
複数の縮小基底辞書を用いたスパースコーディングに基づく 学習型超解像の高速化

High Speed Sparse-coding Superresolution by Using Multiple Segmented Basis Dictionaries

本橋 直樹* 中村 聡史* 鈴木 俊博**
Naoki MOTOHASHI Satoshi NAKAMURA Toshihiro SUZUKI

要 旨

一枚超解像は、低解像度画像の細部情報を他の画像から抽出した高周波成分を加えることで復元し、画質を改善する手法である。一枚超解像の中でも、学習型超解像（Example-based Superresolution: Example-based SR）は復元精度の高さから長年研究されてきた。特に、スパースコーディングを用いた手法（Sparse-coding Superresolution: ScSR）は失われた細部情報を正確に復元でき、かつ従来のExample-based SRに比べて処理時間を大幅に削減できることから盛んに研究されている。しかし、ScSRは未だに低速であり、実用化に向けて更なる高速化が求められている。この課題を解決するために本稿では、ScSRで使われる辞書を複数の縮小基底辞書に分割し、低解像度画像から抽出した入力パッチと辞書に含まれる基底とのマッチング回数を削減することで高速化する手法を提案する。実験により、提案手法は精度低下を最小限に抑制し、処理時間を1/2以下に短縮できることを示した。

ABSTRACT

Single-frame superresolution (single-frame SR) is a technique to improve the quality of low resolution images that restores lost fine details by adding high frequency components extracted from other images. In the field of single-frame SR, example-based superresolution (example-based SR) has been actively studied for many years because of its high restoration capability. Recently, example-based SR using sparse coding (ScSR) has become increasingly popular because it can restore the lost fine details accurately with a processing time that is significantly lower compared to that of the ordinary example-based SR. However, it is still necessary to accelerate the algorithm for practical use. To this end, we propose a new technique to accelerate the ScSR algorithm by splitting the dictionary used in ScSR into multiple sub-dictionaries to reduce the number of matchings between basis in the dictionary and input patches extracted from an input low resolution image. Our experimental results show that the proposed technique can reduce the processing time by more than 50% without compromising the restoration accuracy.

* リコーICT研究所 システム研究センター
System Research & Development Center, Ricoh Institute of Information and Communication Technology
** 画像エンジン開発本部 IIエンジン開発センター
Inkjet Engine Development Center, Imaging Engine Development Division

本稿は、電子情報通信学会に帰属の著作権の利用許諾を受け、2015年3月に開催されたIEICEスマートインフォメディアシステム研究会にて発表し（講演番号 SIS2014-106）、電子情報通信学会技術研究報告（IEICE Technical Report), Vol. 114, No. 496 (2014)に掲載した論文を基に作成した。

1. 背景と目的

近年のディスプレイなどの出力デバイスの性能向上に伴い、過去に撮影された画像を出力する機会が増加してきている。このような画像は、撮像素子の性能などの制約から解像度が低い場合があり、高解像度ディスプレイ等に出力しようとするときボケやジャギーを生じ、視覚的に不良になってしまう可能性があった。この問題に対して、従来は線形補間に代表される補間技術を用いて解像度を向上させてきたが、補間技術は拡大する際、不足している画素を参照元の元画像中に存在する複数画素の平均値などから算出するため、輝度変化が急峻なエッジ部が鈍り、拡大画像がボケてしまう問題があった。そこで、低解像度画像中に失われた高周波成分を復元し、より高精細な画像を生成する超解像技術が提案され、盛んに研究されている。

超解像技術の中でも、事前に学習した高解像度、低解像度パッチペアを保存した辞書を用いて低解像度画像中に欠損している高周波成分を推定する手法を学習型超解像 (Example-based Superresolution: Example-based SR) ^{1,2)} と呼ぶ。Example-based SRは入力画像を始めに既存の補間技術で拡大した後、この補間拡大画像からパッチと呼ばれる小画像領域を抽出し、辞書を探索することで最適なパッチペアを取得する。一般的に辞書の探索は全数探索で行われ、この処理を補間画像中の全パッチに対して行う。最終的に、前記処理によって得られた高解像度パッチを補間拡大画像に重畳していくことで一枚の高解像度画像を生成する。

Example-based SRは高拡大倍率での画像拡大に有効な手法であり、高い性能を示すことが報告されている。しかし、高い復元性能を得るためには多様なパッチを辞書に保存しておく必要があり、辞書サイズが大きくなるという問題がある。

