

マルチクラス辞書学習を用いた低線量CT画像再構成

鴨下 飛竜[†] 北原 大地[†] 平林 晃[†]

[†] 立命館大学大学院情報理工学研究科 〒525-8577 滋賀県草津市野路東 1-1-1

E-mail: [†] is0254iv@ed.ritsumei.ac.jp, d-kita@fc.ritsumei.ac.jp, akirahrb@media.ritsumei.ac.jp

あらまし X線CTにおける低線量投影データからの高精度な画像再構成手法を提案する。パッチベースの単一辞書を用いる従来の再構成手法では、辞書によってスパースに表現できないパッチが多く存在してしまい、十分な再構成結果が得られない。そこで本研究では、パッチをクラスタリングし、クラスごとに異なる辞書を用いて再構成を行う。実際のCT画像を用いたシミュレーションにより提案法の有効性を示す。

キーワード 低線量CT, 画像再構成, 辞書学習, クラスタリング

Low-Dose CT Image Reconstruction with Multiclass Dictionary Learning

Hiryu KAMOSHITA[†], Daichi KITAHARA[†], and Akira HIRABAYASHI[†]

[†] Graduate School of Information Science and Engineering, Ritsumeikan University

1-1-1 Nojihigashi, Kusatsu, Shiga, 525-8577 Japan

E-mail: [†] is0254iv@ed.ritsumei.ac.jp, d-kita@fc.ritsumei.ac.jp, akirahrb@media.ritsumei.ac.jp

Abstract We propose a high-precision CT image reconstruction method from low-dose X-ray projection data. In conventional reconstruction methods using a single patch-based dictionary, there exist many patches that cannot be expressed sparsely by the dictionary, and thus the reconstruction quality would not be sufficient. The proposed method adopts patch clustering and uses a different dictionary for each patch cluster. Simulations using real CT data demonstrate the effectiveness of the proposed method.

Key words Low-Dose CT, Image Reconstruction, Dictionary Learning, Clustering

1. はじめに

X線コンピュータ断層撮影法 (Computed Tomography: CT) や磁気共鳴画像法 (Magnetic Resonance Imaging: MRI) は、体内を非侵襲的に撮像できるため、様々な疾患の診断や発見に役立っている。CTは骨折や肺野病変などの診断に優れており、MRIは水分の多い脳などの診断に優れている。また、CTにはMRIと比べて撮像時間が短いという利点がある。例えば、全身を撮像する際に、MRIは各種パラメータに依存して30分から1時間程度を要するのに対して、CTは数分しか必要としない。一方で、CTは撮像にX線を用いるため、癌性や遺伝性の疾患誘発が懸念されており、なるべく少ないX線量で撮像することが望まれている [1]。X線量を低減する方法には大きく分けて、1) X線の照射強度を下げる、2) X線の投影回数を減らす、の2通りがある。しかし、どちらの場合においても、低線量の投影データに対して、通常の再構成手法であるフィルタ補正逆投影 (Filtered Back Projection: FBP) 法を適用すると、画像内に大きなノイズや不自然なアーチファクトが発生してしまう [2]。結果として、正常組織と病理組織の識別が難しくなる [3]。

低線量の投影データから高品質な画像を再構成するために、圧縮センシング技術 [4] が用いられている。圧縮センシングは、対象信号のスパース表現の存在を仮定した上で、不十分な観測から信号を高精度に復元する技術である。画像処理分野を中心に、対象信号のスパース表現を獲得する手段として辞書学習を利用する [1, 3, 5-8]。辞書は、応用ごとに適切な学習用画像を用いて基底 (またはフレーム) として作成され、基底ベクトルの線形結合により対象信号をスパースに表現できるようになる。

低線量CTの分野においては、統計的反復再構成 (Statistical Iterative Reconstruction: SIR) 法 [9] に辞書学習を適用した画像再構成手法が Xu らにより提案されている [1]。この手法は、ストリークアーチファクトの除去に優れているものの、再構成画像の細部構造が過度な平滑化によって失われてしまうという問題を抱えている。ノイズやアーチファクトを抑制しながら、画像の細部構造を鮮明に再構成するために、画像をよりスパースに表現することが課題となっている。

この課題を解決するために本論文では、Xu らの手法をマルチクラスに拡張した再構成手法を提案する。Xu らの手法では、学習用画像から抽出された全てのパッチに対して単一の辞書を




