

圧縮センシングの基礎と画像取得への応用

平林 晃・北原 大地

Basics of Compressed Sensing and Its Application to Image Acquisition

Akira HIRABAYASHI and Daichi KITAHARA

In this paper, we introduce the basic theory of compressed sensing and its applications to two image acquisition problems. One is pixel number enhancement for high-speed imaging, and the other is image reconstruction in high-speed magnetic resonance imaging (MRI). In the first application, by using the sparsity of the differences of representation coefficients in adjacent frames, we show that the same estimation accuracy as that of the conventional method is very quickly achieved. In the second application, by using a novel dictionary learning which considers both of the previous data and the present observation, we can reconstruct high-quality MR images compared to conventional dictionary learning. Finally, we conclude this paper by giving future perspective along this line.

Key words: compressed sensing, sparse representation, dictionary learning, optimization, image acquisition

はじめに

圧縮センシングの一連の論文が発表されて10年が経過した^{1,2)}。一時の爆発的な取り上げられ方から比べれば、現在はやや落ち着いた状況に感じられる。このことはそのまま、信号処理や画像処理において、スパース性の活用が既に基本技術として定着していることを意味するようと思われる。圧縮センシングは、不良設定逆問題（解を一意に定めることが一般にはできない逆問題）に対する一つの理論体系であり、未知信号にスパース性、あるいは圧縮可能性の前提があれば、適切な観測系を設計することで信号を高精度に復元できることを保証している。昨今はビッグデータの時代であり、データを大量に獲得できることもあるが、そのような場合であっても不良設定の状態が発生することは少なくない。また、あえて不良設定状態で観測を行うことによって、高速性や安全性などの新たな価値を生み出す場合もあるため、圧縮センシングは強力なツールとして注目されているのである。

圧縮センシング理論を適用するためには、観測対象がスパースに表現できることが前提となる。例えば、自然画像は離散コサイン基底やウェーブレット基底に関してスパース性や圧縮可能性が成立していると考えられる。しかしな

がら、このような適切な表現基底が既知でない場合も多く、また既知の場合においても、よりスパースに表現可能な基底を見出すことができれば、信号の推定精度向上が可能となる。この要請に応えるために、大量のデータから、それらをスパースに表現する基底（あるいはフレーム）を生成する技術が辞書学習である。近年は、圧縮センシングと辞書学習を組み合わせる利用することが定着している。

このような認識のもと、本稿ではまず、圧縮センシングの基礎を簡単に振り返る。具体的には、スパースな信号を復元するための l_0 ノルム最小化問題を紹介し、それを凸緩和した l_1 ノルム最小化問題の解の近似精度が保証されるための観測系の条件を述べる。次に、著者らがこの数年に研究してきた2種類の応用事例、ハイスピードイメージングの高画素化³⁾と、高速核磁気共鳴画像法（高速MRI）における画像再構成⁴⁾を概説する。ハイスピードイメージングの高画素化では、離散コサイン係数の隣接時刻間における差分値のスパース性を新たに利用することで、従来と同程度の推定性能を低計算量で実現できることを示す。高速MRIにおける画像再構成では、過去に撮影した高画質なMR画像と現在の観測信号の両方を考慮した新しい辞書学習法により、高精度な再構成が実現できることを示す。最後に、この分野における今後の研究の方向性を展望する。

1. 圧縮センシングに関する基礎知識

N 次元ベクトルとして表現される未知信号 $\mathbf{x}^* \in \mathbb{R}^N$ に対して線形観測を M 回行うことで、観測結果 $\mathbf{y} \in \mathbb{R}^M$ が

$$\mathbf{y} = A\mathbf{x}^* + \mathbf{e} \quad (1)$$

のように得られるものとする。ここで、 $A \in \mathbb{R}^{M \times N}$ は既知の観測行列であり、 $\mathbf{e} \in \mathbb{R}^M$ は観測雑音を表す。このとき、観測回数が信号の次元数以上、すなわち $M \geq N$ であれば、未知信号 \mathbf{x}^* を精度よく推定できるだろう。一方で、圧縮センシングにおいては、「圧縮」という言葉が示唆する様に、観測回数は信号次元数より少ない。つまり $M < N$ であり、この場合、一般には \mathbf{y} から \mathbf{x}^* の N 個の成分を推定することは困難となる。