そこで、複数のパッチから画像構造を抽象化した基底と呼ばれる成分を抽出し、それらを組み合わせることで高周波成分を生成するスパースコーディングに基づく学習型超解像 (Sparse-coding

Superresolution: ScSR) ³⁻⁵⁾ が提案された。Example-based SRでは、高い復元性能を得るためには数十万パッチペアを辞書に蓄積しておく必要があったが、ScSRでは、数百～数千程度の基底ペアでExample-based SRよりも高い復元性能が得られるという特徴を持つ。また、パッチを基底に分解しているため、復元精度が処理対象である入力画像の種類に依存しにくいという特徴を持っている。

しかし、パッチごとに近似に使用する基底の数だけ辞書を全数探索する必要があるため、依然として処理時間の問題は解消されていない。

そこで本稿では、ScSRをベースとし、基底辞書を、保存する基底ペア数がより少ない縮小基底辞書に分解して使用することで、入力パッチと辞書との照合回数を削減し、全体的な処理時間を短縮することを目的とする。

2. Sparse-coding Superresolution

Sparse-coding Superresolution (ScSR) の処理は、Fig. 1に示すようにオフラインで辞書を構築する学習段と、入力された低解像度画像を高解像度化する超解像段に分けることができる。

学習段では、任意の枚数の高解像度画像を用意し、これらを画像の観測モデル⁶⁾に基づき擬似的に劣化させることで同数の低解像度画像群を生成する。次に、これらの低解像度画像を元の画像サイズに拡大した補間拡大画像群を作成する。観測モデルは、実画像がカメラの撮像素子を通して生成される過程をフィルタ関数やダウンサンプリングを用いて模擬したもので、下記の式(1)で表すことができる。

$$I_L = (I_H * G) \downarrow_s \quad (1)$$

ここで、 I_L は観測画像、 I_H は観測される前の理想的な高解像度画像、 $*$ は畳み込み演算、 G はガウス関数などのボケを生成する点広がり関数、 \downarrow_s はダウンサンプリング処理をそれぞれ表している。

次に、低・高解像度画像の対応する位置から部分領域であるパッチを抽出し、複数のパッチペアを生成する。この時、パッチはそのまま使用するのではなく、周波数解析を行い、中・高周波パッチに変換する。ここで中周波パッチとは、低解像度パッチに含まれる周波数帯のうち、相対的に高い周波数成分のみを抽出したものを指す。さらに、ScSRでは、パッチを基底と呼ばれる抽象成分に分解して、中周波基底と高周波基底をペアとして蓄積した基底辞書を構築する。基底の生成方法は様々な手法が提案されているが、K-meansクラスタリングの応用であるK-SVD法⁷⁾が用いられることが多い。このようにして、複数の基底をペアとして辞書に蓄積する。

超解像段では、まず、入力画像である低解像度画像を補間技術で拡大する。次に、この補間拡大画像からパッチを抽出し、パッチ単位で超解像処理を行う。具体的には、入力パッチを線形近似するための中周波基底を辞書から複数個選択する。多くの基底群の中から少数個を選択するため、上記の処理はスパースコーディングと呼ばれる。スパースコーディングは下記の式(2)で定式化される。

$$\min \|x\|_0 \text{ s.t. } \|ax - b\|_2 \leq \varepsilon \quad (2)$$

ここで、 x は係数ベクトル、 a は基底行列、 b は入力パッチ、 ε は誤差の閾値をそれぞれ表している。スパースコーディングでは、入力パッチと基底を線形近似して生成されるパッチ間に生じる誤差のL2ノルムが閾値 ε に収まるように中周波基底と掛かる係数を決定する。また、L0ノルムが最小となる、つまり、選択する基底数ができるだけ少なくなるような組み合わせを探索するように制約をかける。この制約条件下で基底を選択するアルゴリズムには貪欲法的一种である直交マッチング追跡などが使用される。

このようにして入力パッチに対して、中周波基底と係数を決定した後は、選択された中周波基底とペアで蓄積してある高周波基底に同様の係数を掛け、これらの線形和で高周波パッチを生成する。最後に、

入力パッチを抽出した位置に対応するように高周波パッチを重畳していく。この処理を入力画像となる補間拡大画像の全パッチに対して行くと、一枚の高周波画像が生成される。通常、学習型超解像では復元結果の不連続性を解消するために隣接するパッチ間が数ピクセルオーバーラップするようにパッチを処理する。従って、高周波画像を生成する際には、パッチ同士の復元結果が重なることになる。多くの場合、重なった領域は、その重なり回数で平均することで最終的な高周波成分を算出する。

