

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

**FAKULTA ELEKTROTECHNIKY
A KOMUNIKAČNÍCH TECHNOLOGIÍ**

Ústav telekomunikací

**Zvýšení rozlišení perfúzního zobrazování magnetickou
rezonancí pomocí komprimovaného snímání**

**Increasing Resolution in Perfusion Magnetic Resonance
Imaging Using Compressed Sensing**

ZKRÁCENÁ VERZE DIZERTAČNÍ PRÁCE

Ing. Marie Mangová

Obor:	Teleinformatika
Školitel:	doc. Mgr. Pavel Rajmic, Ph.D.
Oponenti:	
Datum obhajoby:	

KLÍČOVÁ SLOVA

Komprimované snímání, perfúzní zobrazování, zobrazování magnetickou rezonancí, zvýšení rozlišení, proximální algoritmy.

KEYWORDS

Compressed sensing, perfusion imaging, magnetic resonance imaging, increasing resolution, proximal algorithms.

Dizertační práce je uložena na oddělení vědy a výzkumu, Fakulta elektrotechniky a komunikačních technologií, Vysoké učení technické v Brně, Technická 12, 618 00 Brno.

© Marie Mangová, 2018

ISBN 80-214-
ISSN 1213-4198

OBSAH

1	ÚVOD	5
2	DOSAVADNÍ VÝVOJ PROBLEMATIKY	6
2.1	Zvýšení rozlišení perfúzního zobrazování v MR	6
3	VYUŽITÍ NOVÝCH APRIORNÍCH INFORMACÍ PRO CS	10
3.1	Lokální L+S model	10
3.2	Lokální L+S model zahrnující anatomickou informaci	12
3.3	Rozšíření mnohaměřítkového nízkohodnostního modelu	13
3.4	Model s omezenými diferencemi	15
4	REDUKCE VYCHÝLENOSTI ODHADŮ MRI REKONSTRUKCÍ	16
5	VLIV KOMPRIMOVANÉHO SNÍMÁNÍ NA PERFÚZNÍ PARAMETRY	19
6	ROZŠÍŘENÍ NA 3D DATA	20
7	ZÁVĚR	24
8	ABSTRAKT	30
9	ABSTRACT	30

1 Úvod

Magnetická rezonance (MR) je jednou z nejuniverzálnějších lékařských zobrazovacích technik – dokáže zobrazit jak anatomickou strukturu těla, tak i funkční a metabolické procesy uvnitř jednotlivých orgánů [30] a lze ji využít i pro zjištění molekulárního složení organismu [54].

Při zobrazování magnetickou rezonancí se využívá interakce silného magnetického pole s jádry vodíku, který je obsažen ve vodě. Voda tvoří dvě třetiny lidského těla, proto je MRI vhodná pro zobrazení prakticky všech měkkých tkání. Naopak není vhodná pro zobrazování kostí, ve kterých není téměř žádná voda. Jádra jsou excitována radiofrekvenčními pulzy (RF), díky kterým dojde k lokální změně magnetického pole (závislé na složení tkáně), a tím se v přijímací cívce indukuje napětí. V magnetické rezonanci je přidáno navíc ještě další slabší magnetické pole – tzv. gradientní pole, které se při měření mění, díky čemuž je možné zjistit, ze kterého místa přijatý signál pochází [28, 36]. Naměřená data (v tzv. k -prostoru) představují diskrétní vzorky integrální 2D (případně 3D) Fourierovy transformace.

Perfúzní zobrazování v magnetické rezonanci je důležitá lékařská diagnostická metoda vhodná pro diagnózu kardiovaskulárních a onkologických onemocnění [31]. Pacientovi je nitrožilně podána vhodná kontrastní látka (bolus) ve formě injekce nebo infúze. Díky kardiovaskulárnímu systému je kontrastní látka rozvedena dále do těla a její časové a prostorové rozložení může být sledováno v oblasti zájmu. Touto oblastí může být jednak nějaký orgán, tak i část orgánu nebo jenom samostatný voxel [39]. Časové průběhy koncentrace této látky v oblasti zájmu se nazývají perfúzní křivky. Analýzou perfúzních křivek podle zvoleného farmakokinetického modelu jsou získány odhady perfúzních parametrů nezbytných pro diagnózu [2, 27].

Běžně používanými modely perfúzního zobrazování jsou Toftsův model, který využívá dva parametry tkáně, a Toftsův rozšířený model [53], který využívá tři parametry tkáně. Pro odhad dalších perfúzních parametrů, jako je krevní tok a propustnost cév, je nutné využít složitější modely [53]. Avšak pro odhad perfúzních parametrů je klíčové zejména vysoké časové rozlišení. Při nedostatečném časovém rozlišení totiž není dostatečně zachycena dynamika kontrastní látky, a tak dochází ke zkreslení perfúzních parametrů. Současně je však nutné mít pro odhad i dostatečné prostorové rozlišení, které je ovšem zároveň limitované časovým rozlišením. Z tohoto důvodu je obvykle stanovené potřebné minimální časové rozlišení a adekvátně k tomu prostorové rozlišení, které bývá poměrně nízké (2D řez s malým prostorovým rozlišením).

2 Dosavadní vývoj problematiky

2.1 Zvýšení rozlišení perfúzního zobrazování v MR

Existuje několik metod, které umožňují zrychlení měření v MR. Tímto způsobem lze zvýšit časové rozlišení při zachování prostorového rozlišení. Tyto techniky zahrnují měření na nekartézských souřadnicích [4, 35, 36, 50, 56, 61], více přijímacími cívkami [15, 23, 47, 58] (tzv. paralelní zobrazování) nebo použití komprimovaného snímání [8, 17, 18, 21, 26, 36] (měření dat pod Nyquistovým kritériem). Tyto metody lze použít zvlášť, ale dají se rovněž kombinovat.

2.1.1 Nekartézské trajektorie

Protože v magnetické rezonanci měření lze interpretovat jako diskretizaci spojitě Fourierovy transformace měřeného objektu, není nutné snímat podél kartézských trajektorií, ale lze využít i jiné trajektorie. Nejčastěji využívané nekartézské trajektorie jsou:

- *spirální* – spirály začínající v počátku k -prostoru [36, 50], tj. na nulovém kmitočtu
- *radiální* – trajektorie představují přímky (tzv. projekce) procházející počátkem nebo polopřímky začínající v počátku souřadnic [4]

Úhel mezi každými dvěma sousedními přímkami radiálních souřadnic bývá často stejný, protože nejlépe pokryje celý k -prostor.

Při měření *dynamických* dat se často využívá tzv. *zlatého úhlu* [35, 56, 61] mezi sousedními přímkami (přibližně $111,24^\circ$ pro celé přímky a $137,51^\circ$ pro polopřímky). Při použití zlatého úhlu každá další projekce dělí největší úhel mezi dvěma sousedními projekcemi, přičemž sousední projekce svírají pouze tři různé úhly a v případě, že počet projekcí je roven nějakému Fibonaccimu číslu, pouze dvě. Tím má toto rozložení přímek suboptimální rozložení v k -prostoru, nejlepšího rozložení dosáhne, pokud počet projekcí v jednom snímku je roven Fibonaccimu číslu. Pro dynamické zobrazování má zlatý úhel tu výhodu, že je možné zvolit počet projekcí na jeden časový snímek až zpětně při rekonstrukci dat díky suboptimalitě rozložení, přičemž je výhodné použít jako počet projekcí Fibonacciho číslo. Tento postup není u statického zobrazování výhodný.

Snímání k -prostorových dat ve 3D lze rovněž několika způsoby. Pokud je měřeno pouze několik málo řezů, snímají se obvykle každý zvlášť některým z výše uvedeným 2D snímáním. Při více řezech už je ve třetím směru dostatečné rozlišení na to, aby se mohlo měřit přímo ve třírozměrném k -prostoru. I ve 3D kromě měření na kartézských souřadnicích lze měřit nekartézsky.

Jednodušší způsob využívá měření trajektorií, které leží v rovnoběžných rovinách (*stack of stars* [1, 3, 35], tj. stoh radiál nad sebou, či *spirály nad sebou* [25, 57]). Složitější způsob je měření přímo *3D obecnějšími trajektoriemi* (3D radiály) [29, 24, 46].

Rekonstrukce dat z nekartézských souřadnic

Zatímco výstupní obraz při snímání na kartézských souřadnicích je z naměřených dat získán pomocí zpětné 2D (případně 3D) diskrétní Fourierovy transformace, u jiných typů trajektorií jsou naměřená data také diskretizací spojitě Fourierovy transformace, ale již se nenacházejí na kartézské mřížce. Proto nelze přímo použít zpětnou diskrétní Fourierovu transformaci, ale data se nejprve musí interpolovat.

Podle použitých interpolačních technik se rozlišují jednotlivé metody rekonstrukce nekartézských dat.

- *Převzorkování do kartézských souřadnic vzhledem k novým souřadnicím* [44] (grid-driven regridding) – nová hodnota ležící na kartézských souřadnicích je určena nejbližšími okolními naměřenými daty. Ta jsou interpolována do kartézských souřadnic s využitím (bilineární) interpolace. Kvůli dosažení lepšího rozlišení výsledného obrazu je nová mřížka často dvakrát hustěji nadvzorkována než je požadováno rozlišení výstupního obrazu.
- *Převzorkování do kartézských souřadnic vzhledem k naměřeným datům* [40, 44] (data-driven regridding) – nová hodnota ležící na kartézských souřadnicích je určena nejbližšími okolními naměřenými daty. Ta jsou interpolována do kartézských souřadnic s využitím (bilineární) interpolace. Kvůli dosažení lepšího rozlišení výsledného obrazu je nová mřížka také často dvakrát hustěji nadvzorkována než je požadováno rozlišení výstupního obrazu.