図1 X線CTにおける投影の模式図

用いている。一方、提案法では各パッチをクラスタリングし、クラスごとに別々の辞書を作成する。そして、これらの辞書を用いて対象画像のパッチをクラスごとに処理し、画像再構成を行う。このとき、辞書によるパッチの近似精度はクラスごとに異なることが想定されるため、辞書を用いた正則化項の重み（正則化パラメータ）をクラスごとに設定することで、再構成精度を向上させる。実際のCT画像を使用して投影回数を減らした場合のシミュレーションを行い、提案法の有効性を示す。

2. X線CTにおける画像再構成

2.1 X線CTの基本原理解

図1の xy 座標系でX線CTにおける画像再構成を説明する。被写体内部のX線減衰係数分布を $\mu(x, y) \geq 0$ とする。投影は、 xy 座標系を角度 θ だけ回転させた uv 座標系

$$\begin{cases} u = x \cos \theta + y \sin \theta \\ v = -x \sin \theta + y \cos \theta \end{cases}$$

を用いて記述される。投影データ $l_{\theta,n}^*$ は、X線源から第 n 番目の検出器までの直線経路 $\gamma_{\theta,n}(v)$ に沿った減衰係数 $\mu(x, y)$ の線積分 $l_{\theta,n}^* := \int \mu(\gamma_{\theta,n}(v)) dv$ として定義され、この積分はラドン変換と呼ばれる。ラドン変換は数値積分により離散化されて、

$$l_{\theta,n}^* = \mathbf{r}_{\theta,n}^T \boldsymbol{\mu} + \xi_{\theta,n}^* \quad (1)$$

と表される。ここで、 $\boldsymbol{\mu} \in \mathbb{R}^J$ は画素数 J の離散画像の画素値、 $\mathbf{r}_{\theta,n} \in \mathbb{R}^J$ は数値積分の重み係数、 $\xi_{\theta,n}^* \in \mathbb{R}$ は数値積分の誤差を表している。第 n 番目のX線検出器における測定値 $z_{\theta,n} \in \mathbb{Z}$ はポアソン分布に従う整数であり、その期待値はX線の照射強度 $b > 0$ を用いて $E[z_{\theta,n}] = b \exp(-l_{\theta,n}^*)$ と与えられる。この関係から投影データを $l_{\theta,n}^* = \ln(b/E[z_{\theta,n}])$ と表せるが、 $E[z_{\theta,n}]$ は未知である。したがって、通常は、測定値 $z_{\theta,n}$ から計算される $l_{\theta,n} := \ln(b/z_{\theta,n})$ を投影データとして用いる。 G 個の角度 $\theta_g \in [0, \pi)$ に対して N 個の検出器により投影データを取得する場合、観測モデルは式(1)をまとめて

$$\mathbf{l} = R\boldsymbol{\mu} + \boldsymbol{\xi} \quad (2)$$

のように表現される。ここで、 $I := GN$ とおけば、 $\mathbf{l} \in \mathbb{R}^I$,

$R \in \mathbb{R}^{I \times J}$ 、 $\boldsymbol{\xi} \in \mathbb{R}^I$ である。通常のX線CTでは、 $I \geq J$ かつノイズレベル $\|\boldsymbol{\xi}\|_2$ も小さいため、角度 θ_g ごとの投影データ $l_{\theta_g,n}$ ($n = 1, \dots, N$)を事前に設計した周波数フィルタにより補正した後に逆投影する(FBP法または逆ラドン変換と呼ばれる)ことで、画像 $\boldsymbol{\mu}$ を高精度に再構成できる。最終的なCT値は、水のX線減衰係数 μ_{water} を基準として、

$$\text{CT} = 1000 \left(\frac{\mu - \mu_{\text{water}}}{\mu_{\text{water}}} \right) \quad (3)$$

のように計算される[10]。式(3)から、水のCT値は0であり、空気中ではX線が減衰しないためCT値は $-1,000$ である。

2.2 低線量CTにおける辞書学習を用いた反復再構成

撮像時のX線量の低減方法として、1) X線強度 b を下げる、2) 投影回数 G を減らす、の2通りが考えられる。しかしながら、前者では、測定値 $z_{\theta_g,n}$ が小さくなり投影データ $l_{\theta_g,n}$ の信頼性が弱まる(ノイズレベル $\|\boldsymbol{\xi}\|_2$ が増大する)という問題が発生し、後者では、 $I = GN$ が減少して $I < J$ となる問題が発生する。したがって、どちらの場合においても単にFBP法を適用するだけでは、画像内に大きなノイズや不自然なアーチファクトが現れてしまい良好な結果は得られない。そこでSauerらは、最大事後確率(Maximum a Posteriori: MAP)推定により $\boldsymbol{\mu}$ を再構成する手法を提案した[9]。この手法は、統計的なコスト

$$\|R\boldsymbol{\mu} - \mathbf{l}\|_{2,w}^2 + \lambda \Psi(\boldsymbol{\mu}) := \sum_{i=1}^I w_i (\mathbf{r}_i^T \boldsymbol{\mu} - l_i)^2 + \lambda \Psi(\boldsymbol{\mu}) \quad (4)$$