上記の処理で生成した高周波画像は、補間拡大画像中に失われた高周波成分を推定したものであるため、最後に補間拡大画像に加算することで復元結果である高解像度画像を得る。

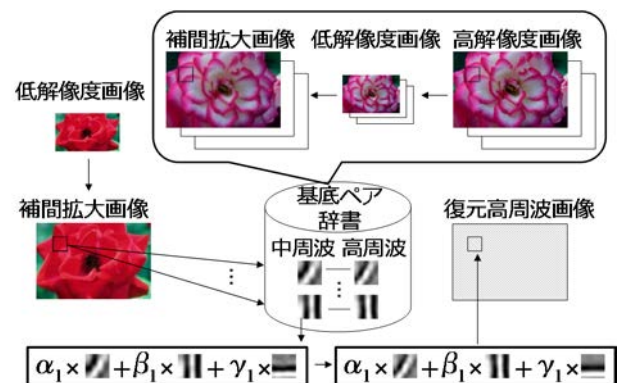


Fig. 1 Overview of Sparse-coding Superresolution.

3. 選択順序に着目した辞書分割

3-1 ScSRの問題点

ScSRは、パッチを基底に分解し、これらの組み合わせで入力パッチを線形近似するため、従来のExample-based SRよりも辞書サイズを縮小することが可能である。しかし、パッチごとに近似に使用する基底の数だけ辞書を全数探索する必要があるため、依然として処理時間がかかるという問題は解消されていない。そこで、基底の構造を解析し、辞書を複数の縮小基底辞書に分割して使用方法を提案する。具体的には、基底が選択される順序に着目し、

その選択順序に合わせた縮小基底辞書を元の辞書を用いて再構築する。従って、1つの基底を選択するために要する照合回数が削減されるため、全体的な処理時間を短縮することができる。以下で、提案手法について解説する。

3-2 基底の周波数と選択される順序の関係

基底は、複数のパッチの構造を分解した多次元ベクトルであるため、その種類は元となったパッチ群に依存する。その理由は、K-SVDのような教師なし学習で基底が構築されているため、初期値や構築する数によって種類が変わってくることが挙げられる。従って、超解像処理に適した基底と適さない基底が同時に構築される可能性がある。適さない基底とは例えば、ノイズとなる成分を多く含むものや、超解像処理に使用されにくいものを指している。本稿では、適さない基底を超解像処理に使用されにくいものと定義して以降で説明する。

まず、各基底が超解像処理でどの程度の頻度で選択されているのかを検証するために、以下の評価実験を行う。仮に、復元に適さない基底を知ることができれば、それらを辞書から除外することで、辞書サイズを縮小することができ、その結果、1つの基底を選択するために要する照合回数を削減することができる。

Fig. 2は、検証に使用したテスト画像とテスト画像以外の学習画像から生成した基底辞書（高周波基底のみ表記）である。基底数が256個の辞書に対して、テスト画像から抽出した6,152個のパッチを24個の基底を用いてそれぞれ線形近似する。なお、これ以降、線形近似に使用する基底の選択数を「スパースレベル」と表記する。例えば「スパースレベル3」と表記した場合、スパースコーディングで入力パッチを近似する時に、3つの基底を選択することを意味する。

Fig. 3は、スパースレベルを3と24にした時のある2つの基底A、Bの累積被参照回数を集計し、グラフ化したものである（256個あるうちの2つに着目した）。

ここで、横軸は各基底を、縦軸はスパースレベル3と24で基底を選択した時の基底A、Bの累積被参照回数を表している。この時、累積被参照回数の上限はテストパッチの総数6,152個である。スパースコーディングでは入力パッチの残差を減少させるために、残差を大きく減らす基底から順に選択される。従って、基底の選択には順序という概念が存在し、スパースレベルごとに累積被参照回数を調査することで、各基底がどの順序で参照されやすいかを知ることができる。Fig. 3より、基底ごとに、それぞれ使用される回数が多い順序があることが確認できる。例えば、基底Aはスパースレベル3での累積被参照回数は少ないが、スパースレベル24になるとその数は急激に伸びている。一方で、基底Bは、スパースレベル3での累積被参照回数は多いが（256個のうちで5番目に多かった）、スパースレベル24までの累積被参照回数の伸びは少ない。つまり、基底Aは選択順序が序盤に近い前半では使用される頻度が少なく、後半になってから多くのパッチの近似で使用されるようになっていくことが読み取れる。一方で、基底Bは、前半では多くのパッチの近似で使用されていたが、後半になってからその数は減少していることが読み取れる。評価実験では、Fig. 3の基底Aに示すように高周波成分を含んでいるものほど後半に使用される傾向があった。一方で、基底Bのように低周波成分を含んでいる基底ほど前半で参照される傾向が見られた。