そこで圧縮センシングでは、 \mathbf{x}^* の成分の多くが0である状況を想定し、残りの僅かな非零成分のみを推定することを考える。ベクトル \mathbf{x}^* の非零成分の個数が高々 K であるとき、 \mathbf{x}^* は「 K -スパース」であるといい、この場合の \mathbf{x}^* の未知数は非零成分の値および位置の $2K$ 個であると考えられる。したがって $M > 2K$ であれば、 K -スパースな未知信号 \mathbf{x}^* の高精度な推定が期待できる。

このための方法としてまず考えられるのが、観測条件を満たすベクトル \mathbf{x} の中で非零成分の個数を最小にするベクトル

$$\mathbf{x}^{(0)} = \operatorname{argmin}_{\mathbf{x} \in \mathbb{R}^N} \|\mathbf{x}\|_0 \quad \text{subject to } \|A\mathbf{x} - \mathbf{y}\|_2^2 \leq \varepsilon \quad (2)$$

を見つけることである。ここで、 $\|\mathbf{x}\|_0$ は \mathbf{x} の非零成分の個数を表し、 \mathbf{x} の ℓ_0 ノルムと慣例的に呼ばれる。また、 $\varepsilon \geq 0$ は式 (1) における観測雑音 \mathbf{e} の大きさに相当する定数であり、 $\|\mathbf{e}\|_2^2 \leq \varepsilon$ を満足している。しかしながら、この問題は「NP 困難な組み合わせ最適化問題」であるため、 N が大きいときには、現実的な時間で最適解 $\mathbf{x}^{(0)}$ を求めることができない。

式 (2) の問題に近似解を与えるアルゴリズムが **Matching Pursuit (MP)** である。MP の基本的な考え方は、 A の列ベクトルの中から、観測誤差 $\|A\mathbf{x} - \mathbf{y}\|_2^2$ を最小にするものを貪欲法的に1本ずつ選択するというもので、選択したベクトルの数が事前に指定した K に達するとアルゴリズムが終了する。とりわけ、誤差ベクトルが選択した A の列ベクトル全てと直交するように修正を加えたものが **Orthogonal Matching Pursuit (OMP)** である⁵⁾。MP や OMP は K 回の繰り返し処理によって高速に K -スパースな近似解 $\tilde{\mathbf{x}}^{(0)}$ を計算できるが、 $\tilde{\mathbf{x}}^{(0)}$ が元の最適化問題の制約 $\|A\tilde{\mathbf{x}}^{(0)} - \mathbf{y}\|_2^2 \leq \varepsilon$ を満たすことは必ずしも保証されず、結果として推定性能が劣化してしまう問題が発生する。この問題を解決するた

めには、観測対象を K -スパースに精度よく表現可能な基底をあらかじめ用意する必要があり、そのために辞書学習が重要となる。この問題については第3節で解説する。

K -スパースなベクトル \mathbf{x}^* を推定するもう一つの方法として、式 (2) において ℓ_0 ノルムを ℓ_1 ノルムによって凸緩和し、これにより得られる最適化問題を解くことも考えられる。すなわち、観測条件を満たすベクトル \mathbf{x} の中で ℓ_1 ノルム (\mathbf{x} の各成分の絶対値和) を最小にするベクトル

$$\mathbf{x}^{(1)} = \operatorname{argmin}_{\mathbf{x} \in \mathbb{R}^N} \|\mathbf{x}\|_1 \quad \text{subject to } \|A\mathbf{x} - \mathbf{y}\|_2^2 \leq \varepsilon \quad (3)$$

