

放射線科領域へのAIの活用: 診断、画質改善・変換、 造影剤投与など

熊本大学大学院 生命科学研究所 放射線診断学講座 | 中浦 猛

近年、放射線科関連の様々な領域へ人工知能の応用が進んでおり、従来用いられてきた技術を置換しつつある。本講演ではこのような人工知能の基本構造とその学習の仕組み、放射線科領域への応用について特に画質改善・変換および造影剤投与への応用について解説する。

機械学習・人工知能の放射線科領域への応用ではいわゆるAIの代表的な応用例として、様々な診断補助などについて説明する。次に機械学習・人工知能の仕組みについて説明する。現在の放射線科領域で用いられている人工知能は特定分野に限った特化型人工知能であり、具体的には既存のデータを学習する事によって未知のデータを予測する手法である機械学習の一種であり、様々な限界がある事を認識することが重要である。そして、画像診断補助以外の応用分野として、画質改善・変換およびCT造影効果予測への応用について述べる。最後に近年話題になっている大規模言語モデルや基盤モデルを含めて、人工知能の将来展望について述べる。

In recent years, artificial intelligence has been applied to various fields related to radiology and is replacing the conventional technologies. In this lecture, I will explain the basic structure of artificial intelligence, its learning mechanism, and its application in radiology, especially in image quality improvement/transformation and contrast agent administration.

人工知能(主にDeep Learning)の仕組み

人工知能(AI)は、人間の知能を模倣し、その機能をコンピュータ上で再現する技術の総称であり、その中でも機械学習は特にデータ解析や予測に特化した一部分を指しており、その機械学習の一種であるNeural Network, Deep Learning (Neural Networkで深い層を持つもの)は、大量の学習データを用いて、画像や音楽などの複雑なデータを学習する能力を持つ¹⁾。Deep Learningは、人間や動物の神経細胞を模倣したパーセプトロンを多数つなげた構造を持つ。各パーセプトロンは入力信号に係数を掛けて加算し、活性

化関数に入出力するという単純な構造をしているが、これらを多数つなげることで複雑な関係を表現することができるようになる万能近似定理という特性を持っている。これは、3層以上(入力層、出力層、隠れ層)のニューラルネットワークが、その重みの数に応じた精度で任意の関数を近似できるというものである²⁾。すなわちDeep Learningは、入力される行列と出力される行列との間にどんなに複雑でも一定の関係がある場合、そのようなデータを多量に用意できれば、その関係を変換する方程式を近似できる能力を持っている事を意味している。画像、文章、音楽などをふくめてこの世界のデータはほとんどが行列で表すことが可能であるため、Deep Learningは様々な用

途に使用することが可能である(図1)。

放射線科領域では、病変検出、鑑別診断、レポート作成、画質改善などにDeep Learningが応用されているが、これらの作業は、画像から画像、画像から分類、画像から文章への変換といった形でDeep Learningによる処理がされている。Deep Learningの種類には、パーセプトロンの連結方法の違いにより、画像の鑑別診断にはConvolutional Neural Network³⁾、画像から画像への変換にはU-net⁴⁾などがある。しかし、人工知能の放射線科領域への応用として一番に連想されるようなCTやMRIなどの画像から直接診断を行うような、Computer Aided Diagnosisについては、近年ではAIの学習が入力されたデータに非常に強く依存しているため、




図1 Deep Learningによるデータの取扱

様々なデータは行列に変換され、その後Deep Learningによって別の行列に変換される。その行列を人間に評価可能なデータに戻すことによってDeep Learningによる様々な処理が行われている。

