

大画像の複層ベイズ超解像と位置ずれ推定に関する検討

木下 俊貴¹ 三好 誠司^{2,a)}

受付日 2013年1月30日, 再受付日 2013年3月5日,
採録日 2013年3月27日

概要: 超解像とは低解像画像から高解像画像を推定する技術である。本論文では、画像を分割することにより、Kanemura らによる複層ベイズ超解像を大画像に適用する。これを実現するために回転の中心を一般化する手法を導入する。これにより、画素値に大きな変化がある領域を位置ずれパラメータの推定に用いることが可能となる。さらに、どの小領域に対しても回転を適用することが可能となり、大画像においても良好な高解像画像の推定が可能となる。

キーワード: 超解像, ベイズ推定, 複層マルコフ確率場, 変分 EM アルゴリズム

Bayesian Super-resolution of Large Image with a Compound MRF and Estimating Registration Parameters

TOSHIKI KINOSHITA¹ SEIJI MIYOSHI^{2,a)}

Received: January 30, 2013, Revised: March 5, 2013,
Accepted: March 27, 2013

Abstract: Super-resolution is a technique to estimate a higher resolution image from low-resolution images. In this paper, we apply Bayesian super-resolution using latent variables proposed by Kanemura et al. to large images. To achieve this, we introduce a method that generalizes the center of rotation. This method allows good estimation of registration parameters by using the area which has a large change of pixel values. Furthermore, we can obtain a good estimated image because we can apply an accurate rotation to any small areas.

Keywords: super-resolution, Bayesian inference, compound Markov random field prior, variational EM algorithm

1. はじめに

超解像とは、低解像画像から高解像画像を推定する手法である [1], [2]。近年ではこの超解像技術を搭載した液晶テレビやデジタルカメラといった製品が登場し、広く知られるようになった。超解像には、1枚の低解像画像から1枚の高解像画像を推定する手法 [3], [4] と、複数枚の低解像画像から1枚の高解像画像を推定する手法 [5], [6], [7], [8], [9] があるが、本論文では後者を扱う。Tipping ら [6] はベ

イズ推定に基づく超解像であるベイズ超解像を提案した。しかし、Tipping らは、画像のなめらかさを表現するために、事前分布として隣り合う画素間にガウス分布を仮定しているため、画像中のエッジの表現が難しくなるという問題があった。Kanemura ら [7] はこの問題を解決するため複層ベイズ超解像を提案した。複層ベイズ超解像においてはラインプロセス [14] を導入することにより画像中のエッジを表現する。これらは、位置ずれパラメータの推定については周辺尤度の最大化による最尤推定、つまり点推定を行っている。この点推定による影響は事前分布や観測モデルで複雑なモデルを扱う際や、観測の信頼度が低い場合の推定において大きな問題となる可能性があった [8]。これを解決するため、Katsuki ら [8] は位置ずれパラメータと高解像画像、さらにハイパーパラメータをも含めて全変数を同時にベイズ推定する手法を提案した。また最近では、事前分

¹ 関西大学大学院理工学研究科
Graduate School of Science and Engineering, Kansai University, Suita, Osaka 564-8680, Japan

² 関西大学システム理工学部
Faculty of Engineering Science, Kansai University, Suita, Osaka 564-8680, Japan

a) miyoshi@kansai-u.ac.jp

布にガウス分布ではなく TV (Total Variation) を用いた分布を用いることで、隠れ変数を導入することなくエッジを表現する超解像の研究も行われている [9].

Kanemura ら [7] や Katsuki ら [8] の研究では必要メモリ量や計算量の都合上、 40×40 px 程度の小さな画像しか扱えていない。超解像技術の応用を考えた場合、より大きな画像を扱う必要がある。そこで本論文では、画像を小領域に分割することにより、大画像に対する複層ベイズ超解像を実現する。大画像を小領域に分割して超解像処理を行う場合、画像の中心部が画素値の変化に乏しい可能性も考えられる。その場合、位置ずれの変化が検出できなくなるため、良好な位置ずれパラメータの推定が困難となり、高解像画像の推定にも影響を及ぼすことが考えられる。また、高解像画像の推定において、画像の中心部にある小領域の回転も、画像の外側にある小領域の回転も正確に表現する必要がある。Kanemura ら [7] や Katsuki ら [8] の手法においては、画像を分割して処理することは考慮されていないため、そのままでは画像の外側の小領域の回転を正確に表現できない。そのため本論文では、位置ずれパラメータの推定処理と高解像画像の推定処理において、回転の中心の一般化も導入する [6], [10]。最後に、提案した手法について様々な画像を用いて実験を行い、性能評価を行う。