Díky konvoluci je každý naměřený vzorek rozložený do kartézské mřížky nezávisle na ostatních a výstupní obraz je dán součtem všech těchto hodnot. Nicméně pro nekartézské vzorkování je typické, že vzorky nejsou rozmístěny rovnoměrně, ale s různou hustotou v k -prostoru, typicky se nejvíce vzorků nachází kolem počátku k -prostoru. To má za následek, že některý bod kartézské mřížky je tvořený součtem více vzorků než jiný. Pro získání výstupního obrazu bez artefaktů je tedy nutné využít tzv. *kompensaci hustoty*, tedy váhovat jednotlivé naměřené vzorky tak, aby po konvoluci s jádrem byly rovnoměrně rozdělené. Kompensaci hustoty lze získat pro jednoduché trajektorie přímým výpočtem, pro složitější je nutné ji odhadnout buď iterativním způsobem [40] nebo za použití Voroného diagramů [44].

- *Využití nerovnoměrné rychlé Fourierovy transformace (NUFFT)* [19, 45] – jedná se o speciální případ převzorkování do kartézských souřadnic vzhledem k naměřeným datům, kdy je konvoluční jádro a pořadí výpočtů optimalizováno tak, aby se výpočet provedl v co nejkratším čase a s co nejmenší chybou.

2.1.2 Paralelní zobrazování

Další technikou, jak zrychlit snímání a přitom ponechat rozlišení v čase, je tzv. paralelní zobrazování [15]. Při paralelním zobrazování je měřený signál snímán na více přijímacích cívkách rozmístěných na různých místech kolem snímaného objektu. Tímto způsobem je počet naměřených dat několikanásobný oproti snímání jednou cívkou. Je tedy možné snížit počet měřených trajektorií. Pro rekonstrukci existují dva typy metod:

- *Rekonstrukce v časové oblasti* – výsledný obraz je tvořen součtem obrazů z jednotlivých cívek vynásobených *citlivostmi*, což jsou prostorové funkce zohledňující rozmístění cívek kolem snímaného objektu. Čím je dané místo blíže k cívce, tím je citlivost vyšší. Citlivosti se dají jednak přímo měřit, nebo odhadovat. Tato skupina metod je označována jako SENSE (sensitivity encoding) [47]. Je obecně flexibilnější, ale její nevýhodou je nutnost znát citlivosti cívek, které se musí získávat pro každý měřený objekt zvlášť.
- *Rekonstrukce v k -prostoru* – tato skupina metod je označována jako GRAPPA (generalized autocalibrating partially parallel acquisitions) [23]. Nenaměřená k -prostorová data výsledného obrazu jsou odhadnuta jako lineární kombinace naměřených sousedních k -prostorových dat ze všech cívek. Váhy nutné pro lineární kombinaci jsou získány z tzv. kalibrační oblasti, což je většinou oblast kolem počátku k -prostoru, kde jsou známy všechny vzorky. Výhodou této metody je, že není nutné znát citlivosti cívek a výsledný obraz je získán jenom z naměřených dat. Nevýhodou je menší přesnost.

Výhody obou metod spojuje metoda ESPIRiT [58]. ESPIRiT odhaduje citlivosti na základě kalibrační oblasti naměřených k -prostorových dat.

2.1.3 Komprimované snímání

Komprimované snímání (compressed sensing, compressive sampling, CS) [8] rekonstruuje signál z podstatně menšího počtu vzorků než klasické rekonstrukce, kde se počet vzorků řídí Nyquistovým kritériem. Komprimované snímání je možné provádět pouze díky nějakým apriorním informacím o měřeném signálu.

V MRI jednotlivé naměřené vzorky představují Fourierovy koeficienty (k -prostorová data) [36], a to jednak na kartézských souřadnicích, tak i jiných nekartézských trajektoriích, kterých stačí pro rekonstrukci obrazu méně než klasicky. Výběr trajektorií ale nemůže být libovolný, protože v k -prostoru nemohou být jakékoliv trajektorie kvůli fyzikálním a fyziologickým omezením.

Počet měření v MRI pomocí komprimovaného snímání je závislý na tzv. koherenci mezi Fourierovou transformací a apriorními znalostmi o signálu [6]. Využití komprimovaného snímání tedy umožní zrychlit měřicí proces (pouze v případě statických snímků) nebo zvýšit rozlišení, rekonstrukce ale již nebude lineární, proto bude trvat déle.

Obecně lze rekonstrukci signálu napsat jako optimalizační problém:

$$\min_{\mathbf{M}} f(\mathbf{M}) \quad \text{vzhledem k} \quad E(\mathbf{M}) = \mathbf{Y}, \quad (1)$$

kde $\mathbf{Y}$ jsou naměřená data (vektor v případě statického snímku, matice v případě dynamických dat), $\mathbf{M}$ je hledaný výstupní obraz (sekvence při dynamických datech) a E je lineární operátor, který modeluje podvzorkovanou spojitou Fourierovu transformaci (na kartézských či obecných trajektoriích), při použití více cívek případně složenou s citlivostmi. Účelová funkce $f(\mathbf{M})$ představuje matematický zápis apriorních znalostí o měřených datech, které se také někdy říká regularizace.

Optimalizační úlohu komprimovaného snímání (1) je možné řešit různými způsoby. Obvykle se v měření vyskytuje šum, a proto se úloha (1) změní na:

$$\min_{\mathbf{M}} \frac{1}{2} \|E(\mathbf{M}) - \mathbf{Y}\|_2^2 + \lambda f(\mathbf{M}), \quad (2)$$

kde $\|\cdot\|_2$ představuje Frobeniovu normu, která zaručí konzistentnost dat s měřením. Regularizační parametr $\lambda > 0$ je volitelný parametr, kterým je určen charakter řešení. Je důležité tento parametr správně nastavit, jinak můžeme dostat řešení s artefakty. Když je λ moc velké, rekonstrukce je tzv. přeregularizovaná a neodpovídá naměřeným datům. Naopak při nastavení λ na velmi nízkou hodnotu se regularizace prakticky neprojeví a v rekonstrukci se nacházejí artefakty způsobené podvzorkováním dat.

Pokud je $f(\mathbf{M})$ konvexní funkce (což všechny dále zmíněné příklady splňují), je celou úlohu (2) možné řešit algoritmy konvexní optimalizace [5]. Člen $f(\mathbf{M})$ není často diferencovatelný, proto se také řada prací specializovala na typy algoritmů vhodné pro tento druh problémů. Často využívané jsou proximální metody [9] (proximálně-gradientní metoda [48], Douglas-Rachfordova metoda [9], obecný proximální algoritmus [10]) či metoda multiplikátorů střídajících směr (ADMM) [5, 43].

Typy apriorních znalostí $f(\mathbf{M})$ – modely CS v MRI

- *Řídkost ve vhodné reprezentaci* – často víme, že měřený signál je řídký v nějaké bázi či framu (v tzv. zřidšující transformaci), tj. má málo nenulových souřadnic v dané bázi či framu. MR obrazy mají řídké waveletové koeficienty [26] nebo mají řídké shearletové koeficienty [34]. S uvažováním dynamiky dat (jako je tomu při perfúzi) můžeme předpokládat i řídkost v časovém směru (např. po Fourierově transformaci). Řídkost lze dosáhnout volbou $f(\mathbf{M}) = \|\mathcal{A}(\mathbf{M})\|_1$, kde $\mathcal{A}$ představuje zřidšující transformaci (analýzu) a $\|\cdot\|_1$ je ℓ_1 norma, tj. součet absolutních hodnot všech prvků matice [48].
- *Nízká maticová hodnota* – předpoklad, že perfúzní parametry v jedné tkáni jsou podobné, se dá matematicky popsat jako nízká hodnota tzv. Casoratiho matice, což je matice, kde každý časový snímek je vektorizován do sloupce matice, tj. každý sloupec této matice představuje jeden časový okamžik a v řádcích se nacházejí přímo perfúzní křivky [16]. Nízkou maticovou hodnotu lze aproximovat volbou $f(\mathbf{M}) = \|\mathbf{M}\|_*$, kde $\|\cdot\|_*$ je nukleární norma matice, což je součet singulárních čísel matice [7, 21].

- *Totální variace* – průběh perfúzních křivek lze považovat za hladký bez velkého množství prudkých změn. Tuto apriorní informaci je možné matematicky vyjádřit jako 1D totální variaci [56], tj. $f(\mathbf{M}) = \sum_{i=1}^{n-1} \|\mathbf{M}_i\|_{\text{tv}}$, kde $\mathbf{M}_i$ představuje perfúzní křivku (i -tý řádek Casoratiho matice), přičemž totální variace je definována jako $\|\mathbf{x}\|_{\text{tv}} = \sum_{t=1}^{T-1} |x_{t+1} - x_t|$, kde T je celkový počet měřených časových okamžiků. Totální variace se také dá chápat jako ℓ_1 norma konečných diferencí. Podobně to lze předpokládat i o výsledném obrazu za použití 2D totální variace [35].