以上より、基底には構造（周波数）によって参照されやすい選択順序があることが確認できた。換言すると、基底Aのような後半での累積被参照回数が多い基底は、前半では参照されづらいため照合をパスしても復元精度に悪影響を与えない可能性が高い。一方で、前半での累積被参照回数が多い基底は、後半での照合をパスすることが可能と推測できる。次節では、選択順序に着目した辞書の分割方法について説明する。




Fig. 2 Example of test image and basis image generated from other training images.




Fig. 3 Accumulated number of references in an ScSR test with 6,152 patches and 256 basis are used to compute the number of references. Basis A and B, at sparse-level 3 and 24 respectively.

3-3 基底辞書の分割

3-2での検証結果に基づき、選択順序に基づいた縮小基底辞書を再構築する手法を提案する。超解像段でスパースコーディングする際は、選択順序に応じて辞書を切り替えて使用する。例えば、スパースレベルが3の時は、1つ目の基底は、1番目に選択されやすい基底を蓄積した辞書から選択し、2つ目の基底は、2番目に選択されやすい基底を蓄積した辞書から選択する。このようにスパースレベルに応じて、事前にスパースレベル分の縮小基底辞書を構築しておく。提案手法により、各順序において使用されづらい基底との照合を回避することができるため、復元精度を維持した状態で、処理時間を短縮することが可能となる。

Fig. 4は、従来手法と提案手法の違いを例示した図である。従来手法では、1つの辞書からスパースレベルに相当する数の基底を全数探索で選択していたが、提案手法では、分割した縮小基底辞書から1つずつ基底を選択する。この場合、従来手法では、基底数が1,000の辞書を用いてスパースレベル3の超解像処理をすると、1つのパッチの照合には $1,000 + 999 + 998$ の処理コストがかかる。一方で、提案手法によって、例えば、基底数が300の縮小基底辞書を使用して、選択順序に従って基底辞書を切り替えて使用すると、照合回数は $300 + 300 + 300$ で済む。

次に、辞書を分割する方法について説明する。辞書の分割は、評価パッチを実際にスパースコーディングした結果に基づいて行う。この時、評価パッチは汎用性の観点から多様なカテゴリの画像から抽出したパッチを用いる。Fig. 5は辞書の分割方法を例示した図である。実際には、基底辞書のサイズは、数百から数千程度になるが、ここでは仕組みを説明するために、元の基底辞書のサイズは4であることを前提とする。また、評価パッチ数は3、分割後の縮小基底辞書数となるスパースレベルは2、前記縮小基底辞書に蓄積する基底ペア数は2と設定する。これらのパラメータに関しても、実際には実験環境に応じて決定する。提案手法では、まず、3個の評価用パッチを、前記基底辞書を使ってスパースコーディングする。その結果、パッチごとに各選択順序(1, 2)における被参照中周波基底と掛かる係数(α , β)が決定する。次に、前記結果に基づき、スパースコーディングで参照された基底を選択順序ごとに被参照回数が多い順にソートし、選択順序ごとに被参照回数が多い中周波基底を決定する。最後に、選択順序ごとに被参照回数が多かった上位2個の中周波基底と対応する高周波基底をペアとして縮小基底辞書に蓄積する。この方法に従うと、各縮小基底辞書間で同様の基底が含まれる可能性があるが、1つの基底は1つの選択順序でのみ使用されとは限らないため、同じ基底が異なる縮小基底辞書に含まれることを許容する。

