

# Super-résolution multi-images en IRM par approximation de Tucker couplée

Clémence PRÉVOST<sup>1</sup>, Freddy ODILLE<sup>2,3</sup>,

<sup>1</sup>Univ. Lille, CNRS, Centrale Lille, UMR 9189 CRISTAL, F-59000 Lille, France – nom.prenom[at]univ-lille[dot]fr

<sup>2</sup>Inserm, Université de Lorraine, U1254 IADI, F-54000 Nancy, France – nom.prenom[at]inserm[dot]fr

<sup>3</sup>Inserm, Université de Lorraine, CHRU Nancy, CIC-IT 1433, F-54000 Nancy, France

**Résumé** – Ce papier résout le problème de super-résolution à partir de plusieurs images IRM. Le problème de reconstruction est formulé comme une approximation multilinéaire tensorielle couplée. Nos résultats théoriques prouvent qu’il est possible de reconstruire exactement l’image à haute résolution. Nous proposons également un algorithme simple basé sur une régularisation de Tikhonov. Nos simulations sur données réelles illustrent les performances de cette approche, à un coût de calcul réduit par rapport à l’état de l’art.

**Abstract** – In this paper, we address the multi-frame super-resolution MRI problem. We formulate the reconstruction problem as a coupled tensor multilinear approximation. We prove that exact recovery of the high-resolution 3D isotropic image is achievable for a variety of multilinear ranks. We propose a simple algorithm based on Tikhonov regularization to perform the reconstruction. Our simulations on real datasets illustrates the good performance of the proposed approach, with a lower computation time than state-of-the-art methods.

## 1 Introduction

L’imagerie à résonance magnétique (IRM) est une technique polyvalente d’imagerie médicale. Elle produit des tableaux 2D ou 3D d’un organe dans une orientation donnée. Les images 3D possèdent deux dimensions spatiales dans le plan, et une troisième dimension spatiale caractérisant la profondeur. Cependant, le temps d’acquisition de ces images est de l’ordre de plusieurs minutes.

La super-résolution [12, 19, 4] vise à contourner cette limitation en reconstruisant une image 3D à haute résolution à partir d’une ou plusieurs observations à basses résolutions. La super-résolution à partir d’une seule observation est souvent basée sur l’apprentissage profond [10, 17].

Ce papier s’inscrit dans le cadre de la super-résolution multi-images. Cette stratégie consiste en l’acquisition de plusieurs observations complémentaires de l’organe d’intérêt [5, 7]. Chaque observation possède de hautes résolutions dans le plan (1 mm) et une basse résolution dans la profondeur (3 à 10mm), obtenues par une opération de flou et d’échantillonnage. Les mouvements du patient sont pris en compte lors d’une étape de pré-traitement [9, 15].

Des méthodes de reconstruction basées sur la régularisation de Tikhonov [21], de Beltrami [9], ou par variation totale [18] ont d’abord été proposées. D’autres approches [2] utilisent une factorisation matricielle de rang faible<sup>1</sup> [16, 2]. Le coût de calcul associé à ces méthodes matricielles est souvent élevé. Celles-ci ne proposent pas de garanties de reconstruction exacte.

En imagerie médicale, des modèles tensoriels couplés ont récemment été établis pour la reconstruction d’images cardiaques dynamiques [20] ou issues de l’imagerie fonctionnelle

[8]. Ces approches préservent les informations structurelles offertes par le format tensoriel.

En particulier, la factorisation multilinéaire (ou Tucker) a été utilisée dans [14] pour traiter le problème de super-résolution en télé-détection. Un algorithme basé sur la SVD a été proposé dans [14], permettant de reconstruire une image à partir de deux observations dégradées. Chaque tenseur était dégradé dans deux dimensions, ce qui rendait les conditions de reconstruction théoriques plus restrictives que celles présentées dans ce papier.

Dans ce papier, nous proposons une nouvelle approche tensorielle au problème de super-résolution multi-images en IRM. Notre solution se base sur une approximation multilinéaire couplée de trois observations. Nous présentons un algorithme à faible coût de calcul, appelé isometRic Image Reconstruction by COupled Tensor Tucker Approximation (RICOTTA), et basé sur la SVD [3]. Nous montrons que notre approche garantit la reconstruction exacte de l’image à haute-résolution. Les simulations sur données réelles illustrent les hautes performances de reconstruction de RICOTTA. Un rapport technique contenant une version étendue de ce travail est disponible [13]. Un logiciel est à disposition en ligne à l’adresse [https://github.com/cprevost4/RICOTTA\\_Software](https://github.com/cprevost4/RICOTTA_Software).

