

トモグラフィ画像再構成の基礎とトレンド

～解析的再構成法から圧縮センシングを経て深層学習まで～

工藤 博幸¹⁾ 藤井 克哉²⁾ 橋本 康²⁾

矢代 航^{**,***} ヴォルフガング・フォグリ^{****}

1. はじめに

CT (Computed Tomography) 技術は1973年に医療診断において実用化されたが、2000年以降非破壊検査や材料計測に用いられ既に有効なツールとして定着している。CT 技術のキーは、X 線・電子線その他波動を用いて測定された物体の線積分を表す投影データから、データ処理により断面の画像を生成する画像再構成法にあるといつて過言ではない。

本論文では、CT 画像再構成法の歴史的な変遷と進歩について、当該分野に馴染みがない読者を対象として平易に解説する。

まず、CT 画像再構成法の進歩をまとめると、表 1 のようになる。2000年頃までは第 1 世代のフーリエ変換や微積分に基づく解析的再構成法、及び画像と投影データの間係を表す線形方程式を反復法で解く逐次近似再構成法が用いられていた⁽¹⁾⁻⁽⁸⁾。これらの手法の欠点は、投影データの方向数が少ない状況(スパースビュー CT と呼ばれる)や投影データの

表 1 CT 画像再構成法の歴史的進歩の概観。

	第1世代 1973年～2000年頃	第2世代 2000年頃～2017年	第3世代 2017年以降
画像再構成法のクラス	・解析的再構成法 (フーリエ変換, 微積分) ・逐次近似再構成法	・圧縮センシング ・統計的再構成法	深層学習
具体的な方法	フィルタ補正逆投影 (FBP) 法, ART 法, SIRT 法	TV 正則化, MBIR (Model-Based Iterative Reconstruction)	FBP 再構成 + 畳み込みニューラルネットワークで雑音・アーティファクトを低減する後処理
性能・何が可能になったか	CT には「細かいサンプリング + 高 SN 比」の投影データが必要	スパースビュー CT, 低線量 CT が実用化	効果は未だ未知

* 筑波大学システム情報系; 1) 教授 2) 研究員 (〒305-8573 つくば市天王台 1-1-1)

** 東北大学 国際放射光イノベーション・スマート研究センター; 教授

*** 東北大学 多元物質科学研究所; 教授

**** 東京学芸大学 自然科学系; 准教授

Fundamental and Trend of Tomographic Image Reconstruction: from Analytical Reconstruction Method, through Compressed Sensing, to Deep Learning; Hiroyuki Kudo*, Katsuya Fujii*, Koh Hashimoto*, Wataru Yashiro**,* and Wolfgang Voegeli**** (*Faculty of Engineering, Information and Systems, University of Tsukuba, Tsukuba. **International Center for Synchrotron Radiation Innovation Smart, Tohoku University, Sendai. ***Institute of Multidisciplinary Research for Advanced Materials, Tohoku University, Sendai. ****Department of Physics, Tokyo Gakugei University, Tokyo)

Keywords: tomography, CT, inverse problem, image reconstruction, sparse-view CT, low-dose CT, filtered backprojection, compressed sensing, total variation, deep learning

2021年 9 月 13 日受理 [doi:10.2320/materia.61.7]

SN 比が悪い状況(低線量 CT と呼ばれる)では、画質の劣化が大きいくことであった。そして、2000年代になり粗くサンプリングされた測定データから原信号を高精度で復元する圧縮センシング(Compressed Sensing, CS)と呼ばれる逆問題解法が発見され、第2世代としてCSやそれに関連したスパース正則化に基づく画像再構成法が研究され実用化に至った⁽⁹⁾⁻⁽¹⁹⁾。CTが発明されて30年が経過して、ようやく少ない方向数やSN比が悪い投影データでCTを実現する夢がかなえられた。更に、2017年には第3世代と位置づけられる深層学習を用いた画像再構成の研究が始まり、現在世界的に精力的に研究が行われている状況である⁽²⁰⁾⁻⁽²⁶⁾。

本論文では、上述の歴史を踏まえ、第1世代の解析的再構成法と逐次近似法、第2世代の圧縮センシング、第3世代の深層学習再構成法、について解説する。

2. 解析的再構成法と逐次近似再構成法(第1世代)