を推定値として用いるのである。これは「凸最適化問題」であるため、比較的効率よく最適解 $\mathbf{x}^{(1)}$ を計算できる⁶⁾。通常、最適解 $\mathbf{x}^{(1)}$ は未知信号 \mathbf{x}^* とは異なるが、 $M > 2K$ のときに観測行列 A が零空間特性や制限付き等長性などの条件を満足すれば、 $\mathbf{x}^{(1)}$ の \mathbf{x}^* に対する近似精度を保証することができる⁷⁾。実際には、上記の条件を満足する観測系を設計することは容易ではなく、 $\mathbf{x}^{(1)}$ の近似精度は保証されないことも多いが、そのような観測系においても式 (3) によって良好な推定結果が得られる場合が多々ある。次節では、式 (3) の考え方に基づいてハイスピードカメラの画素数を拡大した筆者の研究を概説する。

2. ハイスピードイメージングにおける高画素化

1秒間に100フレーム(100fps)以上撮影可能なカメラは「ハイスピードカメラ」と呼ばれ、ハイスペックな製品では、 $2,560 \times 1,920$ の画像を2,000fpsで撮影可能である。ハイスピードカメラには、fpsを上昇させると画素数が減少するという問題が原理的に存在する。実際に、上記製品のfpsを10,000、50,000と上昇させると、画素数は 640×592 、 320×192 と減少する。これは、画素値記録に必要な時間は画素数に比例して増えるのに対し、高いfps値がフレームごとの画素値記録時間を制限してしまうためである。

この問題に対して我々は、高いfps値においてもなるべく多くの画素数を記録できるハイスピードカメラの実現を目指す。そのために、図1に示す光学系を想定する³⁾。これは、シングルピクセルカメラを複数画素に拡張したものである⁸⁾。この光学系では、結像面にCCDなどのイメージセンサではなくDigital Micro-Mirror Device (DMD) 配列が設置されており、例えば、最大32,552Hzで二値パターン切り替えが可能なDMD製品を用いることで、 2×2 のブロックごとにランダムな画素選択を行う。これによって撮影画素数を制限する一方で、画像列におけるある種のスパース性を利用して、撮影された少数の画素から画像全体を高速に再構成する。

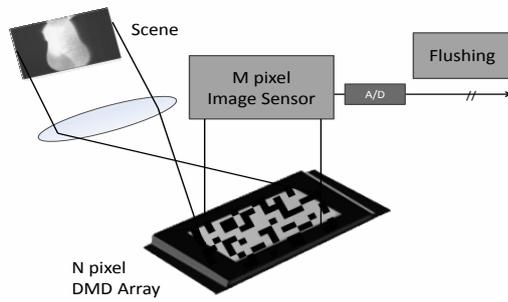


図1 光学系システム³⁾.

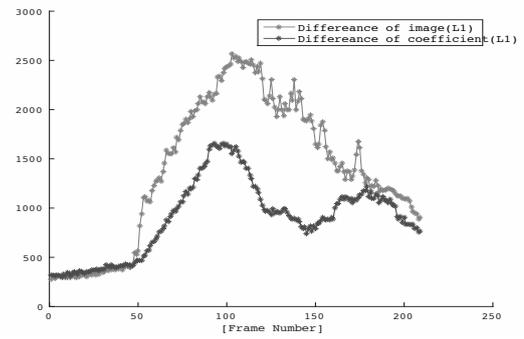


図2 画像列の隣接時刻間における差分情報.