Složitější modely v perfúzním zobrazování kombinují více apriorních znalostí dohromady. Článek [62] předpokládá, že Casoratiho matice má zároveň nízkou hodnotu po blocích a je řídká ve vhodné reprezentaci (*lokální L&S model*). Ještě lepších výsledků dosahuje [42], který dynamická data uvažuje jako součet nízkohodnostní matice a matice s řídkými změnami na perfúzních křivkách (*globální L+S model*). Tento přístup je robustnější vzhledem k šumu.

Mnohaměřítkový rozklad na nízkohodnostní bloky [41] zobecňuje myšlenku rozkladu na nízkohodnostní a řídkou složku v L+S modelu. Namísto rozložení dat na dvě matice – jedné v jemném měřítku (řídká matice) a druhé v hrubém měřítku (nízkohodnostní matice) – tento model využívá více dekompozičních matic v různých měřítkách. Tento model je více adaptivní k datům, protože podobnosti v datech se mohou nacházet na různých úrovních. Avšak v tomto modelu chybí zahrnutý měřicí operátor, využití tedy lze nalézt až na obrazových datech, ne přímo na naměřených datech z MRI.

3 Využití nových apriorních informací pro CS


3.1 Lokální L+S model

Navržený lokální L+S model [14] propojuje výhody globálního L+S modelu a lokálního L&S modelu. Tento model se snaží rozložit hledanou rekonstrukci na dvě matice $\mathbf{L}$ a $\mathbf{S}$ jako je tomu v globálním L+S modelu, což přináší výhodu větší odolnosti vůči šumu. Navíc matici $\mathbf{L}$ modeluje jako nízkohodnostní po blocích jako je tomu v lokálním L&S modelu, což přináší větší adaptivitu na data. Lokální L+S model lze tedy zapsat jako následující optimalizační problém, kde hledaná rekonstrukce $\mathbf{M} = \mathbf{L} + \mathbf{S}$:

$$\min_{\mathbf{L}, \mathbf{S}} \frac{1}{2} \|E(\mathbf{L} + \mathbf{S}) - \mathbf{Y}\|_2^2 + \lambda_L \sum_{i=1}^{N_b} \|B_i \mathbf{L}\|_* + \lambda_S \|\mathcal{A}(\mathbf{S})\|_1, \quad (3)$$

kde B_i je operátor vybírající blok i z matice $\mathbf{L}$ a N_b je počet bloků.

Tento model byl ověřený na simulovaných datech – perfúzním fantomu, který byl pro tyto účely vytvořený dynamickou modifikací Shepp-Loganova fantomu [52]. Pro účely simulace byl využitý perfúzní fantom o rozměrech $100 \times 100 \text{ px} \times 100$ časových snímků, do jejichž k -prostoru byl přidán aditivní komplexní gaussianský šum [59] se



Obrázek 1: (a) Srovnání globálního a lokálního L+S modelu a (b) srovnání lokálního L+S modelu a lokálního L&S modelu – závislost SNR na procentech naměřených koeficientů.

směrodatnou odchylkou 0,05, což modeluje šum obsažený v měření. Pro simulaci měření byly použity radiální trajektorie začínající v počátku k -prostoru s náhodně vygenerovanými směrnici pro každou projekci zvlášť.


Kromě rekonstrukce pomocí lokálního L+S modelu byly také pro srovnání provedeny rekonstrukce pomocí globálního L+S modelu a lokálního L&S modelu. Všechny jmenované optimalizační algoritmy byly implementovány v Matlabu a pro jejich řešení byl využit proximální gradientní algoritmus [48].

Pro lokální metody byly použity nepřekrývající se čtvercové bloky s různými délkami stran. Regularizační parametry λ_L , λ_S byly experimentálně určeny tak, aby dávaly co nejvyšší hodnotu SNR. Jejich nastavení závisí na použité metodě, rozměru bloků a rozlišení. Jejich konkrétní hodnoty jsou pak uvedeny u grafu výsledků (viz obr. 1(a) a 1(b)). Ve všech případech byla jako ukončovací kritérium zvolena relativní odchylka v aktuálním řešení menší než 10^{-5} .

Nejprve byla srovnána rekonstrukce perfúzních křivek pomocí globálního a lokálního L+S modelu pro různé velikosti bloku a různé procento naměřených koeficientů. Úspěšnost rekonstrukce byla měřena pomocí SNR mezi rekonstrukcí a vytvořeným perfúzním fantomem. Výsledky byly zakresleny do grafu 1(a).

Rozdělení na bloky v lokálním L+S modelu přineslo zlepšení SNR. Z grafu je také vidět, že na kvalitu rekonstrukce má vliv velikost bloku. Optimální velikost bloku závisí zřejmě na daném měřeném objektu – lepších výsledků je dosaženo při použití dostatečně malých bloků na to, aby obsahovaly pouze tkáň s podobnými perfúzními parametry, ale zase natolik velké, aby regularizovaly dostatečně velkou oblast. Z výsledků experimentu vyplývá, že pro perfúzní fantom je optimální velikost bloků 10×10 px pro méně podvzorkovaná data a 15×15 px pro velmi podvzorkovaná data.

Dále byl porovnán lokální L+S model (s optimální velikostí bloku 10×10 px) a lokální L&S model s různě nastavenými velikostmi bloku. Výsledky srovnání jsou zobrazeny na obr. 1(b). Zde je možné vidět, že lokální L+S model má lepší SNR ve všech případech nastavení velikosti bloku v L&S modelu (tedy i pro nejlepší volbu velikosti bloku 10×10 px nebo 15×15 px).



Obrázek 2: (a) Anatomický snímek a (b) označené anatomické oblasti využívané při rekonstrukci.

3.2 Lokální L+S model zahrnující anatomickou informaci

Dalším navrženým vylepšením lokálního L+S modelu (3) je využití anatomické informace měřeného objektu při tvorbě bloků pro nízkou hodnotu – místo čtvercových bloků použití bloků libovolných tvarů vytvořených podle anatomie. Toto vylepšení bylo prezentováno na konferenci [11]. Formálně tato úloha má stejnou podobu:

$$\min_{\mathbf{L}, \mathbf{S}} \frac{1}{2} \|E(\mathbf{L} + \mathbf{S}) - \mathbf{Y}\|_2^2 + \lambda_L \sum_{i=1}^{N_b} \|B_i \mathbf{L}\|_* + \lambda_S \|\nabla_t \mathbf{S}\|_1. \quad (4)$$


Jediný rozdíl je zde v tom, že za zřídňující transformaci byly v tomto případě zvoleny difference v časovém směru ∇_t , tj. dohromady s ℓ_1 normou se jedná o 1D totální variaci na perfúzní křivky. Operátory B_i tentokrát nevybírají čtvercové bloky, ale bloky tvaru dle anatomie.

Anatomickou informaci lze získat například z prekontrastních skenů, které se obvykle měří při perfúzním zobrazování. Odsud lze nasegmentovat daný měřený objekt na jednotlivé anatomické části. To lze buď ruční segmentací, anebo některou ze strojových segmentací. V oblasti strojové segmentace se jako slibný směr zdá navržený v [49], kde (zatím pouze v 1D) se jednotlivé oblasti modelují jako polynomiální a hranice mezi nimi se vyskytují pouze řídce.

Tento algoritmus byl aplikovaný na reálná dynamická in-vivo data řezu hlavou potkana¹. Při měření bylo použito radiálních trajektorií se zlatým úhlem, přičemž na každé radiále bylo naměřeno 128 vzorků. Bylo přitom využito čtyřkanálové povrchové hlavové měřicí pole cívek.

Z anatomického snímku 2(a) byly ručně nasegmentovány bloky odpovídající vybraným anatomickým oblastem 2(b). Výsledky byly porovnány s rekonstrukcí bez anatomické informace, tj. s globálním L+S modelem. Pro rekonstrukce bylo využito 21 radiálních trajektorií na snímek (to znamená časové rozlišení 0,357 s) a rozměr rekonstruovaných snímků byl nastaven na 128×128 pixelů. Při rekonstrukci bylo

¹Ústav přístrojové techniky, AV ČR



Obrázek 3: Perfúzní mapy parametru času do maxima: (a) rekonstrukce bez anatomické informace a (b) s anatomickou informací. Barevné škály představují čas (pořadí časového snímku), kdy nastane maximum.

využito citlivostí cívek odhadnutých pomocí ESPIRiT² z prekontrastních kartézských měření.

Rekonstrukční úlohy byly řešeny v Matlabu pomocí 20 iterací proximálního gradientního algoritmu [48]. Regularizační parametry byly experimentálně nastaveny na $\lambda_L = 0,025 \cdot \sigma_1$ (σ_1 je největší singulární číslo aktuální matice $\mathbf{L}^{(k)}$) a $\lambda_S = 0,5$ u obou metod.

Výsledné perfúzní mapy parametru času do maxima obou metod jsou zobrazeny na obr. 3. Je zde vidět, že s využitím anatomické informace (obr. 3(b)) je tento parametr lépe zachycený ve stejném typu tkáně než bez jejího využití (obr. 3(a)), kde nejsou jasně zřetelné oblasti s podobnou hodnotou tohoto parametru a dochází zde k jejich zkreslení (zejména ve žvýkacích svalech).

3.3 Rozšíření mnohaměřítkového nízkohodnostního modelu

Navržené rozšíření a modifikace mnohaměřítkového rozkladu na matice s lokálně nízkou hodnotou publikované v [38] obsahuje měřicí operátor, díky kterému je tento model vhodný pro rekonstrukci perfúzních dat. Formálně má tento model tvar:


$$\min_{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_L} \frac{1}{2} \left\| E \left(\sum_{i=1}^L \mathbf{X}_i \right) - \mathbf{Y} \right\|_2^2 + \lambda \sum_{i=1}^L \sum_{j=1}^{N_i} \lambda_i \left\| B_i^j \mathbf{X}_i \right\|_*. \quad (5)$$

V úloze představuje λ globální regularizační parametr, díky kterému je možné zachovat poměr doporučených hodnot λ_i z [41].

