat, výpočet metrik a vizualizaci. Po softwarové stránce využívá program hybridní architekturu. Pro správu stavu aplikace a událostí grafického rozhraní je využito vnořených funkcí se sdíleným pracovním prostorem. Výpočetně náročné části programu, zejména algoritmy pro výpočet metrik kvality, jsou však vyčleněny do samostatných lokálních funkcí umístěných mimo hlavní tělo programu. Toto oddělení má několik výhod. Především zvyšuje přehlednost kódu, protože hlavní část programu zůstává zaměřena na řízení aplikace a uživatelského rozhraní, zatímco samotné výpočty jsou soustředěny do samostatných funkcí. Lokální funkce mají přesně definované vstupy a výstupy, například datové matice, masky nebo nastavené prahové hodnoty, které jsou jim explicitně předávány jako argumenty. Díky tomu nejsou výpočty závislé na proměnných sdílených v pracovním prostoru grafického rozhraní, což snižuje riziko nechtěných vedlejších efektů. Hlavním milníkem této fáze bylo úspěšné načtení souboru, vyřešení mapování souřadnic a stabilní zobrazení dat ve třech základních anatomických rovinách.

Následovala integrace časové dimenze. Do rozhraní byly přidány ovládací prvky pro procházení jednotlivými časovými snímky a byla zavedena událostmi řízená architektura s centrální synchronizační funkcí `update_all()`. Tato funkce zajišťuje okamžitou datovou konzistenci všech panelů při každé změně stavu aplikace. Kliknutím do libovolné anatomické roviny se tak automaticky aktualizuje pozice křížového kurzoru i navázané časové řady. Během této fáze byl vytvořen modul pro dynamické vykreslování BOLD signálu, který formou konfigurovatelné mřížky grafů reprezentuje lokální okolí vybraného voxelu. Dále byl vyvinut pokročilý správce dat, jenž bezpečně obsluhuje načtení až pěti datových sad současně. Grafické prvky byly provázány se stavem aplikace tak, aby se dodatečné analytické nástroje aktivovaly automaticky až po validním načtení dat.

Třetí fáze vývoje byla výpočetně nejnáročnější, neboť zahrnovala implementaci samotných algoritmů pro výpočet metrik kontroly kvality. Výpočetní logika byla v kódu důsledně oddělena od vykreslovací vrstvy. Jako základ pro prostorové metriky posloužilo vytvoření masky mozku založené na dynamickém prahování časového průměru signálu. Na to navázaly prostorové metriky mapa tSNR a mapa SNS, a následně i globální časové metriky DVARs, Framewise Displacement a komplexní vizualizace formou Carpet plotu. Výpočet SNS vyžadoval navíc implementaci automatického prostorového převzorkování externích atlasů na nativní rozlišení uživatelských dat, aby bylo možné korelační analýzu provést ve stejném souřadnicovém prostoru.



Obr. 4.1: Diagram všech 4 fází vývoje vlastního nástroje

V závěrečné fázi byl proveden rozsáhlý refaktoring zaměřený na zpřehlednění a optimalizaci kódu, jehož komplexita s přibývajícími metrikami výrazně rostla.

Opakující se kód pro obsluhu uživatelských událostí (tzv. *callbacky*) byl sjednocen do univerzálních funkcí. Rovněž došlo k optimalizaci výpočetního výkonu, například předáváním již existující mozkové masky dalším funkcím, čímž se eliminovaly zbytečné redundantní výpočty. Jednotlivé moduly byly důkladně ošetřeny vůči hraničním stavům jako je absence dat, manipulace s neplatnými grafickými objekty nebo zadání nekonzistentních prahových hodnot uživatelem. Završením celého vývoje byla tvorba QC mapy, která spojuje výsledky více samostatných metrik do jedné intuitivní vizualizace.

4.1.3 Architektura softwaru

Na návrh popsany v metodické části navazuje výsledná architektura aplikace, která je realizována jako plně skriptované grafické rozhraní v prostředí MATLAB. Tato část se proto zaměřuje především na vnitřní uspořádání programu, způsob správy dat a mechanismus aktualizace jednotlivých částí rozhraní.

Jádrem aplikace je hybridní architektura kombinující vnořené funkce pro obsluhu grafického rozhraní a samostatné lokální funkce pro výpočetní operace. Hlavní skript nejprve inicializuje sdílený stav aplikace, který zahrnuje zejména pole struktur **datasets**, aktuální prostorové souřadnice **pos**, index zobrazeného časového snímku **currentFrame** a uživatelsky definované prahové hodnoty. Poté je vytvořeno rozvržení grafického rozhraní a jednotlivým ovládacím prvkům jsou přiřazeny odpovídající *callbacky*.

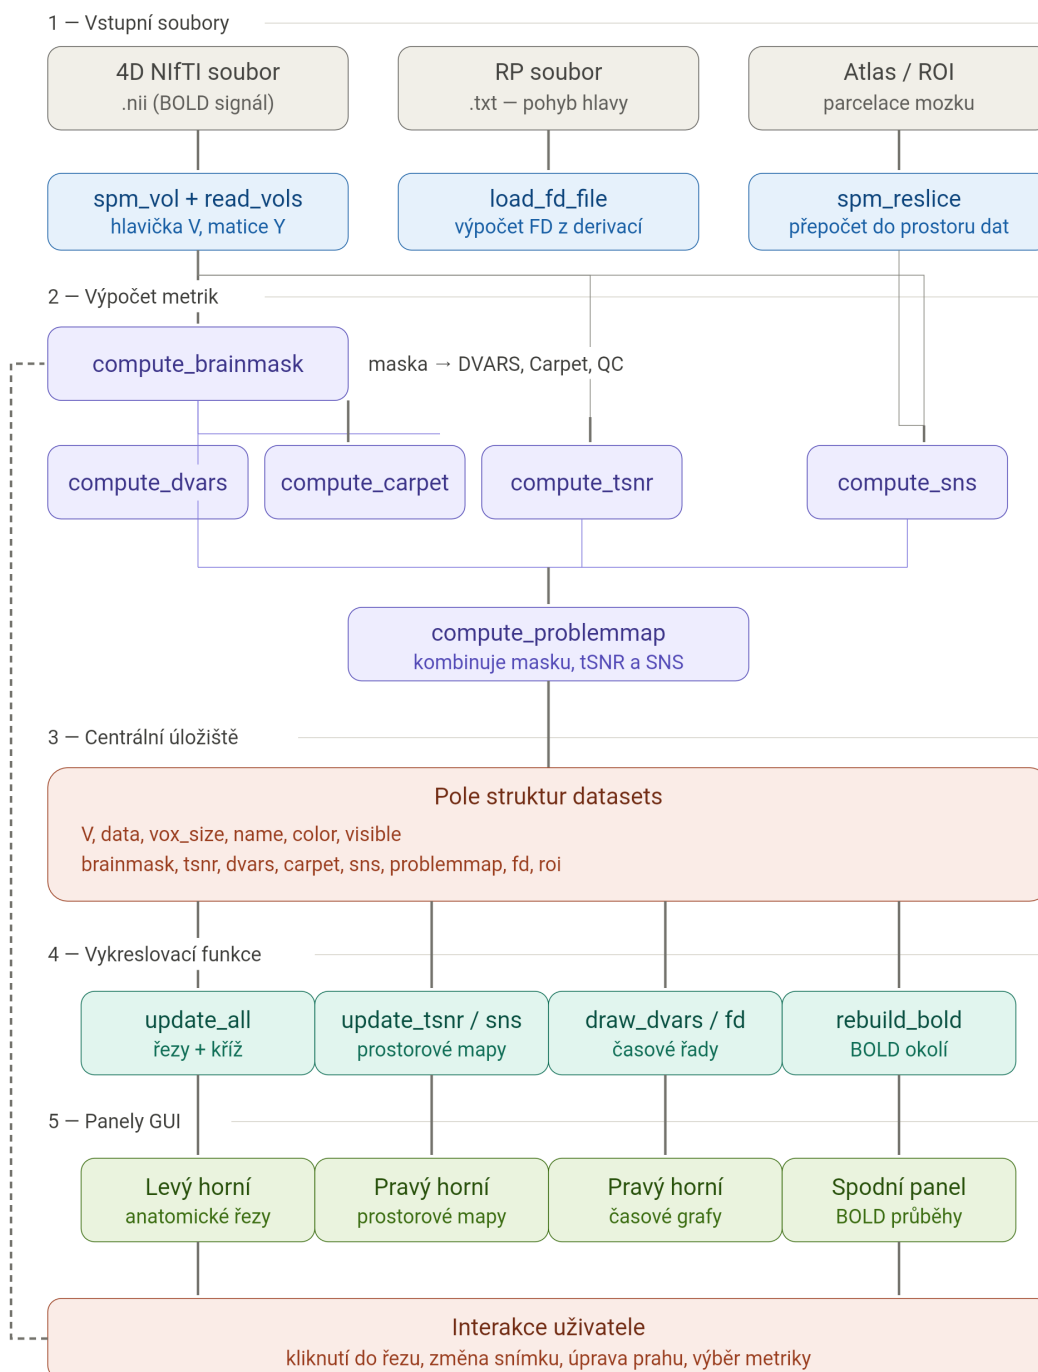
Callbacky jsou implementovány jako vnořené funkce, díky čemuž mohou přímo přistupovat ke sdílenému stavu aplikace bez použití globálních proměnných. Tím je zjednodušena správa interakcí uživatele s rozhraním, například při změně časového snímku, výběru prostorové souřadnice nebo úpravě prahové hodnoty. Výpočetní algoritmy pro jednotlivé metriky jsou naopak odděleny do lokálních funkcí mimo hlavní tělo aplikace. Těmto funkcím jsou data, masky i parametry předávány explicitně jako vstupní argumenty, což omezuje závislost výpočtů na aktuálním stavu GUI a usnadňuje jejich samostatné testování.

Informace o načtených datech jsou organizovány v centrálním poli struktur **datasets**. Každý prvek tohoto pole odpovídá jednomu datasetu a obsahuje jak původní obrazová data, tak informace potřebné pro jejich vizualizaci a hodnocení kvality. Konkrétně jsou zde uloženy:

- původní hlavička dat ve formátu NIFTI,
- surová 4D matice obrazových dat,
- fyzická velikost voxelů odvozená z afinní transformační matice,
- atributy pro vizualizaci, například identifikátor barvy, stav viditelnosti a uživatelský název datasetu,

- předpočítané mapy a vektory metrik kvality, například Brainmask, tSNR, DVARS, FD, Carpet plot, SNS a QC mapa.

Tato struktura umožňuje pracovat s více datovými sadami současně a zároveň udržuje přehledné oddělení mezi daty, vypočtenými metrikami a informacemi potřebnými pro zobrazení. Kompletní tok dat od načtení po jejich vizualizaci je znázorněn na Obr. 4.2.



Obr. 4.2: Diagram toku dat

Uživatelská interakce je řešena událostmi řízeným způsobem. Každá akce uživatele, například kliknutí do zobrazeného řezu, změna hodnoty v textovém poli nebo posun posuvníku, vyvolá příslušnou obslužnou funkci. Tyto funkce nejprve aktualizují vnitřní stav aplikace, například ověří platnost nové souřadnice nebo uloží změněnou prahovou hodnotu, a následně spustí centrální aktualizací rutiny, jako jsou `update_all()` nebo `draw_selected_metric()`.

Aby se omezilo opakování kódu, jsou některé typově podobné interakce sdruženy do společných callbacků. Například kliknutí do různých zobrazených metrik může být obslouženo jednotnou funkcí, která pouze podle zdroje události určí, která část rozhraní má být aktualizována. Tento přístup zjednodušuje údržbu programu a snižuje riziko nekonzistentního chování mezi jednotlivými částmi aplikace.

Důležitou součástí návrhu je také selektivní aktualizace výstupů. Při změně parametru, který ovlivňuje pouze část zobrazení, aplikace nepře počítává všechny metriky znovu, ale aktualizuje pouze ty prvky, které jsou danou změnou skutečně ovlivněny. Například při změně prahové hodnoty pro vizualizaci tSNR není nutné znovu počítat metriky založené na korelačních maticích, jako je SNS. Díky tomu se snižuje výpočetní zátěž a zachovává se plynulá odezva uživatelského rozhraní.

K efektivitě výpočtů přispívá také opětovné využití již předpočítaných mezivýsledků. Například maska mozku je po svém vytvoření uložena v datové struktuře a následně předávána jako vstupní argument funkcím pro výpočet DVARS nebo Carpet plotu. Tím odpadá nutnost jejího opakovaného generování a zároveň je zajištěno, že jednotlivé metriky vycházejí ze stejné definice analyzované oblasti.

Součástí zobrazovací vrstvy je funkce `adjust_view_panel_sizes()`, která zajišťuje geometricky korektní zobrazení anatomických řezů. Z afinní transformační matice uložené v NIfTI hlavičce jsou odvozeny fyzické rozměry voxelů v milimetrech a všechny tři ortogonální pohledy jsou následně vykresleny s odpovídajícím měřítkem. Díky tomu nedochází ke zkreslení obrazu při anizotropním rozlišení voxelů, například při velikosti voxelů $3 \times 3 \times 4$ mm.

Zachování fyzického měřítka má význam také pro vzájemné navázání jednotlivých řezů. Sdílené anatomické osy mezi koronálním, sagitálním a axiálním pohledem jsou v obraze zobrazeny ve stejném měřítku, což usnadňuje orientaci v prostoru a vizuální porovnání jednotlivých řezů. Funkce `adjust_view_panel_sizes()` je volána při aktualizaci zobrazení a automaticky přizpůsobuje rozměry zobrazovacích panelů parametrům aktuálně načtených dat.