高画素数の第 r フレーム画像を $\mathbf{x}_r^* \in \mathbb{R}^N$ ($r = 1, 2, \dots, R$) で表す. 筆者らの手法では, これらを一括に再構成するのではなく, 第1フレームから順に再構成していく. 実際に撮影されるのは, \mathbf{x}_r^* の N 画素のうち, 圧縮率に応じてランダムに選ばれた M 画素である. これを $\mathbf{y}_r \in \mathbb{R}^M$ で表し, ランダム選択行列を $A_r \in \{0, 1\}^{M \times N}$ で表せば,

$$\mathbf{y}_r = A_r \mathbf{x}_r^* \quad (r = 1, 2, \dots, R) \quad (4)$$

が成立する. ここで, ランダム選択行列 A_r はフレームごとに変更する点に注意されたい. 図2は画素数が 256×256 のある画像列(動画)の隣接フレームにおける「画素値差分」と「離散コサイン係数差分」の ℓ_1 ノルムを示しており, $256^2 = 65,536$ であることを考慮に入れれば, どちらも比較的小さな値であることが分かる. 特に, 離散コサイン係数差分のほうが画素値差分より小さいことが確認できる. 他の動画に対しても同様の傾向が見られており³⁾, 上記2種類の差分情報と, 式(4)および画像に関する先験情報を組み合わせることで, 高精度な画像再構成を期待できる. そこで, 我々は最適化問題

$$\hat{\mathbf{x}}_r = \underset{\mathbf{x} \in \mathbb{R}^N}{\operatorname{argmin}} \|C\mathbf{x}\|_1 + \lambda_1 \|\mathbf{x} - \hat{\mathbf{x}}_{r-1}\|_1 + \lambda_2 \|C\mathbf{x} - C\hat{\mathbf{x}}_{r-1}\|_1$$

subject to $A_r \mathbf{x} = \mathbf{y}_r$, (5)

を順に解くことにより画像列全体を復元した. ここで, 第1項は各フレームの画像が離散コサイン変換によりスパースに表現できることを意味している. 第2項, 第3項は隣接フレーム間の画素値差分と離散コサイン係数差分がそれぞれスパースであることを意味し, $\lambda_1 > 0$ と $\lambda_2 > 0$ は3つの項の間の重みを規定している. 最後に, 制約条件 $A_r \mathbf{x} = \mathbf{y}_r$ は式(4)に基づいている. 式(5)は凸最適化問題であり, 例えば Alternating Direction Method of Multipliers (ADMM) などにより, 効率的に最適解 $\hat{\mathbf{x}}_r$ を計算できる.

提案手法のシミュレーション結果を示す. ハイスピードカメラ (Optronis CR450x3, ナックイメージテクノロジー社) を用いて, 撮影速度 6,000 fps で画素数 256×256 の無

圧縮画像 210 枚を得た. 撮影対象は, 屋外におけるテニスボールとラケットの接触の瞬間である. 撮影された画像列に対して, フレームごとに 25% の圧縮率でブロックランダム選択を行い, 選択された画素から画像全体を再構成する. 画像列の第 107 フレーム画像, 観測画像, 提案手法による復元結果とピーク信号対雑音比 (PSNR), 従来手法⁹⁾ による復元結果と PSNR をそれぞれ, 図3 (a), (b), (c), (d) に示す. ここで提案手法では, 式(5)において $\lambda_1 = 0.5$, $\lambda_2 = 1$ とし, ADMM の繰り返し回数は 20 回に設定した. 図3では, 3次元全変動を抑圧して画像列全体を一括に再構成する従来手法より, 提案手法のほうが高い PSNR を与えており, 実際にラケットのガット部分が鮮明に再構成されていることが確認できる. 全 210 フレームの画像に対する PSNR の平均値は従来手法に比べて 0.13 dB 下回っているものの, 提案手法の計算速度は従来手法の約 1,200 倍であり³⁾, 従来と同程度の再構成精度を極めて高速に達成している.

