

AI解析 基礎講座

第3回 深層学習によるX線CT再構成画像の画質改善と解析精度向上

西澤 颯人*

太田 卓見**

深層学習によるX線CT再構成画像の画質改善方法について解説する。短時間撮影の粗いX線CT再構成画像と長時間撮影の明瞭なX線CT再構成画像を教師データに用いて、X線CT再構成画像のノイズパターンを除去するモデルの作成方法を説明する。電池とプラスチック部品を例として、深層学習により短時間撮影のX線CT再構成画像の画質が改善されることを示す。また、それらの画像に対する解析例を紹介し、深層学習によって解析精度が向上することを報告する。

1. はじめに

X線CTは非破壊で試料を3次元的に観察、数値解析できる技術であり、ものづくりの分野において研究開発から品質保証、故障解析まで幅広く使用されている。精度の高い分析を行うためには明瞭なCT画像を得る必要があり、そのためには、例えば使用するX線のエネルギーや分解能、そして撮影時間の選択が重要となる。撮影時間が短いCT画像ではノイズが多くなり、観察、数値解析における精度を損なう要因となる。しかしながら、特に品質保証、故障解析の分野においては、1日当たりの試料数および作業効率(スループット)が重視されるため、短時間で、高精度な評価を行うことが求められる。現状では、X線CTは抜き取り検査での利用が多く、高効率化による検体数の増加が望まれている。

深層学習による画質改善の一般的な手法として、CNN(Convolution Neural Network)を基盤とする深層学習による画像の高画質化が研究されてきた⁽¹⁾。通常、CT画像の深層学習では、大量のデータからCT画像特有のノイズや構造的特徴を学習する⁽¹⁾。CNNは局所的な空間特徴を階層的に抽出できることから、低線量CT画像に含まれる複雑なノイズ分布と微細構造を効果的に分離でき、撮影高速化に伴う画質劣化を補償する手法として注目を集めている。しかしながら、多くの研究では画像の評価指標を用いて画質改善の評価がなされており、その画像を用いた解析の精度に与える

影響はあまり検討されてこなかった^{(1),(2)}。

本稿では、深層学習を用いたX線CT再構成画像の高画質化が解析の精度に与える影響を評価する。2章では、深層学習のモデルの学習に必要な教師データの準備方法を説明する。次に、教師データを用いて学習と推論を行う方法を示す。3章では、電池とプラスチック部品の試料を例として用いて、深層学習によって画質が改善されたことを示す。また、推論前後の画像を解析することで、解析の精度が向上したことを報告する。

2. モデルの作成と推論

2.1. 教師データの用意

本稿で紹介する深層学習のモデルを学習させるために、短時間で撮影した透視画像から再構成した低画質の再構成画像と、長時間で撮影した透視画像から再構成した高画質の再構成画像とを使用する。再構成画像の断面を順番に並べたものをCTデータセットと呼ぶ。低画質のCTデータセットを教師(粗)、高画質のCTデータセットを教師(精)と呼び、これら2つを教師データとして用意する。

モデルは(A),(B)の2通りの方法で作成した。手法(A)では、短時間撮影のCTデータセットを教師(粗)、長時間撮影のCTデータセットを教師(精)とした。ここで、この2個のCTデータセットは、透視像の撮影枚数は同一で、透視像一枚あたりの露光時間だけが異なる。手法(B)では、長時間の撮影を1回行い、そこから透視画像を等間隔に間引いて再構成したCTデータセットを教師(粗)、間引かずに再構成したCTデータ

*株式会社リガク XI設計

**株式会社リガク X線研究所

表1. モデル作成条件.