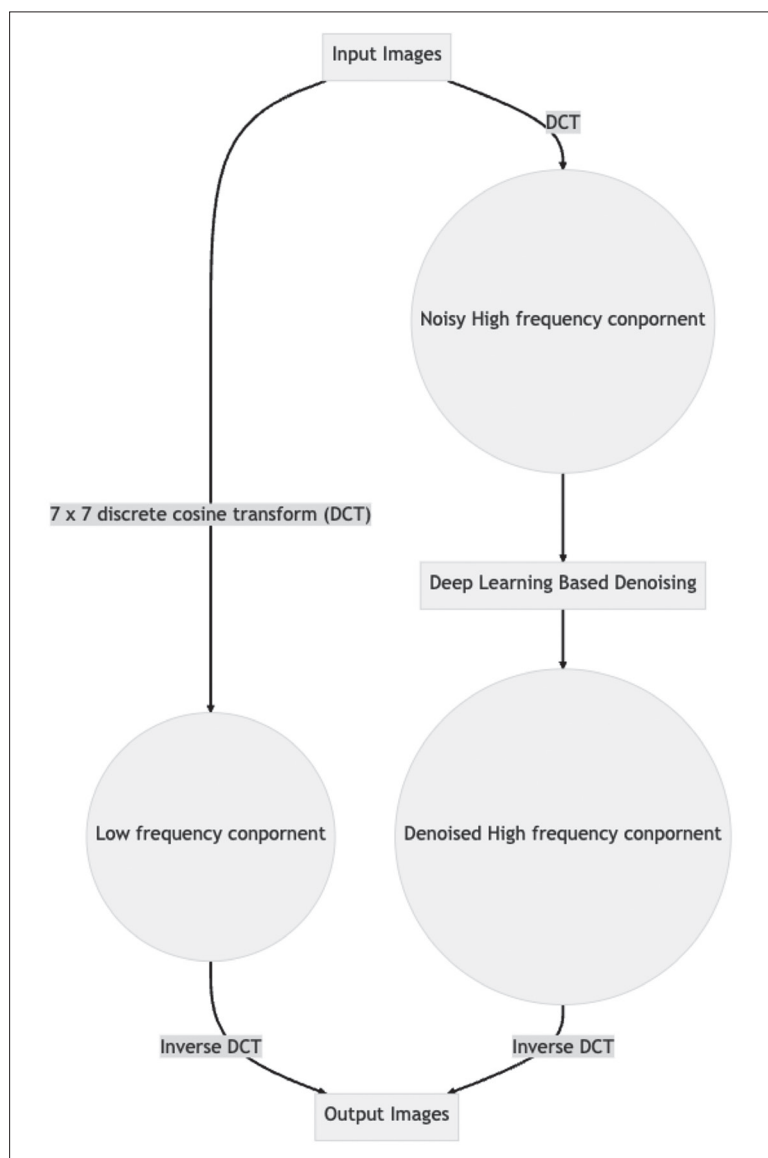


図2 代表的なDeep Learning Reconstruction (AiCE, Canon)の構造

Deep Learningによる処理を高周波成分にのみ行うことにより、様々なコントラストのデータに適用することが可能となっている。

他施設研究では期待されるほどの成績を収めるのはかなり難しいことが報告されつつある。

CT/MRI画質改善におけるDeep Learningの応用

CT/MRIの画像再構成におけるノイズ低減処理としては逐次近似再構成方法が有名であるが、古くからDeep LearningなどのNeural Networkでも画像ノイズの低減が可能なのは報告されている。これはノイズが含まれる画像からノイズが含まれない画像への変換として定義することによって、Deep Learningをこの変換の近似関数として学習させることで実現していることが多い。これは、Deep Learning ReconstructionやDeep Learning Denoisingなどと呼ばれている。しかし、単純な変換では様々なコントラストに対応できない可能性があり、学習データも膨大に必要になるため、各ベンダーで様々な取り組みが行われている。図2は代表的なDeep Learningの一つAiCE(Canon Medical Systems)の概略図である⁵⁾。CT/MRIのコントラストはk空間における低周波成分に含まれ、ノイズは高周波成分に位置する。この手法は画像の高周波成分に含まれるノイズと微細構造のうちノイズのみを除去する学習を行い、低周波成分はそのまま利用する。これによって画像のコントラストによらずCT/MRI特有のノイズを学習することが可能になり、コントラストや撮影部位の異なる様々な画像に対して同じ処理を行うことができる。初期は頭部MRIへの応用が主体であったが、前立腺⁶⁾やMR cholangiography⁷⁾などでも同じように有用であることが報告されている。また、compressed sensingなどの高速化技術との併用でも従来の技術であるwavelet denoisingと比較して、優れたノイズ低減効果があることも報告されており、高速化にも有用である⁸⁾。また、近年では高解像度化へも応用されている。

造影剤投与におけるシミュレーションや機械学習の応用

造影剤および造影効果と体格や心機能の関係について、「造影効果は体格および心機能に反比例する」という非常に多数の報告がある。大部分の症例ではこの関係は成り立っているものの、極端な心機能低下症例でのテストインジェクションで造影効果のピークが得られないなどの全く逆の影響がある⁹⁾。これは拡散が起る面積が大きいほど、また拡散が起る距離が短いほど、物質の拡散速度は速くなり、逆に拡散が起る面積が小さいほど、また拡散が起る距離が長いほど、物質の拡散速度は遅くなる性質でフィックの法則と呼ばれています。したがって、投与される液体の量が増えると、造影剤と血液の接する面積が相対的に小さくなり、拡散速度は遅くなるため影響が小さくなります。しかし、投与される造影剤量が減少して、血液に接する面積が相対的に大きくなり、心機能が低下して造影剤の移動に極端に時間がかかる場合は無視できない影響が出てくるため、注入時間が極端に短い場合は心機能と造影効果は比例するようになってしまう事がファントム実験で報告されている(図3)¹⁰⁾。

