

近傍パッチの情報に基づく重みを利用した スパース再構成による一枚超解像

牧野 賢吾^{1,a)} 櫻井 歩¹ 田中 正行¹ 奥富 正敏¹

概要: 画像の一枚超解像手法について、スパースコーディングを用いたものが近年成果を挙げている。スパースコーディングを用いた画像再構成（スパース再構成）では、画像をパッチに切り分け、各パッチを少数の基底の線形結合によって表現する。この時、線形結合の係数を決める際に基底に重みを与えることで再構成結果が向上することが知られている。本論文ではパッチとその近傍パッチの概形からクラスタリングを行い、クラスタに応じた重みを与えてスパース再構成を行う手法を提案する。従来のスパース再構成ではパッチは独立に処理されていたが、提案手法では近傍のパッチの情報も利用して再構成を行っており、一枚超解像の結果から、提案手法の性能の有効性が確認された。

1. はじめに

劣化画像から画像の復元を行う画像再構成の技術は、より解析的な画像を利用できるようになるなど大変有用である。画像再構成の問題において、劣化画像 \mathbf{y} は一般に式1のようにモデル化されている。 \mathbf{H} は劣化行列であり、元の真値画像 \mathbf{x} を劣化させるような行列である。また、 ν はノイズである。

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \nu \quad (1)$$

劣化行列 \mathbf{H} の種類に応じて劣化画像の種類も変化する。 \mathbf{H} が単位行列の場合は \mathbf{y} はノイズ画像であり、 \mathbf{H} がぼかしとダウンサンプリングを行う行列の場合は \mathbf{y} は低解像画像となる。低解像画像から高解像画像への再構成は超解像と呼ばれており、1枚の観測画像から超解像を行うものを特に一枚超解像と呼ぶ。本論文はこの一枚超解像の問題を取り扱う。

画像再構成の問題は逆問題であり、この問題を解くために、拘束条件を加えて画像を再構成する様々な手法が今日まで提案されてきている。その中でも [1] らの提案したスパースコーディングの考え方に基づく手法が近年さかんに研究されており成果を挙げている。スパースコーディングは観測された信号を少数の基底の線形結合によって表現する手法であり、画像全体をパッチに切り分け、パッチごとにこの処理を行う事で画像全体の再構成を実現することができる。本論文では、まず線形結合の係数決定時に基底へ

の重み付けを行うことで再構成結果がよくなることを確認した。この結果を受けて、基底の重み付けのパターンを入力パッチのパターンに応じて変更させることで、さらに性能が向上するのではないかと考え、パッチをクラスタリングしてクラスタに応じて重み付けを変える手法を提案した。

またクラスタリングの方法としては、入力パッチのパターンだけではなく入力パッチの周辺のパッチのパターンも用いた方が、より細かいクラスタリングを行うことができ、性能の向上が期待されるため、近傍のパッチのパターンも利用したクラスタリング方法を先の提案手法に組み込み、提案手法を拡張した。従来、パッチは独立に扱われていたが、本提案手法では処理するパッチの近傍パッチの情報も利用して再構成を行うため、更に再構成結果が向上することが確認された。

本論文は、まず2章でスパースコーディングによる画像再構成（スパース再構成）について確認する。続いて3章で提案手法の説明を行い、4章にて他手法との比較により性能を評価し、本提案手法の有効性を確認する。最後に5章で本論文のまとめを行う。

2. スパースコーディングによる画像再構成

本章ではスパースコーディングによる画像再構成について確認する。

2.1 画像のスパース表現

オーバーコンプリートな基底を用意し、少数の基底の線形結合によって画像を表現するスパースコーディングという手法が [1] らによって提唱されてきた。[2] での記述を

¹ 東京工業大学

^{a)} makino.k.af@m.titech.ac.jp

借りて、ある画像 \mathbf{x} から切り出すことのできる、大きさ $\sqrt{n} \times \sqrt{n}$ のパッチは $\mathbf{x}_p = \mathbf{R}_p \mathbf{x}$ と表現できる。ここで \mathbf{R}_p は画像 \mathbf{x} の位置 p からパッチを切り出す行列である。