Navržená metoda byla ověřena na reálných dynamických in-vivo datech řezu hlavou potkana³. Při rekonstrukci bylo na jeden časový snímek použito 21 trajektorií (se zlatým úhlem) a výsledná velikost jednotlivých snímků byla 128×128 pixelů. Citlivosti cívek byly odhadnuty pomocí ESPIRiT.

²http://people.eecs.berkeley.edu/~mlustig/software/SPIRiT_v0.3.tar.gz – v tomto programovém balíku je implementována rovněž NUFFT of Fesslera [19]

³Ústav přístrojové techniky, AV ČR




Obrázek 4: Porovnání časových snímků (zleva doprava: 1., 200. a 400.) zrekonstruovaných pomocí globálního L+S modelu (nahore) a mnohaměřítkového nízkohodnostního modelu (dole).

Pro porovnání byla nejprve perfúzní MRI data zrekonstruována pomocí globálního L+S modelu. Parametry byly přitom nastaveny experimentálně na $\lambda_L = 0,025 \cdot \sigma_1$ (σ_1 je největší singulární číslo matice $\mathbf{L}$) a $\lambda_S = 0,1$. Jako zřídšující transformace $\mathcal{A}$ byly použity konečné difference. Pro rekonstrukci bylo použito 20 iterací proximálního gradientního algoritmu [48]. Rekonstrukce několika časových snímků je zobrazena na obr. 4 vlevo. Červená kolečka zde označují místa, ze kterých jsou vykresleny perfúzní křivky na obr. 5(a) a 5(b).

Série snímků z perfúzní MRI byla dále zrekonstruována pomocí mnohaměřítkového nízkohodnostního modelu (5). Parametry λ_i byly přitom nastaveny jako v [41] a λ experimentálně na 0,5. Bylo přitom použito pět měřítek rozkladu se čtvercovými bloky o rozměrech $1 \times 1, 4 \times 4, 16 \times 16, 64 \times 64$ a 128×128 px v prostoru a všemi časovými snímky (v Casoratiho matici to odpovídá $1^2, 4^2, 16^2, 64^2$ a 128^2 řádkům). Pro rekonstrukci bylo použito 20 iterací proximálního gradientního algoritmu [48].

Rekonstrukci několika časových snímků lze vidět na obr. 4 vpravo. Červená kolečka označují místa korespondující s perf. křivkami zobrazenými na obr. 5(a) a 5(b).



Obrázek 5: Rekonstruované perfúzní křivky s využitím globálního L+S modelu a mnohaměřítkového nízkohodnostního modelu (multi low-rank): (a) z červeně zakroužkovaného horního pixelu na obr. 4 (ve spánkovém svalu) (b) z červeně zakroužkovaného dolního pixelu na obr. 4 (v mozku).

Když porovnáme tuto novou metodu s L+S metodou, je možné si všimnout, že navržený algoritmus snižuje artefakty kolem hlavy potkana (obr. 4) v prostorové doméně a navíc zviditelňuje některé anatomické struktury. Když se podíváme do časového směru, lze vidět, že perfúzní křivky (obr. 5(b)) jsou hladší, protože neobsahují „falešné skoky“, které jsou naopak přítomny ve výsledcích L+S modelu (obr. 5(a)). Bohužel ale mnohoměřítkový nízkohodnostní model snižuje hodnoty perfúzních křivek (obr. 5(a)) kvůli měkkému prahování na více úrovních v průběhu iterací. Také pokud mají perfúzní křivky rychlý náběh, mnohaměřítkový nízkohodnostní model zkresluje tento náběh (obr. 5(b)), což může představovat problém.


3.4 Model s omezenými diferencemi

Řídkost časových gradientů (tj. totální variace v časovém směru) může vést ke skokovým artefaktům na perfúzních křivkách. Navržený (dosud nepublikovaný) model se snaží tomuto jevu předejít tím, že omezí maximální velikost difference. Tento model se také snaží rozložit hledanou rekonstrukci na dvě složky **L** a **S**. Zatímco složka **L** je opět nízkohodnostní, na složku **S** se vztahuje navržené omezení maximální velikosti časové difference měřené pomocí ℓ_∞ normy. Navržený model s omezenými diferencemi je ve tvaru:

$$\min_{\mathbf{L}, \mathbf{S}} \frac{1}{2} \|E(\mathbf{L} + \mathbf{S}) - \mathbf{Y}\|_2^2 + \lambda_L \|\mathbf{L}\|_* + \iota_{\{\mathbf{X}: \|\nabla_t \mathbf{X}\|_\infty \leq \lambda_S\}}(\mathbf{S}). \quad (6)$$


Hledaná rekonstrukce je potom rovněž $\mathbf{M} = \mathbf{L} + \mathbf{S}$.

Navržená metoda byla ověřena rovněž na reálných dynamických in-vivo datech řezu hlavou potkana⁴. Při rekonstrukci bylo na jeden časový snímek použito 21 trajektorií (se zlatým úhlem) a výsledná velikost jednotlivých snímků byla 128×128 pixelů. Citlivosti cívek byly odhadnuty pomocí ESPIRiT. Pro rekonstrukci bylo použito 50 iterací obecné proximální metody [10]. Regularizační parametry byly nastaveny na $\lambda_L = 1$ a $\lambda_S = 0,001$.



Obrázek 6: První časový snímek myši zrekonstruované a) pomocí regriddingu a b) pomocí modelu s omezenými diferencemi.

⁴Ústav přístrojové techniky, AV ČR



Obrázek 7: Průběh kontrastní látky z červeně označeného pixelu z obr.6(b). Modrá křivka je zrekonstruovaná pomocí regriddingu a červená pomocí modelu s omezenými diferencemi.

Na obr. 6(a) je zobrazena rekonstrukce prvního časového snímku pomocí regriddingu a vedle něj na obr. 6(b) je tento snímek rekonstruovaný pomocí navrženého modelu s omezenými diferencemi. Na tomto obrázku je červeným kroužkem vyznačen pixel, ze kterého je vykreslena perfúzní křivka na obr. 7 společně pro srovnání i pro rekonstrukci pomocí regriddingu. Perfúzní křivky z více míst a zároveň více zrekonstruovaných časových snímků pomocí modelu s omezenými diferencemi jsou vidět na obr. 7.

Z uvedených obrázků je vidět, že regridding při tomto časovém rozlišení obsahuje množství pruhových artefaktů a je s těžší použitelný. Naproti tomu metoda s omezenými diferencemi je schopná tohoto rozlišení dosáhnout (to platí i pro předešlé CS metody). Při porovnání perfúzních křivek je vidět, že zachovávají stejný časový průběh jako při samotné rekonstrukci pomocí regriddingu a zároveň redukují množství šumu. Oproti regularizaci s totální variací v časovém směru tato metoda přinesla slibovanou redukci skokových artefaktů na perfúzních křivkách.

4 Redukce vychýlenosti odhadů MRI rekonstrukcí

Optimalizační problém komprimovaného snímání (2) lze chápat jako metodu nejmenších čtverců (první člen v účelové funkci) penalizovanou apriorní informací. Je známo, že výsledkem metody nejmenších čtverců je nestranný odhad [60] (odhad nezatížený systematickou chybou). Avšak v úloze komprimovaného snímání (2) díky přidání dalšího členu $f(\mathbf{M})$ řešení už není nestranným odhadem.

Pro zlepšení vychýlenosti již získaného odhadu se používá tzv. debiasing [20, 22]. V případě komprimovaného snímání využívajícího řídkosti představuje debiasing další odhad metodou nejmenších čtverců, přičemž neznámými jsou pouze prvky na pozicích z právě nalezeného nosiče matice. Vyřešením této úlohy je pak získán odhad se

zmenšenou vychýleností.

Debiasing při použití nukleární normy je už o něco komplikovanější [37]. Vyřešením úlohy komprimovaného snímání

$$\hat{\mathbf{L}} = \arg \min_{\mathbf{L}} \frac{1}{2} \|\mathbf{Y} - E(\mathbf{L})\|_2^2 + \lambda \|\mathbf{L}\|_* \quad (7)$$

je získán singulární rozklad matice $\hat{\mathbf{L}} = \hat{\mathbf{U}} \text{diag}(\hat{\sigma}_1, \dots, \hat{\sigma}_r) \hat{\mathbf{V}}^*$, $\text{diag}(\hat{\sigma}_1, \hat{\sigma}_2, \dots, \hat{\sigma}_r)$ je diagonální matice, která má na prvních r pozicích na hlavní diagonále $\hat{\sigma}_1, \hat{\sigma}_2, \dots, \hat{\sigma}_r$, ostatní prvky jsou nulové. Úloha nalezení odhadu se zmenšenou vychýleností je pak

$$\min_{\substack{\sigma_1, \sigma_2, \dots, \sigma_r \geq 0 \\ \sigma_i \in \mathbb{R}}} \frac{1}{2} \left\| \mathbf{Y} - E(\hat{\mathbf{U}} \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r) \hat{\mathbf{V}}^*) \right\|_2^2, \quad (8)$$

odkud jsou získána nenulová singulární čísla $\sigma_1, \sigma_2, \dots, \sigma_r$ a odhad je pak roven $\hat{\mathbf{U}} \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r) \hat{\mathbf{V}}^*$.