シミュレーションや機械学習はこれらの心機能の影響などの複雑な関係についても評価することが可能であり、シミュレーションは体重補正の造影剤投与よりも少ない造影剤量で安定した造影効果が得られる事が報告されている。また、機械学習を用いた場合は同じ造影剤プロトコルに限ればシミュレーションより正確に造影効果を予測できる可能性が報告されているものの、新たな造影剤注入プロトコルの時間の変更などに対応できない欠点があり、一長一短と思われる¹¹⁾。

おわりに

人工知能の放射線科領域への応用について、Deep Learningの仕組み、CT/MRIの画質改善・変換、造影剤投与方法に関して主に述べた。ChatGPTの成功によって大規模言語モデルへの注目も集まっており、今後はこの方面での応用も期待されている。

<文献>

- 1) LeCun Y et al: Deep learning. Nature Nature 521(7553): 436-444, 2015
- 2) Cybenko G: Approximation by superpositions of a sigmoidal function. Mathematics of Control, Signals and Systems 2(4): 303-314, 1989
- 3) Krizhevsky A et al: ImageNet classification with deep convolutional neural networks. Communications of the ACM 60(6): 84-90, 2017
- 4) Ronneberger O et al: U-Net: Convolutional Networks for Biomedical Image Segmentation. arXiv, 2015
- 5) Kidoh M et al: Deep Learning Based Noise Reduction for Brain MR Imaging: Tests on

- Phantoms and Healthy Volunteers. Magnetic Resonance in Medical Sciences 19(3): 195-206, 2020
- 6) Ueda T et al: Deep Learning Reconstruction of Diffusion-weighted MRI Improves Image Quality for Prostatic Imaging. Radiology 303(2): 373-381, 2022
- 7) Shiraishi K et al: Deep learning-based reconstruction and 3D hybrid profile order technique for MRCP a 3T: evaluation of image quality and acquisition time. Eur Radiol. 2023
- 8) Uetani H et al: Hybrid deep-learning-based denoising method for compressed sensing in pituitary MRI: comparison with the conventional wavelet-based denoising method. European Radiology 32(7): 4527-4536, 2022
- 9) Seehofnerová A et al: Feasibility of low contrast media volume in CT angiography of the aorta. European Journal of Radiology Open 2: 58-65, 2015
- 10) Kidoh M et al: Paradoxical Effect of Cardiac Output on Arterial Enhancement at Computed Tomography: Does Cardiac Output Reduction Simply Result in an Increase in Aortic Peak Enhancement? Journal of Computer Assisted Tomography 41(3): 349-353, 2017
- 11) Masuda T et al: Prediction of Aortic Contrast Enhancement on Dynamic Hepatic Computed Tomography—Performance Comparison of Machine Learning Methods and Simulation Software. Journal of Computer Assisted Tomography 46(2): 183-189, 2022

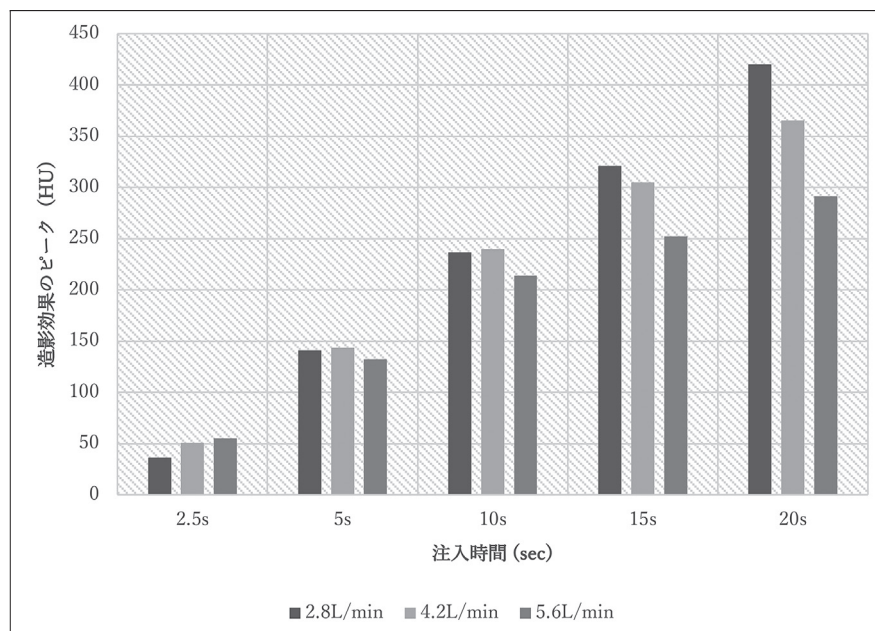


図3 心機能および造影剤注入時間(注入量)と心機能の関係

造影剤注入時間が長い(注入量が多い)場合は心機能と造影効果は反比例しているものの、極端に短い場合は逆に比例している。文献10 (Kidoh M, Nakaura T, et al. Paradoxical Effect of Cardiac Output Reduction Simply Result in an Increase in Aortic Peak Enhancement?) より改変