を最小にする $\boldsymbol{\mu}$ を反復的に再構成するため、SIRと呼ばれる。重み付き l_2 ノルムの各重みは統計的に $w_i := z_i = b / \exp(l_i)$ と定まり、 $\Psi: \mathbb{R}^J \rightarrow \mathbb{R}$ は $\boldsymbol{\mu}$ の先験情報に基づいた正則化項、 i は投影のインデックス、 $\lambda > 0$ は正則化パラメータである。

Xuらは、式(4)にパッチベースの辞書学習を組み合わせた手法を提案した[1]。この手法では、画像 $\boldsymbol{\mu}$ をサイズ $\sqrt{P} \times \sqrt{P}$ のパッチと呼ばれる小領域 $H_s \boldsymbol{\mu} \in \mathbb{R}^P$ ($s = 1, \dots, S$)に分割し、「それぞれのパッチが辞書 $D \in \mathbb{R}^{P \times K}$ と呼ばれる適切な基底(またはフレーム)によりスパースに表現できる」という先験情報に基づいて $\boldsymbol{\mu}$ を再構成する。ここで、 $H_s \in \{0, 1\}^{P \times J}$ はパッチ抽出行列、 s はパッチのインデックス、 S はパッチ数、 K は基底数であり、 D の列ベクトル $\mathbf{d}_k \in \mathbb{R}^P$ ($k = 1, \dots, K$)は $\|\mathbf{d}_k\|_2 = 1$ を満たしている。各パッチのスパース係数を $\mathbf{c}_s \in \mathbb{R}^K$ ($s = 1, \dots, S$)とおけば、再構成結果は最適化問題

$$\underset{\boldsymbol{\mu}, \mathbf{D}, \mathbf{C}}{\text{minimize}} \|R\boldsymbol{\mu} - \mathbf{l}\|_{2,w}^2 + \lambda \sum_{s=1}^S (\|H_s \boldsymbol{\mu} - D \mathbf{c}_s\|_2^2 + \nu_s \|\mathbf{c}_s\|_0) \quad (5)$$

の解として与えられる。ここで、 $\mathbf{C} := (\mathbf{c}_1, \dots, \mathbf{c}_S) \in \mathbb{R}^{K \times S}$ であり、 $\nu_s > 0$ はパッチごとのラグランジュ乗数である。Xuらは式(5)の辞書 D に関して、学習用画像を用いて事前に作成する手法と、再構成中の画像を用いて適応的に更新する手法を提案している。前者はGDSIR(Global Dictionary based SIR)、後者はADSIR(Adaptive Dictionary based SIR)と呼ばれる。

式(5)の最適化問題を直接解くのは困難であるため、FBP法を適用して得られる画像を初期値 $\boldsymbol{\mu}^0$ として、スパース係数

C (及び辞書 D) と画像 μ を交互に更新する. C (及び D) を更新する際には, μ が推定値 μ^{m-1} に固定された最適化問題

$$\underset{(D), C}{\text{minimize}} \sum_{s=1}^S (\|H_s \mu^{m-1} - D c_s\|_2^2 + \nu_s \|c_s\|_0) \quad (6)$$

を考える. 式 (6) の問題に対して, GDSIR では OMP [12] を用いて係数 C のみを更新する. 一方 ADSIR では, 文献 [13] の手法によって辞書 D を更新した後に, OMP で係数 C を更新するため, GDSIR に比べて多くの計算時間を必要とする.