2. 複層ベイズ超解像と回転中心の一般化

本章では、Katsuki らによる観測画像の生成モデル [8] と、Kanemura らによる複層ベイズ超解像 [7] の原理について簡単に説明する。また、次章以降で述べる大画像の超解像処理において必要となる回転中心の一般化についても述べる。まず、観測画像の生成モデルについて説明する。高解像画像の推定に用いる観測画像は、原画像に平行移動、回転、ボケ、正規ノイズの重畳が加わり、 T 枚の観測画像が観測されるとする。 t 枚目の観測画像の生成モデルはまず、画素数が N の原画像を角度 θ_t だけ回転させ、 \vec{o}_t 方向に (横方向に $[\vec{o}_t]_x$ px, 縦方向に $[\vec{o}_t]_y$ px) 平行移動させる。次に、平均 $\mathbf{0}$ 、共分散 $\gamma_t^{-1} \mathbf{I}$ である二次元正規分布に従って周辺のピクセルの輝度値を混ぜ合わせてボケを作り、拡大率 $\alpha (> 1)$ によって解像度を低下させ、最後にこの画像の各画素に平均 0 、分散 β^{-1} の正規ノイズが独立に加わるものとする。原画像を \mathbf{x} と表す。観測画像は T 枚得られているとし、各々を \mathbf{y}_t ($t = 1, \dots, T$) と表す。また T 枚の観測画像をまとめて $\mathcal{D} \equiv \{\mathbf{y}_t\}$ とする。位置ずれパラメータを $\phi_t \equiv [\theta_t, [\vec{o}_t]_x, [\vec{o}_t]_y]^T$ とし、観測画像 T 枚の位置ずれパラメータをまとめて $\Phi \equiv \{\phi_t\}$ 、このパラメータを基に作られる変換行列を $\mathbf{W}(\phi_t)$ 、正規ノイズを ϵ とすると、観測モデルは

$$\mathbf{y}_t = \mathbf{W}(\phi_t) \mathbf{x} + \epsilon \quad (1)$$

となる。変換行列の i 行 j 列要素は

$$\begin{aligned} \mathbf{W}(\phi_t)_{i,j} & \equiv \frac{\frac{\gamma_t}{2\pi} \exp\left(-\frac{\gamma_t}{2} \|\vec{k}\|^2\right)}{\vartheta_3\left(\pi \vec{k}_x, \exp\left(-\frac{2\pi^2}{\gamma_t}\right)\right) \vartheta_3\left(\pi \vec{k}_y, \exp\left(-\frac{2\pi^2}{\gamma_t}\right)\right)}, \end{aligned} \quad (2)$$

$$\begin{aligned} \vec{k} & \equiv \begin{bmatrix} \cos(-\theta_t) & -\sin(-\theta_t) \\ \sin(-\theta_t) & \cos(-\theta_t) \end{bmatrix} (\alpha \vec{i} - \vec{o} - \vec{c}) - \vec{j} + \vec{c}, \end{aligned} \quad (3)$$

$$\vartheta_3(u, q) \equiv 1 + 2 \sum_{n=1}^{\infty} q^{n^2} \cos(2nu) \quad (4)$$

である。ここで、 \vec{j} は原画像の j 番目の画素の座標、 \vec{i} は観測画像の i 番目の画素の座標である。また ϑ_3 は楕円シーク関数と呼ばれる関数で離散サンプリングを行う場合の正規化定数として用いている。 \vec{c} は各小領域の中心を基準とした場合の回転中心の座標を表している [6]。このように、Katsuki らの変換行列に対して \vec{c} を導入することにより回転の中心を一般化している。これは、大画像を小領域に分割して処理を行う場合や画像の中心以外的小領域を用いて位置ずれパラメータを推定する際に必要となる。また、この \vec{c} により画像の中心部以外的小領域に対して、適切な回転を適用することができる。

