

「深層学習を用いた超低線量 CT のノイズ除去とその臨床応用」

先端医療センター PET 診療部

西尾 瑞穂

1 研究の背景と目的

CTは日常の診療で広範に活用されており、病変の局在診断や質的診断に重要な役割を果たしている。日本では東日本大震災の原発事故を契機とし放射線被曝に大きな関心が寄せられており、CTによる医療被曝も大きな課題となっている。

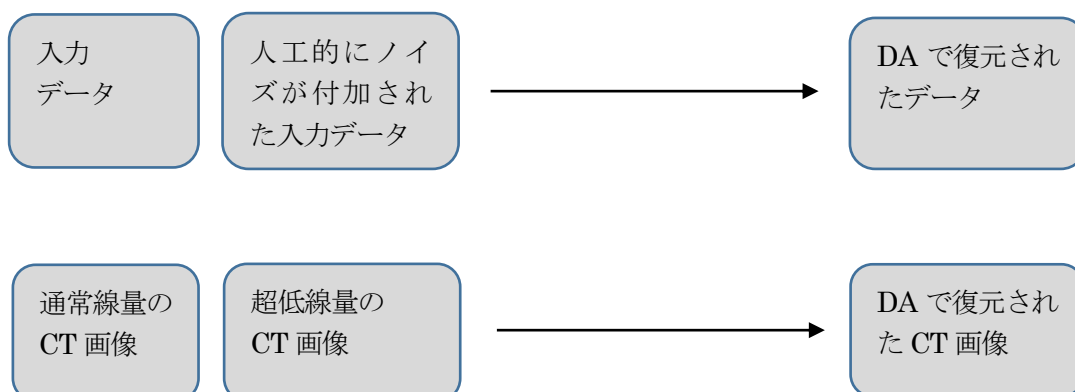
低線量 CT を用いた肺癌検診では、胸部単純 X 線写真と比べて肺癌の死亡率が 20%低減されることが示され、今後は低線量 CT を用いた肺癌検診が広く行われると期待される [1]。この低線量胸部 CT では、診断用の胸部 CT と比べて、放射線被曝が 1/5~1/6 程度に抑えられているが、この低線量 CT であっても肺癌検診を 20~30 年ほど連続で受けることで、肺癌リスクが喫煙と同程度もしくはそれ以上になると推定されている [2]。

このような放射線被曝の影響を軽減するために、従来の低線量 CT よりもさらに被曝を低減させた超低線量 CT や放射線被曝のない MRI の活用が検討されている。著者は過去に肺気腫の定量評価について超低線量 CT の臨床応用の研究を行った経験があり [3]、機械学習と関連の深いコンピューター支援診断の経験も有している [4]。今回は機械学習と超低線量 CT の二つの領域を融合する形で、深層学習を用いて超低線量 CT のノイズ除去を行うことを試みた。超低線量 CT では CT 画像に強いノイズが生じるが、本研究では、この CT 画像のノイズ除去の方法を深層学習によってソフトウェアに学習をさせ、超低線量 CT のノイズ除去が可能であることを示す。

2 研究方法・研究内容

深層学習とは簡潔に言えば 3 層以上の多層の人工ニューラルネットワークの学習方法である。人工ニューラルネットワークは脳の神経回路に見られる特性を計算機上のプログラムで表現することを目指したモデルであるが、back propagation などの既存のアルゴリズムでは多層の人工ニューラルネットワークに学習を行わせるのは困難といわれていた。深層学習はそれを可能とするアルゴリズムで、その一つとして Denoising autoencoder (DA) という方法が知られている。DA では入力データと入力データにノイズをかけたもののペアがニューラルネットワークの学習に利用され、ノイズを除去するように学習が行われる。通常、入力データへのノイズの付加は人工的に行われるが、本研究では人工的に入力データにノイズを付加するのではなく、通常線量 CT と超低線量 CT のペアを用いて、超低線量 CT のノイズを復元するようにニューラルネットワークを学習させた。模式図を下に示す。

図 1、Denoising autoencoder (DA) の模式図



大まかな処理の流れは上記の通りだが、今回は DA の 2 次元画像用である Convolutional autoencoder (CAE) を学習に用いた [6]。なお CAE の実装には chainer (<http://chainer.org/>) を使用した。

#### CT 画像

今回は特注胸部ファントム(京都科学、X-21)を 16 列の CT スキャナー(GE、lightspeed)で撮像した。管電流は超低線量 CT で 10 mA、通常線量 CT で 300 mA とし、ほかのパラメーターとして管電圧 120 kV、gantry rotation time 0.5 秒、スライス厚 1.25 mm に固定した。学習用・検証用として超低線量 CT を二回撮像した。