基底ベクトルの集合を辞書 $\mathbf{D} \in \mathbb{R}^{n \times M}$ と呼び、スパースコーディングではパッチの次元数 n に対して基底の数 M を大きく取ってもよい ($n \leq M$)。

辞書 \mathbf{D} をあらかじめ用意し、式 2 を解くことで、パッチ \mathbf{x}_p に対応したスパース係数ベクトル $\boldsymbol{\alpha}_{\mathbf{x},p}$ (係数のほとんどが 0 であるベクトル) を得ることができる。

$$\boldsymbol{\alpha}_{\mathbf{x},p} = \operatorname{argmin}_{\boldsymbol{\alpha}} \|\mathbf{x}_p - \mathbf{D}\boldsymbol{\alpha}\|_2^2 + \lambda \|\boldsymbol{\alpha}\|_1 \quad (2)$$

得られた係数ベクトルを用いて、少数の基底の線形結合によってパッチ \mathbf{x}_p は $\mathbf{x}_p \approx \mathbf{D}\boldsymbol{\alpha}_{\mathbf{x},p}$ と近似的に表現できる。ここで、 λ はスパース拘束項とデータ拘束項の 2 つの項の調整パラメータである。このパラメータはユーザーが自由に調節することができる。

画像全体の再構成は、再構成されたパッチを元の位置 p に配置する事で実現できる。なお、パッチの切り出しや元の位置への配置は重なりを許しており、画像からパッチを切り出す際には 1px ずつずらして切り出し、元の位置への配置時には、重なり部分は平均している。このようにパッチの重なりを許して画像全体を再構成することで、パッチの境界部分に不自然なアーティファクトが生じてしまうのを抑えている。

本論文ではスパースコーディングによる画像・パッチの再構成をスパース再構成と呼ぶこととする。

2.2 画像のスパース表現を利用した一枚超解像

画像のスパース表現は一枚超解像に応用することができる。式 3 を用いることで実現できる。

$$\boldsymbol{\alpha}_{\mathbf{y},p} = \operatorname{argmin}_{\boldsymbol{\alpha}} \|\mathbf{y}_p - \mathbf{H}\mathbf{D}\boldsymbol{\alpha}\|_2^2 + \lambda \|\boldsymbol{\alpha}\|_1 \quad (3)$$

ここで、 \mathbf{y}_p は低解像パッチであり、 \mathbf{H} はぼかしとダウンサンプリングを行う行列である。式 3 によって得られたスパース係数ベクトル $\boldsymbol{\alpha}_{\mathbf{y},p}$ を用いて、再構成によって得られる高解像パッチ \mathbf{x}_p は $\mathbf{x}_p \approx \mathbf{D}\boldsymbol{\alpha}_{\mathbf{y},p}$ と表現できる。高解像パッチを位置 p の高解像空間での対応位置に配置していくことで画像全体の超解像が実現される。

2.3 辞書学習

スパース再構成を行うためには、辞書 \mathbf{D} を与える必要がある。辞書 \mathbf{D} としては Wavelet 基底や DCT 基底など、人工的に生成したものを利用する方法もあるが、自然画像データから切り出したパッチを学習用パッチとして、学習によって生成した基底 (データベース学習基底) を用いた方が、再構成結果が良くなると報告されている [2]。本研究でも自然画像をデータベースとして、学習で生成した基底を用いてスパース再構成を行うこととする。

辞書の学習は式 4 を解くことによって実現される。ここで \mathbf{x}_i は学習用パッチであり、 N_d は学習用パッチの枚数である。式 4 によって、さまざまなパッチをよりスパースに、より正確に表現できるような辞書が生成される。

$$\mathbf{D} = \operatorname{argmin}_{\mathbf{D}} \sum_{i=1}^{N_d} \min_{\boldsymbol{\alpha}_i} \|\mathbf{x}_i - \mathbf{D}\boldsymbol{\alpha}_i\|_2^2 + \lambda \|\boldsymbol{\alpha}_i\|_1 \quad (4)$$

なお、本論文では自然画像データベースに BSDS300[3] の画像 300 枚を使用し、そこから切り出された全パッチのうち、ランダムに 10 万枚抽出して学習用パッチとして構成している。