試料	手法	教師(粗)	教師(精)
電池	(A)	4分撮影	17分撮影
プラスチック部品	(B)	120/2400枚再構成	2400/2400枚再構成

セットを教師(精)とした。手法(B)は、撮影した画像を間引く手間はああるものの、撮影が1回で済み、なおかつ教師(粗)とデータと教師(精)における試料ドリフトの影響が少ないという利点を持つ。

試料として電池(円筒型電池)とプラスチック部品を使用した。両試料とも、全数検査や短時間での撮影、さらに定量的な数値解析が求められている。電池では、内部短絡や発火の原因となる「巻きずれ」を防ぐために設けられた「オーバーハング」の長さを、短時間で定量的に解析する必要がある。一方、プラスチック部品では、表面積の全数検査を行い、成型不良(バリ、ヒケ、表面粗さ)などを定量的に評価することが求められている。

電池は手法(A)、プラスチック部品は手法(B)でモデル作成を行った。作成条件を表1に示す。電池は4分撮影したCTデータセットを教師(粗)とし、同じ位置で17分撮影したCTデータセットを教師(精)とした。一方、プラスチック部品は透視画像を2400枚分撮影し、そこから120枚まで等間隔に間引いて再構成したものを教師(粗)とし、2400枚全てを再構成に使用したものを教師(精)とした。作成したモデルを用いて推論した結果とともに3章にてそれぞれの画像を示す。

2.2. モデルの学習

今回の深層学習のモデルとしては、一般的な二次元のDnCNN (Denoising Convolutional Neural Network)⁽²⁾⁻⁽⁴⁾を用いた。モデルの学習のイメージを図1に示す。モデルの学習では、まず教師(粗)に対して計10層分、畳み込みとバッチ正規化のカーネルを適用し、ノイズ画像を推定する。そして教師(粗)からノイズ画像を差し引いたものが教師(精)に近づくようにカーネルを精密化する。このサイクルを反復することで、ノイズパターンを除去するモデルを得ることができる。今回は反復計算を20エポック行った。

2.3. 推論

推論では、入力した推論前データセットに学習済みモデル(カーネル)を適用すると、推定されたノイズが差し引かれた推論後データセットが出力される。

各試料における推論対象を表2に示す。電池においては、教師データ(粗)と同じデータ(4分撮影)を推論対象とした。一方、プラスチック部品においては、新しく2分、4分、8分、15分、30分で撮影したデータを用意し、そのうちの2分のデータのみを推論対象とした。

学習済みモデルを使用した推論に要する時間は数秒から数分である。推論時に用意するデータセットは教師(粗)と類似の条件で取得すればよいので、非常に簡便かつ容易に利用可能な深層学習の手法といえる。

表2. 各試料における推論対象.

試料	手法	推論対象
電池	(A)	4分撮影データ
プラスチック部品	(B)	2分撮影データ




図1. モデル作成.

3. 評価方法と評価結果

3.1. 電池

電池について、推論前データ、教師(精)、推論後データを用意し、それぞれの画像における正極と空気部分のCNR (contrast to noise ratio)の比較を行った。さらに、定量的な解析として電極のオーバーハング解析を実施した。

CNRの値を表3に、比較に用いた画像を図2に示す。得られた推論後データでは、推論前データと比較して

ノイズが大幅に低減し、CNRの値は推論前後で7倍改善しており、さらに教師(精)よりも5倍良い値を示した。CNR改善の結果、電池の負極と正極をより明瞭に分離できていることが、図2において線分AB上のラインプロファイルからも確認できる。

さらにこれらのデータに対してオーバーハング解析を行った結果を表4に示す。推論データのオーバーハング長さの値は、教師(精)と同じ値を示した。これは図3に示すように、推論により教師(粗)のノイズ成

表3. 電池CNRの比較.

	Mean (正極)	Mean (空気)	StdDev (空気)	CNR
推論前	26551	18196	1622	5.2
教師(精)	24273	16764	988	7.6
推論後	37691	24273	351	38.2




図2. 電池CT断層画像の比較.

表4. 電池オーバーハング長さの比較.

データ	オーバーハング長さ(mm)
推論前データ	0.64
教師(精)	0.59
推論後データ	0.59




図3. 電池オーバーハング解析.

分が除かれたことで、電極の形状をより明瞭に抽出することができたためである。今回、教師(粗)は4分で撮影し、教師(精)は17分で撮影している。このことは、推論により4分で撮影したデータの解析の精度を17分で撮影したデータの解析精度と同程度にすることができたことを意味する。すなわち、深層学習を用

表5. プラスチック部品CNRの比較.