μ を更新する際には, C (及び D) が固定された最適化問題

$$\underset{\mu}{\text{minimize}} \|R\mu - l\|_{2,w}^2 + \lambda \sum_{s=1}^S \|H_s \mu - D c_s\|_2^2 \quad (7)$$

を考える. 最適解 μ^* は, 対角行列 $W := \text{diag}(w)$ を用いて

$$\mu^* = \left(R^T W R + \lambda \sum_{s=1}^S H_s^T H_s \right)^{-1} \left(R^T W l + \lambda \sum_{s=1}^S H_s^T D c_s \right)$$

と表されるが, 画像サイズが大きい場合には逆行列計算が困難となってしまう. そこで, 現在の推定値 μ^{m-1} において式 (7) と関数値が等しくなるような上界関数を設計し, この上界関数を最小にする μ を新たな推定値 μ^m として用いる [11]. この値は画素値 μ_j^m ($j = 1, \dots, J$) ごとに式 (8) で与えられる.

3. マルチクラス辞書学習を用いた反復再構成

3.1 複数の辞書を用いた再構成手法

近年, 高速撮像 MRI や低線量 CT の分野において, 圧縮率向上やノイズ除去・アーチファクト抑制のために, マルチクラス辞書学習を用いる再構成手法が提案されている [3, 7, 8]. これらの手法では, まずパッチを幾何学的方向または輝度値によって複数のクラスに分類する. そして, クラスごとに別々の辞書を用意することで, パッチのスパース表現の近似精度を向上させ, 画像を良好に再構成できるようにしている. しかし, 文献 [7, 8] は高速撮像 MRI を対象としており, そのままでは低線量 CT には適用できない. 文献 [3] は低線量 CT を対象としているが, 最適化問題のデータ整合性として, FBP 法によって得られる画像との誤差を用いるため, この画像が大きなアーチファクトを含んでいる場合には, 再構成結果が著しく劣化してしまう. 特に, 投影回数を減らす方式の低線量 CT においては, FBP 法によって大きなアーチファクトが発生する (第 5 節の図 3 (b) と図 4 (b) を参照). このため, 文献 [3] の手法は適さない.

一方, GDSIR と ADSIR には, 文献 [3] の手法に比べて計算量は多いものの, X 線量の低減方法を限定しないという利点がある. そこで本研究では, GDSIR をマルチクラスへと一般化した, 高精度な再構成手法を提案する. 提案法では, FBP 法で得られる画像を利用して各パッチのクラスタリングを 1 回のみ行うため, 計算量は GDSIR からほとんど増加しない. また, クラスごとに別々の正則化パラメータを用意しており, これらを適切に設定することで, 高精度な再構成が実現可能である.

3.2 マルチクラス GDSIR

クラス数を Q とし, クラスのインデックスを $q = 1, \dots, Q$ とする. クラス q のパッチを表現するための辞書 $D_q \in \mathbb{R}^{P \times K_q}$ は, 学習用画像を用いて事前に作成されるものとする. ここで, K_q は各辞書の基底数である. 再構成する画像のパッチ $H_s \mu$ はクラスタリングされており, クラス q のパッチのインデックス集合を \mathcal{S}_q とすれば, $\bigcup_{q=1}^Q \mathcal{S}_q = \{1, \dots, S\}$ かつ $\mathcal{S}_q \cap \mathcal{S}_{q'} = \emptyset$ ($q \neq q'$ のとき) が成り立つ. 本研究では, マルチクラス辞書 D_q を用いて式 (5) を一般化した最適化問題

$$\underset{\mu, C}{\text{minimize}} \|R\mu - l\|_{2,w}^2 + \sum_{q=1}^Q \lambda_q \sum_{s \in \mathcal{S}_q} (\|H_s \mu - D_q c_s\|_2^2 + \nu_s \|c_s\|_0) \quad (9)$$

を解くことにより μ を再構成する手法を提案する^(注1). ここで, $\lambda_q > 0$ はクラスごとの正則化パラメータである.

パッチのクラスタリング手法には様々なものが考えられるが, 計算時間と実装の容易さを考慮して, 本研究では文献 [8] と同じく K-means 法を使用する. まず, 学習用画像のパッチを K-means 法により Q 個のクラスに分類し, クラスごとに辞書 D_q を作成する. この際, 各クラスのクラスタリングセンターを記憶しておく. 次に, 式 (2) の投影データ l に FBP 法を適用して初期画像 μ^0 を求め, 記憶したクラスタリングセンターを利用して μ^0 のパッチを K-means 法により分類する. その後, 式 (9) の問題の解を反復的に計算することで, 提案する再構成が達成される. 以下で提案アルゴリズムを詳細に説明する.

3.3 提案する反復再構成アルゴリズム

提案するアルゴリズムは, 事前準備を 1 回した後, 係数更新ステップと画像更新ステップを交互に M 回繰り返すことで, 投影データ l から画像 μ を再構成する.