2.4 重み付きスパース再構成

節 2.1 では画像のスパース表現について説明した。節 2.1 で紹介した式 2 の他にも式 5 のように基底に対して重みをつける手法も過去に提案されている [4]。

$$\boldsymbol{\alpha}_{\mathbf{x},p} = \operatorname{argmin}_{\boldsymbol{\alpha}} \|\mathbf{x}_p - \mathbf{D}\boldsymbol{\alpha}\|_2^2 + \lambda \|\operatorname{diag}(\mathbf{W})\boldsymbol{\alpha}\|_1 \quad (5)$$

ここで、 $\mathbf{W} = [w_1 \dots w_M]$ は重み行列になっており、辞書 $\mathbf{D} = [\mathbf{d}_1 \dots \mathbf{d}_M]$ に対応した重みを設定することができる。また、これを超解像に応用すると式 6 のようになり、得られた係数 $\boldsymbol{\alpha}_{\mathbf{y},p}$ を用いて、高解像パッチ \mathbf{x}_p は $\mathbf{x}_p \approx \mathbf{D}\boldsymbol{\alpha}_{\mathbf{y},p}$ と表現できる。

$$\boldsymbol{\alpha}_{\mathbf{y},p} = \operatorname{argmin}_{\boldsymbol{\alpha}} \|\mathbf{y}_p - \mathbf{H}\mathbf{D}\boldsymbol{\alpha}\|_2^2 + \lambda \|\operatorname{diag}(\mathbf{W})\boldsymbol{\alpha}\|_1 \quad (6)$$

重み行列の設計方針としては、例えば使われやすい基底には小さい重みを、使われにくい基底には大きい重みを与え、スパース再構成のときに基底の使われやすさを反映させる、といったものがある。このような重み行列 \mathbf{W} の作成方法としては、基底 k に対応する係数を $\alpha(k)$ とし、式 7 のように $\alpha(k)$ の標準偏差 σ_k を用いる方法がある。 δ は発散を防ぐための微小量である。

$$w_k = \frac{1}{\sigma_k + \delta} \quad (7)$$

標準偏差 σ_k は式 8 から計算される係数ベクトル $\boldsymbol{\alpha}_{\mathbf{x},i}$ ($i = 1 \dots N_w$) から求めることができる。

$$\boldsymbol{\alpha}_{\mathbf{x},i} = \operatorname{argmin}_{\boldsymbol{\alpha}} \|\mathbf{x}_i - \mathbf{D}\boldsymbol{\alpha}\|_2^2 + \lambda \|\boldsymbol{\alpha}\|_1 \quad (8)$$

ここで、 \mathbf{x}_i は自然画像データベースから切り出された i 枚目のパッチを示している。

N_w 個の係数ベクトル $\boldsymbol{\alpha}_{\mathbf{x},i}$ を全て用いて式 9 により標準偏差 σ_k が求まる。

$$\sigma_k = \left(\frac{1}{N_w} \sum_{i=1}^{N_w} \alpha_{\mathbf{x},i}^2(k) \right)^{\frac{1}{2}} \quad (9)$$

ここで、 $\alpha_{\mathbf{x},i}(k)$ はスカラーであり、スパース係数ベクトル $\boldsymbol{\alpha}_{\mathbf{x},i}$ の基底 k に対応する係数を表している。このようにデータベースからパッチを切り出してスパース再構成を

表 1 スパース再構成と重み付きスパース再構成の比較

手法	スパース再構成	重み付きスパース再構成
PSNR [dB]	31.18	31.27

行い、得られた係数ベクトルから標準偏差を求めることによって、重み行列を設計することができる。本論文ではこの過程を重み学習と呼ぶ。

重み付きスパース再構成の効果を見るため、簡単な実験を行った。使用する辞書 D は共通として、データベースの画像から切り出したパッチを用いて、重み行列 W を作成した。式 3 を用いてスパース再構成を行った場合の超解像結果と式 6 を用いて重み付きスパース再構成を行った場合の超解像結果を比較した。表 1 は Kodak 画像データセット [5] の 24 枚について 2 倍超解像した時のそれぞれの平均 PSNR[dB] である。なお、実験の条件は 4 章で後述するものと同じである。表 1 より、あらかじめ重み学習を行い、超解像時には重み付きスパース再構成を行ったほうが再構成結果がよいことが確認できる。