4.2 Návrh a implementace vizualizačního nástroje


Tato kapitola detailně popisuje implementaci základních vizualizačních a navigačních prvků softwaru. Vzhledem ke komplexní povaze fMRI dat, která představují

čtyřrozměrné matice s obrovským počtem prvků, bylo nutné navrhnout rozhraní tak, aby umožňovalo plynulý, interaktivní a plně synchronizovaný průchod všemi těmito rozměry.

4.2.1 Rozvržení a struktura uživatelského rozhraní

Grafické rozhraní bylo navrženo s důrazem na přehlednost pracovní plochy věnované obrazovým datům. Hlavní okno aplikace je rozděleno do tří hlavních funkčních bloků, jejichž chování je vzájemně propojeno.


Levý horní panel, viz Obr. 4.3, plní roli primárního navigačního prvku pro anatomická data. Skládá se ze tří nezávislých obrazových os, které vizualizují mozek ve standardních ortogonálních rovinách – koronální, sagitální a axiální. Kliknutím do kteréhokoli z těchto řezů se interně přepočítají prostorové souřadnice a synchronizovaný křížový kurzor okamžitě změní svou polohu ve všech třech pohledech. Ve spodní části tohoto panelu je navíc umístěno dynamické menu určené pro výběr tzv. aktivního datasetu. Je-li nahráno vícero datových sad, uživatel si může vybrat, či anatomie a z ní odvozené prostorové mapy jsou v daný moment vykreslovány na obrazovku.



Obr. 4.3: Náhled vizualizačního panelu


Pravý panel je vyhrazen pro kontrolu kvality a interakci s matematickými modely softwaru. Jeho vnitřní struktura se dynamicky proměňuje na základě toho, jakou metriku uživatel z ovládacího menu zvolí. V případě volby prostorové metriky, jakou je např. tSNR či SNS, se panel vertikálně rozdělí na tři ortogonální řezy zrcadlící navigační panel vlevo, viz Obr. 4.4. Na obrazovku je tak promítnuta barevně kódovaná mapa vrstvená přesně přes souřadnice vybraného anatomického prostoru. Je-li ovšem vybrána některá z globálních metrik, ortogonální osy se skryjí

a panel se plynule transformuje v 2D graf vizualizující časový vývoj metrik napříč všemi načtenými daty. Tento blok rovněž obsahuje prvky pro definici uživatelských prahů, na jejichž změnu systém reaguje okamžitým překreslením výsledků.



Obr. 4.4: Náhled panelu pro kontrolu kvality


Spodní polovina okna analyzuje signál na úrovni konkrétních voxelů. Prostor je rozdělen do flexibilní mřížky grafů, která mapuje průběh intenzity voxelů v čase jak pro aktuálně vybraný bod (viz. Obr. 4.5), tak pro jeho bezprostřední anatomické okolí. Panel je zásadním nástrojem komparativní analýzy, neboť do jednoho grafu překrývá signálové křivky všech viditelných datasetů s využitím odlišných barev. Celý modul je opatřen kontextovými menu a možností interaktivního přesunu v čase jednoduchým kliknutím na vybraný bod časové řady.



Obr. 4.5: Náhled kompletního uživatelského rozhraní softwaru

4.2.2 Správa a načítání dat

Pro zajištění podmínek nutných ke komparativní analýze, jakou je typicky srovnání signálu před a po korekci pohybu, implementuje program centralizovaného správce dat. Tento modul se vyvolává jako samostatné vyskakovací okno pojmenované Options & Data Management a poskytuje přehledný nástroj pro nahrávání, pojmenovávání a organizaci vstupních souborů. Z pohledu paměťové architektury je systém dimenzován k souběžné správě až pěti rozsáhlých datových sad.



Obr. 4.6: Náhled správce dat jako vedlejšího okna

Během načítání nového souboru ve formátu NIfTI probíhá na pozadí sekvence bezpečnostních kroků. Pomocí funkcí z SPM softwaru je nejprve načtena hlavička obsahující afinní transformační matice a následně i samotná obrazová data. Systém v tomto kroku automaticky ověřuje prostorové dimenze. Vzhledem k tomu, že vizualizační algoritmy využívají sdílený souřadnicový systém nezbytný pro funkčnost

křížového kurzoru, musí se rozměry matice nově přidávaného souboru exaktně shodovat s daty, která již v paměti figurují. Pokud dojde k neshodě, proces nahrávání je z důvodu zachování datové integrity okamžitě přerušeno a uživatel je upozorněn chybovým hlášením.

Validní data jsou začleněna do sdíleného pole struktur a automaticky zviditelněna. Aby uživatel dokázal odlišit jednotlivé záznamy, je každé sadě přiřazena unikátní barva. Ta plní funkci identifikátoru a drží si svou konzistenci ve všech grafických i textových prvcích rozhraní.

Pro snazší navigaci a prevenci vizuálního zahlcení při práci s více soubory operuje správce dat s rozdělením na aktivní a viditelné datasety. Aktivní dataset, volený pomocí menu v levé části aplikace, určuje primární anatomická data zobrazená v hlavních ortogonálních řezech. Oproti tomu status viditelnosti lze pro každý dataset nezávisle konfigurovat zaškrtnutím polí přímo ve správci, viz Obr. 4.6. Tato funkce dává uživateli svobodu prohlížet anatomii jednoho konkrétního záznamu, zatímco si v grafech BOLD signálů, DVARS a FD ponechá vykreslené časové křivky z několika dalších měření pro posouzení odchylek v signálu.

Správce dat disponuje také logikou pro párování doplňkových souborů. Ke každému záznamu lze nezávisle připojit textový soubor obsahující prostorové translace a rotace vygenerované během korekce pohybu. Aplikace z nich okamžitě derivuje metriku Framewise Displacement. Rovněž lze nahrát anatomický atlas, ke kterému uživatel zadá cestu přes tlačítko. Systém jej načte a zcela automaticky provede jeho prostorové převzorkování tak, aby atlas naprosto přesně lícovал s referenční fMRI maticí načtených dat. Tento sjednocený pohled je následně aplikován na všechny načtené datasety pro výpočet metriky SNS, což eliminuje redundanci uživatelských kroků.

4.2.3 Prostorová vizualizace a mapování souřadnic

Vizualizace fMRI dat na dvojrozměrné ploše monitoru vychází ze zobrazení trojrozměrného objemu ve třech vzájemně ortogonálních anatomických rovinách. Vstupní fMRI data však mají obecně čtyřrozměrný charakter a lze je chápat jako prostorově-časové datové pole

$$\mathbf{Y} \in \mathbf{R}^{X \times Y \times Z \times T}, \quad (4.1)$$

kde první tři dimenze odpovídají prostorovým souřadnicím a čtvrtá dimenze reprezentuje čas. Pro aktuálně zvolený časový bod $t = \text{currentFrame}$ je z tohoto pole extrahován jeden trojrozměrný objem. Z tohoto objemu jsou následně získány tři řezy procházející aktuálně zvoleným bodem zájmu

$$\mathbf{P} = [x_{pos}, y_{pos}, z_{pos}]. \quad (4.2)$$

Jednotlivé anatomické roviny vznikají fixací jedné prostorové souřadnice. Sagitální řez je získán fixací souřadnice x_{pos} , čímž vzniká submatice o rozměrech $Y \times Z$. Koronální řez vzniká fixací souřadnice y_{pos} a má rozměry $X \times Z$. Axiální řez je tvořen fixací souřadnice z_{pos} , což vzniká submatice o rozměrech $X \times Y$.

Získané dvojrozměrné matice jsou převedeny do podoby vhodné pro zobrazení v grafickém rozhraní. Tento krok zahrnuje rotaci a zrcadlení, a je zcela nezbytný, protože výchozí orientace matic v prostředí MATLAB neodpovídá přímo běžným neurovizualizačním konvencím. V MATLABu je počátek obrazových souřadnic umístěn v levém horním rohu, zatímco při zobrazení medicínských dat je nutné zachovat správnou anatomickou orientaci. Aplikované transformace proto zajišťují, aby byly řezy zobrazovány konzistentně podle neurologické konvence, používané i v softwaru SPM. Tato konvence zachovává přirozenou orientaci, tedy levou hemisféru subjektu zobrazenou na levé straně obrazovky a pravou hemisféru na pravé straně, a odlišuje se od tradiční radiologické konvence používané v klinickém zobrazování, kde je orientace zrcadlově obrácená. V axiálním pohledu je přední část mozku orientována směrem nahoru.

Pro usnadnění prostorové orientace je v každém řezu vykreslen kříž, jehož průsečík odpovídá aktuálnímu bodu **P**. Uživatel tak může současně sledovat polohu vybraného voxelu ve všech třech anatomických rovinách. Tento bod zároveň slouží jako referenční poloha pro další analýzy, například zobrazení lokálního okolí voxelu nebo extrakci časového průběhu BOLD signálu.

Interaktivita rozhraní je zajištěna navázáním události kliknutí myši na zobrazované řezy. Po kliknutí do libovolné roviny aplikace nejprve odečte souřadnice kurzoru v rámci dané grafické osy. Protože zobrazené řezy byly před vykreslením rotovány nebo zrcadleny, následuje inverzní geometrický převod z obrazových souřadnic zpět do indexů původní 3D datové matice. Například při kliknutí do axiálního řezu jsou aktualizovány souřadnice x_{pos} a y_{pos} , zatímco souřadnice z_{pos} zůstává zachována.

Nově vypočtené indexy jsou následně omezeny na platný rozsah vstupní matice,

$$1 \leq x_{pos} \leq X, 1 \leq y_{pos} \leq Y \text{ a } 1 \leq z_{pos} \leq Z, \quad (4.3)$$

Tím je zajištěno, že ani při kliknutí mimo oblast mozku nebo mimo hranice zobrazeného řezu nedojde k chybě typu překročení rozsahu indexů. Po ověření platnosti nové polohy je zavolána centrální aktualizací funkce `update_all()`, která synchronizuje celé rozhraní. Tato funkce aktualizuje polohu křížů, indikační oblast lokálního okolí pro analýzu BOLD signálu a všechny navázané prostorové mapy metrik kvality. Díky tomu zůstávají všechny vizualizační panely vzájemně konzistentní a uživatel může plynule procházet daty v prostoru i čase.


Kromě navigace v prostoru platí analogické principy i pro navigaci v čase. Ke změně aktuálního časového snímku dochází prostřednictvím krokovacích tlačítek,

modifikací hodnoty v textovém poli nebo přímou interakcí s grafy. Tato akce okamžitě mění hloubku, v níž jsou řezy extrahovány ze čtvrté dimenze matice. Změna se současně promítá do grafů globálních metrik v podobě červené vertikální indikační linie. Posun tohoto časového kurzoru dává uživateli okamžitou zpětnou vazbu o vztahu mezi pozorovaným prostorovým jevem a jeho polohou v časovém průběhu celého měření.

4.2.4 Analýza BOLD signálu

Analýza časového průběhu BOLD signálu představuje důležitý nástroj pro detailní hodnocení fMRI dat na úrovni jednotlivých voxelů. Zatímco prostorové řezy umožňují posoudit anatomickou lokalizaci a rozložení signálu v obraze, časové křivky poskytují informaci o dynamice signálu v konkrétním místě mozku. Tento typ zobrazení je proto vhodný nejen pro sledování možných funkčních změn, ale také pro identifikaci artefaktů, náhlých výkyvů nebo nestability signálu v čase.

Pro tento účel je ve spodní části uživatelského rozhraní vyhrazen samostatný blok pro vykreslování časových řad. Základní zobrazení obsahuje časový průběh signálu v aktuálně zvoleném voxelu, přičemž uživatel může zobrazení rozšířit také na jeho lokální okolí o velikosti 3×3 nebo 5×5 voxelů, viz Obr. 4.7. Díky tomu lze sledovat, zda je pozorovaná změna signálu přítomna pouze v jednom voxelu, nebo zda se vyskytuje i v jeho okolí, což je důležité při rozlišování lokálního artefaktu od prostorově konzistentního jevu.



Obr. 4.7: Ukázka BOLD grafů s rozložením 3x3

Při každé změně prostorové souřadnice $\mathbf{P}$ aplikace extrahuje z datové matice časovou řadu odpovídající vybranému voxelu, případně voxelům v jeho definovaném okolí. Pro každý platný voxel je získán jednorozměrný vektor

$$\mathbf{v} \in \mathbf{R}^T, \quad (4.4)$$


kde $\mathbf{T}$ označuje počet časových snímků. Algoritmus zároveň kontroluje hraniční podmínky, aby bylo možné bezpečně pracovat i se souřadnicemi nacházejícími se v blízkosti okrajů datové matice. Pokud by část zvoleného okolí přesahovala rozměry dat, jsou tyto voxely automaticky vynechány, čímž se předchází chybám při indexování. Důležitou funkcí tohoto modulu je možnost přímého vizuálního porovnání více datových sad. Aplikace pro stejnou prostorovou souřadnici načte časové řady ze všech aktuálně dostupných a viditelných datasetů a vykreslí je do společné grafické osy. Uživatel tak může bez přepínání mezi okny porovnat například průběh signálu v surových datech a v datech po jednotlivých krocích předzpracování. Tento způsob zobrazení je užitečný zejména při hodnocení vlivu korekce pohybu, vyhlazení nebo jiných preprocessingových kroků na charakter časového signálu.