次に高解像画像の推定手法について説明する。ベイズ超解像 [6] では、画像のなめらかさを表現するために事前分布にガウス分布を仮定していたため、エッジの表現が困難であった。そこで Kanemura らは事前分布にラインプロセス [14] を導入することで、ベイズ超解像でのエッジの表現を可能にした。ラインプロセスとは、隣接する画素 i と j の間に、エッジを表現する 2 値の隠れ変数 $\eta_{i,j} \in \{0, 1\}$ を導入することにより表現される。ここで $\boldsymbol{\eta} \equiv \{\eta_{i,j}\}$ (i, j は隣接する画素) とする。ベイズ超解像では、高解像画像と位置ずれパラメータの両方を推定する必要がある。そこで、変分 EM アルゴリズム [12], [13] を導入する。変分 EM アルゴリズムは E ステップと M ステップの 2 つのステップからなる。E ステップでは高解像画像の事後分布

$$p(\mathbf{x}|\mathcal{D}, \Phi) = \sum_{\boldsymbol{\eta}} p(\boldsymbol{\eta}, \mathbf{x}|\mathcal{D}, \Phi) \quad (5)$$

を計算し、M ステップでは位置ずれパラメータを周辺尤度最大化

$$\hat{\Phi} = \arg \max_{\Phi} L(\Phi) \quad (6)$$

によって推定する。ここで L は周辺尤度の対数

$$L(\Phi) = \ln \int d\mathbf{x} p(\mathbf{x}) p(\mathcal{D}|\mathbf{x}, \Phi) \quad (7)$$

である。隠れ変数の導入による高解像画像の事後分布 $p(\boldsymbol{\eta}, \mathbf{x}|\mathcal{D}, \Phi)$ の計算困難性を回避するため、事後分布を近

似する試験分布 $q(\boldsymbol{\eta}, \boldsymbol{x})$ を導入し、自由エネルギー

$$F(q, \Phi) = - \sum_{\boldsymbol{\eta}} \int d\boldsymbol{x} q(\boldsymbol{\eta}, \boldsymbol{x}) \ln \frac{p(\boldsymbol{\eta}, \boldsymbol{x}, \mathcal{D} | \Phi)}{q(\boldsymbol{\eta}, \boldsymbol{x})} \quad (8)$$

$$= -L(\Phi) + D_{\text{KL}}(q(\boldsymbol{\eta}, \boldsymbol{x}) \| p(\boldsymbol{\eta}, \boldsymbol{x} | \mathcal{D}, \Phi)) \quad (9)$$

を最小化する $q(\boldsymbol{\eta}, \boldsymbol{x})$ を求める. この F は関数 q の汎関数であると同時に、パラメータ Φ の関数でもある. ここで、 L は式 (7) で定義された対数周辺尤度である. また、 D_{KL} は試験分布 $q(\boldsymbol{\eta}, \boldsymbol{x})$ と真の事後分布 $p(\boldsymbol{\eta}, \boldsymbol{x} | \mathcal{D}, \phi)$ との間の KL (カルバック・ライブラ) 擬距離である. KL 擬距離は、つねに $D_{\text{KL}}(q \| p) \geq 0$ であり、 $D_{\text{KL}}(q \| p) = 0$ となるのは q と p が等しいときのみであるという性質を持つ. 式 (9) において、 $L(\Phi)$ が q に対しては定数であることに注意すると、 F を q について最小化することは、KL 擬距離が最小という意味で事後分布 p に最も近い試験分布 q を探すことに対応する. 一方、 F を Φ について最小化することを考えると、 $-L$ の上界の最小化、すなわち L の下界の最大化に帰着し、したがって式 (6) による位置パラメータの推定値 $\hat{\Phi}$ が得られることになる. F の q に関する最小化が E ステップに、 Φ に関する最小化が M ステップに対応する. q を任意の分布から最適化すると、真の事後分布を求めることにはなるが、これは計算困難である. そこで、試験分布の関数形を

$$q(\boldsymbol{\eta}, \boldsymbol{x}) = q(\boldsymbol{x}) \prod_{i \sim j} q(\eta_{i,j}) \quad (10)$$

と因子化された形に制限する. ここで $i \sim j$ は、画素 i, j が隣接していることを意味する. この E ステップと M ステップを収束するまで繰り返し、収束後の事後分布の平均値が高解像画像の推定値となる.