まず、CTにおける画像再構成問題を定式化することから始める。図1に、CTにおける投影データ収集の様子を示す。物体の物理量分布を表す画像を $f(x,y)$ とする。CTでは、各角度 θ 方向から物体に平行なX線を照射してX線源と反対側に配置した検出器により、物体を透過したX線の強度を測定する。この測定データは、動径 r と角度 θ の関数として $p(r,\theta)$ と表され、X線が通過する直線 $x\cos\theta+y\sin\theta=r$ 上の $f(x,y)$ の線積分の意味を持っており投影データと呼ばれる。投影データを測定する角度範囲は通常 $0^\circ\sim 180^\circ$ であり、この範囲の投影データを測定すれば物体を通過する全ての直線上の線積分を測定したことになる。 $f(x,y)$ と $p(r,\theta)$ の関係は次式で表される。

$$p(r,\theta) = \int_{-\infty}^{\infty} f(r\cos\theta - s\sin\theta, r\sin\theta + s\cos\theta) ds \quad (1)$$

式(1)を $f(x,y)$ に $p(r,\theta)$ を対応づける変換と考え発見者の名にちなみラドン変換と呼ぶ。CTにおける画像再構成は、式(1)に基づき $p(r,\theta)$ から $f(x,y)$ を復元する逆問題である。




図1 CTにおける投影データ収集の方法。

(1) フィルタ補正逆投影 (Filtered Backprojection, FBP)法⁽¹⁾⁻⁽³⁾

現在のほとんど全てのCT装置では、第1世代の解析的再構成法に属するFBP法と呼ばれる手法が用いられている。FBP法は式(1)をフーリエ変換や微積分を用いて解析的に $p(r,\theta)$ から $f(x,y)$ を求める逆変換の形に変形し、逆変換を計算することで画像再構成を行う手法である。以降では、FBP法の導出を簡潔に述べる。まず、FBP法の基礎となるのは投影切断面定理と呼ばれる $f(x,y)$ と $p(r,\theta)$ をフーリエ空間で関係づける定理である。いま、 $f(x,y)$ の2次元フーリエ変換を $F(\mu,\nu)$ (μ,ν は x,y に対応する角周波数)、 $p(r,\theta)$ の動径 r に関する1次元フーリエ変換を $P(\omega,\theta)$ (ω は角周波数)で表すと、次式が成り立つ。

$$F(\omega\cos\theta, \omega\sin\theta) = P(\omega,\theta) \quad (2)$$

図2に式(2)の意味を示すが、角度 θ 方向の投影データ $p(r,\theta)$ は $f(x,y)$ の2次元フーリエ変換 $F(\mu,\nu)$ の θ 方向の切断面の情報を持っている。よって、様々な角度 θ の投影データを1次元フーリエ変換して画像の2次元フーリエ変換 $F(\mu,\nu)$ の情報を埋め、2次元フーリエ逆変換することで画像再構成ができる。その手順は次式で表される。

$$p(r,\theta) \xrightarrow{\text{1D Fourier}} P(\omega,\theta) = F(\omega\cos\theta, \omega\sin\theta) \xrightarrow{\text{2D Inverse Fourier}} f(x,y) \quad (3)$$

FBP法は式(3)の2次元フーリエ逆変換の部分を実座標で計算することから導かれ、その処理手順は最終的に Step-by-Step の表現で書くと次式となる。

[Step 1] 投影データの1次元フーリエ変換

$$P(\omega,\theta) = \int_{-\infty}^{\infty} p(r,\theta) \exp(-j\omega r) dr \quad (4)$$

[Step 2] フィルタ関数 $|\omega|$ の乗算と1次元フーリエ逆変換

$$q(r,\theta) = \frac{1}{2\pi} \int_{-\infty}^{\infty} P(\omega,\theta) |\omega| \exp(j\omega r) d\omega \quad (5)$$

[Step 3] 逆投影

$$f(x,y) = \frac{1}{2\pi} \int_0^\pi q(x\cos\theta + y\sin\theta, \theta) d\theta \quad (6)$$




図2 投影切断面定理の意味。

FBP法の直感的な意味は以下のように解釈すると分かりやすい。式(6)の逆投影と呼ばれる演算は、各再構成点 (x, y) に対してこの点を通る $0^\circ \sim 180^\circ$ の投影データを加算する演算で、いわば全ての方向の投影データを重ね合わせる処理である。しかし、数学的に逆投影のみで画像再構成を行うとぼやけて再構成されてしまい、逆投影の画像のぼけを先に投影データに高周波強調フィルタを作用させ補正するのがFBP法である。

現在の医療用CT装置は、X線管からファン状のX線を照射するファンビームCTとコーン状のX線を照射して3次元断層像を生成するコーンビームCTが主流である(図1)。FBP法はファンビームやコーンビームにも拡張することができる⁽¹⁾。