K řešení úlohy (7) lze využít proximální gradientní algoritmus [48]. V tomto případě se proximální gradientní algoritmus skládá ze dvou kroků v každé iteraci: gradientního kroku vzhledem k datovému členu a měkkého prahování singulárních čísel. V navrženém řešení se navíc provádí v každé iteraci debiasing. Po každé iteraci (k) je známý aktuální SVD rozklad $\mathbf{L}^{(k)} = \mathbf{U}^{(k)} \text{diag}(\sigma_1^{(k)}, \dots, \sigma_r^{(k)}) \mathbf{V}^{(k)*}$. Debiasing je pak počítaný pro právě nalezené singulární matice $\mathbf{U}_r^{(k)}, \mathbf{V}_r^{(k)}$, které jsou omezené pouze na pozice odpovídající nenulovým singulárním číslům. Formálně zapsáno


$$\min_{\substack{\sigma_1, \sigma_2, \dots, \sigma_r \geq 0 \\ \sigma_i \in \mathbb{R}}} \frac{1}{2} \left\| \mathbf{Y} - E(\mathbf{U}_r^{(k)} \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r), \mathbf{V}_r^{(k)*}) \right\|_2^2. \quad (9)$$

Tento podproblém lze rovněž řešit iterativně opakováním gradientního kroku vzhledem k σ_i a projektováním výsledku na reálné nezáporné hodnoty.


Koncept debiasingu byl nejprve ověřovaný na simulovaných datech perfúzního fantomu o rozměrech $100 \times 100 \text{ px} \times 100$ časových snímků, přičemž bylo v simulaci využito 100 radiál na snímek.

Vliv debiasingu nízké hodnoty (8) na perfúzní fantom i perfúzní data byl prezentován v [12] a [13]. Pro rekonstrukci dat implementovaných v Matlabu bylo použito 20 iterací proximálního gradientního algoritmu spolu s 10 iteracemi debiasingu (po rekonstrukci/vnitřními iteracemi).

Pro rekonstrukci perfúzního fantomu pomocí nízkohodnostního modelu (7) byl nastavený regularizační parametr $\lambda = 3,525$. Výsledná rekonstrukce měla SNR 26,46 dB a s následným debiasingem se SNR snížilo na 22,86 dB. Ukázalo se tedy jako bezvýznamné použití debiasingu až po nalezení rekonstrukce pomocí komprimovaného snímání. Pokud v nalezených singulárních vektorech příslušných nenulovým singulárním číslům byly obsaženy složky odpovídající šumovému pozadí, debiasing je ještě zvětšil.



(a)




(b)

Obrázek 8: Několik řezů v čase při použití (a) pouze CS, (b) současného použití CS a debiasingu.

Při použití sdruženého algoritmu dohromady s debiasingem se podařilo dosáhnout SNR 27,21 dB při nastavení $\lambda = 12$. Bylo tedy zjištěno, že je debiasing vhodné použít při každé iteraci optimalizační úlohy CS, čímž se vždy přepočítala singulární čísla příslušná aktuálně nalezeným významným singulárním vektorům. Tímto způsobem byly v nalezených výsledných singulárních vektorech potlačeny složky odpovídající šumu a výsledky vykazovaly zlepšení oproti využití samotného komprimovaného snímání.

Dále proběhlo ověření na reálných perfúzních břišních datech bez zadržení dechu⁵. Měření bylo provedeno s dvanáctikanálovým přijímacím cívkovým polem. Měřené trajektorie byly radiální se zlatým úhlem. Pro rekonstrukci bylo využito 21 radiálních trajektorií na snímek, což odpovídá časovému rozlišení 2,75 s (pomalejší dynamika u klinických dat). Výsledné rozměry snímků byly 256×256 px.

Obrázek 8 ukazuje porovnání rekonstrukcí jednoho řezu v čase. Obr. 8(a) zobrazuje



(a)

(b)

Obrázek 9: Střední hodnota μ se zobrazenými trojnásobky směrodatné odchylky σ perfúzních křivek v aortě při použití (a) pouze CS, (b) současného použití CS a debiasingu.

⁵<http://cai2r.net/resources/software/ls-reconstruction-matlab-code>

výsledky rekonstrukce pomocí samotného nízkohodnostního modelu (7) při nastavení regularizačního parametru $\lambda = 0,005 \cdot \sigma_1$ a obr. 8(b) sdruženého algoritmu s debiasingem s využitím $\lambda = 0,025 \cdot \sigma_1$. Obr. 9 ukazuje odpovídající střední hodnoty μ perfúzních křivek v aortě se zobrazenými trojnásobky směrodatné odchylky σ při použití perfúzní křivky v aortě (obr. 9(a) výsledky samotné nízkohodnostní rekonstrukce a obr. 9(b) navíc se sdruženým debiasingem). S použitím debiasingu uvnitř iteračního procesu se perfúzní křivky vyznačují vyšším prvním maximem a druhé maximum je také mnohem viditelnější. Také ostatní oblasti v řezu vykazují větší kontrast.

5 Vliv komprimovaného snímání na perfúzní parametry

Doposud všechny rekonstrukce perfúzních dat pomocí komprimovaného snímání končily ve fázi získání časové série prostorových obrazů. Dalším důležitým krokem je však následná perfúzní analýza, při které se získávají perfúzní parametry, pomocí kterých lze poté stanovovat diagnózu. Výsledky zde uvedené byly publikovány v [32].


Vliv komprimovaného snímání na perfúzní parametry byl zkoumán na reálných dynamických in-vivo datech řezu hlavou potkana⁶. Citlivosti cívek byly odhadnuty pomocí ESPIRiT.

Nejprve byla data pro srovnání rekonstruována pomocí regriddingu o rozměru 128×128 px s využitím 54 projekcí na snímek a 21 projekcí na snímek. Jako další byl při rekonstrukci využit L+S model s parametry $\lambda_L = 0,025 \cdot \sigma_1$ a $\lambda_S = 0,1$. Rozměry výsledných snímků byly 128×128 px a bylo použito 21 projekcí na snímek. Jako zřidšující transformace $\mathcal{A}$ byly využity časové difference. Na rekonstrukci pomocí L+S modelu bylo použito 20 iterací proximálního gradientního algoritmu. Z této rekonstrukce byl pro perfúzní analýzu využit pouze každý třetí snímek, což dává časové rozlišení 1,071 s, která je dostatečná pro perfúzní analýzu. Tímto způsobem teoreticky ještě navíc zbývá čas, za který by se daly nasnímat další dva jiné řezy (pokud by se zkrátila doba TR, tak dokonce více).

Celá perfúzní analýza byla provedena v PerfLabu. Zrekonstruovaná sekvence byla nejprve převedena na časové koncentrace kontrastní látky. Arteriální vstupní funkce (AIF) byla odhadnuta s využitím multikanálové slepé dekonvoluce [51] z perfúzních křivek z oblastí manuálně vybraných z oblasti mozku. Reziduální funkce tkáně (IRF) byla modelována čtyřparametrovým modelem (dvoukompartimentový model tkáně [33]). Perfúzní analýza byla provedena pixel po pixelu, čímž byly získány mapy perfúzních parametrů.

Ukázalo se, že rekonstrukce pomocí regriddingu z 54 projekcí na snímek dává ucházející obrazovou kvalitu a perfúzní křivky s množstvím šumu. Rekonstrukce pomocí regriddingu s 21 projekcemi na snímek obsahuje již množství artefaktů v obraze i v perfúzních křivkách. Rekonstrukce pomocí komprimovaného snímání (L+S model) vedla k nejlepšímu prostorovému obrazu a perfúzním křivkám, kde je nejvíce

⁶Ústav přístrojové techniky, AV ČR



Obrázek 10: Mapy perfúzních parametrů – průtok krve (CBF), objem krve (CBV), střední doba průchodu (MTT) a míra propustnosti povrchu cév (PS): rekonstrukce pomocí regriddingu s 54 projekcemi na snímek (vlevo), rekonstrukce pomocí regriddingu s 21 projekcemi na snímek (uprostřed) a rekonstrukce pomocí komprimovaného snímání (L+S model) s 21 projekcemi na snímek (vpravo).

potlačený šum.

Výsledné perfúzní mapy pro všechny rekonstrukce jsou zobrazeny na obr. 10. Rekonstrukce pomocí regriddingu z 54 projekcí na snímek dává prostorově odpovídající mapy perfúzních parametrů s ohraničenými oblastmi jednotlivých tkání. Rekonstrukce pomocí regriddingu s 21 projekcemi na snímek má mapy zkreslené. Rekonstrukce pomocí L+S modelu vedla k nejlepším perfúzním mapám obsahujícím nejméně šumu.

6 Rozšíření na 3D data

Doposud byly všechny zmíněné metody rekonstrukce testovány na 2D datech. V tomto případě je ještě možné provádět relevantní perfúzní analýzu na rekonstrukcích pomocí klasického regriddingu při použití časového rozlišení okolo jedné sekundy na preklinických experimentálních datech z potkanů a myší. Při 3D snímání však tento postup již není možný, protože nelze klasickými rekonstrukčními metodami dosáh-

nout požadovaného časového rozlišení při zachování rozumného prostorového rozlišení. Proto ani při měření 3D perfúzních dat nejsou známy správné hodnoty rekonstrukce („ground truth“) při dostatečném časovém a prostorovém rozlišení.