Při porovnávání BOLD signálu je nutné zohlednit skutečnost, že absolutní intenzita signálu v MR obraze sama o sobě nenese přímou funkční informaci. Je ovlivněna řadou faktorů, například typem tkáně (šedá hmota má jinou bazální intenzitu než bílá hmota), nastavením přijímacích cívek, parametry EPI sekvence nebo celkovou intenzitní škálou daného datasetu [4]. Přímé porovnávání časových průběhů z různých datasetů proto může být obtížné, pokud se jejich bazální intenzita výrazně liší. Proto se fMRI obvykle interpretuje na základě relativních změn signálu v čase. Z tohoto důvodu byla do nastavení aplikace zařazena volba Subtract mean. Po její aktivaci je na každou extrahovanou časovou řadu před vykreslením aplikováno centrování odečtením střední hodnoty:


$$\mathbf{v}_{centered} = \mathbf{v} - \bar{v}, \quad (4.5)$$

kde $\bar{v}$ představuje průměrnou hodnotu dané časové řady. Výsledkem je vertikální zarovnání všech křivek kolem nulové osy, viz Obr. 4.8. Tím jsou potlačeny rozdíly v absolutní intenzitě signálu a zvýrazněna je především relativní časová dynamika, tedy fluktuace, špičky a lokální rozptyl signálu. Takové zobrazení je vhodné jak pro hodnocení možných BOLD změn, tak pro detekci artefaktů. Je důležité poznamenat, že tato operace je čistě vizualizační – původní data uložená v paměti aplikace nejsou modifikována.

Propojení časové a prostorové vizualizace je dále zajištěno pomocí interaktivního časového kurzoru. Pokud uživatel klikne pravým tlačítkem myši do grafu, zobrazí se mu kontextové menu, které nabízí přechod na konkrétní bod nebo výraznou špičku v časové křivce, viz Obr. 4.9. Aplikace automaticky nastaví odpovídající časový snímek jako aktuální. Tím je možné ihned zobrazit příslušný 3D objekt v anatomických řezech a posoudit, zda pozorovaná změna odpovídá lokálnímu signálu, pohybovému artefaktu nebo jiné technické odchylce.



Obr. 4.8: Ukázka BOLD grafů po odečtení střední hodnoty



Obr. 4.9: Ukázka možností kontextového menu

4.3 Implementace metrik kvality dat

Tato kapitola se věnuje výpočetní vrstvě aplikace. Popisuje výběr indikátorů kvality obrazu, matematický návrh algoritmů a implementační detaily, pomocí nichž jsou tyto metriky derivovány z obrazových matic.

4.3.1 Výběr metrik pro implementaci

Pro komplexní zhodnocení kvality fMRI dat nelze spoléhat pouze na jediný indikátor. Artefakty mohou mít povahu prostorovou – např. ztráta signálu v oblastech s vysokou magnetickou susceptibilitou, nebo časovou – typicky způsobenou náhlým pohybem pacienta během měření. Z metrik popsanych v teoretické části práce

v kap. 3.2 byla proto pro implementaci vybrána skupina šesti indikátorů pokrývajících obě dimenze.

Pro hodnocení globální časové stability byly zvoleny metriky FD a DVARS. Zatímco FD kvantifikuje primární fyzikální příčinu problému, tedy mechanický pohyb hlavy mezi po sobě jdoucími časovými snímky, DVARS měří bezprostřední dopad těchto změn na intenzitu BOLD signálu napříč celým mozkem [11]. Oba indikátory se tak vzájemně doplňují: FD identifikuje, kdy k pohybu došlo, zatímco DVARS ukazuje, jak výrazně se tento pohyb nebo jiný artefakt projevil v obrazových datech. Pro rychlou vizuální inspekci velkého množství voxelových časových řad současně byl implementován Carpet plot, který umožňuje kompaktně zobrazit změny intenzity signálu v čase a usnadňuje detekci globálních artefaktů, například pohybových vlivů nebo systematických technických chyb [46].

K posouzení prostorové kvality signálu byla implementována metrika tSNR. Pro pokročilejší zhodnocení toho, zda v datech převažuje užitečný signál funkčních sítí nad fyziologickým šumem, byla integrována metrika SNS. Finálním prvkem je navržená mapa problematických voxelů, označovaná dále jako QC mapa. Jejím účelem je spojit výsledky prostorových metrik tSNR a SNS do jediného vizuálního výstupu, který uživatele okamžitě upozorní na oblasti s potenciálně sníženou kvalitou dat.

Vedle uvedených metrik nástroj poskytuje také vizualizaci binární masky mozku, která v kontextu kontroly kvality plní dvě funkce. První z nich je diagnostická: maska umožňuje rychle posoudit, které oblasti mozku jsou pokryty signálem s dostatečnou intenzitou. Díky tomu lze odhalit například rozsáhlejší výpadky signálu způsobené susceptibilitními artefakty, neúplným pokrytím mozku nebo neoptimálním umístěním hlavy v zorném poli skeneru. Druhá funkce je výpočetní, protože maska slouží k oddělení mozkových voxelů od pozadí a je následně využívána při výpočtu dalších metrik kvality. Detailní popis konstrukce masky je uveden v následující kapitole 4.3.2.

4.3.2 Vytvoření masky mozku

Před zahájením výpočtů metrik je nezbytné oddělit oblast mozku od šumu pozadí. Použití binární masky mozku patří mezi běžné kroky při zpracování fMRI dat, protože umožňuje omezit výpočty pouze na voxely relevantní pro analýzu a současně snižuje vliv šumu mimo oblast hlavy [54, 53]. Iterování výpočetních funkcí přes prázdný prostor za hranicemi hlavy by zbytečně prodlužovalo výpočetní čas, proto software automaticky vytváří binární masku mozku. Ze čtyřrozměrné matice obrazových dat je nejprve sestavena dvourozměrná matice spojující prostorovou a časovou dimenzi. Nechť $V = X \times Y \times Z$ je celkový počet prostorových voxelů a T je počet časových snímků. Intenzitu i -tého voxelu v čase t pak označíme jako $y_{i,t}$. Pro každý

časový snímek t je nejprve vypočítána průměrná globální intenzita celého objemu μ_t :

$$\mu_t = \frac{1}{V} \sum_{i=1}^V y_{i,t} \quad (4.6)$$

Voxel je následně klasifikován jako součást mozku pouze tehdy, pokud jeho intenzita překračuje uživatelsky definovaný práh θ relativně k celoobjemové střední hodnotě ve všech časových bodech měření. Výchozí hodnota prahu je 10 %, tedy $\theta = 0,10$. Tento postup vychází z principu intenzitního prahování, které je běžně využíváno pro orientační oddělení mozkové tkáně od pozadí ve funkčních MRI datech [53]. Binární příslušnost jednotlivých voxelů k masce je formálně definována jako:

$$M_i = \begin{cases} 1, & \text{pokud } \forall t \in \{1, \dots, T\} : y_{i,t} > \theta \cdot \mu_t \\ 0, & \text{jinak} \end{cases} \quad (4.7)$$

kde $M_i \in \{0, 1\}$ označuje hodnotu masky pro i -tý voxel. Tímto postupem vznikne binární vektor $\mathbf{M} \in \{0, 1\}^V$, který je následně převeden zpět do původního prostorového uspořádání a uložen jako trojrozměrná binární maska o rozměrech $X \times Y \times Z$.

Tato striktní podmínka platnosti průniku přes všechny časové body zajišťuje, že voxely postižené přechodným výpadkem signálu (např. vlivem pohybového artefaktu) jsou z masky automaticky vyloučeny. Tímto přístupem se zvyšuje robustnost masky vůči artefaktům. Výsledná trojrozměrná binární maska se využívá při výpočtech globálních metrik.

Pro metriku SNS je generována mírně odlišná varianta masky, založená na průměrné intenzitě voxelů napříč časem namísto dynamického prahování pro každý časový bod. SNS pracuje s korelacemi časových řad a vyžaduje stabilní prostorové vymezení mozku a pozadí. Dynamická maska by mohla do výpočtu zanášet změny způsobené okamžitými fluktuacemi signálu, což by zhoršilo interpretaci korelační mapy.

4.3.3 Implementace časových metrik

Časové metriky redukuji objem fMRI dat do jednoduchých jednorozměrných křivek, z nichž lze okamžitě posoudit přítomnost pohybových artefaktů.

Framewise Displacement (FD)

Metrika FD slouží k detekci mikropohybů hlavy mezi po sobě jdoucími časovými snímky. Aplikace ji nepočítá přímo z obrazu, ale ze standardizovaného souboru parametrů pohybu generovaného během kroku prostorového zarovnání. Tento soubor obsahuje šest parametrů rigidní transformace – tři translace a tři rotace. Výpočetní algoritmus nejprve určí časové difference každého z těchto parametrů (např.

$\Delta x_t = x_t - x_{t-1}$). Aby bylo možné rotační a translační složky sečíst do jediného indikátoru, jsou hodnoty rotací v radiánech převedeny na milimetry za použití standardní aproximace hlavy jako sféry o poloměru $r = 50$ mm. Výsledná hodnota FD pro každý časový bod odpovídá součtu absolutních hodnot všech šesti diferencí viz rovnice 3.1. Časové body překračující hranici 0,5 mm jsou v grafickém výstupu vizuálně označeny jako potenciálně problematické. [11]

DVARS

Na rozdíl od FD detekuje metrika DVARS globální změny přímo v intenzitě signálu. Jedná se o střední kvadratickou odchylku časové derivace BOLD signálu, která zachycuje jak velká je okamžitá změna intenzity napříč celým mozkem mezi dvěma po sobě jdoucími snímky. V implementaci jsou fMRI data nejprve prostorově redukována binární maskou mozku. Pro každý validní voxel se spočítá difference signálu mezi snímkem t a snímkem $t - 1$. Z těchto rozdílů algoritmus vypočítá kvadráty, určí jejich střední hodnotu a výsledek odmocní, viz rovnice 3.3. DVARS tak doplňuje FD tím, že nezachycuje pouze samotný pohyb hlavy, ale především jeho důsledky v obrazových datech. [11]

Carpet plot

Pro komplexní zobrazení časového vývoje signálu napříč celým mozkem byl implementován Carpet plot. Tento typ vizualizace představuje kompaktní zobrazení velkého množství voxelových časových řad v jedné dvourozměrné mapě, kde jedna osa odpovídá voxelům a druhá časovým snímkům. Ze čtyřrozměrné datové matice jsou extrahovány voxely spadající do masky mozku. Nechť $y_i(t)$ reprezentuje časovou řadu i -tého voxelu. Každá tato řada je nejprve podrobena odstranění střední hodnoty a lineárního trendu pomocí funkce `spm_detrend()`, čímž vznikne centrovaná řada $\tilde{y}_i(t)$. Ta je posléze normalizována dělením vlastní směrodatnou odchylkou σ_i (tzv. Z-score normalizace):

$$z_{i,t} = \frac{\tilde{y}_i(t)}{\sigma_i} \quad (4.8)$$

Tímto krokem je amplituda signálu sjednocena napříč všemi voxely, což zabraňuje situaci, kdy by voxely s přirozeně vyšší variabilitou vizuálně dominovaly celé mapě. Normalizované voxely z_i jsou následně seřazeny na vertikální ose podle průměrné počáteční intenzity, která může přibližně odrážet různé anatomické kompartmenty. Výsledná mapa o rozměrech $N_{\text{voxelů}} \times T$ umožňuje rychle identifikovat globální artefakty, které se projevují jako svislé pruhy narušující jinak rovnoměrný průběh signálu. [46]

4.3.4 Implementace prostorových metrik

Zatímco časové metriky umožňují určit, kdy se v datech objevil problém, prostorové metriky pomáhají lokalizovat, kde v anatomii mozku signál selhává nebo nedosahuje požadované kvality. V této práci byly implementovány zejména mapy tSNR a SNS, které umožňují posoudit prostorové rozložení stability a použitelnosti BOLD signálu [39, 55].

Temporal Signal-to-Noise Ratio (tSNR)

Výpočet tSNR představuje voxelovou analýzu časové stability signálu. Pro každý i -tý voxel trojrozměrné matice se vypočítá podíl jeho průměrné intenzity napříč časem μ_i a jeho směrodatné odchylky σ_i . tSNR je běžně používaným ukazatelem citlivosti fMRI akvizice, protože odráží, do jaké míry je časová řada ovlivněna tepelným a fyziologickým šumem [55]. Signál fMRI skeneru však často vykazuje nízkofrekvenční drift, který by směrodatnou odchylku uměle navýšil a hodnotu tSNR znehodnotil. Před samotným výpočtem je proto čtyřrozměrná matice převedena do dvojrozměrného tvaru a podrobena detrendingu. Nechť $y_{i,t}$ reprezentuje původní intenzitu voxelu v čase t a $\tilde{y}_{i,t}$ jeho intenzitu po odstranění lineárního trendu. Hodnota $tSNR_i$ je formálně definována jako:

$$tSNR_i = \frac{\mu_i}{\sigma_i} = \frac{\frac{1}{T} \sum_{t=1}^T y_{i,t}}{\sqrt{\frac{1}{T-1} \sum_{t=1}^T (\tilde{y}_{i,t} - \bar{\tilde{y}}_i)^2}} \quad (4.9)$$

Použití původní střední hodnoty v čitateli zachovává bazální intenzitu tkáně, zatímco detrendovaná směrodatná odchylka ve jmenovateli lépe reprezentuje časovou nestabilitu signálu po odstranění pomalého driftu. Mapy tSNR jsou proto vhodné pro prostorovou identifikaci oblastí se sníženou stabilitou signálu, například v důsledku fyziologického šumu nebo susceptibilních výpadků [55].

Při vykreslování tSNR mapy představuje specifický problém vizuální saturace. Některé voxely mohou nabývat extrémně vysokých hodnot tSNR, což by při klasickém lineárním zobrazení vedlo ke snížení kontrastu ve zbytku mozku. Nástroj proto před zobrazením mapy dynamicky určí 99. percentil platných hodnot a barevnou osu omezí tímto maximem. Tím je zajištěn konzistentní vizuální kontrast nezávisle na konkrétním datasetu.