**Notation** – Les scalaires sont notés ( $a$ ) ou ( $A$ ), les vecteurs ( $\mathbf{a}$ ), les matrices ( $\mathbf{A}$ ) et les tenseurs ( $\mathcal{A}$ ). Leurs éléments sont notés  $a_i$ ,  $A_{i,j}$  and  $\mathcal{A}_{i_1, \dots, i_N}$ . La transposée matricielle est notée  $\mathbf{A}^T$ . La notation  $\mathbf{X} \geq \mathbf{0}$  dénote la positivité terme à terme. L’opérateur  $\otimes$  dénote le produit tensoriel et l’opérateur  $\bullet_p$  note le produit tenseur-matrice selon la dimension  $p$ .

Ce travail est financé en partie par le projet ANR “Chaire IA Sherlock” ANR-20-CHIA-0031-01, par le programme d’investissements d’avenir ANR-16-IDEX-0004 ULNE et la Région HDF.

1. Dans le cas d’une seule observation.

## 2 Approximation Tucker couplée

### 2.1 Modèle d'observation

L'on souhaite reconstruite une image isotropique 3D à hautes résolutions (HRII)  $\mathcal{Z} \in \mathbb{R}^{I \times J \times K}$ . Le scalaire  $K$  représente la profondeur, tandis que  $I$  et  $J$  sont les résolutions dans le plan. Trois images à basse résolution (LRI) sont observées. Notons  $\mathcal{Y}_1 \in \mathbb{R}^{I_1 \times J \times K}$ ,  $\mathcal{Y}_2 \in \mathbb{R}^{I \times J_2 \times K}$  and  $\mathcal{Y}_3 \in \mathbb{R}^{I \times J \times K_3}$ , où  $I_1$ ,  $J_2$  et  $K_3$  représentent les basses résolutions, *i.e.*,  $I_1 \ll I$ ,  $J_2 \ll J$  et  $K_3 \ll K$ . Le ratio entre hautes et basses résolutions est défini par les paramètres de la machine et la séquence d'acquisition considérée. Le modèle de dégradation s'écrit

$$\begin{cases} \mathcal{Y}_1 = \mathcal{Z} \bullet_1 \mathbf{D}_1 + \mathcal{E}_1, \\ \mathcal{Y}_2 = \mathcal{Z} \bullet_2 \mathbf{D}_2 + \mathcal{E}_2, \\ \mathcal{Y}_3 = \mathcal{Z} \bullet_3 \mathbf{D}_3 + \mathcal{E}_3. \end{cases} \quad (1)$$

Les matrices de dégradation  $\mathbf{D}_i$  ( $i = 1, 2, 3$ ), supposées connues, sous-échantillonnent une dimension donnée. Elles sont telles que  $\mathbf{D}_1 \in \mathbb{R}^{I_1 \times I}$ ,  $\mathbf{D}_2 \in \mathbb{R}^{J_2 \times J}$  and  $\mathbf{D}_3 \in \mathbb{R}^{K_3 \times K}$ . Les tenseurs  $\mathcal{E}_i$  ( $i = 1, 2, 3$ ) sont des termes de bruit.

Considérons le problème d'optimisation suivant :

$$\begin{aligned} \min_{\hat{\mathcal{Z}}} \lambda_1 \|\mathcal{Y}_1 - \hat{\mathcal{Z}} \bullet_1 \mathbf{D}_1\|_F^2 + \lambda_2 \|\mathcal{Y}_2 - \hat{\mathcal{Z}} \bullet_2 \mathbf{D}_2\|_F^2 \\ + \lambda_3 \|\mathcal{Y}_3 - \hat{\mathcal{Z}} \bullet_3 \mathbf{D}_3\|_F^2 + \mu \mathcal{R}(\hat{\mathcal{Z}}), \end{aligned} \quad (2)$$

où les scalaires  $\lambda_i$  ( $i = 1, 2, 3$ ) contrôlent le poids des observations. L'opérateur  $\mathcal{R}(\cdot)$  impose une régularisation de Tikhonov [6] sur l'image reconstruite  $\hat{\mathcal{Z}}$ . Son poids est contrôlé par  $\mu$ . Le terme de régularisation promeut une forme de douceur spatiale dans l'image, tout en réduisant les potentiels artefacts survenant lors de l'approximation de rang faible.