3. 融合型辞書学習を利用した高速 MRI

辞書学習を用いた高速 MRI に関する研究成果を述べる. この問題では未知信号である断面画像 \mathbf{x}^* は通常, 複素数値として考えられるため, $\mathbf{x}^* \in \mathbb{C}^N$ である. 高速 MRI における観測系は, 2次元離散フーリエ変換 $F \in \mathbb{C}^{N \times N}$ からのランダム選択 $A \in \{0, 1\}^{M \times N}$ である. 観測雑音を $\mathbf{e} \in \mathbb{C}^M$ で表せば, 観測信号 $\mathbf{y} \in \mathbb{C}^M$ は $\mathbf{y} = A F \mathbf{x}^* + \mathbf{e}$ で与えられる. この \mathbf{y} から \mathbf{x}^* を推定する.

画像は, 医療用であっても自然風景であっても, 局所情報の集まりであることが多い. 更に, 高次元データに対する辞書学習には多大な計算時間を必要とする. そこで, $\sqrt{N} \times \sqrt{N}$ の画像全体を, 小さな $\sqrt{n} \times \sqrt{n}$ の局所領域 (パッチと呼ぶ) に分割し, これらをスパースに表現する辞書 (基底あるいはフレーム) を学習する.

さて, 辞書学習には大きく分けて, 事前型, 適応型, 融合型 (提案手法) の3種類がある. 事前型辞書学習では, 過去に撮影した高画質な MR 画像を用いて辞書学習を行い, 得

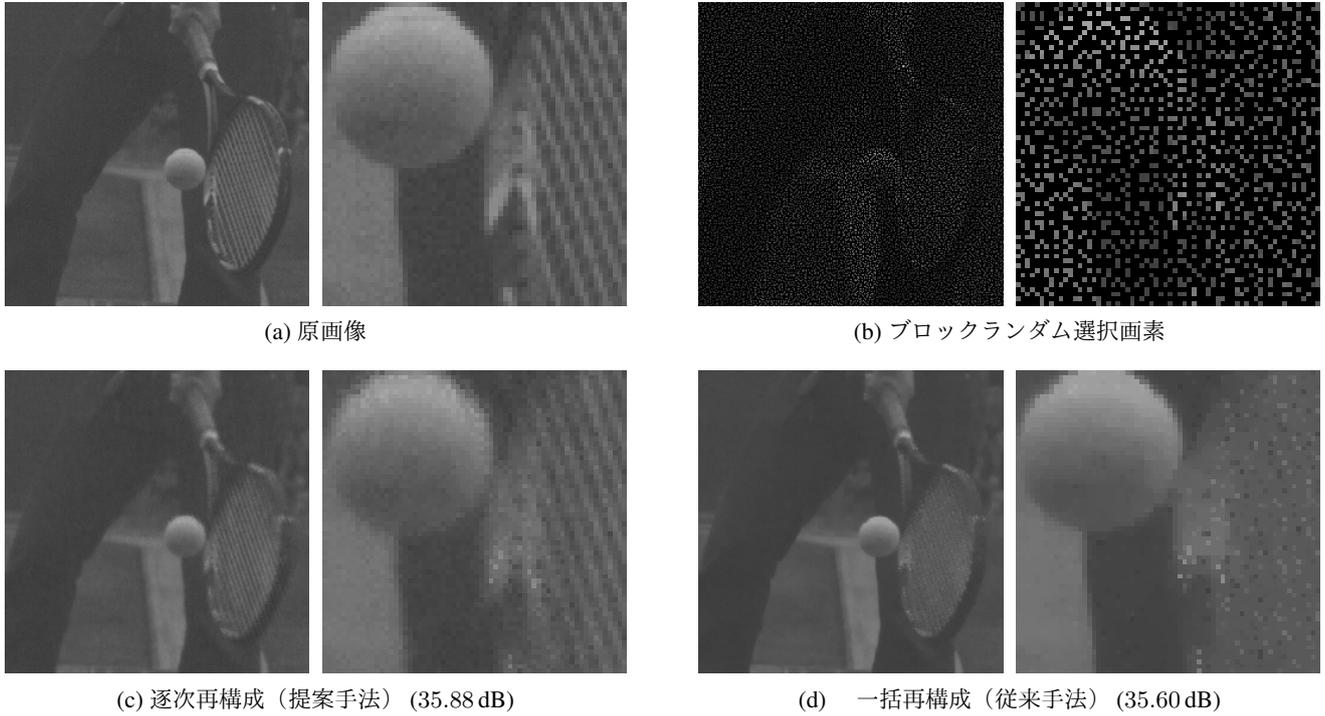


図3 ブロックランダム選択画素からの再構成結果.