Signal-to-Noise Separation (SNS)

Metrika SNS byla navržena jako ukazatel separace mezi časovými korelacemi odpovídajícími funkčním mozkovým sítím a korelacemi spojenými se šumem [39]. V této práci je implementována jako prostorová mapa, která porovnává míru korelace časové řady každého voxelu s referenčními časovými průběhy odvozenými z atlasových

oblastí zájmu a s referenčními časovými průběhy šumu odebranými z pozadí mimo mozek.

Načtený anatomický nebo funkční atlas poskytuje prostorovou definici K oblastí zájmu (ROI). V implementaci odpovídá K počtu nenulových atlasových oblastí, tedy unikátních hodnot atlasu po vyloučení pozadí a hodnot NaN. Z detrendovaných dat je pro každou oblast odvozena reprezentativní referenční časová řada $\mathbf{c}_k$ ($k \in \{1, \dots, K\}$), která vzniká zprůměrováním časových řad voxelů náležících do dané oblasti. Paralelně je z oblasti mimo masku mozku vyčleněn náhodný vzorek M voxelů pozadí. Z každého z těchto voxelů je získána jedna referenční časová řada šumu $\mathbf{n}_j$ ($j \in \{1, \dots, M\}$). V implementaci je počet šumových referencí omezen hodnotou

$$M = \min(1000, M_{\text{bg}}), \quad (4.10)$$

kde M_{bg} označuje celkový počet voxelů dostupných v oblasti pozadí. Toto omezení snižuje výpočetní náročnost a zároveň poskytuje dostatečně velký vzorek referenčních šumových průběhů.

Tento princip vychází z předpokladu, že kvalitní fMRI data by měla vykazovat vyšší podobnost s časovými průběhy odvozenými z mozkových oblastí než s časovými průběhy získanými z pozadí mimo mozek [39]. Prostřednictvím Pearsonova korelačního koeficientu r je zkoumaná časová řada i -tého voxelu $\mathbf{v}_i$ korelována s oběma referenčními sadami. Výsledná hodnota SNS_i je definována jako podíl průměrné absolutní korelace s atlasovými referencemi a průměrné absolutní korelace se šumovými referencemi:

$$SNS_i = \frac{\frac{1}{K} \sum_{k=1}^K |r(\mathbf{v}_i, \mathbf{c}_k)|}{\max\left(\frac{1}{M} \sum_{j=1}^M |r(\mathbf{v}_i, \mathbf{n}_j)|, \varepsilon\right)}. \quad (4.11)$$

Člen ε představuje malou kladnou konstantu zavedenou z numerických důvodů, aby nedošlo k dělení nulou nebo extrémně malou hodnotou v případě velmi nízké korelace voxelové časové řady se šumovými referencemi.

Voxely s hodnotou $SNS_i > 1$ vykazují podle této definice vyšší průměrnou podobnost s atlasově definovanými referenčními časovými řadami než s referenčními průběhy šumu. Takové voxely lze interpretovat jako oblasti s příznivější separací signálové a šumové složky. Nízké hodnoty SNS naopak mohou upozorňovat na oblasti, jejichž časový průběh je méně podobný atlasovým referencím nebo relativně více podobný šumovým průběhům.

Hodnoty SNS je však nutné interpretovat jako relativní ukazatel závislý na použité masce, atlasu, výběru šumových referencí a předzpracování dat. Zejména velmi vysoké hodnoty mohou vzniknout také v situaci, kdy je korelace se šumovými referencemi velmi nízká, a proto nemusí samy o sobě představovat jednoznačný důkaz vysoké kvality signálu.

QC mapa

Pro rychlou a přehlednou vizualizaci byla v rámci této práce navržena QC mapa, která průběžně kombinuje výsledky metrik tSNR a SNS. Algoritmus vyhodnocuje každý voxel datové matice s přihlédnutím k jeho příslušnosti k masce mozku, což je reprezentováno proměnnou $M_i \in \{0, 1\}$. Na základě uživatelsky definovaných prahů θ_{tSNR} a θ_{SNS} je následně každý voxel klasifikován do jedné z pěti vizuálních tříd. Matematicky lze výslednou třídu Q_i pro i -tý voxel popsat následující logickou strukturou:

$$Q_i = \begin{cases} \text{Pozadí,} & M_i = 0, \\ \text{OK,} & M_i = 1 \wedge tSNR_i \geq \theta_{tSNR} \wedge SNS_i \geq \theta_{SNS}, \\ \text{Nízké tSNR,} & M_i = 1 \wedge tSNR_i < \theta_{tSNR} \wedge SNS_i \geq \theta_{SNS}, \\ \text{Nízké SNS,} & M_i = 1 \wedge tSNR_i \geq \theta_{tSNR} \wedge SNS_i < \theta_{SNS}, \\ \text{Nízké tSNR i SNS,} & M_i = 1 \wedge tSNR_i < \theta_{tSNR} \wedge SNS_i < \theta_{SNS}. \end{cases} \quad (4.12)$$

Z této rovnice vyplývá hierarchický přístup klasifikace. Nejdříve jsou vyřazeny voxely pozadí, které se ve vizualizační vrstvě vykreslují jako černé. Zbylé voxely uvnitř masky mozku jsou rozřazeny do čtyř kvalitativních kategorií. Voxely splňující obě nastavená kritéria jsou označeny jako validní a jsou vizualizovány neutrální šedou barvou. Voxely s nedostatečným tSNR – vyskytující se typicky v oblastech s vysokou magnetickou susceptibilitou, jako jsou lebeční dutiny – tvoří druhou kategorii značenou žlutou barvou. Třetí kategorii představují voxely s dostatečným tSNR, jejichž signál však dle metriky SNS koreluje spíše se šumem než s funkčními sítěmi mozku, ty jsou označeny oranžovou barvou. Čtvrtou kategorii tvoří voxely, které nesplnily ani jedno z kritérií, a jsou označeny červenou barvou.

Mapa se automaticky přepočítává okamžitě při změně kteréhokoliv z prahů (θ_{tSNR} , θ_{SNS}), ale též při úpravě limitu pro samotnou detekci mozkové tkáně (masky). To poskytuje uživateli přímou vizuální zpětnou vazbu o tom, jak se nově zahrnuté či vyloučené hraniční voxely chovají z hlediska stability signálu, a ukazuje reálný dopad nastavených kritérií na prostorový rozsah problematických oblastí.

5 Testování nástroje

Tato kapitola dokumentuje testování funkčnosti vyvinutého vizualizačního nástroje na reálných fMRI datech poskytnutých laboratoří MAFIL CEITEC MU. Cílem testování bylo prakticky ověřit, zda nástroj dokáže identifikovat data se sníženou kvalitou, zvýraznit problematické voxely a časové body, umožnit detailní inspekci naměřených dat v jednotlivých místech a porovnat kvalitu dat v závislosti na provedeném měření i zpracování.

5.1 Testovací data

Testovací data pocházejí ze dvou výzkumných projektů realizovaných v laboratoři MAFIL CEITEC MU. První skupinu tvoří data čtyř subjektů z blokového řečového experimentu, dostupná ve čtyřech variantách zpracování – surová data, data po prostorové normalizaci do MNI prostoru (předpona w), data po dodatečné korekci pohybu (předpona wr) a data po finálním prostorovém vyhlazení (předpona swr). Tato datová sada umožňuje současně testovat dopad jednotlivých kroků preprocessingové pipeline na kvalitu dat a porovnávat subjekty s různou úrovní pohybu během akvizice. Druhou skupinu představují multi-echo data z odlišného projektu, která obsahují výrazný technický artefakt, jehož charakter odpovídá možnému elektromagnetickému rušení. Pro výpočet metriky SNS, která vyžaduje data v MNI prostoru, byl použit standardní atlas AAL (Automated Anatomical Labeling) [57]. Tento atlas rozděluje mozek na 116 anatomicky definovaných oblastí.

5.2 Metodika testování

Testování bylo strukturováno do čtyř komplementárních scénářů, z nichž každý se zaměřuje na specifický typ situace, se kterou se uživatel může v rámci kontroly kvality fMRI dat setkat. První scénář ověřuje schopnost nástroje detekovat změny v kvalitě dat napříč jednotlivými kroky standardní preprocessingové pipeline. Druhý scénář testuje identifikaci pohybových artefaktů a rozlišení subjektů s nízkou a vysokou mírou pohybu. Třetí scénář se zaměřuje na chování nástroje při technickém artefaktu na multi-echo datech, kde umožňuje současně testovat citlivost metrik na pokles signálu napříč echo. Čtvrtý scénář demonstruje specifickou metriku SNS, která vyžaduje samostatné testovací prostředí kvůli své závislosti na atlasu v MNI prostoru.

Pro získání numerických hodnot metrik kvality byl do nástroje implementována funkce, která pro každý načtený dataset vypisuje souhrnnou statistiku obsahující

průměr, medián a směrodatnou odchylku metriky tSNR a SNS v masce mozku, maximální a průměrnou hodnotu metriky DVARs, statistiky metriky FD včetně počtu snímků překračujících konvenční práh 0,5 mm a velikost mozkové masky vyjádřenou počtem voxelů. Tyto numerické výstupy doplňují vizuální dokumentaci v podobě obrazových snímků uživatelského rozhraní a tvoří základ pro kvantitativní hodnocení v následujících podkapitolách.

5.3 Vliv preprocessingu na kvalitu dat

Cílem prvního testovacího scénáře bylo ověřit schopnost nástroje detekovat změny v kvalitě dat napříč jednotlivými kroky standardní preprocessingové pipeline. Pro testování byly vybrány dva subjekty (sub1, sub2) charakterizované nízkým pohybem, u nichž byly k dispozici kromě surových dat (*raw*) další tři varianty zpracování: data po prostorové normalizaci do MNI prostoru (*w*), data po dodatečné korekci pohybu (*wr*) a data po finálním prostorovém vyhlazení (*swr*).

Vzhledem k tomu, že prostorová normalizace mění rozměry datové matice (přesun do MNI prostoru s odlišným prostorovým rozlišením), nelze surová data a normalizovaná data zobrazit současně v jednom okně aplikace. Porovnání bylo proto provedeno prostřednictvím statistických výstupů exportovaných z nástroje a doplňkových screenshotů pro každou variantu samostatně.

5.3.1 Interpretace výsledků

Tabulky 5.1 a 5.2 shrnují hodnoty implementovaných metrik pro oba subjekty napříč všemi variantami zpracování.

Tab. 5.1: Souhrn intenzitních metrik kvality pro jednotlivé varianty zpracování

Subjekt	Variant	Velikost masky	Průměrné tSNR	Medián tSNR	Max DVARs
sub1	raw	55 448	55,44	52,86	396,74
sub1	w	72 188	64,07	60,79	324,67
sub1	wr	72 737	78,11	76,98	310,31
sub1	swr	77 023	177,89	166,95	150,29
sub2	raw	60 768	39,02	33,05	535,25
sub2	w	72 313	45,34	39,24	483,28
sub2	wr	73 336	59,49	58,12	418,20
sub2	swr	79 711	127,10	122,33	231,20


Hodnoty metrik pro surová data jsou v tabulce 5.1 uvedeny pouze pro orientační srovnání, protože jejich přímé porovnání s normalizovanými variantami je ovlivněno

změnou prostorové mřížky, převzorkováním do MNI prostoru a rozdílným rozsahem výsledné masky. Prostorová normalizace primárně mění prostorové uspořádání dat a jejich referenční rámec; změny intenzitních metrik je proto nutné interpretovat opatrně, zejména s ohledem na interpolaci a změnu prostorového rozlišení. Následující interpretace se proto soustředí především na porovnání variant w , wr a swr , které jsou již zobrazeny ve stejném prostorovém referenčním rámci.

Mezi variantami w a wr dochází u obou subjektů k nárůstu průměrného i mediánového tSNR. U subjektu 1 se průměrné tSNR zvýšilo z 64,07 na 78,11 a u subjektu 2 z 45,34 na 59,49. Tento nárůst je v souladu s očekávaným vlivem korekce pohybu, která může snížit část časové variability způsobené změnou polohy hlavy během akvizice. Současně je však třeba zohlednit, že realignment zahrnuje také prostorové transformace a interpolaci dat, takže pozorovanou změnu nelze interpretovat výhradně jako odstranění pohybového artefaktu.


Mezi variantami wr a swr je patrný výrazně větší nárůst tSNR. U subjektu 1 se průměrné tSNR zvýšilo přibližně 2,3krát a u subjektu 2 přibližně 2,1krát. Tento efekt odpovídá očekávanému vlivu prostorového vyhlazení, při němž Gaussovský filtr kombinuje hodnoty sousedních voxelů a potlačuje lokální vysokofrekvenční šum [56]. Vyšší tSNR po vyhlazení proto nelze chápat pouze jako zlepšení kvality dat v užším smyslu, ale také jako důsledek změny prostorových vlastností obrazu a snížení lokální variability signálu.

Vizuální srovnání tSNR map mezi variantami w a swr na Obr. 5.1 tento trend podporuje. Po vyhlazení je patrný nárůst hodnot tSNR a současně prostorová homogenizace mapy. Rozložení hodnot je méně lokálně proměnlivé a přechody mezi sousedními oblastmi jsou plynulejší. Tento výsledek je konzistentní s účinkem prostorového vyhlazení, zároveň však upozorňuje na to, že absolutní hodnoty tSNR mezi různými variantami zpracování je nutné interpretovat s ohledem na použité preprocessingové kroky.



Obr. 5.1: Porovnání tSNR map před a po prostorovém vyhlazení

Současně s nárůstem tSNR je napříč variantami zpracování patrný pokles hodnot metriky DVARS. U subjektu 1 se maximální hodnota DVARS snížila z 324,7 u varianty *w* na 150,3 u varianty *swr*, u subjektu 2 pak z 483,3 na 231,2. Tento pokles ukazuje, že po jednotlivých krocích zpracování jsou rozdíly obrazových intenzit mezi po sobě jdoucími snímky menší. Ke snížení DVARS může přispívat korekce pohybu, která omezuje změny způsobené posunem hlavy mezi snímky, ale také prostorové vyhlazení. Vyhlazení potlačuje lokální vysokofrekvenční fluktuace a snižuje rozdíly mezi sousedními voxely, což se může projevit poklesem DVARS i bez úplného odstranění původního artefaktu.