#### 前処理

CAE に学習を行わせる前に、CT 画像の前処理を行った。撮像ごとに CT 画像に微妙な位置ずれが生じるので、まずは deformable image registration で学習用の超低線量 CT と通常線量 CT の位置ずれを補正した。処理には ANTs (<http://stnava.github.io/ANTs/>) を用いた [7]。次に CT 値の範囲を変更した。通常、CT 画像の画素値は整数値で -1000 から 1000 の値を取ることがほとんどであるが、これを 0 から 1 の範囲の浮動小数となるように線形関数で処理した。

#### 学習データ作成と機械学習

位置ずれ補正済みの超低線量 CT、通常線量 CT のペアから、肺野に相当する部分を対象として無作為に 28x28 のサイズの画像パッチを 100000 ペア抽出して訓練用データとし、CAE で学習させた。訓練時の CAE では、入力に超低線量 CT と通常線量 CT のペアであり、CAE は超低線量 CT の画像パッチを通常線量 CT の画像パッチと似せるように学習を行う。また、学習の良さを評価するために別途 1000 ペアを無作為に抽出した。訓練後の CAE への入力は超低線量 CT の画像パッチであり、CAE はこの入力から 28x28 の画像パッチを出力する。1000 ペアを用いて、ペアごとにノイズ除去後の超低線量 CT、通常線量 CT の画像パッチ間で mean squared error (MSE) を計算し、学習の良さをパッチ間の平均の MSE で評価した。

CAE では入力・出力の次元を合わせる(入力 28x28、出力 28x28)ために、convolutional layer の kernel のサイズを 3x3、padding のサイズを 1x1 とし、pooling layer は除外した。チャンネル数は 20, 30, 40 を評価した。他、convolutional layer の層数が与える影響を評価するために、層数 1, 3, 5, 7, 9 で評価を行った。

#### CAE を用いたノイズ除去と他のノイズ除去の方法

前項で最も良い学習を行ったパラメーターの CAE を用いて、位置ずれ補正を行っていない検証用の超低線量の CT 画像に対して slice by slice でノイズ除去をした。ノイズ除去を行う前には前述の前処理を行い、ノイズ除去後に後処理として、浮動小数を整数値に変換し、通常の CT 画像と同じ範囲の値を取るようにした。

CAE を用いたノイズ除去では、まず超低線量 CT の画像のピクセルごとに 28x28 のパッチを抽出し、それを CAE にかけて CT 画像のピクセル数の分だけノイズ除去後の 28x28 のパッチを得る。次に、ノイズ除去後のパッチを重ね合わせて CT 画像とした。重ね合わせは過去の研究と同じ方法を用いた [5]。

他のノイズ除去の方法として、non-local means (NLM) [8] と BM3D [9] を CAE の比較対象とした。前処理・後処理は CAE と同じとした。NLM のパラメーターはパッチサイズを 11x11、パッチ間距離を 41x41, 81x81 とし [10]、h を 0.0001-0.05 とした。また、BM3D

のパラメーターとして  $\sigma$  を 5-40 とした。いずれも、画質の最も良いものを二つ視覚的に選んで、後述の視覚的評価の対象とした。

### 視覚的評価

上述のノイズ除去を上中下肺野の超低線量 CT 画像に行い、ノイズ除去後の画像を視覚的に評価した。視覚的評価の対象はストリークアーチファクトの強弱、ストリークアーチファクト以外のノイズの強弱、模擬血管の描出の良悪、全体の画質の良悪の 4 項目とした。これらの項目について、CAE、NLM、BM3D の画像を放射線科診断専門医が視覚的に評価し、各項目に順位を付けた。

### 3 研究成果

表 1 に訓練用データにおける CAE のパラメーターごとの MSE を提示する。基本的に層数が増えるほど、チャンネル数が増えるほど MSE が低下しており、良い学習が出来ていることが分かる。今回は層数 9、チャンネル数 40 の CAE で MSE が最も低く、これを超低線量 CT のノイズ除去に用いた。

表 1、1 ペア当たりの平均の mean squared error (MSE)

number of layer	number of channel		
	20	30	40
1	0.5547	0.5557	0.5390
3	0.4244	0.4048	0.3934
5	0.3892	0.3784	0.3634
7	0.3700	0.3614	0.3514
9	0.3656	0.3506	0.3313