られた辞書と観測信号を用いて画像再構成を行う. 学習用パッチをラスターキャンして得られるベクトルを $\mathbf{z}_p \in \mathbb{C}^n$ ($p = 1, 2, \dots, P$) で表す. 辞書を構成するベクトルの数を m で表せば, 辞書は $n \times m$ 行列 $D \in \mathbb{C}^{n \times m}$ となる. 各学習用パッチ \mathbf{z}_p の辞書 D に関する表現係数を \mathbf{c}_p で表すと, 辞書は最適化問題

$$[\hat{D}, \{\hat{\mathbf{c}}_p\}] = \underset{D, \{\mathbf{c}_p\}}{\operatorname{argmin}} \sum_{p=1}^P \|\mathbf{z}_p - D\mathbf{c}_p\|_2^2 \quad \text{subject to } \|\mathbf{c}_p\|_0 \leq T_0 \quad (6)$$

を解くことにより得られる. ここで, $\|\mathbf{c}_p\|_0$ はベクトル \mathbf{c}_p の非零成分の個数であり, T_0 はその上限値である. こうして得られた辞書 \hat{D} に関して各パッチがスパースに表現され, かつ観測信号 \mathbf{y} とのデータ整合性がとれる画像を \mathbf{x}^* の再構成結果として用いる. しかし, 式 (6) によって得られた辞書には, 現在の推定対称である \mathbf{x}^* に関する情報が含まれていないという問題が存在する.

一方, Ravishankar らは, 観測信号から辞書を適応的に学習し (適応型辞書学習と呼ぶ), 同時に \mathbf{x}^* を再構成する DLMRI¹⁰⁾ という手法を提案した. この方法では, 最適化問題

$$[\hat{\mathbf{x}}, \hat{D}, \{\hat{\mathbf{c}}_{i,j}\}] = \underset{\mathbf{x}, D, \{\mathbf{c}_{i,j}\}}{\operatorname{argmin}} \left[\nu \|\mathbf{A}\mathbf{F}\mathbf{x} - \mathbf{y}\|_2^2 + \sum_{i=1}^I \sum_{j=1}^J \|\mathbf{R}_{i,j}\mathbf{x} - D\mathbf{c}_{i,j}\|_2^2 \right] \quad \text{subject to } \|\mathbf{c}_{i,j}\|_0 \leq T_1 \quad (7)$$

を解くことにより, 辞書学習と画像再構成を同時に実現し

ている. ここで, $\mathbf{R}_{i,j} \in \mathbb{R}^{n \times N}$ は再構成画像 $\mathbf{x} \in \mathbb{C}^N$ の (i, j) 画素を左上に持つ $\sqrt{n} \times \sqrt{n}$ のパッチを抽出する行列である. DLMRI では高圧縮信号を逆フーリエ変換することで低品質な再構成画像をまず生成し, この画像を初期値に用いて推定値を更新していく. ところが, 式 (7) では過去の学習用画像を用いず, 高圧縮信号のみで辞書を学習するために, 鮮明な画像の生成が難しい.