Obr. 5.2: Porovnání průběhu metriky DVARS u subjektu 2 pro varianty *w*, *wr* a *swr*


Obr. 5.2 zobrazuje DVARS křivky pro tři varianty zpracování subjektu 2 vykreslené v jednom okně. Křivky variant *w* a *wr* mají podobný průběh i amplitudu, zatímco po vyhlazení, tedy u varianty *swr*, je celková úroveň DVARS výrazně nižší. Tento výsledek je v souladu s očekávaným účinkem prostorového vyhlazení, nikoli však nutně s úplným odstraněním artefaktů. Pokles DVARS po vyhlazení je proto vhodné chápat spíše jako důsledek snížení lokální variability obrazových intenzit než jako samostatný důkaz vyšší kvality dat.

Tab. 5.2: Pohybové metriky po kroku korekce pohybu

Subjekt	Varianta	Max FD [mm]	FD > 0,5 mm
sub1	wr	0,249	0
sub1	swr	0,249	0
sub2	wr	0,660	2
sub2	swr	0,660	2

Hodnoty FD v Tab.5.2 potvrzují, že u subjektu 1 nebyl detekován pohyb překračující konvenční práh 0,5 mm [11]. U subjektu 2 byly detekovány dva snímky

s pohybem nad tímto prahem (maximální hodnota 0,660 mm), viz Obr. 5.3, na kterém lze vidět jen křivku po prostorovém vyhlazení, neboť křivky kopírují svůj průběh. Tento pohybový artefakt je viditelný i v DVARS křivce jako lokální špička přibližně kolem snímku 56, který označuje červená svislá linie na Obr. 5.2.




Obr. 5.3: FD křivky po korekci pohybu a vyhlazení

Růst velikosti masky mozku napříč pipeline (např. u subjektu 1 z 55 448 na 77 023 voxelů) je primárně způsoben změnou prostorového rozlišení při normalizaci do MNI prostoru a sekundárně rozšířením signálu při vyhlazení. Prahová hodnota masky byla nastavena na hodnotu 0,5.

5.3.2 Carpet plot

Srovnání carpet plotu surových a finálně zpracovaných dat na Obr. 5.4 ukazuje změnu charakteru časoprostorového průběhu signálu po preprocessingu. U surových dat je patrná výraznější lokální variabilita intenzit a nepravidelná textura napříč voxely i časovými snímky. Viditelné horizontální rozdíly mezi řádky odrážejí rozdílnou úroveň signálu v jednotlivých voxelech nebo skupinách voxelů.

Po finálním zpracování je carpet plot vizuálně homogennější a lokální vysoko-frekvenční variabilita je méně výrazná, což je v souladu s účinkem prostorového vyhlazení a dalších preprocessingových kroků. Současně jsou patrné opakující se vertikální změny intenzity napříč větším počtem voxelů. Tyto změny mohou souviset s časovou strukturou experimentu, například s blokovým designem řečového úkolu, jejich přesnou interpretaci by však bylo nutné ověřit porovnáním s časováním stimulace.



Obr. 5.4: Porovnání carpet plotu pro surová data (nahore) a data po kompletním zpracování (dole).

5.4 Detekce pohybových artefaktů

Druhý testovací scénář byl zaměřen na ověření schopnosti nástroje identifikovat snímky postižené pohybovými artefakty a vizuálně i kvantitativně rozlišit subjekty s nízkou a vysokou mírou pohybu. Pro testování byly použity datové sady čtyř subjektů: sub1 a sub2 charakterizované nízkým pohybem (kontrolní skupina) a sub4 a sub10 s výrazným pohybem během akvizice. Všechny datasety byly načteny ve variantě *wr* po prostorové normalizaci a korekci pohybu, bez vyhlazení.

5.4.1 Interpretace výsledků


Tabulka 5.3 shrnuje hodnoty metriky Framewise Displacement (FD) získané z odpovídajících souborů parametrů pohybu pro všechny čtyři subjekty.

Z tabulky je patrný výrazný rozdíl v rozsahu pohybu mezi jednotlivými subjekty. Subjekty 1 a 2 vykazují nízké průměrné hodnoty FD, které nepřesahují 0,15 mm. U subjektu 1 nebylo zaznamenáno žádné překročení prahu 0,5 mm, zatímco u subjektu 2 se tento práh objevil pouze ve dvou snímcích. Tyto hodnoty odpovídají datasetům s nízkou mírou pohybu.

Tab. 5.3: Souhrn hodnot metriky FD u testovaných subjektů

Subjekt	Průměrné FD [mm]	Max FD [mm]	FD > 0,5 mm	Charakteristika
sub1	0,114	0,249	0	nízký pohyb
sub2	0,139	0,660	2	nízký pohyb
sub4	0,544	6,261	72	vysoký pohyb
sub10	0,465	1,664	95	vysoký pohyb

Naproti tomu u subjektů 4 a 10 je patrný podstatně vyšší rozsah pohybu. Subjekt 4 dosahuje maximální hodnoty FD 6,261 mm, tedy více než dvanásobnou často používaného prahu 0,5 mm [11], a celkem 72 snímků této akvizice tento práh překračuje. U subjektu 10 byl práh 0,5 mm překročen dokonce v 95 snímcích z celkového počtu 230. Na základě těchto hodnot byly subjekty 4 a 10 zařazeny do skupiny s vysokou mírou pohybu.




Obr. 5.5: Porovnání křivek FD (nahore) a DVARS (dole) v datech s výrazným pohybem.

Obr. 5.5 zobrazuje průběh metrik FD a DVARS u subjektu 4. V průběhu FD je patrná výrazná pohybová špička s maximální hodnotou 6,26 mm přibližně ve snímku 38. Ve stejném časovém úseku se objevuje také dominantní špička v metrice DVARS, jejíž hodnota přesahuje 1400 RMS. Časová shoda těchto dvou metrik naznačuje, že

výrazná změna polohy hlavy byla doprovázena náhlou změnou obrazových intenzit mezi po sobě jdoucími snímky. Tato interpretace je podpořena tím, že FD a DVARS popisují odlišné aspekty dat. FD je odvozena z parametrů pohybu získaných při realignmentu, zatímco DVARS je počítána přímo ze změn obrazových intenzit mezi sousedními časovými snímky. Jejich současné zvýšení proto představuje silný indikátor pohybového artefaktu a podporuje využití obou metrik při hodnocení kvality fMRI dat [11].

Klíčovou funkcí nástroje je také možnost současného zobrazení více datasetů a jejich přímého vizuálního porovnání. Obr. 5.6 zachycuje FD křivky subjektů 1 a 10 zobrazené současně v jednom panelu. Zatímco křivka subjektu 1 setrvává po celou dobu akvizice hluboko pod prahem 0,5 mm, křivka subjektu 10 ho opakovaně překračuje a vykazuje výrazný pohybový vrchol ve snímku 194.



Obr. 5.6: Porovnání průběhu FD křivek u subjektu s nízkým (modrá) a vysokým (fialová) pohybem

Obr. 5.7 ukazuje příklad propojení globální metriky kvality s lokálními BOLD průběhy. V horním panelu je u subjektu 10 (fialová) patrná výrazná špička metriky DVARS v okolí snímku 194. Po výběru tohoto časového bodu se aktualizují také anatomické řezy a mřížka 3×3 voxelových časových řad v okolí zvolené prostorové pozice. V zobrazených BOLD průbězích je u subjektu 10 patrný náhlý pokles signálu v několika voxelech, zatímco odpovídající průběhy subjektu 1 (modrá) vykazují ve stejném časovém úseku menší změny. Tento příklad ilustruje, že interaktivní propojení DVARS, anatomického řezu a lokálních časových řad umožňuje rychleji posoudit, zda se globální odchylka v metrice kvality promítá také do konkrétních prostorových oblastí obrazu.




Obr. 5.7: Porovnání průběhu DVARS a BOLD křivek u subjektu s nízkým (modrá) a vysokým (fialová) pohybem


5.4.2 Carpet plot

Carpet ploty subjektů 4 a 10 na Obr. 5.8 ukazují časově lokalizované změny signálu, které se projevují jako svislé pruhy napříč větším počtem voxelů. U subjektu 4 je patrných několik výrazných svislých struktur v časových bodech, které odpovídají zvýšeným hodnotám metrik FD a DVARS. Tento typ změny je typický pro artefakty ovlivňující větší část obrazového objemu, například pro pohyb hlavy během akvizice [46].

U subjektu 10 je dominantní odchylka soustředěna přibližně kolem snímku 194, kde se v carpet plotu projevuje jako tmavý svislý pruh narušující jinak relativně rovnoměrný průběh signálu. Vzhledem k tomu, že stejný časový úsek byl identifikován také v metrice DVARS a lokálních BOLD průbězích, tento nálezn podporuje interpretaci časově lokalizovaného artefaktu s dopadem na větší počet voxelů.



(a) Subjekt 4




(b) Subjekt 10

Obr. 5.8: Carpet ploty subjektů s výrazným pohybem.

5.4.3 QC mapa

Srovnání QC map subjektu 1 a subjektu 4 na Obr. 5.9 ukazuje odlišný prostorový rozsah voxelů zařazených do kategorie nízkého tSNR. Zatímco u subjektu 1 jsou tyto voxely soustředěny převážně do oblastí náchylných k susceptibilitním artefaktům, u subjektu 4 zaujímají větší část mozkového objemu. Samotné absolutní hodnoty tSNR však nelze mezi subjekty interpretovat izolovaně, protože mohou být ovlivněny řadou individuálních a technických faktorů.

U subjektu 4 je však rozsáhlejší výskyt voxelů s nízkým tSNR doprovázen také výraznými špičkami v metrikách FD a DVARS. Nejvýraznější pohybová odchylka se objevuje přibližně kolem snímku 38, kde FD výrazně překračuje zvolený práh 0,5 mm, a ve stejném časovém úseku je patrná také výrazná špička v DVARS. Další zvýšené hodnoty se objevují například kolem snímků 65 a 190–200. Tato kombinace prostorových a časových ukazatelů podporuje interpretaci, že kvalita dat subjektu 4 je ovlivněna výraznější časovou nestabilitou, pravděpodobně související s pohybem subjektu.



(a) Subjekt s nízkým pohybem

(b) Subjekt s vysokým pohybem

Obr. 5.9: Porovnání QC map u subjektů s tSNR limitem 50.

5.5 Detekce technického artefaktu na multi-echo datech

Třetí testovací scénář byl zaměřen na ověření chování nástroje na multi-echo datech postižených technickým artefaktem způsobeným elektromagnetickým rušením. Multi-echo akviziční protokol pořizuje při jediném repetičním čase TR několik snímků s odlišnými časy echa (TE), což umožňuje studovat závislost signálu na $T2^*$ relaxaci. S rostoucí dobou echa současně klesá amplituda signálu, což představuje ideální podmínky pro testování citlivosti implementovaných metrik na pokles signálu. Pro testování byla použita data jednoho subjektu se třemi echy (echo-1 až echo-3) ve variantě *wr* po prostorové normalizaci a korekci pohybu.

5.5.1 Interpretace výsledků

Tabulka 5.4 shrnuje hodnoty průměrného tSNR a velikosti masky mozku pro jednotlivá echa získaná exportem ze statistického modulu nástroje.


Tab. 5.4: Hodnoty velikosti masky a průměrného tSNR pro jednotlivá echa

Echo	Velikost masky [voxely]	Průměrné tSNR
echo-1	66 302	25,98
echo-2	53 853	20,23
echo-3	46 853	16,45

Výsledky ukazují pokles obou sledovaných veličin s rostoucím číslem echa. Průměrné tSNR klesá z hodnoty 25,98 v prvním echu na 16,45 ve třetím echu, což odpovídá poklesu přibližně o 37 %. Současně se zmenšuje velikost masky mozku z 66 302 voxelů v echu 1 na 46 853 voxelů v echu 3, tedy přibližně o 29 %.

Tento trend je v souladu s fyzikálním očekáváním pro delší časy echa, protože amplituda signálu u gradient-echo EPI sekvenec klesá vlivem T_2^* relaxace přibližně úměrně členu e^{-TE/T_2^*} [4]. V pozdějších echech proto může být část voxelů s nižším signálem snadněji zařazena pod prahovou hodnotu masky a klasifikována jako pozadí. Interpretace těchto výsledků však musí být opatrná, protože poskytnutá multi-echo data jsou zároveň postižena technickým artefaktem. Pozorovaný pokles velikosti masky tedy nelze přisuzovat pouze fyziologickému poklesu signálu s rostoucím TE, ale pravděpodobně se na něm podílí také kvalita konkrétní akvizice, lokální výpadky signálu a zvolený způsob prahování masky.

Vizuální srovnání masek pro jednotlivá echa na Obr. 5.10 ukazuje, že s rostoucím číslem echa se rozsah oblastí zařazených do masky postupně zmenšuje. Ztráta voxelů je patrná zejména v okrajových a ventrálních oblastech mozku, kde lze očekávat vyšší citlivost na susceptibilitní efekty, například v oblasti temporálních pólů a spodního čelního laloku. Vzhledem k přítomnému technickému artefaktu je však vhodné tento obraz chápat spíše jako demonstraci citlivosti implementované masky a metrik na kvalitu jednotlivých ech než jako obecně platný popis chování multi-echo dat.




Obr. 5.10: Porovnání masek mozku pro jednotlivá echa.