### 2.2 Modèle Tucker couplé

Dans ce papier, nous utilisons une approximation Tucker couplée pour résoudre le problème de reconstruction. Supposons que  $\mathcal{Z}$  admet une décomposition Tucker de rangs multi-linéaires  $(R_1, R_2, R_3)$  telle que

$$\mathcal{Z} = \llbracket \mathcal{G}; \mathbf{U}, \mathbf{V}, \mathbf{W} \rrbracket, \quad (3)$$

avec  $\mathbf{U} \in \mathbb{R}^{I \times R_1}$ ,  $\mathbf{V} \in \mathbb{R}^{J \times R_2}$  et  $\mathbf{W} \in \mathbb{R}^{K \times R_3}$ , et  $\mathcal{G} \in \mathbb{R}^{R_1 \times R_2 \times R_3}$ . Le modèle (1) devient alors

$$\begin{cases} \mathcal{Y}_1 = \llbracket \mathcal{G}; \mathbf{D}_1 \mathbf{U}, \mathbf{V}, \mathbf{W} \rrbracket + \mathcal{E}_1, \\ \mathcal{Y}_2 = \llbracket \mathcal{G}; \mathbf{U}, \mathbf{D}_2 \mathbf{V}, \mathbf{W} \rrbracket + \mathcal{E}_2, \\ \mathcal{Y}_3 = \llbracket \mathcal{G}; \mathbf{U}, \mathbf{V}, \mathbf{D}_3 \mathbf{W} \rrbracket + \mathcal{E}_3. \end{cases} \quad (4)$$

En incorporant (4) dans (2), le problème de super-résolution revient à minimiser une fonction de coût :

$$\begin{aligned} \mathfrak{f}_T(\hat{\mathcal{G}}, \hat{\mathbf{U}}, \hat{\mathbf{V}}, \hat{\mathbf{W}}) = \lambda_1 \|\mathcal{Y}_1 - \llbracket \hat{\mathcal{G}}; \mathbf{D}_1 \hat{\mathbf{U}}, \hat{\mathbf{V}}, \hat{\mathbf{W}} \rrbracket\|_F^2 \\ + \lambda_2 \|\mathcal{Y}_2 - \llbracket \hat{\mathcal{G}}; \hat{\mathbf{U}}, \mathbf{D}_2 \hat{\mathbf{V}}, \hat{\mathbf{W}} \rrbracket\|_F^2 \\ + \lambda_3 \|\mathcal{Y}_3 - \llbracket \hat{\mathcal{G}}; \hat{\mathbf{U}}, \hat{\mathbf{V}}, \mathbf{D}_3 \hat{\mathbf{W}} \rrbracket\|_F^2 \\ + \mu \|\llbracket \hat{\mathcal{G}}; \hat{\mathbf{U}}, \hat{\mathbf{V}}, \hat{\mathbf{W}} \rrbracket\|^2. \end{aligned} \quad (5)$$

## 2.3 Algorithme

Nous proposons une solution sous-optimale au problème de minimisation de (5). Elle est décrite dans l'algorithme algébrique 1, appelé isometRic Image Reconstruction by COupled Tensor Tucker Approximation (RICOTTA).

### Algorithm 1: RICOTTA

---

**init.** :  $\mathcal{Y}_1, \mathcal{Y}_2, \mathcal{Y}_3, \mathbf{D}_1, \mathbf{D}_2, \mathbf{D}_3; R_1, R_2, R_3$   
**retourner:**  $\hat{\mathcal{Y}} \in \mathbb{R}^{I \times J \times K}$