式 (6), 式 (7) におけるそれぞれの問題点を解決するために, 我々は, 学習用画像と観測信号の両方を用いて辞書を学習し, 同時に高精度な画像を生成する手法を提案した. これが融合型辞書学習であり⁴⁾, 提案手法は最適化問題

$$[\hat{\mathbf{x}}, \hat{D}, \{\hat{\mathbf{c}}_p\}, \{\hat{\mathbf{c}}_{i,j}\}] = \underset{\mathbf{x}, D, \{\mathbf{c}_p\}, \{\mathbf{c}_{i,j}\}}{\operatorname{argmin}} \left[\nu \|\mathbf{A}\mathbf{F}\mathbf{x} - \mathbf{y}\|_2^2 + \sum_{p=1}^P \|\mathbf{z}_p - D\mathbf{c}_p\|_2^2 + \sum_{i=1}^I \sum_{j=1}^J \|\mathbf{R}_{i,j}\mathbf{x} - D\mathbf{c}_{i,j}\|_2^2 \right] \quad \text{subject to } \|\mathbf{c}_p\|_0 \leq T_0 \text{ and } \|\mathbf{c}_{i,j}\|_0 \leq T_1 \quad (8)$$

を解くことによって実現される. 式 (8) における辞書学習では, 学習用パッチの選択が再構成結果に大きく影響する. 適切な学習用パッチを得るために, 我々は, 学習用画像から得られる全パッチを K-means 法でクラスタリングし, 体外部分に相当するクラスのパッチをあらかじめ排除する手法を提案している. また, 学習用パッチ数 P と観測画像パッチ数 IJ の比率も重要であり, 以下の実験では $P : IJ = 9 : 1$ としている.

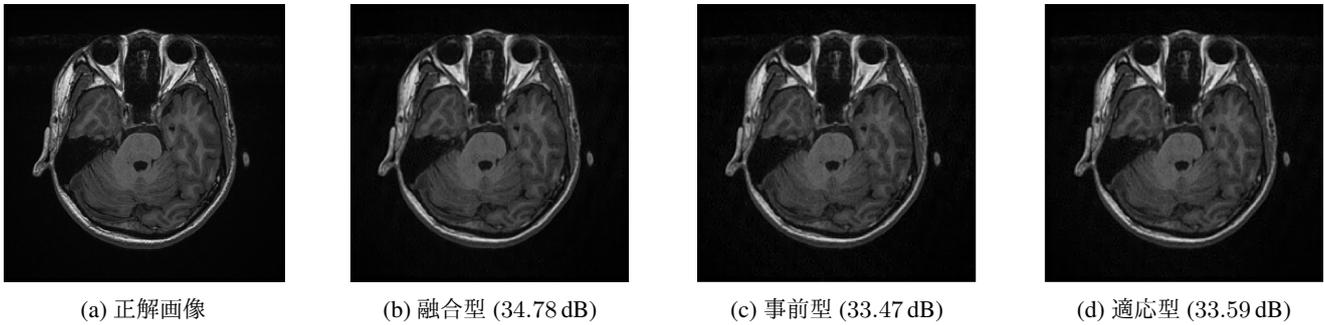


図4 圧縮率20%のシミュレーション結果.

提案手法のシミュレーション結果を示す。健常な20代の男性2名(A, Bと呼ぶ)の頭部をMRI装置(SignaHDxt, 1.5T, GE Healthcare UK社)によって撮像した。各種パラメータは, TR = 12.4 ms, TE = 5.2 ms, FOV = 240 mm × 240 mm, Gap = 0, Thickness = 1 mmであり, 8ch Brain Coilを使用した。学習用画像として実験参加者Aの画像を用い, 実験参加者Bの画像を圧縮率20%の観測信号から再構成する。正解画像および融合型(提案手法), 事前型, 適応型それぞれの辞書学習法による再構成結果とPSNRを図4(a), (b), (c), (d)に示す。図4から, PSNRは融合型が最も高く, 事前型, 適応型に比べてそれぞれ1.31 dB, 1.19 dBの改善が確認できる。図が小さいため分かりづらいが, 拡大すれば, 融合型により鮮明な画像が再構成できていることが確認できる。式(8)のように, 過去のデータと現在の観測信号の両方を用いる考え方はMRIに限らず応用可能であり, 今後は他の画像処理問題にも展開していく予定である。一方で, 式(8)(および式(7))には, 辞書学習と画像再構成を同時に行うため計算量が大きいという問題点がある。筆者らはこの問題に対して, 辞書に構造を持たせることにより高速化するという研究も行っている¹¹⁾。