Vizualizace tSNR map napříč jednotlivými echy na Obr. 5.11 ukazuje nejen pokles hodnot tSNR, ale také změnu jejich prostorového rozložení. Ve všech echách jsou patrné horizontální pruhové struktury, které pravděpodobně souvisejí s technickým artefaktem v poskytnutých datech a komplikují přímou interpretaci map.

V prvním echu dosahují nejvyšší hodnoty tSNR přibližně 50–55, zatímco ve třetím echu se maximální hodnoty barevné škály pohybují přibližně do 30. S rostoucím číslem echa je zároveň patrné zmenšení oblastí s vyšším tSNR a větší zastoupení oblastí s nízkými hodnotami. Tento trend je v souladu s očekávaným poklesem signálu při delším čase echa, avšak vzhledem k přítomnému technickému artefaktu jej nelze interpretovat pouze jako důsledek fyzikálního útlumu signálu podle T_2^* relaxace.


tSNR mapy proto slouží především jako vizuální doplnění kvantitativních hodnot uvedených v Tab. 5.4. Ukazují, že změny mezi echy nejsou rovnoměrné v celém objemu, ale mají výraznou prostorovou strukturu, včetně oblastí se ztrátou signálu a pruhových artefaktů.



Obr. 5.11: Porovnání tSNR map pro jednotlivá echa.


Jednotlivé křivky DVARs na Obr. 5.12 vykazují podobný časový průběh napříč všemi třemi echy. Výraznější špičky se objevují ve srovnatelných časových bodech, což opět ukazuje, že pozorované změny nejsou omezeny pouze na jedno echo. Tento

nález je v kombinaci s vizuálně patrnými pruhovými artefakty v anatomických řezech v souladu s interpretací technického artefaktu.



Obr. 5.12: Průběh DVARs křivek při přítomnosti technického artefaktu

Vizuální inspekce anatomických řezů na Obr. 5.13 ukazuje výrazný čárový artefakt, který se projevuje jako světlé horizontální pruhy procházející napříč obrazem mozku. Artefakt je patrný ve všech třech echách na podobné prostorové pozici, což podporuje interpretaci, že se nejedná pouze o lokální ztrátu signálu specifickou pro jedno echo. Konzistentní výskyt pruhového artefaktu napříč echy může být důležitým diagnostickým vodítkem při hodnocení původu odchylky. V tomto případě podporuje hypotézu technického artefaktu, protože podobný prostorový vzor se opakuje nezávisle na čísle echa.



Obr. 5.13: Porovnání anatomických řezů pro jednotlivá echa.

5.6 Demonstrace metriky SNS

Čtvrtý testovací scénář byl zaměřen na demonstraci specifické metriky SNS, která na rozdíl od ostatních implementovaných metrik vyžaduje data normalizovaná do MNI prostoru a externí atlas anatomických oblastí. Použití dat v nativním prostoru subjektu by vedlo k anatomické neshodě mezi voxely dat a regiony atlasu, a výsledné SNS hodnoty by nebyly interpretovatelné. Pro testování byla proto použita standardní single-echo data subjektů 1 a 2 ve variantě *swr* po prostorové normalizaci, korekci pohybu a vyhlazení z blokového řečového experimentu, společně se standardním atlasem AAL v MNI prostoru.

5.6.1 Interpretace výsledků

Tabulka 5.5 shrnuje hodnoty metriky SNS pro oba testované subjekty získané ze statistického výstupu nástroje.

U obou subjektů přesahuje medián SNS hodnotu 1. Podle použité definice metriky to naznačuje, že většina voxelů zahrnutých do masky vykazuje vyšší podobnost s referenčními atlasovými časovými řadami než s referenčními průběhy šumu. Tento výsledek lze chápat jako příznivý ukazatel z hlediska separace signálové a šumové


složky, nelze jej však samostatně interpretovat jako jednoznačný důkaz celkové kvality dat. Hodnocení SNS je vhodné posuzovat společně s dalšími metrikami kvality a s vizuální kontrolou prostorového rozložení hodnot.

Tab. 5.5: Statistiky metriky SNS pro testované subjekty

Subjekt	Velikost masky [voxely]	Průměrné SNS	Medián SNS
sub1	124 687	1,47	1,31
sub2	133 672	1,71	1,08

Obr. 5.14a zobrazuje prostorovou distribuci SNS pro subjekt 1 při hodnotě parametru **snsMaskThreshold** rovné 0,5. Mapa ukazuje výrazně nehomogenní rozložení hodnot napříč mozkem. Vyšší hodnoty SNS jsou patrné zejména v některých korových oblastech, zatímco nižší hodnoty se objevují spíše v centrálních oblastech mozku, včetně oblasti bazálních ganglií a thalamu. Toto rozložení může souviset s rozdíly v časových průbězích jednotlivých anatomických oblastí, s odlišnou úrovní šumu, s citlivostí BOLD signálu v různých strukturách nebo také s vlastnostmi použité atlasové segmentace. Tyto možné příčiny však z uvedené mapy nelze jednoznačně oddělit.

Pro ověření citlivosti metriky na nastavení masky byla SNS mapa subjektu 1 vypočítána pro dvě hodnoty parametru **snsMaskThreshold**. Při vyšší hodnotě prahu 0,5 je výpočet omezen na voxely s vyšší střední intenzitou, čímž se z analyzované oblasti vyloučí větší část okrajových voxelů a oblastí s nižším signálem. Při nižší hodnotě prahu 0,1 maska zahrnuje větší objem mozku včetně okrajových oblastí, kde mohou být hodnoty SNS ovlivněny nižším poměrem signálu k šumu nebo částečným zahrnutím pozadí, viz Obr. 5.14.



(a) Práh masky 0,5

(b) Práh masky 0,1

Obr. 5.14: Porovnání SNS map subjektu 1 při různém nastavení prahu masky.

Toto srovnání ukazuje, že výsledná SNS mapa je citlivá na volbu prahu masky. Interaktivní nastavení tohoto parametru proto umožňuje uživateli kontrolovat roz-

sah analyzované oblasti a přizpůsobit výpočet charakteru konkrétních dat. Zároveň však ukazuje, že hodnoty SNS je nutné interpretovat s ohledem na použitou masku, protože změna prahu může ovlivnit jak velikost analyzovaného objemu, tak výsledné statistiky metricky.


Metrika SNS může přispět k rozlišení voxelů, které mají odlišný charakter časového průběhu i v případech, kdy samotná hodnota tSNR neposkytuje úplnou informaci o kvalitě signálu. Obr. 5.15 ukazuje příklad dvou rozdílně klasifikovaných voxelů v QC mapě. V prvním případě je vybraný voxel zařazen do kategorie *Both low*, tedy jako voxel s nízkým tSNR i nízkým SNS. Odpovídající BOLD průběh u subjektu 1 vykazuje výraznější časovou variabilitu a nepravidelné kolísání, bez zřetelné opakující se struktury, kterou by bylo možné očekávat u blokového experimentu.

Naproti tomu voxel zařazený do kategorie *OK* vykazuje v zobrazeném časovém průběhu menší míru náhlých výkyvů a stabilnější charakter signálu. Toto srovnání ilustruje praktický význam kombinované QC mapy: uživatel může propojit prostorovou klasifikaci voxelu s jeho konkrétní časovou řadou a posoudit, zda se nízké hodnoty metrik promítají také do lokálního průběhu BOLD signálu. Protože jsou v grafech současně zobrazeny průběhy obou testovaných subjektů, lze zároveň orientačně posoudit, zda je odchylka specifická pro aktivní dataset, nebo se v podobné podobě objevuje i u druhého subjektu.


Pro ilustraci doplňkové informace poskytované metrikou SNS bylo provedeno srovnání BOLD průběhů ve dvou prostorových lokalitách subjektu 1, které se lišily hodnotou SNS při prahovém limitu 3,5. Obr. 5.16a) ukazuje oblast s vyšší hodnotou SNS (3,73). V zobrazených voxelových časových řadách je patrná pravidelnější časová struktura a opakující se fluktuace signálu.

Naproti tomu Obr. 5.16b) zobrazuje oblast s nižší hodnotou SNS (1,09). Odpovídající BOLD průběhy vykazují méně pravidelný charakter a nižší míru zřetelné časové struktury. Toto srovnání ukazuje, že SNS může v rámci implementovaného nástroje pomoci rozlišit oblasti, jejichž časové průběhy se více podobají referenčním atlasovým průběhům, od oblastí s méně strukturovaným signálem.

Význam SNS je proto vhodné chápat jako doplněk k tSNR. Zatímco tSNR popisuje především časovou stabilitu signálu v jednotlivém voxelu, SNS poskytuje informaci o relativní podobnosti voxelové časové řady k atlasovým a šumovým referencím. Kombinace obou metrik v QC mapě tak umožňuje posoudit kvalitu dat z hlediska stability i charakteru časového průběhu signálu.




(a) Centrální voxel kategorie *Both low*




(b) Centrální voxel kategorie *OK*

Obr. 5.15: Porovnání QC mapy a BOLD grafů pro voxel s nízkými hodnotami obou metrik a pro voxel bez detekovaného problému.



(a) Centrální voxel s vyšší hodnotou SNS (3,73)



(b) Centrální voxel s nízkou hodnotou SNS (1,09)

Obr. 5.16: Porovnání SNS mapy a BOLD grafů pro oblasti s vyšší a nízkou hodnotou SNS.

5.7 Shrnutí výsledků

Cílem testovací části práce bylo ověřit funkčnost vyvinutého nástroje na reálných fMRI datech poskytnutých laboratoří MAFIL CEITEC MU. Testování bylo struktu-

rováno do čtyř scénářů, z nichž každý byl zaměřen na specifickou situaci, se kterou se uživatel může při kontrole kvality fMRI dat setkat. V této podkapitole jsou shrnuty hlavní závěry vyplývající z provedených experimentů.

První scénář ukázal, že nástroj umožňuje kvantitativně i vizuálně sledovat změny metrik kvality napříč jednotlivými kroky standardní preprocessingové pipeline. Průměrné tSNR u obou testovaných subjektů narůstalo s postupujícím zpracováním dat, přičemž nejvýraznější změna nastala po aplikaci prostorového vyhlazení. U subjektu 1 vzrostlo tSNR mezi variantami *wr* a *swr* z 78,1 na 177,9, u subjektu 2 z 59,5 na 127,1. Současně byl v testovaných datech pozorován pokles hodnot DVARS. Tento výsledek je v souladu s očekávaným působením Gaussovského filtru, který potlačuje lokální vysokofrekvenční variabilitu signálu. Zároveň ukazuje, že interpretace QC metrik musí vždy zohledňovat fázi zpracování dat, protože preprocessing může měnit nejen hodnoty metrik, ale také vizuální podobu artefaktů.

Druhý scénář demonstroval schopnost nástroje zachytit časové úseky se zvýšeným pohybem a odlišit subjekty s nízkou a vyšší mírou pohybu podle metriky FD. Zatímco subjekty kontrolní skupiny (sub1, sub2) nevykázaly žádné nebo pouze ojedinělé překročení často používaného prahu FD 0,5 mm, subjekty s výraznějším pohybem (sub4, sub10) překračovaly tento práh v desítkách časových snímků. Současný výskyt zvýšených hodnot FD a DVARS ve stejných časových oblastech podporuje interpretaci pohybových artefaktů, protože FD zachycuje změnu polohy hlavy a DVARS změny obrazových intenzit mezi sousedními snímky. Praktickým přínosem nástroje je možnost zobrazit více subjektů v jednom okně a přímo přejít na problematický časový snímek kliknutím do grafu časové metriky.

Třetí scénář ověřil chování nástroje na multi-echo datech postižených technickým artefaktem. Výsledky ukázaly pokles sledovaných metrik napříč jednotlivými echo, který se projevil snížením průměrného tSNR z 25,98 na 16,45 a zmenšením velikosti masky mozku z 66 302 na 46 853 voxelů. Tento trend je v souladu s očekávaným poklesem signálu při delším čase echa, avšak vzhledem k přítomnému artefaktu jej nelze přisuzovat výhradně fyzikálnímu útlumu signálu podle T_2^* relaxace. Konzistentní výskyt pruhových struktur napříč všemi echo zároveň podporuje interpretaci technického artefaktu, nikoli lokální odchylky omezené pouze na jedno echo.

Čtvrtý scénář demonstroval využitelnost metriky SNS jako doplňkového ukazatele k tSNR. Kromě kvantitativního výstupu bylo možné vizuálně porovnat časové průběhy BOLD signálu ve voxelech s vyšší a nižší hodnotou SNS. Voxely s vyšší hodnotou SNS vykazovaly pravidelnější časovou strukturu a opakující se fluktuace signálu, zatímco voxely s nižší hodnotou SNS měly méně strukturovaný průběh. Tyto výsledky naznačují, že SNS může v rámci navrženého nástroje pomoci rozlišit oblasti podle relativní podobnosti jejich časových průběhů k atlasovým a šumovým referencím. V kombinaci s tSNR tak poskytuje doplňující informaci nejen o stabilitě

signálu, ale také o charakteru jeho časové dynamiky.

5.7.1 Omezení a možná rozšíření

V průběhu testování bylo identifikováno několik omezení, která zároveň naznačují možné směry dalšího rozvoje navrženého nástroje. Nejvýznamnějším omezením se ukázala paměťová náročnost výpočtu metriky SNS. Tato metrika pracuje s korelacemi mezi velkým počtem voxelových časových řad a referenčními signály, což při rozsáhlejších datových sadách vede k vysokým nárokům na operační paměť. Konkrétní paměťový limit pro výpočet SNS závisí především na dostupné operační paměti použitého systému a na velikosti zpracovávaného datasetu. Z tohoto důvodu nebylo možné SNS vyhodnotit na multi-echo datech ve scénáři 3, která obsahovala 660 časových snímků. Možným řešením tohoto problému je implementace blokového zpracování dat, při němž by se korelační výpočty neprováděly nad celou maticí současně, ale postupně po menších částech.