(2) 逐次近似再構成法⁽⁴⁾⁻⁽⁸⁾

次に、解析的再構成法とは考え方が全く異なる逐次近似再構成法について述べる。基本となる考え方は、式(1)を離散化して画像と投影データの関係を表す線形方程式を作り、これを様々な反復法を用いて解くことで画像再構成を行う手法である。いま、画像の画素値を一列に並べた J 次元ベクトルを $\mathbf{x} = (x_1, x_2, \dots, x_J)^T$ 、投影データを一列に並べた I 次元ベクトルを $\mathbf{b} = (b_1, b_2, \dots, b_I)^T$ で表す。このとき、式(1)を離散化すると次式の線形方程式で近似的に表すことができる。

$$A\mathbf{x} = \mathbf{b} \left(\sum_{j=1}^J a_{ij}x_j = b_i \quad (i=1, 2, \dots, I) \right) \quad (7)$$

式(7)において測定した投影データの数 I が画像の画素数 J より大きく $I \geq J$ であれば、式(7)を解くことで投影データ $\mathbf{b}$ から画像 $\mathbf{x}$ を再構成することができる。ただし、式(7)は次元が極めて大きく数万次元になるため反復法を用いて解くのが一般的である。このような考え方の再構成法を逐次近似再構成法と呼ぶ。代数的に定式化することが本質であり逐次近似法という用語は適切でないと思われるが、CT分野ではそのように呼ばれる。

式(7)を解く線形方程式の反復解法は様々なものが存在するが、ここでは初期の段階に考案されたART(Algebraic Reconstruction Technique)法とSIRT(Simultaneous Iterative Reconstruction Technique)法について述べる⁽⁵⁾⁻⁽⁸⁾。幾

何学的に考えると、方程式 $A\mathbf{x} = \mathbf{b}$ を構成する各々の式 $\sum_j a_{ij}x_j = b_i (i=1, 2, \dots, I)$ は J 次元ベクトル空間の超平面 $h_1, h_2, \dots, h_I$ を表しており、全ての超平面は一点で交わりその交点が方程式の解である。一般の次元の場合には図では描けないが、 $J=2, I=2$ の場合の様子を図3(a)に示す。交点を求める反復法として、初期画像 $\mathbf{x}^{(0)}$ を与え図3(a)に示すように超平面 $h_1, h_2, \dots, h_I$ に順番に一つずつ射影を行うことを繰り返す(一巡が終了したら最初に戻る)方法が考えられる。このような反復法は画像再構成の分野でGordonらにより提案されART法と呼ばれる⁽⁶⁾。後になって、ART法は数学者Kaczmarzが既に発見していた線形方程式の反復解法と同じであることが分かった。ART法の反復式は、一般の次元 J の場合について次式で表される。

初期化: $\mathbf{x}^{(0)}$, arbitrary

反復: $k=0, 1, 2, \dots$

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \frac{b_i - \mathbf{a}_i \cdot \mathbf{x}^{(k)}}{\|\mathbf{a}_i\|^2} \mathbf{a}_i \quad (i = k \pmod I + 1) \quad (8)$$

ただし、 $\mathbf{a}_i$ は行列 A の i 行目の行ベクトルを表し($\cdot$ はベクトルの内積)、最後の $i = k \pmod I + 1$ は射影を行う超平面を選ぶ順番を決める関数でアクセスオーダーと呼ばれる。ART法の最大の特徴は一回の画像更新に投影データの二標本値 b_i のみを用いる点で、このような構造の反復法をRow-Action型と呼ぶ。近年ART法のアクセスオーダーを上手く設計すると極めて高速に収束することが示され、Row-Action型の反復法がリバイバルしている⁽⁸⁾。問題点としては、線形方程式の解法であるため、投影データに雑音が含まれ全ての超平面が一点で交差しない場合には、雑音が上手く平均化されずSN比が悪い画像に収束する点が挙げられる。

次に、ART法の雑音特性が悪い問題点を解決したSIRT法について述べる。いま、式(7)において $I > J$ ではあるが投影データ $\mathbf{b}$ に雑音が含まれる場合を考える。この場合、 $A\mathbf{x} = \mathbf{b}$ を満足する $\mathbf{x}$ は存在せず、雑音の影響を抑制するには最小2乗法に基づき次式の評価関数 $f(\mathbf{x})$ を最小化するのが妥当である。

$$f(\mathbf{x}) = \|A\mathbf{x} - \mathbf{b}\|^2 = \sum_{i=1}^I \left(\sum_{j=1}^J a_{ij}x_j - b_i \right)^2 \quad (9)$$

$f(\mathbf{x})$ を最急降下法を用いて最小化する具体的な反復式は次式




図3 (a) ART法の画像更新の幾何学的意味、(b) SIRT法の画像更新方向とART法の画像更新方向の関係。

となる。

初期化: $\mathbf{x}^{(0)}$, arbitrary

反復: $k=0,1,2, \dots$

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha A^T(\mathbf{b} - A\mathbf{x}^{(k)}) \quad (10)$$