まとめ

本稿では, 圧縮センシングの基礎と応用事例2件を解説した。第1の応用事例では, ハイスピードイメージングの高画素化において, 画素値差分と離散コサイン係数差分のスパース性を利用しながら, フレームごとに画像を再構成することで, 従来と同程度の推定性能を極めて高速に実現できることを示した。第2の応用事例では, 高速MRIの画像再構成問題において, 過去に撮影した高画質なMR画像と現在の観測信号の両方を利用する融合型辞書学習によって, 従来より高精度なMR画像が再構成されることを示した。

上記のように, 本稿では圧縮センシングと辞書学習について解説してきたが, 一方で深層学習を用いた画像処理手法が急速な展開を示していることも事実である¹²⁾。辞書学習と深層学習を比較した場合, 後者に比べて前者のほうが

パラメータ数が少なく, 必要データ数も少ないと考えられる。また, 辞書学習では明示的にデータの表現基底を求めるが, 深層学習では結果的に表現基底のようなものが得られていると考えられる。このような違いを意識して, 両者を適切に使い分けていくことが今後は必要になると筆者は考えている。

文献

- 1) D. L. Donoho: "Compressed sensing," *IEEE Trans. Inf. Theory*, **52** (2006) 1289–1306.
- 2) E. J. Candès and M. B. Wakin: "An introduction to compressive sampling," *IEEE Signal Process. Mag.*, **25** (2008) 21–30.
- 3) N. Nogami, A. Hirabayashi, T. Ijiri and J. White: "Toward large-pixel number high-speed imaging exploiting time and space sparsity," *IEICE Trans. Fundam. Electron. Commun. Comput. Sci.*, **E100-A** (2017) 1279–1285.
- 4) 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", *IEICE Tech. Rep.*, **116** (2017) 123–128.
- 5) T. T. Cai and L. Wang: "Orthogonal matching pursuit for sparse signal recovery with noise," *IEEE Trans. Inf. Theory*, **57** (2011) 4680–4688.
- 6) P. L. Combettes and J. C. Pesquet: "Proximal splitting methods in signal processing," *Fixed-Point Algorithms for Inverse Problems in Science and Engineering*, eds. H. H. Bauschke, R. S. Burachik, P. L. Combettes, V. Elser, D. R. Luke and H. Wolkowicz (Springer, New York, 2011) pp. 185–212.
- 7) 平林晃: "Compressed sensing: 基本原理と最新研究動向", *IEICE Tech. Rep.*, **109** (2009) 55–60.
- 8) R. G. Baraniuk: "Compressive sensing," *IEEE Signal Process. Mag.*, **24** (2007) 118–121.
- 9) S. H. Chan, R. Khoshabeh, K. B. Gibson, P. E. Gill and T. Q. Nguyen: "An augmented lagrangian method for total variation video restoration," *IEEE Trans. Image Process.*, **20** (2011) 3097–3111.
- 10) S. Ravishankar and Y. Bresler: "MR image reconstruction from highly undersampled k-space data by dictionary learning," *IEEE Trans. Med. Imaging*, **30** (2011) 1028–1041.
- 11) C. Tang, N. Inamuro, T. Ijiri and A. Hirabayashi: "Compressed sensing MRI using double sparsity with additional training images," *Proc. of 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (New Orleans, 2017) pp. 801–805.
- 12) C. Dong, C. C. Loy, K. He and X. Tang: "Image super-resolution using deep convolutional networks," *IEEE Trans. Pattern Anal. Mach. Intell.*, **38** (2016) 295–307.

(2017年7月18日受理)