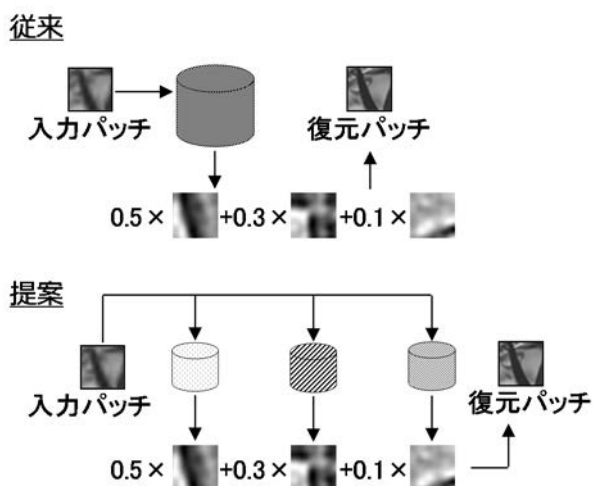


Fig. 4 Comparison between conventional method (single dictionary) and proposed multiple sub-dictionary based method.

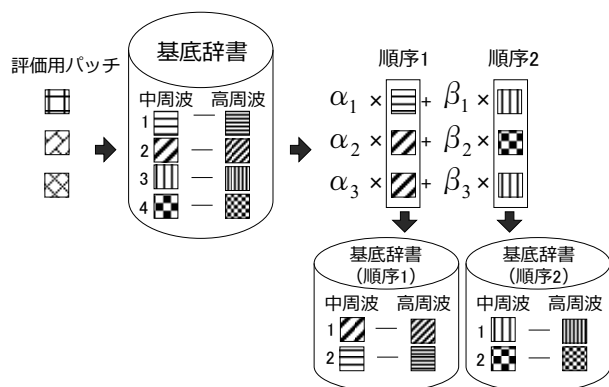


Fig. 5 Construction procedure of sub-dictionaries. Basis are selected based on their frequency of use in each sparse-level.

4. 実験と検証

4-1 実験概要

提案手法の有効性を検証するため、従来手法との比較実験を行う。

学習段では、Berkeley Segmentation Dataset⁸⁾から選択した16枚を用いて基底辞書を構築する (Fig. 6)。ここで、拡大倍率は2倍に固定し、パッチサイズを9×9、学習画像から抽出するパッチの総数は65,728個とした。辞書はK-SVD法⁵⁾を使用し、係数と基底の更新を40回繰り返して、1,024個の基底を構築した。

また、処理時間を高速化するために学習パッチに対して主成分分析を適用し、学習段で算出した固有値ベクトルと平均ベクトルは辞書と一緒に記憶しておく。超解像段では、入力画像から抽出したパッチをこれらのベクトルで主成分空間に射影してから使用する。本実験では、学習パッチ間の表現力を表す累積寄与率を99.9%に設定した。

超解像段では、同データセットの画像を含む20枚のテスト画像を、1/2倍にダウンサンプリングして入力画像とした上で、各入力画像の超解像処理に要する処理時間と復元精度を比較した (Fig. 7)。

パッチサイズは学習段と同様であり、パッチを抽出する間隔は2ピクセルとした。従って、隣接するパッチ間は7ピクセル分オーバーラップすることになる。重なった領域に関しては、重なった回数で復元した高周波成分を平均して最終的な値とした。また、スパースコーディングには、貪欲法である直交マッチング追跡を使用した。スパースレベルは1, 2, 3, 4, 5, 7, 9, 12, 20の9パターンで実験を行った。

評価は客観評価で用いられるPSNRで行い、補間技術であるバイキュービック補間と従来のScSRとを比較した。

次に、評価対象として4種類の基底辞書を構築する。まず、上記で構築した基底数が1,024個の辞書を辞書Aとして、本実験における評価基準とする。次に、辞書Bでは、辞書Aの30%に相当する基底数を蓄積した辞書を65,728個のパッチから構築する。辞書Cは、辞書Aをベースに提案手法を用いて構築した縮小基底辞書であり、辞書Bと同サイズになる。辞書Bと辞書Cの違いは、前者が一度に一定数の基底を構築するのに対し、後者は、最初に多くの基底を構築した後、その中から、一定数の基底を選択した縮小基底辞書を複数個構築する点である。最後に、辞書Dは、辞書Aからランダムに基底を選択し、辞書Cと同数、同サイズの縮小基底辞書を構築する。辞書Dは、選択順序に基づく基底選択の有効性を検証するために使用する。



Fig. 6 Example of training images.




Fig. 7 Example of test images.