次に回転中心の一般化について説明する. M ステップにおいては F の Φ に関する最小化を正規化共役勾配法 [15] を用いて数値的に実行する. その際、式 (2)~(4) の変換行列を用いる. 1 章でも述べたとおり、画像の中心と回転の中心が一致している場合を扱おうと、図 1 のように、回転の中心である領域が画素値の変化に乏しい場合、平行移動や回転といった位置ずれを正確に検出するための特徴がなく、位置ずれパラメータの推定の精度が劣化する可能性がある. そのため、回転の中心以外の場所でも位置ずれパラメータの推定を行う必要がある. ここでは、すでに述べた回転の中心を一般化した式 (3) を位置ずれパラメータの推定処理にも用いることで、回転の中心以外の場所での位置ずれパラメータの推定を実現する.

3. 画像分割による大画像の複層ベイズ超解像

1 章でも触れたように、Kanemura ら [7], [11] の研究では 40×40 px 程度の小さな画像しか扱えていなかった. 本論文では、より大きな画像を扱える手法を提案する. ベイズ超解像の処理の中では画素数を行数とする行列を扱うた

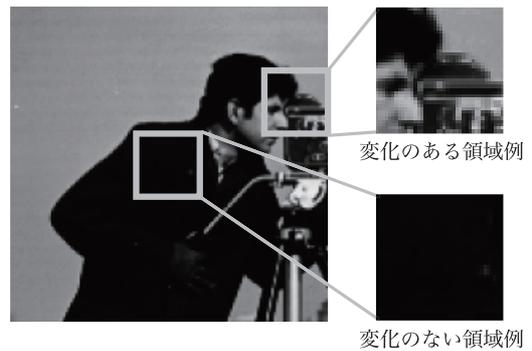


図 1 画像の中心部に変化がない場合の例. 画像中央の枠線は従来推定に用いていた回転の中心の領域を表している. この場合、中心の領域は黒一色なので、良好な位置ずれ推定ができない

Fig. 1 Example of image that has poor variance of pixel values in the center area of the image. Flame border of the center area indicates the center area that has been conventionally used to estimate the registration parameters. In this case, we can not obtain a good estimation of registration parameters because that area is almost black.

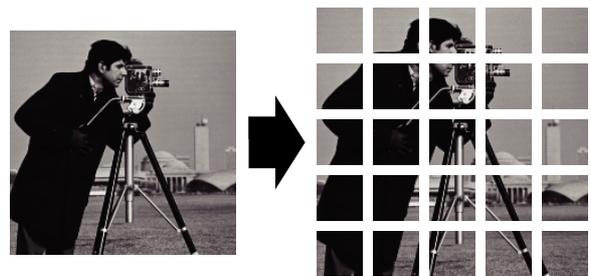


図 2 大画像の小領域への分割

Fig. 2 Dividing a large image into small areas.

め、必要なメモリ量は画素数の 2 乗に比例する. またその行列の逆行列計算が入っているため、必要な計算量は画像の 1 辺の 6 乗に比例する. よってメモリ量と計算量の観点から、そのままでは大画像を処理できないため、大画像を小領域に分割することによって、大画像の超解像処理を実現する.

小領域への分割について説明する. まず大画像を図 2 のように小領域に分割し、1 つの小領域を用いて変分 EM アルゴリズムで位置ずれパラメータの推定を行う. その後、位置ずれパラメータの推定結果を用いて大きな画像を推定する. その際、推定した位置ずれパラメータを用いて各領域に平行移動と回転を適用するが、その場合、図 3 のように、出力する画像中に画像とは関係のない部分が入り込んでしまう. これは、推定画像に悪影響を及ぼす可能性がある. そのため、図 4 のように小領域を大きめに切り出し、位置ずれの復元を行う. これにより、隣の領域と重複した部分が生じるため、各領域の連続性も保たれることになる. 最終的に、1 枚の大画像にする際には枠線の外部を切り落とす. また、大画像を小領域に分割して処理を行う際、画

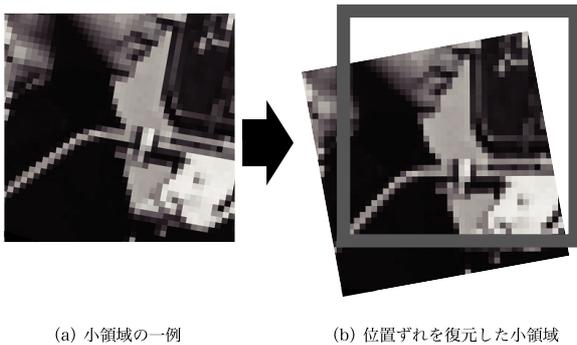


図 3 小領域への位置ずれの適用. 枠線は実際に画像として出力される領域を表している. また, 枠線内の白い部分は画像とは関係のない部分を表している

Fig. 3 Applying position gap to a small area. Flame border indicates the actual output image. White area in the flame border indicates the unrelated part.