Současná verze aplikace je také omezena při porovnávání datasetů s rozdílnými prostorovými rozměry nebo odlišným souřadnicovým prostorem. Přímé srovnání srovnání srovnání a normalizovaných dat je komplikované, protože tyto varianty se mohou lišit velikostí voxelů, počtem řezů i prostorovou mřížkou. V aktuální implementaci je proto nejvhodnější pracovat s datasety ve stejném referenčním prostoru. Rozšíření o současné porovnání dat v nativním a normalizovaném prostoru by nevyžadovalo pouze prosté převzorkování na stejnou velikost matice, ale také aplikaci prostorové normalizace, tedy transformaci dat do definovaného anatomického prostoru, včetně případné nelineární deformace. Tento krok by výrazně zvýšil výpočetní náročnost, zejména ve fázi načítání datasetu, a mohl by zpomalit následnou interaktivní práci s aplikací. Alternativou by bylo ponechat data v jejich původních prostorech a průběžně přepočítávat souřadnice mezi jednotlivými referenčními systémy, což by však představovalo netriviální rozšíření architektury aplikace.

Doplňkové porovnání implementovaných metrik s výstupy nástroje MRIQC bylo zvažováno jako další validační krok. Dostupná data byla poskytnuta ve formátu NIfTI včetně odpovídajících JSON metadat, což by teoreticky umožňovalo přípravu BIDS struktury. Praktická realizace tohoto porovnání by však vyžadovala lokální instalaci a konfiguraci MRIQC v kontejnerovém prostředí Docker, v případě systému Windows také zprovoznění příslušného linuxového subsystému, a následnou validaci připraveného BIDS datasetu. Vzhledem k rozsahu práce nebylo toto porovnání provedeno a zůstává možným směrem dalšího rozšíření validace.

Správnost implementovaných metrik byla v této práci ověřována na základě publikovaných výpočetních definic, kontroly očekávaných vztahů mezi metrikami a vizuální inspekce odpovídajících artefaktů v datech. Současně je nutné zdůraznit, že

ani při porovnání s MRIQC by nebylo možné automaticky očekávat úplnou numerickou shodu vypočtených hodnot. Jednotlivé QC nástroje se mohou lišit například způsobem konstrukce masky mozku, aplikovaným detrendingem, normalizací signálu nebo zařazením pomocných předzpracovacích kroků. Smyslem takového porovnání by proto nebylo dosažení totožných absolutních hodnot, ale ověření konzistence trendů, časové lokalizace problematických snímků a relativního rozdílu mezi kvalitními a artefaktově zatíženými daty.

Potenciálním rozšířením nástroje je také doplnění dalších QC metrik a vizualizačních prvků. Kromě již implementovaných ukazatelů by bylo možné zahrnout například pokročilejší metriky popisující šum v pozadí, míru ghostingu nebo lokální výpadky signálu. Z hlediska uživatelského rozhraní by bylo přínosné rozšířit možnosti exportu výsledků, například automatické generování souhrnného reportu pro jednotlivé subjekty nebo celé skupiny měření. Takový report by mohl obsahovat tabulky vypočtených metrik, vybrané grafy, náhledy prostorových map a seznam časových bodů označených jako problematické.

I přes uvedená omezení testování ukázalo, že vyvinutý nástroj je schopen pracovat s reálnými 4D fMRI daty a poskytovat výstupy využitelné při jejich kontrole kvality. Aplikace umožňuje načítat a vizualizovat fMRI data, počítat vybrané metriky kvality a interaktivně propojovat časové průběhy metrik s prostorovým zobrazením mozku. Uživatel tak může rychle identifikovat problematické časové body, ověřit jejich prostorový projev v obrazových datech a porovnat kvalitu dat v různých fázích zpracování.

Závěr

Tato diplomová práce se zabývala problematikou hodnocení kvality dat fMRI s důrazem na jejich interaktivní vizualizaci. V teoretické části byly shrnuty fyzikální principy magnetické rezonance, vznik BOLD kontrastu, základní charakteristiky fMRI experimentu, běžné kroky předzpracování dat a přehled používaných softwarových nástrojů. Samostatná kapitola byla věnována kontrole kvality fMRI dat, faktorům ovlivňujícím jejich kvalitu, používaným QC metrikám a limitacím existujících řešení. Z této rešerše vyplynulo, že zavedené nástroje poskytují řadu užitečných funkcí. Jejich omezením však zůstává nedostatečné propojení kvantitativního hodnocení s interaktivní vizuální inspekci v rámci jedné aplikace.

V praktické části byl navržen a implementován softwarový nástroj v prostředí MATLAB využívající knihovnu SPM. Aplikace umožňuje načítání a porovnání více fMRI datasetů, výpočet vybraných metrik kvality a jejich propojení s prostorovou i časovou vizualizací dat. Do nástroje byly implementovány metriky FD, DVARS, tSNR a SNS, dále vizualizace typu Carpet plot a kombinovaná QC mapa. Uživatelské rozhraní propojuje anatomické řezy, časové průběhy metrik a lokální BOLD signály tak, aby uživatel mohl rychle přecházet mezi globálním hodnocením kvality a detailní kontrolou konkrétních časových bodů nebo prostorových oblastí.

Funkčnost nástroje byla ověřena na reálných fMRI datech poskytnutých laboratoří MAFIL CEITEC MU ve čtyřech testovacích scénářích. Testování ukázalo, že nástroj umožňuje sledovat změny metrik napříč kroky preprocessingu, identifikovat časové úseky se zvýšeným pohybem, vizualizovat artefakty v multi-echo datech a využít metriku SNS jako doplňující informaci k tSNR. Výsledky zároveň potvrdily, že interpretace QC metrik musí vždy zohledňovat fázi zpracování dat, použitou masku a charakter konkrétní akvizice.

Hlavním přínosem práce je vytvoření jednotného prostředí, které kombinuje výpočet QC metrik s interaktivním prohlížením fMRI dat. Navržený nástroj umožňuje rychlejší prostorově-časovou interpretaci artefaktů, porovnání více subjektů nebo variant zpracování a přímé propojení problematických hodnot metrik s odpovídajícími obrazovými daty. Díky implementaci v MATLABu a využití SPM je řešení dobře začlenitelné do pracovních postupů používaných v laboratoří MAFIL CEITEC MU.

Současná implementace má také určitá omezení. Nejvýznamnější z nich představuje paměťová náročnost výpočtu metriky SNS u rozsáhlejších datasetů, protože výpočet pracuje s korelacemi mezi velkým počtem voxelových časových řad a referenčními signály. V budoucnu by bylo možné toto omezení zmírnit například blokovým zpracováním dat. Další rozšíření mohou zahrnovat podporu porovnání dat v různých souřadnicových prostorech, doplnění dalších QC metrik, automatické generování souhrnných reportů a ověření nástroje na rozsáhlejších datových souborech.

Navzdory těmto omezením představuje vytvořený software funkční nástroj pro interaktivní kontrolu kvality fMRI dat. Jeho hlavní hodnota spočívá v tom, že uživateli umožňuje propojit číselné metriky kvality s konkrétními prostorovými a časovými projevy artefaktů, což může usnadnit rozhodování o použitelnosti dat pro následnou analýzu.

Literatura

- [1] OGAWA, S; LEE, T M; KAY, A R a TANK, D W. Brain magnetic resonance imaging with contrast dependent on blood oxygenation. Online. *Proceedings of the National Academy of Sciences*. 1990, roč. 87, č. 24, s. 9868-9872. ISSN 0027-8424. Dostupné z: <https://doi.org/10.1073/pnas.87.24.9868>. [cit. 2025-12-21].
- [2] LOGOTHETIS, Nikos K. What we can do and what we cannot do with fMRI. Online. *Nature*. 2008, roč. 453, č. 7197, s. 869-878. ISSN 0028-0836. Dostupné z: <https://doi.org/10.1038/nature06976>. [cit. 2025-12-21].
- [3] BROWN, Mark A.; SEMELKA, Richard C. *MRI : Basic Principles and Applications*. 2nd ed. John Wiley & Sons, 1999. ISBN 0471330620.
- [4] HUETTEL, Scott A.; SONG, Allen W. a MCCARTHY, Gregory. *Functional magnetic resonance imaging*. Sinauer Associates, 2004. ISBN 0-87893-288-7.
- [5] CAROLIN, Paula. In situ solid-state NMR and XRD investigations of structural transformations in crystalline porous solids. 2021. Dostupné z: <https://doi.org/10.25593/978-3-96147-450-9>. [cit. 2025-12-22].
- [6] CURRIE, Geoffrey M.; KAMVOSOU LIS, Peter a BUSHONG, Stewart. PET/MRI, Part 2: Technologic Principles. Online. *Journal of Nuclear Medicine Technology*. 2021, roč. 49, č. 3, s. 217-225. ISSN 0091-4916. Dostupné z: <https://doi.org/10.2967/jnmt.120.261862>. [cit. 2025-12-22].
- [7] *Functional Magnetic Resonance Imaging of Tinnitus*. Online. Bibliotheek der Rijksuniversiteit Groningen, 2010. ISBN 978-90-367-4258-0. Dostupné z: https://www.researchgate.net/publication/42788125_Functional_magnetic_resonance_imaging_of_tinnitus. [cit. 2025-12-30].
- [8] SHAH, N. Jon. *Hybrid MR-PET imaging: systems, methods and applications*. Online. New developments in NMR, no. 19. Cambridge: Royal Society of Chemistry, 2018. ISBN 978-1-78801-306-2. Dostupné z: <https://doi.org/10.1039/9781788013062-00001>. [cit. 2025-12-22].
- [9] FOX, P T a RAICHLE, M E. Focal physiological uncoupling of cerebral blood flow and oxidative metabolism during somatosensory stimulation in human subjects. Online. *Proceedings of the National Academy of Sciences*. 1986, roč. 83, č. 4, s. 1140-1144. ISSN 0027-8424. Dostupné z: <https://doi.org/10.1073/pnas.83.4.1140>. [cit. 2025-12-22].

- [10] *BOLD and Brain Activity*. Online. Magnetism — Questions and Aswers in MRI. 2015. Dostupné z: <https://mriquestions.com/does-boldbrain-activity.html>. [cit. 2025-12-22].
- [11] POWER, Jonathan D.; BARNES, Kelly A.; SNYDER, Abraham Z.; SCHLAGGAR, Bradley L. a PETERSEN, Steven E. Spurious but systematic correlations in functional connectivity MRI networks arise from subject motion. Online. *NeuroImage*. 2012, roč. 59, č. 3, s. 2142-2154. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1016/j.neuroimage.2011.10.018>. [cit. 2025-12-22].
- [12] BIRN, Rasmus M.; DIAMOND, Jason B.; SMITH, Monica A. a BANDETTINI, Peter A. Separating respiratory-variation-related fluctuations from neuronal-activity-related fluctuations in fMRI. Online. *NeuroImage*. 2006, roč. 31, č. 4, s. 1536-1548. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1016/j.neuroimage.2006.02.048>. [cit. 2025-12-22].
- [13] *Different k-space trajectories*. Online. In: MR Basics Recap: Signal Encoding & k-Space. 2020. Dostupné z: <https://cds.ismrm.org/protected/20MProceedings/PDFfiles/E1159.html>. [cit. 2025-12-30].
- [14] JEZZARD, Peter a BALABAN, Robert S. Correction for geometric distortion in echo planar images from B<i>0</i> field variations. Online. *Magnetic Resonance in Medicine*. 1995, roč. 34, č. 1, s. 65-73. ISSN 0740-3194. Dostupné z: <https://doi.org/10.1002/mrm.1910340111>. [cit. 2025-12-22].
- [15] FEINBERG, David A. a SETSOMPOP, Kawin. Ultra-fast MRI of the human brain with simultaneous multi-slice imaging. Online. *Journal of Magnetic Resonance*. 2013, roč. 229, s. 90-100. ISSN 1090-7807. Dostupné z: <https://doi.org/10.1016/j.jmr.2013.02.002>. [cit. 2025-12-22].
- [16] POLDRACK, Russell A.; MUMFORD, Jeanette A. a NICHOLS, Thomas E. *Handbook of functional MRI data analysis*. New York: Cambridge University Press, 2011. ISBN 978-0-521-51766-9.
- [17] BISWAL, Bharat; ZERRIN YETKIN, F.; HAUGHTON, Victor M. a HYDE, James S. Functional connectivity in the motor cortex of resting human brain using echo-planar mri. Online. *Magnetic Resonance in Medicine*. 1995, roč. 34, č. 4, s. 537-541. ISSN 0740-3194. Dostupné z: <https://doi.org/10.1002/mrm.1910340409>. [cit. 2025-12-23].
- [18] JENTOFT, Elian E. *Working with fMRI Data - An Introduction*. Online. Oslo: Universitas Osloensis, 2019. Dostupné z: <https://www.sv>.