ただし, $\alpha > 0$ は更新量を表すステップサイズである. SIRT 法は α を $0 < \alpha < 2/\|A^T A\|$ を満たすように選べば式(9)を最小化する最小2乗解に収束し ART 法と比較して雑音特性が良い. 一方, 式(10)は投影データの全標本値を同時に用いて画像更新を行う形をしており, このような構造の反復法を同時反復型と呼び収束が遅いことが知られる. また, ART 法の画像更新と SIRT 法の画像更新には図3(b)に示す関係がある. SIRT 法の画像更新方向 $A^T(\mathbf{b} - A\mathbf{x}^{(k)})$ は ART 法の更新方向である各超平面 $\mathbf{a}_i \cdot \mathbf{x} = b_i (i=1,2, \dots, I)$ への射影を全ての超平面について同時に計算して重み付き平均化したものになっている. 最後に, 歴史的に ART 法や SIRT 法は電子顕微鏡分野において3次元画像を様々な方向の電子顕微鏡画像から構築する(現在の電子線トモグラフィを)目的に提案されたこともあり, 電子線トモグラフィ分野では SIRT 法の使用が定着している.

3. 圧縮センシング(第2世代)⁽⁹⁾⁻⁽¹⁹⁾

様々な CT 技術の応用において, 長年少ない方向数の投影データから画像再構成を行うスパースビュー CT, X 線管の電流を落として低線量で測定した SN 比が悪い投影データから画像再構成を行う低線量 CT の実用化の要望が大きい. 例を挙げればきりが無いが, 代表的な例を述べる. 医療用 CT の分野では, 2000年代に入り CT 検査の被曝ががんリスクを高めることを指摘する論文発表や米国で発生した被曝事故が重なり, 低線量 CT の実用化は2000年頃から現在の最重要テーマの一つである⁽⁹⁾⁽¹⁰⁾. 別の例として, 電子線トモグラフィの分野では, 連続傾斜像の測定に数十分程度の時間がかかり測定時間短縮のためスパースビュー CT への期待が非常に大きい⁽¹¹⁾. 放射光 CT や暗視野 CT においても, 同様に測定時間が長い問題点がある. 第1世代の画像再構成法では, 再構成の処理中に雑音の平滑化を行ったり測定データ不足を何らかの先験情報で補う枠組みが組み込まれていないため, スパースビュー CT や低線量 CT の画像再構成には太刀打ちできなかった. しかし, 2000年代に入って Candès らと Donoho が, 圧縮センシング(Compressed Sensing, CS)と呼ばれる不足した測定データから原信号を高精度で復元する逆問題の新解法を発見し, 状況は一変した⁽¹²⁾⁽¹³⁾. その後 CS は多くの計測技術に波及したが, CT 分野でも膨大な数の CS を用いた画像再構成法の研究開発が行われようやくスパースビュー CT や低線量 CT が実用化に至った. 以降では, CS の原理を平易に述べる.

CS の原理はスパースビュー CT を例に説明するのが最も分かりやすい. 投影データの方向数が少ないスパースビュー CT の状況では, 式(7)の画像と投影データの関係を表す式において未知数の数 J が測定データの数 I よりはるかに大き

い $J \gg I$ の状況となり, $A\mathbf{x} = \mathbf{b}$ を満たす画像 $\mathbf{x}$ は無数に存在し画像再構成問題の解は一意に定まらない. このような状況でも, 高精度で画像 $\mathbf{x}$ が復元できる場合があることを数学的に示し, 更には実際に様々な事例に適用すると従来の逆問題解法と比較してはるかに高精度で画像復元できる手法が CS である. CS のキーは以下に述べる「スパース性」という従来の逆問題解法にはなかった着想である. スパース性とは, 画像 $\mathbf{x}$ にある行列 W を乗じて線形変換した際に変換係数 $W\mathbf{x}$ にゼロ成分(ゼロに近く無視できる成分)の数が多い性質のことである. 図4に, 楽器音と自然画像の場合の典型的なスパース性の例を示す. 例えば, 望遠鏡で撮影された画像は背景が黒でゼロの画素が多い, 楽器音は少数の正弦波の重ね合わせで表現できフーリエ変換した空間ではスパース, 自然画像は(画像自身はスパースでないが)微分して濃度勾配を取るとエッジ以外はほぼゼロになりスパース, などが代表的な例である. この信号をスパースにする変換 W をスパースファイ変換と呼び, 扱う信号の種類により様々なものが考えられる. そして, $A\mathbf{x} = \mathbf{b}$ を解いて信号を復元する際にスパース性を用いて $\mathbf{x}$ の未知数の数を削減して解が一意に定まる良条件の問題にして解くのが CS である. しかし, 変換 W でスパースにできることは既知でも変換係数 $W\mathbf{x}$ のどの要素がゼロかは事前に未知の場合が多いため, CS では,