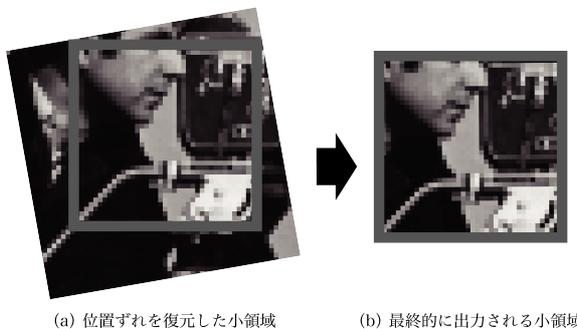


図 4 大きめに切り出した小領域への位置ずれの適用

Fig. 4 Applying position gap to a small area clipped largely.

像の中心部以外での回転の中心の取扱いに注意する必要がある. この点に関しては, 回転中心が一般化された式 (3) を用いることにより, 画像の中心部以外の小領域に対しても, 大画像での回転の中心を原点とした正確な回転を適用することが可能となる.

4. 実験

4.1 分割時のオーバーラップの効果

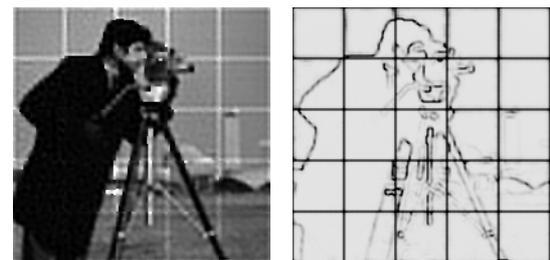
まず, 小領域に分割して大画像を推定する際の小領域をオーバーラップさせる量を変化させた実験を行う. 実験は, 図 5 (a) の原画像から, 以下の条件で位置ずれがそれぞれ異なる 4 枚の観測画像を作成し, その観測画像だけを用いて高解像画像の推定を行う. 実験の条件は, 拡大率 $\alpha = 4$ 倍, 平行移動量は高解像画像換算で縦および横に $-0.5 \sim 0.5$ px の一様乱数で生成, 回転量は $-0.5\pi/180 \sim 0.5\pi/180$ rad で生成, 観測ノイズは SN 比が 30 dB のガウスノイズ, ボケは標準偏差 1.5 px のガウス型点広がり関数によって生成した. ここで SN 比とは, 画像の画素値の分散とそれに重畳するノイズの分散の比である. また, 大画像を 25 の小領域に分割 (1 つの領域の大きさは低解像画像で 10×10 px) した. 図 5 (b) に観測画像の例を示す. ここでは, 同じ位



(a) 原画像 (200×200 px) (b) 観測画像例 (50×50 px)

図 5 原画像と観測画像の例 (Cameraman)

Fig. 5 Original image and an example of observed image (Cameraman).



(a) 推定画像 (b) 隠れ変数の推定値

図 6 領域間の重複がない場合の結果 (Cameraman, 200 × 200 px)

Fig. 6 Result with no overlap between areas (Cameraman, 200 × 200 px).

置ずれパラメータを持つ 1 つのセットについて, オーバラップがない小領域と, 低解像画像換算で上下左右それぞれ 2 px のオーバーラップがある小領域の, 2 種類の実験を行い, ISNR をそれぞれ計算した. ここで ISNR とは, 画質を最小二乗誤差を基に比較するための指標で, たとえば, 正解の原画像を \mathbf{x}^* , 基準となる画像を $\tilde{\mathbf{x}}$, 評価したい推定手法による推定画像を $\hat{\mathbf{x}}$ とすると,

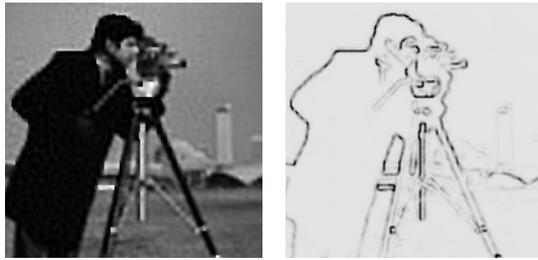
$$\text{ISNR} \equiv 10 \log_{10} \frac{\|\tilde{\mathbf{x}} - \mathbf{x}^*\|^2}{\|\hat{\mathbf{x}} - \mathbf{x}^*\|^2} \quad (11)$$

で定義される. 今回は, 基準となる画像として, 超解像に用いる複数枚の観測画像の平均画像を用いて, 提案手法を評価した.