3. 提案手法

本章ではパッチをクラスタリングすることによって、クラスタに応じて重みを変化させて重み付きスパース再構成を行う提案手法を説明する。その後、入力パッチの近傍の情報も用いたクラスタリング方法を説明し、これを先の提案手法に導入し、提案手法を拡張する。

3.1 クラスタ適応的の重みを利用した重み付きスパース再構成

データベースに含まれるパッチは、縦エッジ成分の強いもの、横エッジ成分の強いもの、などさまざまなパターンのものが存在し、パッチのパターンと基底の使われ方には相関があると考えられる。例えば、横エッジのパターンを持つパッチをスパース再構成した際に、縦エッジ成分を表現する基底が使われるとは考えにくい。この点を考慮すると、データベース全体の全スパース係数ベクトルから重みを学習してしまうことは、パッチのパターンと基底の使われ方の相関を無視していることになるといえる。そこでパッチをクラスタリングし、クラスタごとに重み行列を変化させることによってさらに性能が向上するのではないかと考えた。本節では、パッチのパターンに基づいてクラスタリングを行い、クラスタに応じた重み行列を用いてスパース再構成を行う手法を提案する。

パッチをパターンによってクラスタリングするために、まずクラスタリング辞書 D_c を作成した。これはパッチを 1 つの基底のみによって表現するのに最適化された辞書であり、式 10 から作成できる。

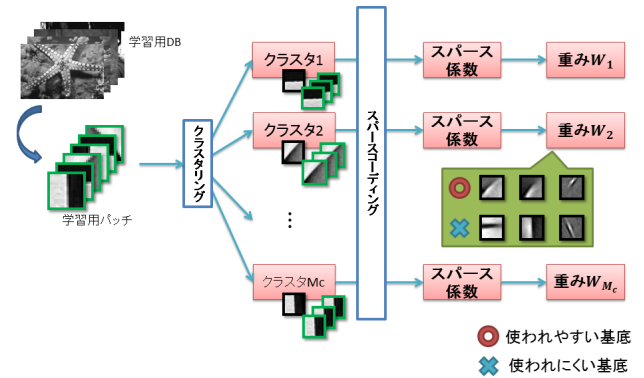


図 1 学習用パッチのクラスタリングとクラスタごとの重み学習

$$D_c = \underset{D}{\operatorname{argmin}} \sum_{i=1}^{N_d} \min_{\alpha_i} \|\mathbf{x}_i - D\alpha_i\|_2^2 \text{ s.t. } \|\alpha_i\|_0 \leq L = 1 \quad (10)$$

パッチのクラスタリングは、クラスタリング辞書 D_c 中のどの基底とベクトルの向きが近いかによって行う。これは、式 11 (高解像パッチ用: 重み学習時に使用) や式 12 (低解像パッチ用: 超解像時に使用) によって得られる係数ベクトルの非ゼロ要素の位置を用いればよい。(係数ベクトルは 1 つの要素のみ値を持ち、その他が 0 であるベクトルとなっている。非ゼロ要素に対応する基底はパッチとベクトルの向きが近いといえる。)

$$\alpha_{\mathbf{x},p} = \underset{\alpha}{\operatorname{argmin}} \|\mathbf{x}_p - D_c\alpha\|_2^2 \text{ s.t. } \|\alpha\|_0 \leq L = 1 \quad (11)$$

$$\alpha_{\mathbf{y},p} = \underset{\alpha}{\operatorname{argmin}} \|\mathbf{y}_p - HD_c\alpha\|_2^2 \text{ s.t. } \|\alpha\|_0 \leq L = 1 \quad (12)$$

クラスタリング辞書 D_c の基底の数を M_c として、データベースから切り出されたパッチは M_c 個のクラスタに分類することができる。各クラスタごとに重みを学習することで、重み付けのパターンは M_c 通りになる (図 1)。