4-2 実験結果

Fig. 8は、20枚のテスト画像のPSNR平均を、Fig. 9は同テスト画像を処理する際に要した処理時間平均をスパースレベルごとに各辞書に対して算出したものである。実験結果より、辞書Aの復元精度を最大値とし、辞書C、D、Bの順に精度が減少する傾向が確認された。特に、スパースレベルが5の時に、提案手法を用いて構築した辞書Cでは復元精度の減少を最小限に抑制し、2倍以上の高速化を達成した。また、辞書B、Dと同程度の処理時間で、より高精度を達成できていることから、提案手法が有効であることを確認できた。前記結果となった理由は、辞書Cに含まれる基底の種類が辞書B、Dと比較して多いことが挙げられる。分割後の辞書サイズを辞書Aの30%、スパースレベルを20に固定した場合、20個の縮小基底辞書に含まれる重複分を除外した時の

基底の種類をカウントすると、辞書Cで590種類、辞書Dで468種類であった。また、辞書Aは上記辞書作成時のベースとなる辞書であり1,024種類の基底を含み、辞書Bは辞書Aの30%分に当たる307種類の基底を含んでいる。従って、辞書Bの基底の種類が最少となる。また、辞書CとDを比較した場合、差異は選択順序を考慮して辞書を分割しているか、ランダムに選択しているかという点にある。辞書Dは辞書Aから基底をランダムに選択しているため、重複した基底が縮小基底辞書間で出現する確率が高い。一方で、辞書Cは前半で特に使用されやすい基底は、後半の辞書には含まれず、また、逆も成立するため、縮小基底辞書全体で見ると、種類は最も多くなる。上記のような理由から選択順序を考慮して縮小基底辞書を構築する提案手法は、復元精度と処理時間の両面で有効である。

ここで、辞書Cにおいて、1番目と20番目に使用される縮小基底辞書の一部をFig. 10にそれぞれ示す。図示するように、前半で使用される基底は、相対的に低周波なものとなっており、後半で使用される基底は前半と比較して高周波なものとなっていることがわかる。これはスパースコーディングに使用した直交マッチング追跡の性質によるものと言える。このアルゴリズムは、残差の削減量が最も多い基底から順に選択される。つまり、基底が選択される順序としては、おおまかに構造を近似できる低周波なものが前半に選択され、後半になると近似しきれなかった微細構造を近似するためにより高周波な基底が選択される。

さらに、処理時間について考察する。実験にはスペックがCore i5-2400 CPU @3.1GHz、実装メモリ4 GB、OS64ビット（Windows7）であるPCを使用した。Fig. 9では、基底辞書のサイズは元の30%に縮小されているにも関わらず、処理コストが削減された割合は50%程度であった。これは、Fig. 11に示すように、辞書の全数探索に要する時間は1/3になっているにも関わらず、係数と残差の更新に多くの処理時間がかかっているためである。直交マッチング追跡では、基底が1つ選択される度に、それまでに

決定された係数を破棄し、新規追加された基底を含めて、係数を再計算する処理が含まれる。提案手法は、この更新部の処理コスト削減には寄与しないため、全体での処理時間の削減量は少なかった。

最後に、辞書サイズを元の辞書の30%でかつ、スパースレベル5で超解像した時の結果画像の一例をFig. 12に示す。これらの図は左から順に、元画像（Ground Truth）、Ground Truthを1/2に縮小し、バイキュービック補間で2倍に拡大した補間拡大画像、補間拡大画像を従来の基底辞書で超解像した復元画像、補間拡大画像を提案手法で拡大した復元画像をそれぞれ示している。この図に示すように、提案手法は従来のScSRと視覚的に殆ど差異がなく、かつバイキュービック補間で拡大した時よりも高精細な画像に復元できていることがわかる。

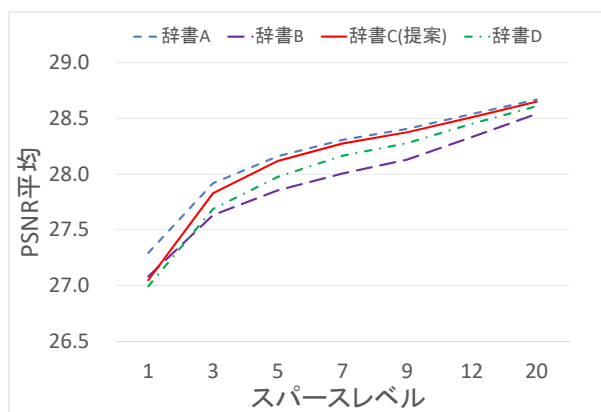


Fig. 8 PSNR of four methods at each sparse-level.