観測画像を 4 枚用いた場合の実験結果を図 6 と図 7 に示す. 図 6 より小領域間にオーバーラップがない場合, 小領域の境界に白い線が発生していることが分かる. この場合の ISNR は 1.36 dB であった. これに対して図 7 より, 2 px のオーバーラップがある場合では小領域の境界での白い線がなくなり, 各領域が違和感なくつながった良好な高解像画像を推定できていることが分かる. この場合の ISNR は 2.78 dB と向上している. よって, オーバラップを設けることで, 大きな画像を小領域に分割して超解像を行った際でも良好に推定できることが分かる.

4.2 中央小領域の特徴が豊かな場合

3 章で述べた大画像の複層ベイズ超解像について, 観測画



(a) 推定画像 (b) 隠れ変数の推定値

図 7 領域間の重複を 2px 設けた場合の結果 (Cameraman, 200 × 200 px)

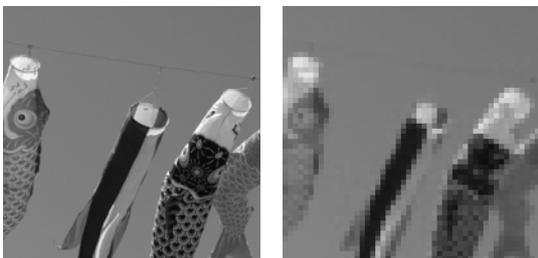
Fig. 7 Result with 2 px overlap between areas (Cameraman, 200 × 200 px).



(a) 原画像 (200×200 px) (b) 観測画像例 (50×50 px)

図 8 原画像と観測画像の例 (Lenna)

Fig. 8 Original image and an example of observed image (Lenna).

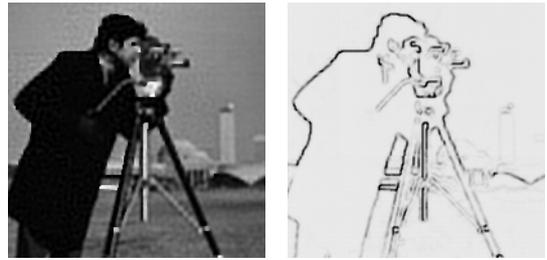


(a) 原画像 (200×200 px) (b) 観測画像例 (50×50 px)

図 9 原画像と観測画像の例 (Koi)

Fig. 9 Original image and an example of observed image (Koi).

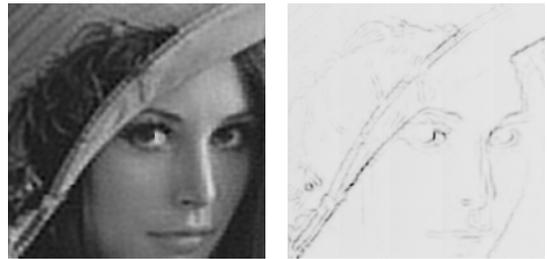
像の枚数, 観測画像の生成に用いる位置ずれパラメータを変化させて実験を行い, 性能評価を行う. 実験は, 4.1 節で用いた図 5(a) の原画像と新たに 2 種類の原画像, 図 8(a), 図 9(b) から, 位置ずれがそれぞれ異なる複数枚の観測画像を生成し, その観測画像だけを用いて高解像画像の推定を行う. その際の位置ずれパラメータの推定は, 3 章でも述べたように 25 個の小領域のうちの 1 つを用いて行う. ここで用いる 3 種類の原画像, 図 5(a), 図 8(a), 図 9(a) はいずれもその中心部は特徴が豊かであるので, 位置ずれパラメータの推定には中心部の小領域を用いる. 実験の条件は, 4 枚および 10 枚の観測画像を用い, 拡大率, 平行移動量, 回転量, ボケ, 観測ノイズ, 小領域の分割数については 4.1 節と同じ条件で生成した. このとき, 低解像画像換算で上下左右それぞれ 2px のオーバーラップとし, それぞれ



(a) 推定画像 (b) 隠れ変数の推定値

図 10 観測画像 10 枚の場合の結果 (Cameraman, 200 × 200 px)

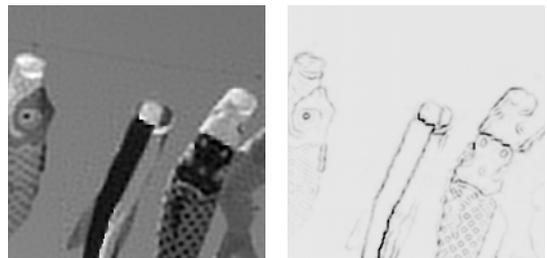
Fig. 10 Result using 10 observed images (Cameraman, 200 × 200 px).