(1) $W\mathbf{x}$ のどの要素がゼロ(ゼロに近い)かを同定すること,

(2) $W\mathbf{x}$ のゼロと同定された要素を無視して $\mathbf{x}$ を復元すること, の2つの問題を同時に解く必要がある. その解法としては, 分析型と呼ばれる解法と合成型と呼ばれる解法が存在する. 合成型 CS の説明は他の文献に譲り, 以降では通常の正則化を用いた逆問題解法と類似して分かりやすく CT で採用されている分析型について述べる. 分析型では, 以下の最適化問題を解くことにより信号復元を行う.

[測定データに雑音がない場合]

$$\text{minimize } f(\mathbf{x}) \text{ subject to } A\mathbf{x} = \mathbf{b} \quad (f(\mathbf{x}) \equiv \|W\mathbf{x}\|_p^p) \quad (11)$$

[測定データに雑音がある場合]

$$\text{minimize } \beta f(\mathbf{x}) + \|A\mathbf{x} - \mathbf{b}\|^2 \quad (f(\mathbf{x}) \equiv \|W\mathbf{x}\|_p^p) \quad (12)$$

ただし, $p \geq 0$ はノルムの次数を表すパラメータで, CS では




図4 圧縮センシングにおけるスパースファイ変換 W によるスパース化の例.

$p=1$ が用いられ理由は後述する．式(11)の意味は， $f(\mathbf{x})$ で $W\mathbf{x}$ のスパース性を評価しており，計測方程式 $A\mathbf{x}=\mathbf{b}$ を満たす $\mathbf{x}$ の中からスパース性が最大($f(\mathbf{x})$ が最小)のものを選り出すと解釈できる．また，式(12)のパラメータ β はハイパーパラメータと呼ばれ，この値を調節してどの程度強くスパース性を課すかを決定して使用する．次に，式(11)，(12)の $f(\mathbf{x})$ において $p=1$ とすれば，何故スパース性を評価してスパースな $\mathbf{x}$ を抽出できるかを述べる．まず， $p=0, 1, 2$ について $\|\cdot\|_p$ の定義は次式である．

$$\|\mathbf{z}\|_2^2 = \sum_{k=1}^K z_k^2, \|\mathbf{z}\|_1 = \sum_{k=1}^K |z_k|, \|\mathbf{z}\|_0 = \lim_{\varepsilon \rightarrow +0} \sum_{k=1}^K |z_k|^\varepsilon \quad (13)$$

図5に，式(13)のノルムの等値線を変換係数ベクトル $\mathbf{z}$ の次元が2の場合について $p=0, 1, 2$ を比較して示す．スパースな $\mathbf{z}$ は $\mathbf{z}=(z_1, z_2)^T$ の片方の成分がゼロのベクトルだから座標軸上の黒丸で示す点である．図から， $p=0$ と $p=1$ は座標軸上から離れた非スパースな点を過度に大きく評価する性質があり，逆に座標軸上のスパースな点を上手く選り出すことができる．これが $p=1$ が好まれる理由であり，その効果は実際の問題では $p=2$ と比較して非常に大きい．一方，CS のほとんど全ての手法で $p=1$ が使われ $p=0$ はほとんど使われないが， $p=0$ のノルムは非凸関数で最小化が困難なことが主な理由である．

CT 画像再構成の分野では，分析型の CS 解法の中でもトータルバリエーション (Total Variation, TV) 正則化と呼ばれる手法が多く用いられる．TV 正則化では，解を選り出す評価関数として画像の TV ノルムと呼ばれるものを用い，画像再構成問題を次式のように定式化する．

[測定データに雑音がない場合]

$$\text{minimize } \|\mathbf{x}\|_{\text{TV}} \text{ subject to } A\mathbf{x}=\mathbf{b} \quad (14)$$

[測定データに雑音がある場合]

$$\text{minimize } \beta \|\mathbf{x}\|_{\text{TV}} + \|A\mathbf{x}-\mathbf{b}\|^2 \quad (15)$$




図5 スパースファイ変換 W を施した変換係数 $\mathbf{z}$ の空間における L^2, L^1, L^0 ノルムの等値線．

ただし， f_{mn} をサンプリングされた2次元画像とすると，TV ノルム $\|\mathbf{x}\|_{\text{TV}}$ は次式で定義される．

$$\|\mathbf{x}\|_{\text{TV}} \equiv \|\nabla f_{mn}\| = \sum_m \sum_n \sqrt{(f_{mn}-f_{m+1,n})^2 + (f_{mn}-f_{m,n+1})^2} \quad (16)$$