Ověřit relevantnost perfúzních parametrů na 3D datech zrekonstruovaných pomocí CS je možné na sadě dvou perfúzních měření, kdy jsou data nejprve nasnímaná pouze v jednom 2D řezu a poté několik řezů ve 3D, přičemž jeden z řezů odpovídá 2D měření. Pak lze porovnat výsledky perfúzní analýzy pro 2D data zrekonstruovanými pomocí regriddingu a ze stejného řezu ze 3D dat zrekonstruovaných pomocí CS se stejným časovým rozlišením. Data ve 2D tak mohou být považována jako základní rekonstrukce („ground truth“), ke které je možné výsledky ze 3D porovnat. Tato metoda ověření ještě nebyla dosud publikována.

Byla naměřena série reálných dynamických in-vivo dat šesti laboratorních myší⁷, kterým byly podkožně implantovány nádorové buňky do slabiny levé zadní nohy. Pro každou myš byly naměřeny dvě série perfúzních měření – jedno ve 2D a jedno ve 3D. Bylo přitom využito čtyřkanálové povrchové hlavové měřicí pole cívek. Tato data byla měřena radiálním snímáním se zlatým úhlem, přičemž na radiále bylo naměřeno 128 vzorků. Data ve 3D byla měřena jako stoh radiál se zlatým úhlem nad sebou, přičemž všechny radiály byly stejně natočeny. Ve 3D bylo na každé radiále také naměřeno 128 vzorků a celkem bylo naměřeno 25 řezů, přičemž jeden z řezů byl totožný s řezem měřeným pomocí 2D sekvence.

Nejprve byla zrekonstruována 2D data pomocí regriddingu. Při rekonstrukci bylo použito 66 projekcí na snímek, což odpovídá časovému rozlišení 0,99 s. Výsledná velikost jednotlivých snímků byla 128×128 pixelů.


Dále byla rekonstruována 3D data. Za prvé byla rekonstruována pomocí modelu s omezenými diferencemi (6), který byl upravený pro 3D data (úprava spočívala zejména v úpravě měřicího operátoru pro 3D data). Dále byla pro srovnání rekonstruována také pomocí NUFFT v rovině xy kombinovaným s FFT v z směru (protože 3D Fourierova transformace je v rovině xy nerovnoměrná kvůli radiálám, ale v z směru rovnoměrná, protože jsou jednotlivé řezy od sebe stejně vzdáleny). Při rekonstrukci bylo použito 8 projekcí na jeden řez (s celkem 25 měřenými řezy), což odpovídá časovému rozlišení 1,1 s. Citlivosti cívek byly odhadnuty pomocí ESPIRiT pro každý řez zvlášť a výsledná velikost jednotlivých snímků řezů byla 128×128 pixelů. Pro rekonstrukci pomocí modelu s omezenými diferencemi bylo použito 50 iterací obecné proximální metody. Rekonstrukce přitom byla spočítána dvakrát s mírně odlišnými regularizačními parametry:

1. $\lambda_L = 1$ a $\lambda_S = 0,001$ (rekonstrukce označená dále jako CS 1),
2. $\lambda_L = 0,5$ a $\lambda_S = 0,0001$ (rekonstrukce označená dále jako CS 2).

Následně byla na zrekonstruovaných datech provedena perfúzní analýza v oblasti nádoru a zádových svalů. Pro perfúzní analýzu byl použitý PerfLab. Zrekonstruovaná sekvence byla nejprve převedena na časové koncentrace kontrastní látky. Arteriální


⁷Ústav přístrojové techniky, AV ČR

vstupní funkce (AIF) byla odhadnuta slepou dekonvolucí na pěti vybraných datasetech nádorových myší a následně byla zprůměrována a zparametrizována. Reziduální funkce tkáně (IRF) byla modelována pomocí ATH modelu [55]. Perfúzní analýza byla provedena pixel po pixelu, čímž byly získány mapy perfúzních parametrů.



Obrázek 11: Rekonstrukce šesti datasetů (v řádcích) prvního časového snímku řezu s nádorem. Ve sloupcích jsou zobrazeny (zleva doprava) rekonstrukce 2D dat, 3D dat pomocí NUFFT, 3D dat s využitím modelu s omezenými diferencemi s dvěma různými nastaveními parametrů (rekonstrukce CS 1 a CS 2).

Zrekonstruované první časové snímky ze všech šesti datasetů jsou zobrazeny na obrázku 11. Zde jsou zobrazeny jednak rekonstrukce 2D dat pomocí regriddingu, tak i 3D rekonstrukce pomocí NUFFT a metody s omezenými diferencemi se dvěma nastaveními regularizačních parametrů (rekonstrukce CS 1 a CS 2). Z obrázku je patrné, že 3D NUFFT rekonstrukce nemá potřebné prostorové rozlišení a artefakty v řezu jsou natolik velké, že obraz je velmi znehodnocený a prakticky nepoužitelný (jsou zde k rozeznání pouze velmi jasné oblasti). Rekonstrukce 3D dat CS 1 a CS 2 dopadla ob-



Obrázek 12: Střední hodnota μ ze šesti datasetů korelačních koeficientů ρ mezi 2D daty a 3D daty zrekonstruovanými pomocí NUFFT, 3D rekonstrukce CS 1 a CS 2 pro různé perfúzní parametry. V tabulce pod příslušným parametrem je vypsána střední hodnota daného korelačního koeficientu.

dobně jen s nepatrnými rozdíly. Jsou zde vidět již detaily řezu, i když některé artefakty jsou zde stále patrné. Vizuálně nejlepší podoby rekonstrukce 3D dat dosáhl dataset 5, kde se v řezu s nádorem nenachází močový měchýř (kulovitá oblast s vysokou intenzitou jasu) na rozdíl od ostatních datasetů.

Dále byly perfúzní mapy odpovídajícího řezu ze 3D dat kvantitativně porovnány s 2D daty. Toto vyhodnocování probíhalo v oblasti nádoru, kde je možno perfúzní analýzu využít ke sledování onkologické léčby. Kvantitativně byla data porovnána pomocí korelačního koeficientu ρ . Z jednotlivých korelačních koeficientů jednotlivých perfúzních parametrů byla spočítána střední hodnota ze všech datasetů vždy pro každou 3D rekonstrukci zvlášť. Tyto střední hodnoty jsou vykresleny na obr. 12. Z grafu je vidět, že střední hodnota korelačního koeficientu u všech perfúzních parametrů se významně zvýšila u obou CS rekonstrukcí oproti 3D NUFFT rekonstrukci. Mírnou výjimku tvoří parametr T_c , kde není tento rozdíl tak významný. Rozdíl mezi oběma CS rekonstrukcemi je minimální.

7 Závěr

Práce nejprve nastiňuje problematiku perfúzního zobrazování v magnetické rezonanci. Ukazuje se, že kritickým místem perfúzní analýzy je nutnost mít zároveň vysoké prostorové a časové rozlišení současně, čehož je obtížné dosáhnout. Práce dále představuje současné metody pro zvýšení rozlišení perfúzního zobrazování v magnetické rezonanci. Stěžejní metodou pro tuto práci je komprimované snímání. Tento koncept umožňuje rekonstruovat data i při snímání dat pod Nyquistovým kritériem pomocí optimalizační úlohy, ve které vystupují apriorní informace o snímaných datech.

V praktické části je nejprve navrženo několik nových modelů komprimovaného snímání pro perfúzní zobrazování v magnetické rezonanci, a to lokální L+S model, jeho rozšíření o anatomickou informaci, rozšíření mnohaměřítkového nízkohodnostního modelu o měřicí operátor a model s omezenými diferencemi. Tyto modely byly ověřeny na simulovaných a reálných datech, na kterých byly ukázány jejich výhody a nevýhody. Pomocí těchto modelů se u 2D dat podařilo přibližně třikrát zvýšit časové rozlišení perfúzních dat při zachování prostorového rozlišení.

Dále je v práci uvedena metoda redukce vychýlenosti MRI rekonstrukcí. Debiasing aplikovaný po nízkohodnostním modelu nepřinesl zvýšení SNR na rozdíl od jeho aplikování přímo do jednotlivých iterací optimalizačního algoritmu.

Práce rovněž zkoumala vliv rekonstrukce pomocí komprimovaného snímání přímo na perfúzní parametry. CS rekonstrukce vedla k prostorově odpovídajícím mapám perfúzních parametrů s ohraničenými oblastmi s potlačeným šumem.

Na závěr práce byla metoda s omezenými diferencemi rozšířena na 3D data. Kvůli ověřitelnosti perfúzní analýzy byla tato metoda vyhodnocována na datasetech, kde byla kromě 3D měření provedena také měření ve 2D, přičemž tento 2D řez se shodoval s jedním řezem ve 3D. Ukázalo se, že 3D data rekonstruovaná pomocí NUFFT nemají odpovídající kvalitu rekonstrukce pro perfúzní analýzu a díky použití komprimovaného snímání se podařilo zvýšit korelační koeficienty u většiny perfúzních parametrů. Závěrem lze tedy konstatovat, že pomocí 3D snímání se podařilo $25\times$ zvýšit prostorové rozlišení při zachování stejného časového rozlišení.