1.  $\mathbf{U} \leftarrow \text{tSVD}_{R_1} \left( \begin{bmatrix} \mathcal{Y}_2^{(1)} & \mathcal{Y}_3^{(1)} \end{bmatrix} \right)$ ,  
 $\mathbf{V} \leftarrow \text{tSVD}_{R_2} \left( \begin{bmatrix} \mathcal{Y}_1^{(2)} & \mathcal{Y}_3^{(2)} \end{bmatrix} \right)$ ,  
 $\mathbf{W} \leftarrow \text{tSVD}_{R_3} \left( \begin{bmatrix} \mathcal{Y}_1^{(3)} & \mathcal{Y}_2^{(3)} \end{bmatrix} \right)$
2.  $\hat{\mathcal{G}} \leftarrow \underset{\mathcal{G}}{\text{argmin}} \mathfrak{f}_T(\mathcal{G}, \hat{\mathbf{U}}, \hat{\mathbf{V}}, \hat{\mathbf{W}})$ ;
3.  $\hat{\mathcal{Z}} = \llbracket \hat{\mathcal{G}}; \hat{\mathbf{U}}, \hat{\mathbf{V}}, \hat{\mathbf{W}} \rrbracket$ .

---

Premièrement, RICOTTA estime les facteurs  $\mathbf{U}$ ,  $\mathbf{V}$  et  $\mathbf{W}$  par SVD tronquée (tSVD) des observations. Ensuite, l'algorithme résout le problème de moindres carrés

$$\arg \min_{\hat{\mathcal{G}}} \|\mathbf{X} \text{vec}\{\hat{\mathcal{G}}\} - \mathbf{z}\|_F^2 + \mu \|\text{vec}\{\hat{\mathcal{G}}\}\|_F^2, \quad (6)$$

par la résolution d'une équation normale

$$\left( \mathbf{X}^T \mathbf{X} + \mu \mathbf{I} \right) \text{vec}\{\hat{\mathcal{G}}\} = \mathbf{X}^T \text{vec}\{\mathbf{z}\}, \quad (7)$$

voir XXX pour le détail des calculs. La complexité de RICOTTA est

- $\mathcal{O}((R_1 + R_2 + R_3)IJK)$  pour les SVD;
- $\mathcal{O}(\min(R_3^3 + (R_1 R_2)^3; R_1^3 + (R_2 R_3)^3))$  pour (7).

## 3 Garanties de reconstruction exacte

Dans cette partie, nous proposons des conditions génériques de reconstruction pour l'image à super-résolution. La preuve de ce théorème, ainsi que des conditions déterministes, sont disponibles dans XXX.

**Théorème 3.1** Soient  $\mathbf{D}_1 \in \mathbb{R}^{I_1 \times I}$ ,  $\mathbf{D}_2 \in \mathbb{R}^{J_2 \times J}$ , and  $\mathbf{D}_3 \in \mathbb{R}^{K_3 \times K}$  de rang plein. Soit

$$\mathcal{Z} = \llbracket \mathcal{G}; \mathbf{U}, \mathbf{V}, \mathbf{W} \rrbracket, \quad (8)$$

avec  $\mathcal{G} \in \mathbb{R}^{R_1 \times R_2 \times R_3}$ ,  $R_1 \leq I$ ,  $R_2 \leq J$ ,  $R_3 \leq K$ , and  $\mathbf{U} \in \mathbb{R}^{I \times R_1}$ ,  $\mathbf{V} \in \mathbb{R}^{J \times R_2}$ ,  $\mathbf{W} \in \mathbb{R}^{K \times R_3}$  aléatoires, de distributions absolument continues. Soient également  $\mathcal{E}_i$  ( $i = 1, 2, 3$ ) in (1). 1. si au choix  $R_3 \leq K_3$  ou  $R_1 \leq I_1$  ou  $R_2 \leq J_2$ , et si

$$\begin{cases} R_1 \leq \min(R_3, K_3) R_2, \\ R_2 \leq \min(R_3, K_3) R_1 \\ R_3 \leq \min(R_1, I_1) \min(R_2, J_2), \end{cases} \quad (9)$$

alors il existe un unique tenseur  $\hat{\mathcal{Z}}$  tel que  $\hat{\mathcal{Z}} \bullet_1 \mathbf{D}_1 = \mathcal{Y}_1$ ,  $\hat{\mathcal{Z}} \bullet_2 \mathbf{D}_2 = \mathcal{Y}_2$  et  $\hat{\mathcal{Z}} \bullet_3 \mathbf{D}_3 = \mathcal{Y}_3$ .  
2. si  $(R_1, R_2, R_3) > (I_1, J_2, K_3)$ , alors il existe une infinité de  $\hat{\mathcal{Z}}$  satisfaisant  $\hat{\mathcal{Z}} \bullet_1 \mathbf{D}_1 = \mathcal{Y}_1$ ,  $\hat{\mathcal{Z}} \bullet_2 \mathbf{D}_2 = \mathcal{Y}_2$  et  $\hat{\mathcal{Z}} \bullet_3 \mathbf{D}_3 = \mathcal{Y}_3$ ;  $\|\hat{\mathcal{Z}} - \mathcal{Z}\|$  pouvant être arbitrairement grand.