事前準備 まず, 学習用画像からパッチを抽出し, K-means 法により Q 個のクラスに分類する. 再構成する画像のパッチも後にクラスタリングするため, 各クラスタリングセンターを記憶しておく. 次に, クラスごとの辞書 D_q を最適化問題

$$\underset{D_q, C}{\text{minimize}} \sum_{s \in \mathcal{S}_q^{\text{tr}}} (\|H_s \mu^{\text{tr}} - D_q c_s^{\text{tr}}\|_2^2 + \nu_s \|c_s^{\text{tr}}\|_0) \quad (10)$$

の解として作成する. ここで, μ^{tr} は学習用画像, c_s^{tr} は第 s 番目の学習用画像パッチに対するスパース係数, $\mathcal{S}_q^{\text{tr}}$ はクラス q の学習用画像パッチのインデックス集合である. D_q が辞書として適切であるためには, 各パッチを少ない誤差で表現できる能力が必要と考え, 本研究では式 (10) を等価な問題である

$$\underset{D_q, C}{\text{minimize}} \sum_{s \in \mathcal{S}_q^{\text{tr}}} \|c_s^{\text{tr}}\|_0 \quad \text{s.t.} \quad \|H_s \mu^{\text{tr}} - D_q c_s^{\text{tr}}\|_2^2 \leq \varepsilon_s \quad (11)$$

に変形する [4]. ここで, $\varepsilon_s > 0$ は各スパース表現の近似誤差の許容範囲を示している. 式 (11) の問題に対する高速解法が文献 [13] に提案されており, 本研究でもこの解法を使用する.

(注1): 式 (9) において $Q = 1$ とすれば, 式 (5) が直ちに導かれる.

$$\mu_j^m = \mu_j^{m-1} - \frac{\sum_{i=1}^I r_{ij} w_i (r_i^T \mu^{m-1} - l_i) + \lambda \sum_{s=1}^S \sum_{p=1}^P h_{pj}^s ([H_s \mu^{m-1}]_p - [D c_s]_p)}{\sum_{i=1}^I r_{ij} w_i \sum_{j'=1}^J r_{ij'} + \lambda \sum_{s=1}^S \sum_{p=1}^P h_{pj}^s \sum_{j'=1}^J h_{pj'}^s} \quad (8)$$

式 (9) の問題を解くに当たり、初期画像 μ^0 と集合 S_q を決定する。まず、投影データ l に FBP 法を適用して得られる画像を初期値 μ^0 とする。次に、学習用画像のバッチに対するクラスタリングセンターを再度利用して、初期画像の各バッチ $H_s \mu^0$ を K-means 法により Q 個のクラスに分類する。これにより S_q が定まり、以降、画像が更新されてもクラスタリングは行わない。

以上の事前準備が完了したら、以下の係数更新ステップと画像更新ステップを $m = 1, \dots, M$ に渡って繰り返すことで、最終的な再構成結果 μ^M を得る。

係数更新ステップ スパース係数 C の第 m 回目の更新時には、画像 μ が μ^{m-1} に固定された最適化問題

$$\underset{C}{\text{minimize}} \sum_{s=1}^S (\|H_s \mu^{m-1} - D_{q(s)} c_s\|_2^2 + \nu_s \|c_s\|_0) \quad (12)$$

を考える。ここで、 $q(s)$ は第 s 番目のバッチが属するクラスを表している。式 (12) の問題は、係数 c_s ごとの最適化問題

$$\underset{c_s}{\text{minimize}} \|H_s \mu^{m-1} - D_{q(s)} c_s\|_2^2 + \nu_s \|c_s\|_0$$

に帰着され、GDSIR と同様OMPを用いて c_s を更新する。


画像更新ステップ 画像 μ の第 m 回目の更新時には、係数 C が固定された最適化問題

$$\underset{\mu}{\text{minimize}} \|R\mu - l\|_{2,w}^2 + \sum_{q=1}^Q \lambda_q \sum_{s \in S_q} \|H_s \mu - D_q c_s\|_2^2 \quad (13)$$

を考える。式 (13) の問題の解は閉形式で与えられるものの、第 2.2 節で説明したように画像サイズが大きくなると数値計算が困難になる。文献 [11] に基づいて、現在の推定値 μ^{m-1} において関数値が等しくなるような上界関数を設計することで、新たな推定値 μ^m が画素値ごとに式 (14) のように与えられる。