Fig. 9 Processing time of four methods at each sparse-level.


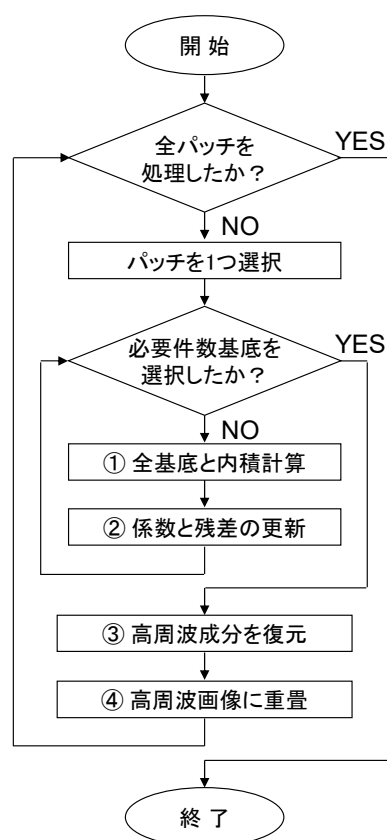


Fig. 10 Comparison between components / elements of sub-dictionaries. Sub-dictionary 1 with 1st -selected-basis (left) and Sub-dictionary 20 with 20th-selected-basis (right).



	分割前 [Sec]	分割後 [Sec]
①	65.80	<u>19.30</u>
②	19.70	19.00
③	0.14	0.20
④	0.01	0.01
計	85.80	38.70

Fig. 11 Processing flow (top) and processing time of each steps (bottom).



Fig. 12 Example of test images.

5. 結論

本稿では、基底のスパースコーディングに基づく学習型超解像を高速化する手法として、辞書を基底が選択される順序に基づいて縮小基底辞書に分割する手法を提案した。具体的には、評価パッチを事前に作成した基底群に割り当てて、各選択順序で被参照回数が多い上位30%分の基底を抽出し、選択順序に適応的な縮小基底辞書をスパースレベル分構築した。実験では、選択順序に応じて使用する辞書を切り替えて使用することで、辞書サイズを元の1/3に縮小しても、スパースレベル5以上で超解像処理することで、元の辞書を使用した場合と同等の復元性能が得られ、かつ、処理時間を1/2以下に短縮できることを示した。今後の課題としては、基底の分析方法の検討が挙げられる。本稿では、単純に評価パッチを事前に構築した基底に割り当てることで辞書の分割を行った。今後は、周波数解析等を行い、各選択順序で使用されやすい基底の種類を定量的に評価する必要がある。

参考文献

- 1) W. T. Freeman, T. R. Jones, E. C. Pasztor: Example-based Super-Resolution, *IEEE Computer Graphics and Applications*, Vol. 22, No. 2, pp. 56-65 (2002).
- 2) W. T. Freeman, E. C. Pasztor, O. T. Carmichael: Learning Low-Level Vision, *Proceedings of the Seventh IEEE International Conference on*, Vol. 2, pp. 1182-1189 (1999).
- 3) J. Yang et al.: Image super-resolution as sparse representation of raw image patches, *Proc. IEEE Conference on Computer Vision Pattern Recognition*, pp. 1-8 (2008).
- 4) J. Yang et al.: Image Super-Resolution Via Sparse Representation, *Proc. Image Processing, IEEE Transactions on*, pp. 2861-2873 (2010).
- 5) R. Zeyde et al.: On single image scale-up using sparse-representations, *Proceedings of the 7th international conference on Curves and Surfaces*, pp. 711-730 (2012).
- 6) S. Dai et al.: SoftCuts: A soft edge smoothness prior for color image super-resolution, *IEEE Transactions on Image Processing*, Vol. 18, No. 5, pp. 969-981 (2009).

- 7) M. Aharon, M. Elad, A. Bruckstein: K-SVD: An Algorithm for Designing Overcomplete Dictionaries for Sparse Representation, *IEEE Transactions on Signal Processing*, Vol. 54, No. 11, pp. 4311-4322 (2006).
- 8) D. Martin et al.: 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, pp. 419-423 (2001).

注1) Core i5はIntel Inc.の商標です.

注2) Windows7はMicrosoft Corp.の商標です.