注：位置ずれ補正済みのノイズ除去前の超低線量 CT、通常線量 CT 間で、1 ペア当たりの平均 MSE は 1.8472。

次に表 2 に視覚的評価の結果を示す。事前の評価から NLM ではパッチサイズが 11x11、パッチ間距離が 81x81、 $h$  が 0.02 と 0.03 の二つが選ばれ、BM3D では  $\sigma$  が 20 と 25 が選ばれた。表 2 に示すように上中下肺野のすべての項目において CAE が最も良い順位であった。

表 2、視覚的評価の結果、順位は小さいほど良い。

	BM3D ( $\sigma=25$ )	BM3D ( $\sigma=20$ )	NLM ( $h=0.03$ )	NLM ( $h=0.02$ )	CAE
上肺野					
ストリークアーチファクトの強弱	3	2	4	5	1
ストリークアーチファクト以外のノイズの強弱	3	2	4	5	1
模擬血管の描出の良悪	5	4	3	2	1
全体の画質の良悪	2	3	5	4	1

中肺野

ストリークアーチフ アクトの弱さ	3	2	4	5	1
ストリークアーチフ アクト以外のノイズ の弱さ	3	2	4	5	1
模擬血管の描出の良 悪	3	2	5	4	1
全体の画質の良悪	2	3	5	4	1

下肺野

ストリークアーチフ アクトの弱さ	3	2	4	5	1
ストリークアーチフ アクト以外のノイズ の弱さ	3	2	4	5	1
模擬血管の描出の良 悪	2	3	5	4	1
全体の画質の良悪	2	3	5	4	1

最後に図2にノイズ除去後のCT画像を提示する。ウィンドウ条件は同一である。

図2、左から BM3D( $\sigma=25$ )、BM3D( $\sigma=20$ )、NLM( $h=0.03$ )、NLM( $h=0.02$ )、CAE



4 生活や産業への貢献および波及効果

本研究の結果により、超低線量CTのノイズ除去にCAEを用いることが可能であることが示された。また、放射線科診断専門医による視覚的評価では、CAEによるノイズ除去は既存の方法を上回っていた。この結果を実際の患者の超低線量CTに応用することで、CT検査を受ける患者の放射線被曝を軽減させることが可能になると期待される。医療被曝による癌の誘発については明らかになっていない部分もあるが、医療被曝を低減させることは潜在的な放射線誘発癌の減少につながると予想される。

参考文献

1. National Lung Screening Trial Research Team; Aberle DR, Adams AM, et al. Reduced lung-cancer mortality with low-dose computed tomographic screening. *N Engl J Med* 2011; 365:395- 409
2. McCunney RJ, Li J. Radiation risks in lung cancer screening programs: a comparison with nuclear industry workers and atomic bomb survivors. *Chest* 2014; 145:618- 624
3. Nishio M, Koyama H, Ohno Y, et al. Emphysema Quantification Using Ultralow-Dose CT With Iterative Reconstruction and Filtered Back Projection. *AJR*: in p

ress.

4. Nishio M, Matsumoto S, Koyama H, et al. Computer-aided diagnosis for differentiation of lung nodules on CT: a scheme using sparse coding with spatial zoning. Proceedings of The 28th Computer Assisted Radiology and Surgery, 2014
5. Burger H, Schuler C, Harmeling S. Image denoising: Can plain neural networks compete with bm3d? Proceedings of Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on, pp. 2392- 2399.
6. Masci J, Meier U, Ciresan D, Schmidhuber J. Stacked Convolutional Auto-Encoders for Hierarchical Feature Extraction. ICANN 2011, Part I, LNCS 6791, pp. 52- 59, 2011.
7. Murphy K, van Ginneken B, Reinhardt JM, et al. Evaluation of registration methods on thoracic CT: the EMPIRE10 challenge. IEEE Trans Med Imaging. 2011 Nov;30(11):1901-20.
8. Buades A, Coll B, Morel JM. A non-local algorithm for image denoising. Proceedings of Computer Vision and Pattern Recognition (CVPR), 2005. IEEE Conference on, pp 60- 65 vol. 2
9. Dabov K, Foi A, Katkovnik V, Egiazarian K. Image denoising by sparse 3D transform-domain collaborative filtering. IEEE Trans. Image Process. 2007;16:2080-2095
10. Chen Y, Chen W, Yin X, et al. Improving low-dose abdominal CT images by Weighted Intensity Averaging over Large-scale Neighborhoods. Eur J Radiol. 2011 Nov;80(2):e42-9.