Reference

- [1] Adluru, G.; Chen, L.; Kim, S.; aj.: Three-dimensional late gadolinium enhancement imaging of the left atrium with a hybrid radial acquisition and compressed sensing. *Journal of Magnetic Resonance Imaging*, ročník 34, č. 6, 2011: s. 1465–1471.
- [2] Bartoš, M.: *Advanced signal processing methods in dynamic contrast enhanced magnetic resonance imaging*. Doctoral thesis, Brno University of Technology, 2014.
- [3] Block, K. T.; Chandarana, H.; Milla, S.; aj.: Towards routine clinical use of radial stack-of-stars 3D gradient-echo sequences for reducing motion sensitivity. *Journal of the Korean Society of Magnetic Resonance in Medicine*, ročník 18, č. 2, 2014: s. 87–106.
- [4] Block, K. T.; Uecker, M.; Frahm, J.: Undersampled radial MRI with multiple coils. Iterative image reconstruction using a total variation constraint. *Magnetic Resonance in Medicine*, ročník 57, č. 6, 2007: s. 1086–1098, ISSN 1522-2594.
- [5] Boyd, S. P.; Vandenberghe, L.: *Convex Optimization*. Cambridge University Press, 2004, ISBN 0521833787.
- [6] Candes, E.; Romberg, J.: Sparsity and incoherence in compressive sampling. *Inverse Problems*, ročník 23, 2006: s. 969–985.
- [7] Candes, E. J.; Recht, B.: Exact Matrix Completion via Convex Optimization. *Foundations of Computational Mathematics*, ročník 9, č. 6, 2009: s. 717–772, ISSN 1615-3375.
- [8] Candes, E. J.; Wakin, M. B.: An introduction to compressive sampling. *IEEE Signal Processing Magazine*, ročník 25, č. 2, 2008: s. 21–30, ISSN 1053-5888.
- [9] Combettes, P.; Pesquet, J.: Proximal splitting methods in signal processing. *Fixed-Point Algorithms for Inverse Problems in Science and Engineering*, 2011: s. 185–212.
- [10] Condat, L.: A Generic Proximal Algorithm for Convex Optimization—Application to Total Variation Minimization. *Signal Processing Letters, IEEE*, ročník 21, č. 8, Aug 2014: s. 985–989, ISSN 1070-9908.
- [11] Daňková, M.; Rajmic, P.: Content-aware low-rank plus sparse model for perfusion MRI reconstruction. Harmonic Analysis and Applications, Strobl, Austria, 2016, str. 1, poster.
- [12] Daňková, M.; Rajmic, P.: Debiasing incorporated into reconstruction of low-rank modelled dynamic MRI data. In *Proceedings of the third “international Traveling Workshop on Interactions between Sparse models and Technology” iTWIST’16*, Aalborg, Dánsko, 2016, s. 53–55.
- [13] Daňková, M.; Rajmic, P.: Low-rank model for dynamic MRI: joint solving and debiasing. In *ESMRMB 2016, 33rd Annual Scientific Meeting, Vienna, AT, September 29–October 1: Abstracts, Friday. Magnetic resonance materials in physics biology and medicine*, Berlin: Springer, 2016, s. 200–201.
- [14] Daňková, M.; Rajmic, P.; Jiřík, R.: Acceleration of Perfusion MRI Using Locally Low-Rank plus Sparse Model. In *Latent Variable Analysis and Signal Separation*, Liberec: Springer, 2015, ISBN ISBN: 978-3-319-22481-7, s. 514–521.
- [15] Deshmane, A.; Gulani, V.; Griswold, M. A.; aj.: Parallel MR Imaging. *Journal of Magnetic Resonance Imaging*, ročník 36, č. 1, 2012: s. 55–72, ISSN 1522-2586.
- [16] Dikaio, N.; Arridge, S.; Hamy, V.; aj.: Direct parametric reconstruction from undersampled (k, t)-space data in dynamic contrast enhanced MRI. *Medical Image Analysis*, ročník 18, č. 7, 2014: s. 989–1001, ISSN 1361-8415.

- [17] Donoho, D.: Compressed sensing. *IEEE Transactions on Information Theory*, ročník 52, č. 4, 2006: s. 1289–1306, ISSN 0018-9448.
- [18] Eldar, Y. C.; Kutyniok, G.: *Compressed sensing: theory and applications*. Cambridge University Press, 2012.
- [19] Fessler, J. A.; Sutton, B. P.: Nonuniform fast Fourier transforms using min-max interpolation. *IEEE Transactions on Signal Processing*, ročník 51, č. 2, February 2003: s. 560–574.
- [20] Figueiredo, M. A. T.; Nowak, R. D.; Wright, S. J.: Gradient Projection for Sparse Reconstruction: Application to Compressed Sensing and Other Inverse Problems. *IEEE Journal of Selected Topics in Signal Processing*, ročník 1, č. 4, Dec 2007: s. 586–597, ISSN 1932-4553.
- [21] Foucard, S.; Rauhut, H.: *A Mathematical Introduction to Compressive Sensing*. Applied and Numerical Harmonic Analysis, Springer New York, 2013.
- [22] Foucart, S.: Hard Thresholding Pursuit: An Algorithm for Compressive Sensing. *SIAM Journal on Numerical Analysis*, ročník 49, č. 6, 2011: s. 2543–2563.
- [23] Griswold, M. A.; Jakob, P. M.; Heidemann, R. M.; aj.: Generalized autocalibrating partially parallel acquisitions (GRAPPA). *Magnetic Resonance in Medicine*, ročník 47, č. 6, 2002: s. 1202–1210, ISSN 1522-2594.
- [24] Gurney, P. T.; Hargreaves, B. A.; Nishimura, D. G.: Design and analysis of a practical 3D cones trajectory. *Magnetic Resonance in Medicine*, ročník 55, č. 3: s. 575–582.
- [25] Han, M.; Daniel, B. L.; Hargreaves, B. A.: Accelerated bilateral dynamic contrast-enhanced 3D spiral breast MRI using TSENSE. *Journal of Magnetic Resonance Imaging*, ročník 28, č. 6: s. 1425–1434.
- [26] Han, S.; Paulsen, J. L.; Zhu, G.; aj.: Temporal/spatial resolution improvement of in vivo DCE-MRI with compressed sensing-optimized FLASH. *Magnetic Resonance Imaging*, ročník 30, č. 6, 2012: s. 741–752, ISSN 0730-725X.
- [27] Harabiš, V.; Kolář, R.; Mézl, M.; aj.: Comparison and evaluation of indicator dilution models for bolus of ultrasound contrast agents. *Physiological Measurement*, ročník 34, 2013: s. 151–162.
- [28] Hendee, W. R.; Morgan, C. J.: Magnetic resonance imaging. Part I—physical principles. *The Western journal of medicine*, ročník 141, č. 4, 10 1984: s. 491–500.
- [29] Chan, R. W.; Ramsay, E. A.; Cunningham, C. H.; aj.: Temporal stability of adaptive 3D radial MRI using multidimensional golden means. *Magnetic Resonance in Medicine*, ročník 61, č. 2: s. 354–363.
- [30] Chlebus, P.; Mikl, M.; Brázdil, M.; aj.: Funkční magnetická rezonance – úvod do problematiky. *Neurologie pro praxi*, ročník 6, č. 3, 2005: s. 133–138.
- [31] Jackson, A.; Buckley, D. L.; Parker, M.: *Dynamic Contrast-Enhanced Magnetic Resonance Imaging in Oncology*. Berlin: Springer, 2005.
- [32] Jiřík, R.; Daňková, M.; Rajmic, P.; aj.: Absolute Quantification of Brain Perfusion using Golden Angle Compressed Sensing DCE-MRI. In *ISMRM 2016, 25th Annual Meeting & Exhibition, Honolulu, HI, USA, April 22–27, 2017*.
- [33] Koh, T. S.; Bisdas, S.; Koh, D. M.; aj.: Fundamentals of tracer kinetics for dynamic contrast-enhanced MRI. *Journal of Magnetic Resonance Imaging*, ročník 34, č. 6, 2011: s. 1262–1276.
- [34] Kutyniok, G.; Lim, W.-Q.: Compactly supported shearlets are optimally sparse. *Journal of Approximation Theory*, ročník 163, č. 11, 2011: s. 1564–1589, ISSN 0021-9045.