データ	Mean (試料)	Mean (空気)	StdDev (空気)	CNR
教師(粗)	53390	11113	4722	9.0
教師(精)	53771	11082	953	44.8
2分推論前	56515	11802	4230	10.6
2分推論後	53699	14253	141	280




図4. プラスチック部品CT断層画像の比較.

いることで、解析精度を同程度に保ったまま、撮影時間を約4分の1にできることが期待できる。

3.2. プラスチック部品

プラスチック部品について、教師(粗)、教師(精)、および2分撮影の推論前後のそれぞれの画像における試料と空気部分のCNR (contrast to noise ratio) の比較を行った。さらに、撮影時間の条件を変えた複数の撮影データと、短時間撮影(2分)の推論データについて表面積を算出し、推論によってどの程度の解析精度の向上が得られるかを検証した。

CNRの値を表5、比較に用いた画像を図4に示した。2分撮影の推論後では、推論前と比較してCNRが28倍改善しており、さらに教師(精)より6倍良い値を示した。

推論前のデータ(2分, 4分, 8分, 15分, 30分), 2分撮影の推論後のデータ, 教師(精)に対して表面積を求めた結果を表6に示した。今回、教師(精)の値を表面積の真値として取り扱っている。推論前のデータにおける表面積値は、撮影時間が長くなるほど真値に漸近することが確認された。一方、2分撮影のデータを推論すると、表面積値は真値に近づいた(図5)。

また、2分撮影データの推論前後の3D画像を図6に

表6. プラスチック部品の表面積.

撮影時間	表面積(mm ²) 推論前	表面積(mm ²) 推論後
2分	2956	2821
4分	2895	—
8分	2849	—
15分	2838	—
30分	2833	—
教師(精)	2836	—




図5. プラスチック部品の撮影時間-表面積グラフ.



図6. 推論前後の3D画像の比較.

示す。推論後のデータでは、推論前のデータに見られた表面のざらつきが緩和されており、これが表面積の低下と解析精度の向上につながったと考えられる。今回、教師(精)の撮影時間(露光時間)は40分であるため、深層学習により解析精度を保ったまま、撮影時間を約20分の1にすることが期待できる。

4. おわりに

深層学習によるX線CT再構成画像の画質改善方法について解説した。短時間撮影の粗いX線CT再構成画像と長時間撮影の明瞭なX線CT再構成画像を教師データ

に用いて、X線CT再構成画像のノイズパターンを除去するモデルの作成方法を説明した。電池とプラスチック部品を例として、深層学習により短時間撮影のX線CT再構成画像の画質が改善されることを示すとともにそれらの画像に対する解析例を紹介し、深層学習によって解析精度が向上することを報告した。

本稿で紹介した例では、学習時と推論時で同一のCT装置を用いて撮影を行った。類似の試料であれば深層学習の汎化性が期待できるので、必ずしもCT装置は同一でなくてもよい。例えば、放射光施設で撮影したデータを教師データとして学習させたモデルを、他のCT装置で撮影したデータの推論に使用できる。これにより研究室や製造現場で得られたデータを放射光施設のデータと同等の品質にすることも可能である。実際の応用例に関しては、今後の出版物または研究会での発表を参考にされたい。

参考文献

- (1) J. Zhou, T. Xia, E. Lee and K. Cai: *First Online*: 11 October 2024.1–19.
- (2) K. Zhang, W. Zuo, Y. Chen, D. Meng, and L. Zhang: *IEEE Trans. Image Process.*, **26** (2017), 3142–3155.
- (3) K. Usui, K. Ogawa, M. Goto, Y. Sakano, S. Kyougoku and H. Daida: *Vis. Comput. Ind. Biomed. Art*, **4** (2021), 21.
- (4) T. Zhao, M. McNitt-Gray and D. Ruan: *Med. Phys.*, **46** (2019), 3941–3950.