- uio.no/psi/english/research/projects/human-time-data/documents/data-lifecycle/fmri/images/fmridoc_draft1.pdf. [cit. 2025-12-31].
- [19] LAROBINA, Michele. Thirty Years of the DICOM Standard. Online. *Tomography*. 2023, roč. 9, č. 5, s. 1829-1838. ISSN 2379-139X. Dostupné z: <https://doi.org/10.3390/tomography9050145>. [cit. 2026-05-25].
 - [20] C. Rorden and R. Karnath, *dcm2niix: DICOM to NIfTI converter*. Dostupné z: <https://github.com/rordenlab/dcm2niix> [cit. 2026-05-25].
 - [21] GORGOLEWSKI, Krzysztof J.; AUER, Tibor; CALHOUN, Vince D.; CRADDOCK, R. Cameron; DAS, Samir et al. The brain imaging data structure, a format for organizing and describing outputs of neuroimaging experiments. Online. *Scientific Data*. 2016, roč. 3, č. 1. ISSN 2052-4463. Dostupné z: <https://doi.org/10.1038/sdata.2016.44>. [cit. 2026-05-25].
 - [22] GOEBEL, Rainer. *Coordinate Systems*. Online. In: BrainVoyager. 2023. Dostupné z: <https://www.brainvoyager.com/bv/doc/UsersGuide/CoordsAndTransforms/CoordinateSystems.html>. [cit. 2026-01-02].
 - [23] Wellcome Centre for Human Neuroimaging, University College London, *SPM12 Documentation*, 2025. Dostupné z: <https://www.fil.ion.ucl.ac.uk/spm/docs/> [cit. 2026-01-02].
 - [24] *Motion of a rigid body (like the head) in 3D space*. Online. In: NEWBI 4 fMRI. 2019. Dostupné z: <https://www.newbi4fmri.com/tutorial-5-motion>. [cit. 2026-01-05].
 - [25] FENGLER, Anja. *How the brain attunes to sentence processing: Relating Behavior, Structure, and Function*. Dissertation. Dresden: Universität Potsdam, 2015.
 - [26] SLADKY, Ronald; FRISTON, Karl J.; TRÖSTL, Jasmin; CUNNINGTON, Ross; MOSER, Ewald et al. Slice-timing effects and their correction in functional MRI. Online. *NeuroImage*. 2011, roč. 58, č. 2, s. 588-594. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1016/j.neuroimage.2011.06.078>. [cit. 2026-01-02].
 - [27] FMRI Analysis Group, University of Oxford, *FSL – FMRI Software Library Documentation*, 2025. Dostupné z: <https://fsl.fmrib.ox.ac.uk/fsl/docs/> [cit. 2026-01-02].
 - [28] *FSL GUIs*. Online. In: Tcler's Wiki. 2018. Dostupné z: <https://wiki.tcl-lang.org/page/FSL>. [cit. 2025-12-31].

- [29] AFNI Development Team, *AFNI Documentation: Analysis of Functional NeuroImages*, National Institute of Mental Health. Dostupné z: <https://afni.nimh.nih.gov/pub/dist/doc/htmldoc/index.html> [cit. 2026-01-02].
- [30] *AFNI_screenshot*. Online. In: Open Source Imaging. 2006. Dostupné z: https://www.opensourceimaging.org/wp-content/uploads/AFNI_screenshot.png. [cit. 2025-12-29].
- [31] LIU, Thomas T. Noise contributions to the fMRI signal: An overview. Online. *NeuroImage*. 2016, roč. 143, s. 141-151. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1016/j.neuroimage.2016.09.008>. [cit. 2026-01-05].
- [32] FRISTON, Karl J.; WILLIAMS, Steven; HOWARD, Robert; FRACKOWIAK, Richard S. J. a TURNER, Robert. Movement-Related effects in fMRI time-series. Online. *Magnetic Resonance in Medicine*. 1996, roč. 35, č. 3, s. 346-355. ISSN 0740-3194. Dostupné z: <https://doi.org/10.1002/mrm.1910350312>. [cit. 2026-01-05].
- [33] ZHANG, Xiaodong; VAN DE MOORTELE, Pierre-Francois; PFEUFFER, Josef a HU, Xiaoping. Elimination of k-space spikes in fMRI data. Online. *Magnetic Resonance Imaging*. 2001, roč. 19, č. 7, s. 1037-1041. ISSN 0730-725X. Dostupné z: [https://doi.org/10.1016/s0730-725x\(01\)00428-3](https://doi.org/10.1016/s0730-725x(01)00428-3). [cit. 2026-01-05].
- [34] GAILLARD, Frank. *Herringbone MRI artifact*. Online. In: Radiopaedia. 2012. Dostupné z: <https://radiopaedia.org/cases/herringbone-mri-artifact>. [cit. 2026-01-05].
- [35] GIANNELLI, Marco; DICHIOTTI, Stefano; TESSA, Carlo a MASCALCHI, Mario. Characterization of Nyquist ghost in EPI-fMRI acquisition sequences implemented on two clinical 1.5 T MR scanner systems: effect of readout bandwidth and echo spacing. Online. S. 170-180. Dostupné z: <https://doi.org/10.1120/jacmp.v11i4.3237>. [cit. 2026-01-05].
- [36] *Nyquist N/2 Ghost Artifact*. Online. In: Questions and Answers in MRI. 2015. Dostupné z: <https://mriquestions.com/nyquist-n2-ghosts.html>. [cit. 2026-01-05].
- [37] BASHIR, Usman. *Magnetic susceptibility artifact: Case 1*. Online. In: Radiopaedia. 2012. Dostupné z: <https://radiopaedia.org/articles/magnetic-susceptibility-artifact>. [cit. 2026-01-05].

- [38] MURPHY, Kevin; BODURKA, Jerzy a BANDETTINI, Peter A. How long to scan? The relationship between fMRI temporal signal to noise ratio and necessary scan duration. Online. *NeuroImage*. 2007, roč. 34, č. 2, s. 565-574. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1016/j.neuroimage.2006.09.032>. [cit. 2026-01-05].
- [39] SHIRER, William R.; JIANG, Heidi; PRICE, Collin M.; NG, Bernard a GREICIUS, Michael D. Optimization of rs-fMRI Pre-processing for Enhanced Signal-Noise Separation, Test-Retest Reliability, and Group Discrimination. Online. *NeuroImage*. 2015, roč. 117, s. 67-79. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1016/j.neuroimage.2015.05.015>. [cit. 2026-01-05].
- [40] DEDORA, Daniel J.; NEDIC, Sanja; KATTI, Pratha; ARNAB, Shafique; WALD, Lawrence L. et al. Signal Fluctuation Sensitivity: An Improved Metric for Optimizing Detection of Resting-State fMRI Networks. Online. *Frontiers in Neuroscience*. 2016, roč. 10. ISSN 1662-453X. Dostupné z: <https://doi.org/10.3389/fnins.2016.00180>. [cit. 2026-01-05].
- [41] ESTEBAN, Oscar; BIRMAN, Daniel; SCHAER, Marie; KOYEJO, Oluwasanmi O.; POLDRACK, Russell A. et al. MRIQC: Advancing the automatic prediction of image quality in MRI from unseen sites. Online. *PLOS ONE*. 2017, roč. 12, č. 9, s. e0184661. ISSN 1932-6203. Dostupné z: <https://doi.org/10.1371/journal.pone.0184661>. [cit. 2026-01-04].
- [42] FRIEDMAN, Lee; GLOVER, Gary H.; KRENZ, Diana a MAGNOTTA, Vince. Reducing inter-scanner variability of activation in a multicenter fMRI study: Role of smoothness equalization. Online. *NeuroImage*. 2006, roč. 32, č. 4, s. 1656-1668. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1016/j.neuroimage.2006.03.062>. [cit. 2026-01-05].
- [43] ATKINSON, D.; HILL, D.L.G.; STOYLE, P.N.R.; SUMMERS, P.E. a KE-EVIL, S.F. Automatic correction of motion artifacts in magnetic resonance images using an entropy focus criterion. Online. *IEEE Transactions on Medical Imaging*. 1997, roč. 16, č. 6, s. 903-910. ISSN 0278-0062. Dostupné z: <https://doi.org/10.1109/42.650886>. [cit. 2026-01-05].
- [44] ESTEBAN, Oscar; BLAIR, Ross W.; NIELSON, Dylan M.; VARADA, Jan C.; MARRETT, Sean et al. Crowdsourced MRI quality metrics and expert quality annotations for training of humans and machines. Online. *Scientific Data*. 2019, roč. 6, č. 1, s. 4. ISSN 2052-4463. Dostupné z: <https://doi.org/10.1038/s41597-019-0035-4>. [cit. 2026-01-05].

- [45] *Group Anatomical Report*. Online. In: MRIQC-s documentation. 2016. Dostupné z: <https://mriqc.readthedocs.io/en/latest/reports/group.html>. [cit. 2026-01-05].
- [46] POWER, Jonathan D. A simple but useful way to assess fMRI scan qualities. Online. *NeuroImage*. 2017, roč. 154, s. 150-158. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1016/j.neuroimage.2016.08.009>. [cit. 2026-01-04].
- [47] ESTEBAN, Oscar; MARKIEWICZ, Christopher J.; BLAIR, Ross W.; MOODIE, Craig A.; ISIK, A. Ilkay et al. FMRIprep: a robust preprocessing pipeline for functional MRI. Online. *Nature Methods*. 2018, roč. 16, č. 1, s. 111-116. ISSN 1548-7091. Dostupné z: <https://doi.org/10.1038/s41592-018-0235-4>. [cit. 2026-01-04].
- [48] The fMRIPrep Developers, *Outputs of fMRIPrep*. Dostupné z: <https://fmriprep.org/en/latest/outputs.html> [cit. 2026-01-04].
- [49] JENKINSON, Mark; BECKMANN, Christian F.; BEHRENS, Timothy E.J.; WOOLRICH, Mark W. a SMITH, Stephen M. FSL. Online. *NeuroImage*. 2012, roč. 62, č. 2, s. 782-790. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1016/j.neuroimage.2011.09.015>. [cit. 2026-05-24].
- [50] COX, Robert W. AFNI: Software for Analysis and Visualization of Functional Magnetic Resonance Neuroimages. Online. *Computers and Biomedical Research*. 1996, roč. 29, č. 3, s. 162-173. ISSN 0010-4809. Dostupné z: <https://doi.org/10.1006/cbmr.1996.0014>. [cit. 2026-05-24].
- [51] *Compatible Array Sizes for Basic Operations*. Online. MathWorks. 2016. Dostupné z: https://www.mathworks.com/help/matlab/matlab_prog/compatible-array-sizes-for-basic-operations.html. [cit. 2026-05-21].
- [52] FRIMAN, Ola; BORGA, Magnus; LUNDBERG, Peter a KNUTSSON, Hans. Detection and detrending in fMRI data analysis. Online. *NeuroImage*. 2004, roč. 22, č. 2, s. 645-655. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1016/j.neuroimage.2004.01.033>. [cit. 2026-05-21].
- [53] PEER, Michael; ABOUD, Sami; HERTZ, Uri; AMEDI, Amir a ARZY, Shahrar. Intensity-based masking: A tool to improve functional connectivity results of resting-state fMRI: Intensity-Based Masking. Online. *Human Brain Mapping*. 2016, roč. 37, č. 7, s. 2407-2418. ISSN 1065-9471. Dostupné z: <https://doi.org/10.1002/hbm.23182>. [cit. 2026-05-23].

- [54] SMITH, Stephen M. Fast robust automated brain extraction. Online. *Human Brain Mapping*. 2002, roč. 17, č. 3, s. 143-155. ISSN 1065-9471. Dostupné z: <https://doi.org/10.1002/hbm.10062>. [cit. 2026-05-23].
- [55] TRIANTAFYLLOU, Christina; POLIMENI, Jonathan R. a WALD, Lawrence L. Physiological noise and signal-to-noise ratio in fMRI with multi-channel array coils. Online. *NeuroImage*. 2011, roč. 55, č. 2, s. 597-606. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1016/j.neuroimage.2010.11.084>. [cit. 2026-05-24].
- [56] Wellcome Centre for Human Neuroimaging, University College London, *Spatial smoothing – SPM Documentation*. Dostupné z: https://www.fil.ion.ucl.ac.uk/spm/docs/wikibooks/Spatial_smoothing/ [cit. 2026-05-24].
- [57] TZOURIO-MAZOYER, N.; LANDEAU, B.; PAPATHANASSIOU, D.; CRIVELLO, F.; ETARD, O. et al. Automated Anatomical Labeling of Activations in SPM Using a Macroscopic Anatomical Parcellation of the MNI MRI Single-Subject Brain. Online. *NeuroImage*. 2002, roč. 15, č. 1, s. 273-289. ISSN 1053-8119. Dostupné z: <https://doi.org/10.1006/nimg.2001.0978>. [cit. 2026-05-25].

Seznam symbolů a zkratek

AAL	angl. Automated Anatomical Labeling
ATP	adenosintrifostát
BIDS	angl. Brain Imaging Data Structure
BOLD	angl. Blood Oxygen Level Dependent
EPI	echo-planární akvizice, angl. Echo Planar Imaging
DVARs	angl. Derivative of Variance over Voxels
fMRI	funkční magnetická rezonance, angl. functional Magnetic Resonance Imaging
FD	angl. Framewise Displacement
FOV	zorné pole, angl. Field of View
FWHM	šířka jádra Gaussovského filtru, angl. Full Width at Half Maximum
GLM	obecný lineární model, angl. General Linear Model
MNI	angl. Montreal Neurological Institute
MRI	magnetická rezonance, angl. Magnetic Resonance Imaging
QC	kontrola kvality, angl. Quality Control
ROI	oblast zájmu, angl. Region of Interest
RMS	střední kvadratická hodnota, angl. Root Mean Square
RF	radiofrekvenční
SMS	multiband akvizice, angl. Simultaneous Multi-Slice
SNR	poměr signálu k šumu, angl. Signal-to-Noise Ratio
SNS	separace signálu od šumu, angl. Signal-to-Noise Separation
tSNR	časový poměr signálu k šumu, angl. Temporal Signal-to-Noise Ratio
TR	repetiční čas, angl. Repetition Time

6 Obsah elektronické přílohy

Elektronická příloha zahrnuje dva soubory. Prvním z nich je soubor `README.md`, který popisuje obsah hlavního skriptu, jeho požadavky a postup spuštění. Druhým z nich je hlavní skript `visualize_fmri.m`, který se spouští v prostředí MATLAB.