

3. AIを用いた超解像処理とfMRIの高解像度化への期待

大田 淳子 量子科学技術研究開発機構量子生命・医学部門QST病院医療技術部医療情報室/
量子医科学研究所分子イメージング診断治療研究部医工連携画像研究グループ/QST未来ラボ・量子医療AI研究グループ

近年、人工知能(AI)技術は急速な発展を遂げ、ディープラーニングは画像認識・識別タスクにとどまらず、画像を生成する画像処理タスクにも急速に応用が進んでいる。

2019年に、米国国立衛生研究所(National Institutes of Health: NIH)、北米放射線学会(Radiological Society of North America: RSNA)などが中心となって作成し、*Radiology*誌に掲載された医用画像におけるAI研究のロードマップ¹⁾によると、優先すべき重点5領域のうちの1つとして、AIによる画像再構成や画像処理法の開発が挙げられており、実用化まで含め加速度的な進展を遂げている分野の一つである。本稿では、ディープラーニングを用いた超解像(super resolution)処理の技術概要を説明し、敵対的生成ネットワーク(generative adversarial network: GAN)を用いた超解像処理の概要と、畳み込みニューラルネットワーク(convolutional neural network: CNN)を用いた超解像との違い、MRIへの応用例、さらに、近年、筆者らが取り組んできた機能的MRI(functional MRI: fMRI)への応用例について紹介する。

ディープラーニングを用いた超解像

超解像とは、画像の解像度を向上させる画像処理技術の総称で、低画質・低解像度な画像を入力して、高画質・高解像度な画像へと復元、推定する操作である。超解像処理そのものはディープラーニングとは直接関係ないが、本稿では、ディープラーニングを用いた超解像技術に関して主に述べる。

ディープラーニングを用いた超解像処理のほとんどはCNNを用いて行われている(図1)。CNNを用いた超解像処理は、基本的には、入力層と出力層のベクトルサイズが一致する、もしくは入力層の後にアップスケーリング層によって拡大が行われ、出力層と同じサイズになれば、ほかの層がどのような形になっても超解像処理の学習を行うことができる。つまり、超解像処理そのものは画像を高解像度化することが目的であるが、画像の解像度を向上させるための拡大そのものは既存の手法を用い、ディープラーニングを用いて学習するのは、あくまで画像の拡大により起こる画像の劣化を復元すること、とりわけ、高周波成分の喪失を復元するために行われるというのがコンセプトである。入力画像は劣化画像(低解像度画像)、出力画像は高解像度画像である。そのため、超解像処理は、高解像度化するとは言いつつも画質改善タスクであるので、解像度が向上

するだけではなく、実際には、デノイズのような、解像度の向上とは直接関係のない画質改善を伴う。

一方で、CNN以外で実現可能なディープラーニングを用いた超解像処理として、GANを用いた超解像処理が挙げられる。GANは、generator(生成ネットワーク:生成器)とdiscriminator(識別ネットワーク:識別器)の2つのネットワークから構成されており、この2つのネットワークが拮抗しながら学習が進んでいく。通常のGANは、特定の画像ペアの対応関係を学習するのではなく、識別器が特定のデータセット内の任意の画像と生成器が生成した画像の判別をするので、教師データがなくても画像を生成することができる。生成したい画像に類似した画像を多数用意すれば、入力画像はランダムノイズでよい。教師なし学習の一つとしてとらえられ、学習データの増しによく用いられる。しかし、実際の課題設定では、教師あり学習の方が実用的な局面が多いため、GANを教師あり学習の形にした条件付きGAN(conditional GAN: cGAN)がよく用いられる。cGANは、データセットの中でも特定の画像に限定したラベルと併せて学習を行うため、CNNの画像生成、画像再構成手法と同じような教師あり学習が可能になる(図2)。GANを用いた超解像処理も、基本的にはこのcGANと同じ構造である。

では、超解像処理において、CNNを用いるのとGANを用いるのとでは、何