- [35] Li, Z.; Berman, B. P.; Altbach, M. I.; aj.: Highly Accelerated 3D Dynamic Imaging with Variable Density Golden Angle Stack-of-Stars Sampling. In *Proc. Intl. Soc. Mag. Reson. Med.* 21, 2013, ISSN 1545-4428, str. 3797.
- [36] Lustig, M.; Donoho, D.; Santos, J.; aj.: Compressed Sensing MRI. *IEEE Signal Processing Magazine*, ročník 25, č. 2, 2008: s. 72–82, ISSN 1053-5888.
- [37] Ma, S.: *Algorithms for Sparse and Low-Rank Optimization: Convergence, Complexity and Application*. Dizertační práce, Columbia University, 2011.
- [38] Mangová, M.; Rajmic, P.; Jiřík, R.: Dynamic Magnetic Resonance Imaging using Compressed Sensing with Multi-scale Low Rank Penalty. In *40th International Conference on Telecommunications and Signal Processing*, 2017, ISBN 978-1-5090-3981-4, s. 780–783.
- [39] Mézl, M.; Jiřík, R.; Harabiš, V.: Akvizice a zpracování dat v ultrazvukové perfuzní analýze. In *Nové směry v biomedicínském inženýrství*, Vysoké učení technické v Brně, 2013, s. 44–51.
- [40] Neumann, D.: *Advances in Fast MRI Experiments*. Dizertační práce, Julius-Maximilians-Universität Würzburg, 2014.
- [41] Ong, F.; Lustig, M.: Beyond Low Rank + Sparse: Multiscale Low Rank Matrix Decomposition. *IEEE Journal of Selected Topics in Signal Processing*, ročník 10, č. 4, June 2016: s. 672–687, ISSN 1932-4553.
- [42] Otazo, R.; Candes, E.; Sodickson, D. K.: Low-rank plus sparse matrix decomposition for accelerated dynamic MRI with separation of background and dynamic components. *Magnetic Resonance in Medicine*, ročník 73, č. 3, 2015: s. 1125–1136, ISSN 1522-2594.
- [43] Parikh, N.; Boyd, S.: *Proximal Algorithms*. Now Foundations and Trends, 2014, ISBN 9781601987167, 128- s.
- [44] Pauly, J.: Non-Cartesian Reconstruction. 2005.
- [45] Pauly, J.: Gridding & the NUFFT for Non-Cartesian Image Reconstruction. ISMRM, 2013.
- [46] Piccini, D.; Littmann, A.; Nielles-Vallespin, S.; aj.: Spiral phyllotaxis: The natural way to construct a 3D radial trajectory in MRI. *Magnetic Resonance in Medicine*, ročník 66, č. 4: s. 1049–1056.
- [47] Pruessmann, K. P.; Weiger, M.; Scheidegger, M. B.; aj.: SENSE: Sensitivity encoding for fast MRI. *Magnetic Resonance in Medicine*, ročník 42, č. 5, 1999: s. 952–962, ISSN 1522-2594.
- [48] Rajmic, P.; Daňková, M.: *Úvod do řídkých reprezentací signálů a komprimovaného snímání*. Vysoké učení technické v Brně, 2014.
- [49] Rajmic, P.; Novosadová, M.; Daňková, M.: Piecewise-polynomial signal segmentation using convex optimization. *Kybernetika*, ročník 53, č. 6, 2017: s. 1131–1149.
- [50] Rapacchi, S.; Han, F.; Natsuaki, Y.; aj.: High spatial and temporal resolution dynamic contrast-enhanced magnetic resonance angiography using compressed sensing with magnitude image subtraction. *Magnetic Resonance in Medicine*, ročník 71, č. 5, 2014: s. 1771–1783, ISSN 1522-2594.
- [51] Riabkov, D. Y.; Di Bella, E. V. R.: Estimation of kinetic parameters without input functions: Analysis of three methods for multichannel blind identification. *IEEE Transactions on Biomedical Engineering*, ročník 49, č. 11, 2002: s. 1318–1327.
- [52] Shepp, L. A.; Logan, B. F.: The Fourier Reconstruction of a Head Section. *IEEE Transactions on Nuclear Science*, ročník 21, 1974: s. 21–43.

- [53] Sourbron, S. P.; Buckley, D. L.: Tracer kinetic modelling in MRI: estimating perfusion and capillary permeability. *Physics in medicine and biology*, ročník 57, č. 2, Leden 2012: s. R1–33, ISSN 1361-6560.
- [54] Starčuk, Z.; Krupa, P.; Starčuk, Z.; aj.: ^1H in vivo MR spektroskopie v klinické neurologii. *Neurologie pro praxi*, ročník 6, č. 3, 2005: s. 140–148.
- [55] St Lawrence, K. S.; Lee, T. Y.: An adiabatic approximation to the tissue homogeneity model for water exchange in the brain: I. Theoretical derivation. *Journal of cerebral blood flow and metabolism*, ročník 18, č. 12, Prosinec 1998: s. 1365–1377, ISSN 0271-678X.
- [56] Sungheon, K.; Feng, L.; Moy, L.; aj.: Highly Accelerated Golden-Angle Radial Acquisition with Joint Compressed Sensing and Parallel Imaging Reconstruction for Breast DCE-MRI. In *Proc. Intl. Soc. Mag. Reson. Med.* 21, 2012, ISSN 1545-4428, str. 1468.
- [57] Thedens, D. R.; Irarrazaval, P.; Sachs, T. S.; aj.: Fast magnetic resonance coronary angiography with a three-dimensional stack of spirals trajectory. *Magnetic Resonance in Medicine*, ročník 41, č. 6: s. 1170–1179.
- [58] Uecker, M.; Lai, P.; Murphy, M. J.; aj.: ESPIRiT – an eigenvalue approach to autocalibrating parallel MRI: Where SENSE meets GRAPPA. *Magnetic Resonance in Medicine*, ročník 71, č. 3, 2014: s. 990–1001, ISSN 1522-2594.
- [59] Wikipedia a přispěvatelé: Complex normal distribution, [cit. 2018-06-18]. [online].
- [60] Wikipedia a přispěvatelé: Metoda maximální věrohodnosti, [cit. 2018-08-20]. [online].
- [61] Winkelmann, S.; Schaeffter, T.; Koehler, T.; aj.: An Optimal Radial Profile Order Based on the Golden Ratio for Time-Resolved MRI. *IEEE Transactions on Medical Imaging*, ročník 26, č. 1, 2007: s. 68–76.
- [62] Zhang, T.; Alley, M.; Lustig, M.; aj.: Fast 3D DCE-MRI with sparsity and low-rank enhanced SPIRiT (SLR-SPIRiT). *Proceedings of the 21st Annual Meeting of ISMRM, Salt Lake City, Utah, USA*, 2013: str. 2624.

CURRICULUM VITÆ

Jméno: **Ing. Marie Mangová, roz. Daňková**

Narozen: 27. 5. 1990 v Brně

Kontakt: marie.mango@seznam.cz

Vzdělání

- 2001 – 2009 Gymnázium CMGaSOŠPg, Brno
- 2009 – 2012 Vysoké učení technické v Brně, Fakulta strojního inženýrství,
bakalářské studium oboru Matematické inženýrství
celkové hodnocení studia: prospěla s vyznamenáním
- 2012 – 2014 Vysoké učení technické v Brně, Fakulta strojního inženýrství,
magisterské studium oboru Matematické inženýrství
celkové hodnocení studia: prospěla s vyznamenáním, cena děkana
- 2014 – 2018 Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, doktorské studium oboru Teleinformatika

Praxe

- 2014 – 2018 VUT v Brně, FEKT, odborný asistent

Účast na řešení projektů

- Aplikace řídkých řešení systému lineárních rovnic ve zpracování vícerozměrných dat, mezifakultní juniorský projekt VUT FEKT/FSI-J-13-1903, 2013
- Perfuzní zobrazování v magnetické rezonanci pomocí komprimovaného snímání, GAČR, GA16-13830S, 2016–2018
- Multimodální zpracování nestrukturovaných dat s využitím strojového učení a sofistikovaných metod analýzy signálů a obrazů, standardní grantový projekt VUT FEKT-S-17-4476, 2017–2019

Klasifikace vědeckovýzkumných aktivit dle ISI Web of Knowledge

- Nalezených záznamů: 4
- Celkový počet citací: 3
- Počet citací bez autocitací: 2
- Citujících článků: 3
- Citujících článků bez autocitací: 2
- h-index: 1

Pedagogické aktivity

- 2012 – 2016 Analýza signálů a soustav, numerická cvičení
- 2013 – 2017 Číslíkové zpracování signálů, laboratorní cvičení

8 Abstrakt

Perfúzní zobrazování v magnetické rezonanci je lékařská diagnostická metoda, která vyžaduje vysoké prostorové i časové rozlišení. Toto vysoké rozlišení je důležité proto, aby bylo možné zachytit dynamiku nitrožilně podané kontrastní látky, která se pro měření perfúze používá. Magnetická rezonance má však svá fyzikální omezení, která nedovolují dosáhnouti současně vysokého časového i prostorového rozlišení.

Práce se zabývá komprimovaným snímáním, které umožňuje rekonstrukci obrazu i z relativně malého počtu naměřených dat (pod Nyquistovým kritériem), zatímco rozlišení potřebné k perfúzní analýze se zvýší. Toho lze dosáhnout pomocí vhodně navržených apriorních informací o snímaných datech a sestavení modelu. Rekonstrukce pak probíhá jako optimalizační problém.

Dizertační práce přináší několik nových rekonstrukčních modelů, dále navrhuje metodu, jak zmenšit vychýlenost těchto odhadů, a zkoumá vliv komprimovaného snímání na perfúzní parametry. Celá práce je zakončena rozšířením komprimovaného snímání na trojrozměrná data, u kterých je rovněž popsán vliv rekonstrukce na perfúzní parametry. Celkově práce ukazuje, že díky komprimovanému snímání je možné zvýšit buď časové rozlišení při ponechání prostorového rozlišení, nebo při ponechání časového rozlišení lze zvýšit prostorové rozlišení.

9 Abstract

Perfusion magnetic resonance imaging is a medical diagnostic method which requires high spatial and temporal resolution simultaneously to capture dynamics of an intravenous contrast agent which is used to perfusion measurement. However, magnetic resonance imaging has physical limits which do not allow to have this resolution simultaneously.

This thesis deals with compressed sensing which enables to reconstruct measured data from relatively few acquired samples (below Nyquist rate) while resolution required to perfusion analysis is increased. This aim could be achieved with suitably proposed apriory information about sensed data and model proposal. The reconstruction is then done as an optimization problem.

Doctoral thesis brings several new reconstruction models, further proposes method to debias this estimates and examines influence of compressed sensing onto perfusion parameters. Whole thesis is ended with extension of compressed sensing into three-dimensional data. Here, the influence of reconstruction onto perfusion parameters is also described. In summary, the thesis shows that due to compressed sensing, temporal resolution can be increased with the fixed spatial resolution or spatial resolution can be increased with the fixed temporal resolution.