Le Théorème 3.1 est illustré à la Figure 1. En vert apparaissent les rangs pour lesquels la reconstruction exacte est possible, tandis que la reconstruction est non-unique dans la zone rouge. L'aire hachurée contient les cas pour lesquels (9) ne sont pas satisfaites. La Figure 1 montre que l'on peut choisir deux rangs très grands, tant que le troisième reste petit. Dans [14],  $R_1$  et  $R_2$  devaient rester tous les deux pour augmenter  $R_3$ , ce qui générait des conditions moins flexibles.




FIGURE 1 – Illustration du Théorème 3.1.

## 4 Simulations

### 4.1 Données et validation

Un objet de test qualité a été scanné avec un appareil 3T Prisma (Siemens Healthineers, Erlangen, Allemagne). La HRII de référence était  $\mathcal{Z} \in \mathbb{R}^{224 \times 224 \times 224}$ . Son temps d'acquisition était de 6 min 30 s. Les LRI étaient de résolutions  $1 \times 1 \times 4 \text{ mm}^3$ . Le taux de sous-échantillonnage entre la HRII et les LRI était  $d = 4$ , soit  $\mathbf{D}_1 = \mathbf{D}_2 = \mathbf{D}_3 \in \mathbb{R}^{56 \times 224}$ . Le temps d'acquisition de chaque image était de 2 min.

L'acquisition du cerveau d'un volontaire sain<sup>2</sup> a été effectuée sur un appareil 3T Signa HDxt (General Electric, Milwaukee, USA). L'image de résolution  $1 \times 1 \times 1 \text{ mm}^3$  telle que  $\mathcal{Z} \in \mathbb{R}^{224 \times 224 \times 224}$ . Le temps d'acquisition était de 8 min. Les LRI avaient une résolution de  $1 \times 1 \times 4 \text{ mm}^3$ , soit  $d = 4$ . Le temps d'acquisition de chaque LRI était de 2 min.

Nous avons comparé RICOTTA à l'état de l'art en super-résolution multi-images [9]. Les approches vectorielles de référence, notées SR-T et SR-B, utilisaient des régularisations de Tikhonov et de Beltrami [22], respectivement. Les données ont été pré-traitées afin de correspondre au modèle séparable (1).

Nous avons utilisé divers indicateurs de qualité de reconstruction. Le premier était le *peak signal-to-noise ratio* (PSNR) [11] :

$$\text{PSNR} = \frac{10}{K} \sum_{k=1}^K \log_{10} \left( \frac{\text{IJE} \{(\mathcal{Z})_{:, :, k}\}}{\|(\mathcal{Z})_{:, :, k} - (\hat{\mathcal{Z}})_{:, :, k}\|_F^2} \right), \quad (10)$$

Le second était la corrélation croisée (CC) [11]. Le troisième était l'indice d'acuité (SI) [1], moyenné dans le plan ( $\text{SI}_{1,2}$ ) et pour la profondeur ( $\text{SI}_3$ ). Le temps de calcul était donné par les fonctions `tic` et `toc` de MATLAB. Les paramètres du modèle (rangs et poids  $\lambda_i$ ) ont été choisis de façon à obtenir les meilleurs indicateurs de reconstruction. Des simulations supplémentaires sur le choix de ces paramètres sont disponibles dans XXX.

2. L'étude a été approuvée par un comité d'éthique et le volontaire a donné son consentement écrit. Voir identifiant ClinicalTrials.gov : NCT02887053.

## 4.2 Résultats

Pour l'objet de test, nous avons utilisé  $R = (220, 220, 50)$ ,  $\lambda_1 = \lambda_2 = 0.2$ ,  $\lambda_3 = 0.8$ , et  $\mu = 0.005$ . Les indicateurs sont regroupés dans le Tableau 1. La Figure 2 montre des coupes de l'image de référence et des reconstructions.