再構成を行う場合は、まず入力パッチを式 12 によってクラスタリングする。その後クラスタに応じて重みを設定した後に式 6 から係数を推定し、パッチを再構成する。図 2 は斜めパターンが入力パッチがあった時に、クラスタリング辞書によって入力パッチが分類され、クラスタごとに学習された重み行列を用いて重み付きスパース再構成を行っている様子为例として載せている。ここで、学習されている重み行列 W_2 は、斜めパターンの基底は使いやすく、そうでないパターンの基底は使いづらくする、といった重み付けがなされている。

3.2 近傍のパターンに基づくパッチクラスタリング

節 3.1 でのクラスタリングは処理を行うパッチのパターンのみに注目していたが、クラスタリングのために近傍の

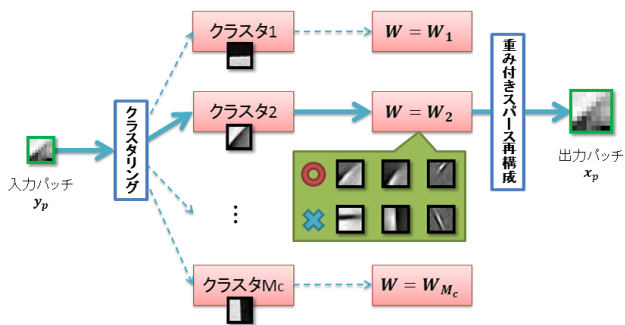


図 2 入力パッチのクラスタリングとクラスタ適応的の重みを用いた重み付きスパース再構成




図 3 クラスタリングするパッチとその近傍 8 パッチの番号

パッチのパターンにも注目することも可能である。本節では、処理を行うパッチを中央パッチとし、中央パッチとその近傍のパッチのパターンに基づくクラスタリング方法を説明する。この方法を用いると、近傍パッチの情報に基づき、更に細かいクラスタリングを行うことが可能となり、節 3.1 のクラスタリング方法を本節での方法に変更することで、節 3.1 の手法を拡張することができる。

まず説明のため、図 3 のように、クラスタリングするパッチを 1 番として、残りの 8 近傍のパッチにも番号を与える。

式 11 や 12 によって、パッチ 1 番から 9 番までそれぞれに 1 つのクラスタリング基底を対応付けることができる。中央パッチの時のみの場合、クラスタリングのパターン数はクラスタリング辞書の基底の個数の M_c であった。しかし、今回の場合は周囲 8 近傍のパッチにもクラスタリング基底が対応付けられているため、各パッチのパターン数が M_c であることから、クラスタリングのパターン数は最大 M_c^9 となる。例えば、パッチ 1 番から 9 番に対応付けられた基底をそれぞれ a, b, \dots, i とすると、中央パッチのクラスタをクラスタ $C_{a,b,c,d,e,f,g,h,i}$ に分類する。といった事が可能になる。

理想的には M_c^9 通りのクラスタを作成可能だが、組み合わせ爆発によって M_c^9 は値が大きくなってしまい、計算機のメモリの問題で実際には実現できない。このため本提案手法では別のアプローチをとって、近傍の情報を用いたクラスタリング・重み付きスパース再構成を行った。