(a) 推定画像 (b) 隠れ変数の推定値

図 11 観測画像 10 枚の場合の結果 (Lenna, 200 × 200 px)

Fig. 11 Result using 10 observed images (Lenna, 200 × 200 px).



(a) 推定画像 (b) 隠れ変数の推定値

図 12 観測画像 10 枚の場合の結果 (Koi, 200 × 200 px)

Fig. 12 Result using 10 observed images (Koi, 200 × 200 px).

の観測画像の枚数ごとに平行移動量, 回転量がそれぞれ異なる 10 セットを用いて実験を行った. 図 5(b), 図 8(b), 図 9(c) に観測画像の例を示す.

性能評価は, 観測画像の枚数ごとに 10 セットの実験を行ったうえで, その ISNR の平均値と, 位置ずれパラメータの推定誤差平均量の平均値を示した. ISNR を計算する際の基準となる画像として, 超解像に用いる複数枚の観測画像の平均画像, 位置ずれのない観測画像 1 枚を bilinear 法によって拡大した画像の 2 種類を用いて, 提案手法を評価した. 実験結果を図 10, 図 11, 図 12 と表 1, 表 2 に示す. 表 1 を見ると, 10 セットの平均値ではまだばらつきが大きいので, Lenna の回転量に関しては観測画像 4 枚の場合よりも 10 枚の場合の方が推定誤差はわずかに大きくなっているものの, おおむね, 観測画像の枚数増加にとともに, 位置ずれパラメータの推定誤差が減少する傾向があることが分かる. なお, 位置ずれパラメータの推定は中

表 1 位置ずれパラメータ推定誤差平均量

Table 1 Average of estimation errors of registration parameters.

原画像	観測画像 の枚数	位置ずれパラメータ推定誤差平均量		
		平行移動量 [px]		回転量 [rad]
		縦	横	
Cameraman	4 枚	0.435	0.798	0.0230
	10 枚	0.079	0.110	0.0018
Lenna	4 枚	0.158	0.172	0.0038
	10 枚	0.117	0.157	0.0039
Koi	4 枚	0.149	0.128	0.0240
	10 枚	0.108	0.104	0.0015

表 2 観測画像の枚数別 ISNR (10 セットの平均)

Table 2 Numbers of observed images and ISNR (average of 10 sets).

原画像	基準となる画像	観測画像の枚数	
		4	10
Cameraman	平均画像	0.94	3.28
	bilinear	0.6	2.97
Lenna	平均画像	3.06	3.27
	bilinear	2.38	2.64
Koi	平均画像	2.65	3.29
	bilinear	2.30	2.96

心部の 1 個の小領域を用いて行っているため、その精度に関しては、本研究の主題である複層ベイズ超解像の大画像への適用とは関係がない。表 2 からは、観測画像の枚数増加により、ISNR が向上することが分かる。また、隠れ変数を導入しているため、図 10 (a), 図 11 (a), 図 12 (a) の推定画像において、Cameraman の肌ともみあげの境界や人物と背景の境界等、エッジも再現されていることが分かる。図 10 (b), 図 11 (b), 図 12 (b) に隠れ変数の推定値を示した。これらから、各画像のエッジが良好に抽出されていることが確認できる。また、各領域間にオーバーラップを設けて処理しているため、小領域の間も途切れなくエッジが再現されていることが分かる。

4.3 中央小領域の特徴が乏しい場合

4.2 節の実験に続いて、中央小領域の特徴が乏しい画像を用いた実験と性能評価を行った。ここでは、Cameraman に関しては 256×256 px のもとの画像を bilinear 法により 1.5 倍に拡大した画像から図 13 (a) のように 200×200 px に切り出した画像を原画像とし、Lenna と Koi に関しては図 14 (a), 図 15 (a) のようにもとの画像から 200×200 px を切り出した画像を原画像とした。それぞれの原画像において、位置ずれがそれぞれ異なる複数枚の観測画像を生成し、その観測画像だけを用いて高解像画像の推定を行う。実験は観測画像は 4 枚および 10 枚で行った。平行移動量、回転量といった位置ずれパラメータは 4.2 節で生成したも