Alg.	PSNR	CC	$\text{SI}_{1,2}$	$\text{SI}_3$	Time (s)
RICOTTA	18.531	0.9631	<b>104.403</b>	<b>528.274</b>	215.231
SR-T	<b>19.386</b>	<b>0.9638</b>	87.427	330.561	<b>49.091</b>
SR-B	17.101	0.9613	103.31	424.816	219.735

TABLE 1 – Reconstruction d'un objet de test qualité ( $d = 4$ ).




FIGURE 2 – Reconstructions de l'objet de test qualité ( $d = 4$ ).

RICOTTA donnait un PSNR et une CC comparables à ceux de SR-T, avec un SI était supérieur. Le temps de calcul de RICOTTA était similaire à celui de SR-B tandis que ses performances étaient supérieures.

Pour les images de cerveau, nous avons utilisé les paramètres  $R = (220, 220, 50)$ ,  $\lambda_1 = \lambda_2 = 0.2$ ,  $\lambda_3 = 0.8$  et  $\mu = 0.001$ . Les résultats sont disponibles dans le Tableau 2 and la Figure 3.

Alg.	PSNR	CC	$\text{SI}_{1,2}$	$\text{SI}_3$	Time (s)
RICOTTA	<b>24.764</b>	<b>0.9153</b>	174.346	<b>580.933</b>	<b>236.506</b>
SR-T	22.557	0.8854	<b>278.068</b>	422.824	266.280
SR-B	22.709	0.8842	264.000	447.629	361.398

TABLE 2 – Reconstruction d'un volume de cerveau ( $d = 4$ ).

RICOTTA a fourni les meilleurs PSNR, CC et  $\text{SI}_3$ . L'indice d'acuité dans le plan était plus bas que pour l'état de l'art. Son temps de calcul était comparable avec le temps d'acquisition de la référence. Ce temps peut être réduit davantage en considérant une approche par blocs.

## 5 Conclusion

Dans ce papier, nous avons proposé une nouvelle méthode tensorielle de super-résolution multi-images en IRM. Notre algorithme effectue la reconstruction exacte avec un temps de calcul compétitif. Nous espérons pouvoir appliquer des approches tensorielles similaires à d'autres problèmes de reconstruction en imagerie médicale.




FIGURE 3 – Reconstructions d’un volume de cerveau ( $d = 4$ ).