3.4 正則化パラメータ λ_q の重要性

マルチクラス辞書学習では、クラスごとにバッチ数が違い、更に学習用画像と対象画像でバッチ数の比率も大きく変化する可能性がある。そのため、辞書によるスパース表現の各バッチに対する近似精度はクラスごとに異なっている。したがって、良好な再構成結果を得るために、基底数 K_q や辞書学習のパラメータ ε_s 、及び係数更新のパラメータ ν_s をクラスごとに設定することが望ましい。しかしながら、設定するパラメータ数はクラス数に比例して増大するため、これら全てをクラスごとに設定することは現実的ではない。この問題を解決するために、提案法では式 (9) においてクラスごとの正則化パラメータ λ_q を導入した。これにより、 ε_s 、 ν_s 、 K_q が全てのクラスに対して共通の値であっても、 λ_q がクラスごとに適切に設定されれば高精度な画像再構成を実現できる。具体的には、辞書によるスパース表現の近似精度が高いクラスでは、 λ_q を大きくすることで辞書の影響を強調し、近似精度が低いクラスでは、 λ_q を小さくすることで辞書の影響を抑えるようにすればよい。



(a) 学習用画像 (No. 1601) (b) クラスタリングセンター
図 2 事前辞書学習に用いた画像と各クラスタリングセンター

4. 計算機シミュレーション

4.1 実験設定

実際の CT 画像を用いた数値実験によって提案法の有効性を示す。学習用画像と対象画像には同一人物の頭部画像を用い、サイズはどちらも 256×256 ($J = 65,536$) である。画像には CT 値が記録されていたため、1 cm あたりの水の減衰係数を $\mu_{\text{water}} = 0.2059 \text{ cm}^{-1}$ 、1 画素の横幅と縦幅を 0.09 cm として、式 (3) から真の X 線減衰係数 μ を作成した。通常の X 線 CT において、1 度刻みで 0 から 179 度までの $G = 180$ 個の角度に対して投影を行うと想定し、MATLAB のラドン変換行列 R に基づいて、X 線検出器の数は $N = 367$ とした。このときは、 $I = GN = 66,060 > J$ が成り立つため、FBP 法により良好な再構成結果が得られる。投影回数を減らす方式の低線量 CT を再現するために、3 度刻みで 0 から 177 度までの $G = 60$ 個の角度に対してのみ投影を行う (圧縮率 1/3 の投影と呼ぶ)。測定値は本来ポアソン分布に従うが、本実験では X 線の照射強度を $b = 10^6$ とし、 $b \exp(-r_i^T \mu)$ を四捨五入した値を z_i とした。

提案法の比較対象を GDSIR 及び ADSIR とし、それぞれの手法で $M = 1,000$ 回の反復計算により再構成を行った。辞書学習と係数更新に用いるパラメータは、全ての手法で $K = 256$ 、 $\varepsilon_s = 0.2$ 、 $\nu_s = 0.2$ に固定した。高速辞書学習 [13] と OMP [12] の実装には公開されているプログラム [14] を使用し、高速辞書学習の設定項目は更新回数 2,000、バッチサイズ 40、 $t_0 = 0.001$ とした。各画像からサイズ 8×8 ($P = 64$) のバッチを、1 画素ずつずらしながら $S = 62,001$ 個抽出する。提案法と GDSIR で用いる辞書は図 2 (a) の学習用画像を用いて作成され、提案法では学習用画像のバッチを K-means 法によって $Q = 7$ 個のクラスに分類した。また、各クラスタリングセンターは図 2 (b) のようになった。正則化パラメータは、GDSIR と ADSIR では $\lambda = 60$ とし、提案法では均一な値 $\lambda_q = 60$ ($q = 1, \dots, 7$) にした場合と、クラスごとに最適な値 $\lambda_1 = 600$ 、 $\lambda_2 = \lambda_3 = 60$ 、 $\lambda_4 = \lambda_5 = \lambda_6 = \lambda_7 = 0.06$ にした場合で実験を行った。計算の環境は MacBook Pro, OS X Yosemite version 10.10.5, プロセッサ 2.9GHz Intel Core i5, メモリ 8GB 1867MHz DDR3, プラットフォーム MATLAB R2015a 64-bit (maci64) である。

$$\mu_j^m = \mu_j^{m-1} - \frac{\sum_{i=1}^I r_{ij} w_i (r_i^T \mu^{m-1} - l_i) + \sum_{q=1}^Q \lambda_q \sum_{s \in S_q} \sum_{p=1}^P h_{pj}^s ([H_s \mu^{m-1}]_p - [D_q c_s]_p)}{\sum_{i=1}^I r_{ij} w_i \sum_{j'=1}^J r_{ij'} + \sum_{q=1}^Q \lambda_q \sum_{s \in S_q} \sum_{p=1}^P h_{pj}^s \sum_{j'=1}^J h_{pj'}^s} \quad (14)$$