即ち，TV 正則化はスパースファイ変換として画像の濃度勾配 $\|\nabla f_{mn}\|$ を計算する変換を用いた CS とみなすことができる．簡単なものであるが，TV 正則化は画像のエッジを保存して濃度変化が平らな部分のみを平滑化する効果が驚くほど大きく，これが TV 正則化が好まれる理由である．

次に，式(14)，(15)の問題を解く反復法について述べる．

TV 正則化の反復解法の研究は画像再構成分野における人気テーマで実用的にも重要であることから，多くの研究が行われている(14)–(19)．この問題が難しい理由は TV ノルムが微分不可能であるため，最急降下法など微分可能な評価関数の最適化手法を使用できない点にある ($\mathbf{x}=0$ で微分不可能であることは簡単に確認できる)．初期の研究では，簡単な解決策である次式のように微分可能な関数で近似して微分可能最適化の手法を用いるアプローチが用いられた．

$$\|\mathbf{x}\|_{\text{TV}} \cong \sum_m \sum_n \sqrt{(f_{mn}-f_{m+1,n})^2 + (f_{mn}-f_{m,n+1})^2 + \varepsilon} \quad (17)$$

ただし， $\varepsilon > 0$ は評価関数を平滑化して原点で微分可能にするために導入した小さな正の定数である．しかし，TV が上手く効きにくい問題点があり，最近では微分不可能最適化の手法で厳密に最小化する研究が主流である．表2に，TV 正則化の画像再構成問題を解く最近の反復法を整理してまとめて示す(14)–(19)．

上述の説明はスパースビュー CT を想定したが，投影方向数は十分だが低線量で投影データを測定する低線量 CT の画像再構成についても，式(12)，(15)の定式化を用いて行うことができる．最小2乗誤差 $\|A\mathbf{x}-\mathbf{b}\|^2$ が小さいこと，スパース性が大きい画像であることの2つの条件を同時に満たす $\mathbf{x}$ が高画質の画像である点は同様であり，式(12)，(15)のように定式化して両者の重み付き和を最小化して画像再構成を行う．ハイパーパラメータ β の値を調節して，2つの条

表2 TV 正則化の画像再構成問題を解く最近の反復法のまとめ．

手法(文献番号)	定式化	収束	厳密な収束性
SART-TV法 (14)	式(14)	遅い	?
FISTA (15)	式(15)	遅い	Yes
Chambolle-Pockアルゴリズム (16)	式(14),(15)	遅い	Yes
OS拡張ラグランジアン (17)	式(15)	速い	No
Row-Action型近接スプリッティング (18)	式(14),(15)	速い	Yes
FBP法組み込み型主双対反復法 (19)	式(14),(15)	速い	Yes




図6 スパースビューCT(投影データ方向数64)と低線量CTにおけるFBP法、SIRT法、TV正則化の再構成画像の比較(腹部CT実画像の例)。

件のバランスを決定して使用する。医療用CT分野では、2010年代に医療用CT装置の大手メーカーによる低線量CT再構成法の開発競争が行われ、現在は全ての大手メーカーがTV正則化による再構成法を製品に搭載している。学術的な名称としては、MBIR(Model-Based Iterative Reconstruction)と呼ばれている。

図6に、スパースビューCTと低線量CTの設定で、FBP法、SIRT法、TV正則化の3手法の再構成画像を比較したシミュレーション実験の結果を示す。原画像として腹部CT実画像を用い、スパースビューCTでは投影方向数が64方向で弱いポアソン雑音を加えた投影データから、低線量CTでは投影方向数が1024方向で強いポアソン雑音を加えた投影データから再構成を行っている。TV正則化の再構成画像は、FBP法やSIRT法と比較して劇的に画質が改善されていることが分かる。