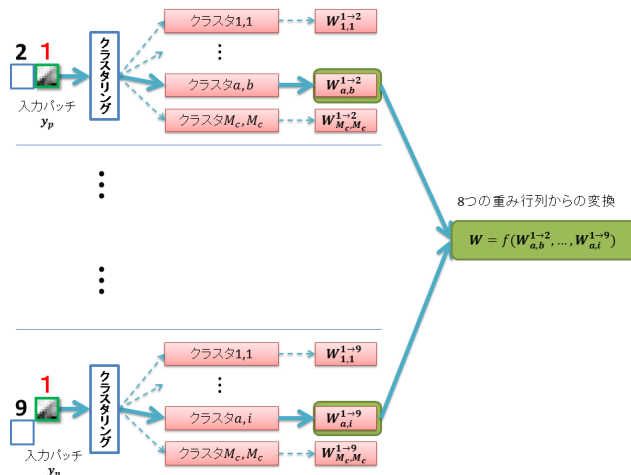


図 4 中央パッチと近傍の 1 パッチを用いたクラスタリングとクラスタ適応的の重みの変換

上記の組み合わせ爆発の問題を抑えるため、本提案手法では中央のパッチとその 8 近傍のパッチのうちの 1 つのパッチのクラスタリング基底の情報に基づいて、クラスタリングを行うことにした。つまり、クラスタリングのパターンは M_c^2 通りである。例えば、パッチ 1 番とパッチ 2 番に対応付けられた基底をそれぞれ a, b とすると、中央のパッチはクラスタ $C_{a,b}$ に分類する。パッチ 1 番とパッチ 3 番、1 番と 4 番... に注目した場合も同様である。注目する 2 つのパッチを、 $(1 \rightarrow 2)$ のように方向で記述するとして、クラスタリングの方法は $(1 \rightarrow 2)$, $(1 \rightarrow 3)$, ... $(1 \rightarrow 9)$ の 8 通りある。この 8 通りについて全て重み学習を行う事で、 M_c^2 通りの重み付けを行える重み行列が 8 つ得られる。 ($W^{1 \rightarrow 2}, W^{1 \rightarrow 3}, \dots, W^{1 \rightarrow 9}$)

超解像のために重み付きスパース再構成を行う際には、これらの 8 通りの重み行列から 1 つの重み行列への変換を行う (図 4)。

$$W = f(W_{a,b}^{1 \rightarrow 2}, \dots, W_{a,i}^{1 \rightarrow 9}) = \frac{c_{a,b}^{1 \rightarrow 2} W_{a,b}^{1 \rightarrow 2} + c_{a,c}^{1 \rightarrow 3} W_{a,c}^{1 \rightarrow 3} + \dots + c_{a,i}^{1 \rightarrow 9} W_{a,i}^{1 \rightarrow 9}}{c_{a,b}^{1 \rightarrow 2} + c_{a,c}^{1 \rightarrow 3} + \dots + c_{a,i}^{1 \rightarrow 9}} \quad (13)$$

この式 13 は 8 つの重み行列の加重平均になっており、 $c_{a,b}^{1 \rightarrow 2}$ は 1 番と 2 番のパッチに注目してクラスタリングし重み学習した際の、クラスタ $C_{a,b}$ に分類されたデータベースパッチの個数である。すなわち、データベースをクラスタリングした時に多くのデータが集まるクラスタは重み行列の信頼度が高いとみなしている。

4. 実験

本章では、3 章で提案した 2 つの手法について実験を行い、性能を評価する。

表 2 実験で用いたパラメータ・データベース

辞書学習データベース	BSDS[3]Train+Test
重み学習データベース	BSDS[3]Train+Test
辞書学習パラメータ λ	0.1
重み学習パラメータ λ	0.1
重み学習パラメータ λ	0.00001
パッチの大きさ $\sqrt{n} \times \sqrt{n}$	16×16
辞書の基底個数 M	1024
クラスタリング辞書の基底個数 M_c	64

4.1 実験条件・調整パラメータ

実験は Kodak 画像データセット [5] の画像 24 枚をそれぞれブラー・ダウンサンプリングしたものに超解像処理を行う。超解像によって得られた再構成画像を真値と比較し PSNR を計算し、24 枚の平均 PSNR によって性能を評価する。

調整パラメータや学習用データベース、基底の個数などは表 2 にまとめている。

4.2 結果

まず、2 つの提案手法が従来のスパース再構成、重み付きスパース再構成よりも性能が向上していることを確認する。節 3.1 で説明した手法を提案手法 1、節 3.2 で説明した手法を提案手法 2 として、PSNR の計算結果を表 3 に示す。重み付きスパース再構成よりも、クラスタに応じて重みを変化させる提案手法 1、提案手法 2 の方が性能がよい。また、近傍のパッチも用いてクラスタリングする提案手法 2 は若干ではあるが更に性能がよいことが確認できる。

次に提案手法とその他の超解像手法との比較を行う。比較対象として、the new edge-directed interpolation (NEDI) [6], the direction filtering and data fusion interpolation (DFDF) [7], super resolution from single image (SRfSI) [8], the sparse mixing estimation interpolation (SME) [9], super resolution via sparse representation (ScSR) [10], の 5 つを選んだ。どの手法も一枚超解像手法として効果が高いと知られており、プログラムが公開されている。提案手法と比較手法の PSNR 計算結果を表 4 に示す。また、各手法における出力画像の一部を図 5 に載せている。画像を比較すると提案手法 2 は他に比べてオウムの目の周辺の縞模様ははっきり出ていることが確認できる。