表 1 圧縮率 1/3 の投影からの再構成時間 [s]

再構成手法	事前辞書	事前準備	更新 1 回
GDSIR	4.76	1.51	平均 1.31
ADSIR	—	1.55	平均 5.84
提案法	35.08	1.75	平均 1.58

4.2 実験結果

まず、提案法と GDSIR 及び ADSIR の再構成結果の精度を比較する。再構成する対象画像を学習用画像と同一人物の頭部画像とし、スライス番号は No. 1610 と No. 1615 を選んだ。画像の評価指標として PSNR (Peak Signal-to-Noise Ratio) と SSIM (Structural SIMilarity) の 2 つを用いた。図 3 と図 4 は No. 1610 と No. 1615 の画像を圧縮率 1/3 の投影から再構成した結果を示しており、(a) が原画像、(b) が FBP 法により得られる初期画像、(c), (d), (e), (f) がそれぞれ GDSIR, ADSIR, λ_q を均一に設定した提案法, λ_q を最適に設定した提案法の再構成結果である。図 3 (b) と図 4 (b) から分かるように、FBP 法により得られる初期画像には多くのアーチファクトが含まれている。GDSIR や ADSIR では、正則化パラメータ λ を小さくするとアーチファクトが抑制しきれずに残ってしまい、大きくするとアーチファクトのみならず画像の細部構造も失われた、過度に平滑化された画像が再構成されてしまう [3]。一方、提案法では、正則化パラメータ λ_q を全てのクラスに対して均一に設定した場合でも、GDSIR と ADSIR に比べて高い PSNR と SSIM を与えており、マルチクラス辞書学習により再構成精度が向上していることが確認できる。更に、正則化パラメータ λ_q をクラスごとに最適に設定した場合では、PSNR と SSIM の値が大幅に上昇しており、実際に再構成された画像を見てみると、アーチファクトを抑制しながらも、複雑な構造は平滑化されていない良好な画像が得られていることが分かる。

次に、提案法と GDSIR 及び ADSIR の計算時間を比較する。表 1 は各手法における事前辞書学習、事前準備、反復再構成の更新 1 回の計算時間を示している。提案法では、学習用画像のバッチをクラスタリングして $Q = 7$ 個の辞書を作成するため、事前辞書学習において GDSIR に比べて 7 倍強の時間を要している。一方、ADSIR では事前に辞書を作成しないため、表中で空欄になっている。事前準備は、FBP 法による初期画像 μ^0 の作成、初期画像のパッチ抽出、パッチ $H_s \mu^0$ のクラスタリング (提案法のみ)、式 (8) または式 (14) の分母計算のことであり、提案法のみクラスタリングを行うため計算時間が約 0.2 秒長くなった。反復再構成の更新 1 回にかかる時間は、ADSIR のみ辞書を再構成中の画像を用いて適応的に学習するため、非常に長くなる。提案法では式 (14) の計算や OMP による係数更新の際に、プログラム内でクラスを区別しなければならないため、GDSIR に比べて時間が約 0.3 秒増加した。以上から、提案法は高精度な画像を比較的高速に再構成できることが確認された。


5. おわりに

本研究では、低線量 CT における画像再構成に対して、マルチクラス辞書学習を利用する反復再構成アルゴリズムを提案した。


提案法では、FBP 法で得られる初期画像のパッチを学習用画像と同じクラスタリングセンターを用いて 1 回のみ分類するため、マルチクラスでありながら計算量をほとんど増加させずに画像を再構成できる。また、クラスごとの正則化パラメータを新たに導入することで、辞書学習や係数更新のパラメータが全てのクラスに対して共通であっても、高精度な画像再構成が可能となった。実データを用いたシミュレーションにより、提案法がシングルクラスの辞書学習を用いる GDSIR や ADSIR に比べて、遥かに高精度に画像を再構成できることを示した。なお、提案法は画像再構成に 1,000 回の更新で約 30 分の時間を要しているため、高速化が今後の課題である。

