

Deep Learning pour l'optimisation de l'acquisition IRM

Stage Master 2

Encadrants :

Thierry Artières : thierry.artieres@lis-lab.fr (Laboratoire d'informatique et systèmes, UMR 7020)

Ludovic de Rochefort : ludovic.de-rochefort@univ-amu.fr (Centre de résonance magnétique biologique et médicale, UMR 7339)

Contexte

L'IRM est un outil diagnostique indispensable dans de nombreuses maladies, essentiel pour la recherche en biologie et en médecine, ainsi que pour les neurosciences. Les appareils sont chers (de l'ordre de 3 M€ pour un appareil clinique standard de 3T, et entre 7 et 10 M€ pour un appareil de 7T) et la demande est croissante avec une augmentation des indications. L'objectif du stage est d'explorer le développement de méthodes permettant de réduire les données à acquérir pour former des images et ainsi augmenter l'accessibilité des appareils. Lors d'un examen IRM, qui dure entre 30 min et 1 heure, des données redondantes sont acquises inutilement. Idéalement, il faudrait optimiser le processus d'acquisition en n'acquérant que les données informatives pour réduire le temps d'examen. Le stage consiste à développer des approches d'apprentissage automatique et profond pour déterminer ces données informatives, avec preuve de concept dans le contexte applicatif de l'imagerie de la sclérose en plaque (SEP) sur des données brutes déjà disponibles.

L'idée est d'accélérer l'acquisition en sous-échantillonnant l'espace d'entrée (les observations) et en utilisant des approches de super-résolution (5,) pour inférer les données manquantes (inférer conjointement des images haute résolution à partir d'images basse résolution). Pour ce faire, on peut formaliser le processus, y compris le sous-échantillonnage qui est traditionnellement traité par des convolutions (1, 4), directement sous forme d'une architecture neuronale. Il s'agit alors d'optimiser ce problème de dégradation-restauration et de comparer ses performances aux techniques actuelles de reconstruction de données partielles (2, 7). Mettre en place ces approches neuronales nécessite d'étudier des problèmes durs, incluant la gestion de données dans le domaine complexe (8) appelant à des architectures adaptées. Ces réseaux seront probablement difficiles à entraîner ce qui nécessitera d'inclure des contraintes structurelles ou algorithmiques pour que le réseau respecte certaines propriétés physiques connues du processus (3), par exemple la linéarité globale ou des contraintes de distribution pour lesquelles l'adversarial learning semble adapté et pourra être utilisé.

Références bibliographiques :

1. **Akçakaya M, et al.** *Scan-specific robust artificial-neural-networks for k-space interpolation (RAKI) reconstruction: Database-free deep learning for fast imaging.* Magn Reson Med 2019 81:439, <https://doi.org/10.1002/mrm.27420>
2. **Candes EJ, Romberg J, Tao T.** *Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information.* IEEE Transactions on Information Theory 2006;52:489,
3. **De Bezenac E, Pajot A, Gallinari P.** *Deep Learning for Physical Processes: Incorporating Prior Scientific Knowledge.* ICLR; 2018, <https://arxiv.org/abs/1702.00748>
4. **Griswold MA, et al.** *Generalized autocalibrating partially parallel acquisitions (GRAPPA).* Magn Reson Med 2002;47:1202, <https://doi.org/10.1002/mrm.10171>
5. **Ledig C, et al.** *Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network.* 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2017. p105, <https://arxiv.org/abs/1609.04802>
6. **Lim B, et al.** *Enhanced deep residual networks for single image super-resolution.* arXiv:170702921v1 2017, <https://arxiv.org/abs/1707.02921>
7. **Ma D, et al.** *Magnetic resonance fingerprinting.* Nature 2013;495:187, <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3602925/>
8. **Trabelsi C, et al.** *Deep Complex Networks.* ICLR2017, <https://arxiv.org/abs/1705.09792>