5. おわりに

5.1 まとめ

本論文では、超解像を行う際にパッチをクラスタリングし、クラスタごとに異なる重み行列を用いてスパース再構成をする手法を提案した。クラスタリングでは中央のパッチのみを用いて行う方法も十分効果は得られるが、中央とその近傍のパッチの情報も用いてクラスタリングすることで更に性能が向上することが確認された。

いくつかの超解像手法との比較を行ったところ、提案手法は PSNR においても見た目においても優れており、十分な性能を持っていることが確認された。

5.2 今後の課題

今回は中央のパッチと近傍の 1 パッチの情報に基づいてクラスタリングを行った。周辺 8 近傍のパッチを使う場合、重み行列は 8 つ得られるが、本提案手法では単純にそれらを加重平均によって 1 つの重み行列に変換している。この加重平均によって重み行列の性質が少し複雑になってしまっていると考えられ、提案手法 1 からの大きな性能向上を目指すために、この重み行列の分析が必要であると感じている。また、加重平均による変換ではこれ以上いい結果が見込めない場合は、作成した 8 つの重み行列の別の利用方法を模索していく必要がある。

参考文献

- [1] Olshausen, B., Field, D. et al.: Sparse coding with an overcomplete basis set: A strategy employed by V1?, *Vision research*, Vol. 37, No. 23, pp. 3311–3326 (1997).
- [2] Elad, M. and Aharon, M.: Image denoising via sparse and redundant representations over learned dictionaries, *Image Processing, IEEE Transactions on*, Vol. 15, No. 12, pp. 3736–3745 (2006).
- [3] Martin, D., Fowlkes, C., Tal, D. and Malik, J.: A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics, *Computer Vision, 2001. ICCV 2001. Proceedings. Eighth IEEE International Conference on*, Vol. 2, IEEE, pp. 416–423 (2001).
- [4] Candes, E. J., Wakin, M. B. and Boyd, S. P.: Enhancing sparsity by reweighted ℓ_1 minimization, *Journal of Fourier Analysis and Applications*, Vol. 14, No. 5–6, pp. 877–905 (2008).
- [5] Franzen, R.: Kodak lossless true color image suite, see <http://r0k.us/graphics/kodak> (1999).
- [6] Li, X. and Orchard, M.: New edge-directed interpolation, *Image Processing, IEEE Transactions on*, Vol. 10, No. 10, pp. 1521–1527 (2001).
- [7] Zhang, L. and Wu, X.: An edge-guided image interpolation algorithm via directional filtering and data fusion, *Image Processing, IEEE Transactions on*, Vol. 15, No. 8, pp. 2226–2238 (2006).
- [8] Glasner, D., Bagon, S. and Irani, M.: Super-resolution from a single image, *Computer Vision, 2009 IEEE 12th International Conference on*, IEEE, pp. 349–356 (2009).
- [9] Mallat, S. and Yu, G.: Super-resolution with sparse mixing estimators, *Image Processing, IEEE Transactions on*, Vol. 19, No. 11, pp. 2889–2900 (2010).
- [10] Yang, J., Wright, J., Huang, T. and Ma, Y.: Image super-resolution via sparse representation, *Image Processing, IEEE Transactions on*, Vol. 19, No. 11, pp. 2861–2873 (2010).

表 3 Kodak 画像データセット (24 枚) の平均 PSNR[dB]

手法	スパース再構成	重み付きスパース再構成	提案手法 1	提案手法 2
PSNR [dB]	31.18	31.27	31.39	31.41

表 4 各手法における Kodak 画像データセット (24 枚) の平均 PSNR[dB]

手法	NEDI[6]	DFDF[7]	SRfSI[8]	SME[9]	ScSR[10]	提案手法 2
PSNR [dB]	29.81	30.33	30.27	30.91	30.57	31.41




図 5 Parrot 画像による比較