文 献


- [1] Q. Xu, H. Yu, X. Mou, L. Zhang, J. Hsieh, and G. Wang, "Low-dose X-ray CT reconstruction via dictionary learning," *IEEE Transactions on Medical Imaging*, vol. 31, no. 9, pp. 1682–1697, 2012.
- [2] 田中 敏幸, "X 線 CT の原理・現状とさらなる画像の高品質化," 計測と制御, vol. 56, no. 11, pp. 874–879, 2017.
- [3] Y. Chen, L. Shi, Q. Feng, J. Yang, H. Shu, L. Luo, J. L. Coatrieux, and W. Chen, "Artifact suppressed dictionary learning for low-dose CT image processing," *IEEE Transactions on Medical Imaging*, vol. 33, no. 12, pp. 2271–2292, 2014.
- [4] M. Elad, *Sparse and Redundant Representations: From Theory to Applications in Signal and Image Processing*. New York, NY: Springer, 2010.
- [5] C. Zhang, T. Zhang, M. Li, C. Peng, Z. Liu, and J. Zheng, "Low-dose CT reconstruction via ℓ_1 dictionary learning regularization using iteratively reweighted least-squares," *Biomedical Engineering Online*, vol. 15, no. 66, pp. 1–21, 2016.
- [6] Y. Chen, X. Yin, L. Shi, H. Shu, L. Luo, J. L. Coatrieux, and C. Toumoulin, "Improving abdomen tumor low-dose CT images using a fast dictionary learning based processing," *Physics in Medicine and Biology*, vol. 58, no. 16, pp. 5803–5820, 2013.
- [7] Z. Zhan, J. F. Cai, D. Guo, Y. Liu, Z. Chen, and X. Qu, "Fast multiclass dictionaries learning with geometrical directions in MRI reconstruction," *IEEE Transactions on Biomedical Engineering*, vol. 63, no. 9, pp. 1850–1861, 2016.
- [8] 稲室 憲人, 柴田 基, 湯 晨旻, 井尻 敬, 平林 晃, "学習用画像と観測信号を併用した辞書学習による MR 画像高精度再構成," 電子情報通信学会技術研究報告, vol. 116, no. 395, pp. 123–128, 2017.
- [9] K. Sauer and C. Bouman, "A local update strategy for iterative reconstruction from projections," *IEEE Transactions on Signal Processing*, vol. 41, no. 2, pp. 534–548, 1993.
- [10] 小西 達郎, 浅井 義行, 上村 正信, 山田 浩司, 松本 政雄, "被写体物質の違いに起因する X 線 CT 画像コントラストの管電圧依存性の変化," 医用画像情報学会雑誌, vol. 25, no. 4, pp. 90–95, 2008.
- [11] I. A. Elbakri and J. A. Fessler, "Statistical image reconstruction for polyenergetic X-ray computed tomography," *IEEE Transactions on Medical Imaging*, vol. 21, no. 2, pp. 89–99, 2002.
- [12] Y. C. Pati, R. Rezaifar, and P. S. Krishnaprasad, "Orthogonal matching pursuit: Recursive function approximation with applications to wavelet decomposition," in *Conference Record of The Twenty-Seventh Asilomar Conference on Signals, Systems and Computers*, 1993, pp. 40–44.
- [13] J. Mairal, F. Bach, J. Ponce, and G. Sapiro, "Online learning for matrix factorization and sparse coding," *Journal of Machine Learning Research*, vol. 11, pp. 19–60, 2010.
- [14] J. Mairal, J. P. Chieze, Y. Chen, G. Durif, R. Jenatton, F. Bach, J. Ponce, G. Obozinski, B. Yu, G. Sapiro, and Z. Harchaoui, *Spams: a SParse Modeling Software ver. 2.6*. [Online] <http://spams-devel.gforge.inria.fr/doc/html>




(a) 原画像 (No. 1610)




(b) FBP 法により得られる初期画像




(c) GDSIR [31.26 / 0.817]



(d) ADSIR [30.48 / 0.769]




(e) 提案法 (均一な λ_q) [32.10 / 0.858]




(f) 提案法 (最適な λ_q) [**37.04 / 0.980**]


図 3 No. 1610 の CT 画像の再構成結果 [PSNR / SSIM]




(a) 原画像 (No. 1615)




(b) FBP 法により得られる初期画像




(c) GDSIR [31.51 / 0.831]



(d) ADSIR [30.71 / 0.786]



(e) 提案法 (均一な λ_q) [32.28 / 0.865]



(f) 提案法 (最適な λ_q) [**37.00 / 0.980**]

図 4 No. 1615 の CT 画像の再構成結果 [PSNR / SSIM]