4. 深層学習(第3世代)⁽²⁰⁾⁻⁽²⁶⁾

画像処理分野において、深層学習は画像認識、領域分割、

物体検出などの問題から研究が開始されたが、2017年に初めてCT画像再構成に適用した2件の論文が発表された⁽²⁰⁾⁽²¹⁾。そして、その後論文数が急激に増加してCT分野のホットな研究テーマとなっている。深層学習とCSの優劣に関しては世界的に未だはっきり断言できない状況であるが、以降では深層学習がどのようにスパースビューCTや低線量CTの画像再構成に用いられるかを述べる。図7に、深層学習を用いた再構成法の原理を示す。まず、スパースビューや低線量で測定した投影データに通常のFBP法で画像再構成を行い、アーティファクトや雑音で劣化した劣化画像 y を生成する。そして、 y を画像変換を行う畳み込みニューラルネットワーク(Convolutional Neural Network, CNN)に入力して画質を改善した出力画像 x を求めるのが基本となる適用方法である。即ち、画像再構成には通常のFBP法を用い、発生した雑音やアーティファクトを低減する後処理をCNNで行うのである。CNNとしては画像変換を行うネットワークのU-Net、敵対的生成ネットワーク(Generative Adversarial Network, GAN)に属するpix2pix、ResNetなどの構造のものが用いられる。CNNの学習では画質を最も良く改善するCNNパラメータ(重み w 、バイアス b)を決める必要があるが、劣化画像 y と正解画像 x のペアを多数集めた学習データ (x_i, y_i) ($i=1, 2, \dots, N$)を準備して、次式で表される平均2乗誤差(MSE)の損失関数を最小化してCNNパラメータを求める。

$$MSE(w, b) = \frac{1}{N} \sum_{i=1}^N \|x_i - \text{CNN}(w, b)y_i\|^2 \quad (18)$$

ただし、 $\text{CNN}(w, b)$ はCNNに劣化画像を入力して画質を改善した画像に変換する演算を表す。学習に用いる損失関数としては、相互エントロピーや平均 L^1 ノルム誤差、最近の研究では人間が画像を見るときの画質評価指標に近いSSIM(Structural Similarity Index)やPerceptual Lossと呼ばれるものを用いる研究も存在する。上述の適用方法で最も問題になるのは、学習データをどのように収集するかである。CNNの学習には、多数の正解画像 x_i と劣化画像 y_i のペアが必要だが、同一の人物を良条件と悪条件の両方で撮影したCT画像ペアなど全く存在しない。そこで、通常の撮影条件

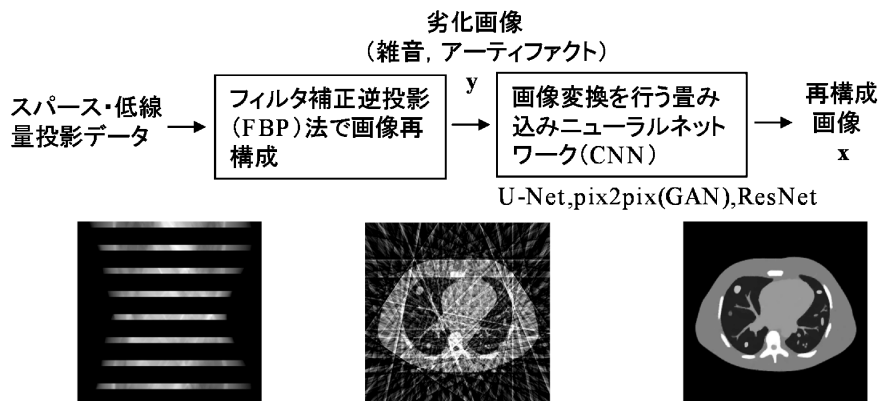


図7 深層学習を用いたCT画像再構成法の原理。

の正解画像 $\mathbf{x}_i (i=1, 2, \dots, N)$ のみを集め対応する劣化画像 $\mathbf{y}_i (i=1, 2, \dots, N)$ は投影データを測定して FBP 法で画像再構成するイメージング過程を計算機でシミュレーションして生成する方法が多くの場合用いられている。

深層学習を用いた手法に関して最も興味があるのは、画質性能や計算時間などの視点で CS より優れているかだが、現状で結論が出ている箇所を整理すると以下になるだろう。まず、計算時間に関しては、深層学習は学習に時間はかかる反面 CNN モデルを作ってしまうと CNN を通すだけで画質改善が実現でき CS のように反復計算が不要であり、CS より優れている。画質性能に関しては、CS と深層学習で発生する劣化の性質に違いがある。CS では、TV 正則化などの手法が画像は区分的に（構造物境界を除いて値が一定の領域の組み合わせでできている）という仮定で画像再構成を行うため、階段状アーティファクトの発生や滑らかな濃度変化の消失の形で劣化が現れやすい。一方、深層学習では、学習データに含まれない構造物（例えば、医療用 CT の場合では病変や血管）や個人差が大きい構造物が消失する形の機械学習特有の劣化が発生しやすい。

図 8 に、深層学習と TV 正則化の再構成画像を比較した実例を示す。腹部 CT 実画像のデータセットを用い、投影方向数が 64 方向のスパースビュー CT の状況を想定している。学習データは 58 症例の 3D-CT 画像から肝臓が大きく写るスライスを 5 枚ずつ切り出した計 290 枚の画像、評価に用いるテストデータは 16 症例の 3D-CT 画像から肝臓が大きく写るスライスを 5 枚ずつ切り出した計 80 枚の画像としている。画質評価指標である MSE 値と SSIM 値を個別の画像上