## Références

- [1] G. Blanchet and L. Moisan. An explicit sharpness index related to global phase coherence. In *2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 1065–1068. IEEE, 2012.
- [2] A. Bustin, D. Voilliot, A. Menini, J. Felblinger, C. de Chillou, D. Burschka, L. Bonnemains, and F. Odille. Isotropic Reconstruction of MR Images Using 3D Patch-Based Self-Similarity Learning. *IEEE transactions on medical imaging*, 37(8):1932–1942, August 2018.
- [3] L. De Lathauwer. Decompositions of a Higher-Order Tensor in Block Terms—Part II : Definitions and Uniqueness. *SIAM J. Matrix Anal. Appl.*, 30(3):1033–1066, 2008.
- [4] M. Delbany, A. Bustin, J. Poujol, I. Thomassin-Naggara, J. Felblinger, P.-A. Vuissoz, and F. Odille. One-millimeter isotropic breast diffusion-weighted imaging : Evaluation of a superresolution strategy in terms of signal-to-noise ratio, sharpness and apparent diffusion coefficient. *Magnetic Resonance in Medicine*, 81(4), 2019.
- [5] A. Gholipour, J.A. Estroff, and S.K. Warfield. Robust Super-Resolution Volume Reconstruction From Slice Acquisitions : Application to Fetal Brain MRI. *IEEE Transactions on Medical Imaging*, 29(10):1739–1758, October 2010.
- [6] G. H. Golub, P. C. Hansen, and D. P. O’Leary. Tikhonov regularization and total least squares. *SIAM journal on matrix analysis and applications*, 21(1):185–194, 1999.
- [7] H. Greenspan, G. Oz, N. Kiryati, and S. Peled. MRI interslice reconstruction using super-resolution. *MAGNETIC RESONANCE IMAGING*, 20(5):437–446, June 2002.
- [8] C. I. Kanatsoulis, X. Fu, N. D. Sidiropoulos, and M. Akçakaya. Tensor Completion from Regular Sub-Nyquist Samples. *arXiv e-prints*, page arXiv :1903.00435, March 2019.
- [9] F. Odille, A. Bustin, B. Chen, P.-A. Vuissoz, and J. Felblinger. Motion-corrected, super-resolution reconstruction for high-resolution 3d cardiac cine mri. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 435–442. Springer, 2015.
- [10] O. Oktay, W. Bai, M. Lee, R. Guerrero, K. Kamnitsas, J. Caballero, A. de Marvao, S. Cook, D. O’Regan, and D. Rueckert. Multi-input Cardiac Image Super-Resolution Using Convolutional Neural Networks. In *MICCAI 2016, editor, Medical Image Computing and Computer-Assisted Intervention, Lecture Notes in Computer Science*, pages 246–254, Cham, 2016. Springer International Publishing.
- [11] W. Pei, G. Wang, and X. Yu. Performance evaluation of different references based image fusion quality metrics for quality assessment of remote sensing image fusion. In *2012 IEEE International Geoscience and Remote Sensing Symposium*, pages 2280–2283. IEEE, 2012.
- [12] E. Plenge, D. J. Poot, M. Bernsen, G. Kotek, G. Houston, P. Wielopolski, L. van der Weerd, W. J. Niessen, and E. Meijering. Super-resolution methods in MRI : Can they improve the trade-off between resolution, signal-to-noise ratio, and acquisition time ? *Magnetic Resonance in Medicine*, 68(6):1983–1993, 2012.
- [13] C. Prévost and F. Odille. Super-resolution reconstruction of brain 3D magnetic resonance images using a coupled tensor multilinear approximation. working paper or preprint, June 2022.
- [14] C. Prévost, K. Usevich, P. Comon, and D. Brie. Hyperspectral Super-Resolution with Coupled Tucker Approximation : Identifiability and SVD-based algorithms. *IEEE Trans. Signal Process.*, 68:931–946, 2020.
- [15] F. Rousseau, O. Glenn, and C. Studholme. *A novel approach to high resolution fetal brain MR imaging*, volume 3749 of *Lecture Notes in Computer Science*. Springer, Berlin New York London [etc.], 2005.
- [16] F. Shi, J. Cheng, L. Wang, P.-T. Yap, and D. Shen. LRTV : MR Image Super-Resolution with Low-Rank and Total Variation Regularizations. *IEEE transactions on medical imaging*, 34(12):2459–2466, December 2015.
- [17] J. Shi, Z. Li, S. Ying, C. Wang, Q. Liu, Q. Zhang, and P. Yan. MR Image Super-Resolution via Wide Residual Networks With Fixed Skip Connection. *IEEE Journal of Biomedical and Health Informatics*, 23(3):1129–1140, May 2019.
- [18] S. Tourbier, X. Bresson, P. Hagmann, J.-P. Thiran, R. Meuli, and M. B. Cuadra. Efficient total variation algorithm for fetal brain MRI reconstruction. *Medical image computing and computer-assisted intervention : MICCAI ... International Conference on Medical Image Computing and Computer-Assisted Intervention*, 17(Pt 2):252–259, 2014.
- [19] E. Van Reeth, I. K. Tham, C. H. Tan, and C. L. Poh. Super-resolution in magnetic resonance imaging : A review. *Concepts in Magnetic Resonance Part A*, 40A(6):306–325, 2012.
- [20] B. Yaman, S. Weingärtner, N. Kargas, N. D. Sidiropoulos, and M. Akçakaya. Low-rank tensor models for improved multidimensional mri : Application to dynamic cardiac  $t_1$  mapping. *IEEE transactions on computational imaging*, 6:194–207, 2019.
- [21] X. Zhang, E. Y. Lam, E. X. Wu, and K. Y. Wong. Application of Tikhonov Regularization to Super-Resolution Reconstruction of Brain MRI Images. In Xiaohong Gao, Henning Müller, Martin J. Loomes, Richard Comley, and Shuqian Luo, editors, *Medical Imaging and Informatics*, number 4987 in *Lecture Notes in Computer Science*, pages 51–56. Springer Berlin Heidelberg, 2008.
- [22] D. Zosso and A. Bustin. A primal-dual projected gradient algorithm for efficient beltrami regularization. *Computer Vision and Image Understanding*, pages 14–52, 2014.