に、80 枚のテストデータの平均の PSNR (Peak Signal-to-Noise Ratio) 値と SSIM 値を図中の表にまとめて示す。上述のように、TV 正則化の画像は滑らかな濃度変化が消失しており、深層学習では血管などの低コントラスト構造物の消失が随所に見られる。更に、図中で Hybrid 法と記載したのは、筆者らが文献(26)で提案した TV 正則化と深層学習を組み合わせ、TV 正則化と FBP 法の 2 つの再構成画像を 2 入力 1 出力の CNN に入力して組み合わせ画質改善を行う新手法の結果であるが、両者の欠点を上手く補い合い驚きの画質改善が実現できている。

深層学習を用いた CT 画像再構成法の最新のトレンドとしては、投影データを入力として直接再構成画像を出力する CNN の構造を用いる方向⁽²²⁾、学習の損失関数に人間の視覚により合致したものをを用い性能を向上させる方向⁽²³⁾、Cycle GAN や教師あり自己学習など必要な学習データを削減する方向⁽²⁴⁾⁽²⁵⁾、CS と組み合わせ画質性能を向上させる方向⁽²⁶⁾、などがある。

5. おわりに

本論文では、CT 画像再構成の基礎と近年のトレンドについて、解析的再構成法から出発して CS を経由して深層学習に至るまでを平易に解説した。画像再構成に関して深く理解するには各々の項目を詳しく説明した論文や書籍を読むことが必要だが、本論文を読んで興味を持った内容や手法にたどり着くまでのインデックス的なものとして、利用していただきたい。最後に、より深く学びたい読者のために、CT の画像再構成に関して日本語で詳しく書かれた文献として筆者による文献(27)があることを申し添える。

本研究は JST-CREST(JPMJCR1765)の助成を受けた。

文 献

- (1) A. C. Kak and M. Slaney: Principles of Computerized Tomographic Imaging, SIAM, (2001).
- (2) R. M. Lewitt: Proc. IEEE, **71**(1983), 390-408.
- (3) L. A. Shepp and B. F. Logan: IEEE Trans. Nucl. Sci., **21** (1974), 21-43.
- (4) Y. Censor: Proc. IEEE, **71**(1983), 409-419.
- (5) G. T. Herman: Fundamentals of Computerized Tomography: Image Reconstruction from Projections, Springer, (2009).
- (6) R. Gordon, R. Bender and G. T. Herman: J. Theor. Biol., **29** (1970), 471-481.
- (7) P. Gilbert: J. Theor. Biol., **36**(1972), 105-117.
- (8) G. T. Herman and L. B. Meyer: IEEE Trans. Med. Imaging, **12** (1993), 600-609.
- (9) 工藤博幸: 日本医用画像工学会誌, Medical Imaging Technology, **32**(2014), 239-248.
- (10) H. Kudo, T. Suzuki and E. A. Rashed: Quantitative Imaging in Medicine and Surgery, **3**(2013), 147-161.
- (11) 工藤博幸, 董建, 加茂勝己他: 日本顕微鏡学会誌, 顕微鏡, **51**(2016), 48-53.
- (12) E. J. Candes, J. Romberg and T. Tao: IEEE Trans. Inf. Theory, **52**(2006), 489-509.
- (13) D. L. Donoho: IEEE Trans. Inf. Theory, **52**(2006), 1289-1306.





図 8 スパースビュー CT (投影データ方向数 64) における FBP 法, TV 正則化, 深層学習, Hybrid 法 (文献 26) の再構成画像の比較 (腹部 CT 実画像の例)。

- ★★★★★★★★★★★★★★★★★★★★★★★★★★★★★★★★★★★★★★
工藤博幸
1985年東北大・工・通信卒．1990年同大大学院博士課程了．現在，筑波大・システム情報系・教授．2020～，日本医用画像工学会(JAMIT)会長．1990年電子情報通信学会論文賞，1991年・2001年・2006年・2008年・2018年・2019年日本医用画像工学会論文賞(6回)，2018年日本コンピュータ外科学会論文賞，2006年・2008年国際雑誌「Inverse Problems」High Lights，2008年国際雑誌「Physics in Medicine and Biology」High Lights，「新方式CTの構成方式と画像再構成法に関する先駆的研究」により平成30年度文部科学大臣表彰科学技术術賞(研究部門)受賞．CTを中心とした医用イメージング、画像処理の研究に従事．



橋本 康



ヴォルフガング・フォグリ