(a) 原画像 (200×200 px) (b) 観測画像例 (50×50 px)

図 13 原画像と観測画像の例 (Cameraman)

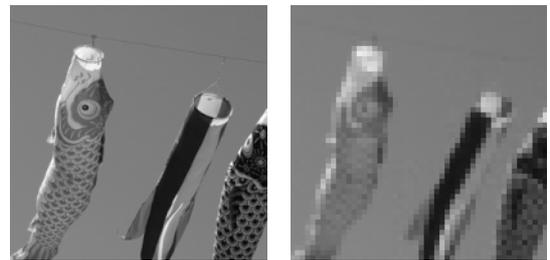
Fig. 13 Original image and an example of observed image (Cameraman).



(a) 原画像 (200×200 px) (b) 観測画像例 (50×50 px)

図 14 原画像と観測画像の例 (Lenna)

Fig. 14 Original image and an example of observed image (Lenna).



(a) 原画像 (200×200 px) (b) 観測画像例 (50×50 px)

図 15 原画像と観測画像の例 (Koi)

Fig. 15 Original image and an example of observed image (Koi).

のを用い、拡大率、ボケ、観測ノイズ、分割した小領域の数とその大きさ、実験したセット数は 4.2 節と同じ条件とした。観測画像生成時の回転の中心は画像の中心とした。図 13 (b), 図 14 (b), 図 15 (b) に観測画像の例を示す。位置ずれパラメータの推定は、3 章でも述べたように 25 個の小領域のうちの一つを用いて行う。図 16, 図 17, 図 18 に本実験で位置ずれ推定に用いた小領域の場所を示す。領域 1 および領域 2 の 2 条件で実験を行った。

性能評価は 4.2 節と同じく、観測画像の枚数ごとに 10 セット実験を行ったうえで、その ISNR の平均値と、位置ずれパラメータの推定誤差平均量の平均値を示した。実験結果を図 19, 図 20, 図 21, 図 22, 図 23, 図 24 と表 3, 表 4 に示す。表 3 から、位置ずれパラメータの推定においては、おおむね、特徴の乏しい画像の中心 (領域 1) より

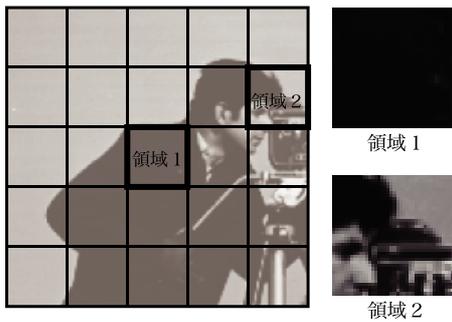


図 16 位置ずれ推定に用いた領域 (Cameraman). 本実験では領域 1, 2 を用いて位置ずれ推定を行った

Fig. 16 Areas used to estimate registration parameters (Cameraman). Areas 1 and 2 are used to estimate the registration parameters.



図 17 位置ずれ推定に用いた領域 (Lenna). 本実験では領域 1, 2 を用いて位置ずれ推定を行った

Fig. 17 Areas used to estimate registration parameters (Lenna). Areas 1 and 2 are used to estimate the registration parameters.

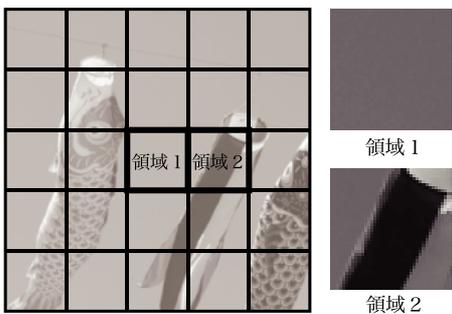


図 18 位置ずれ推定に用いた領域 (Koi). 本実験では領域 1, 2 を用いて位置ずれ推定を行った

Fig. 18 Areas used to estimate registration parameters (Koi). Areas 1 and 2 are used to estimate the registration parameters.

も、特徴の豊かな領域 (領域 2) を用いた場合の方が推定精度が良い傾向にあることが分かる。ここで、Lenna で観測画像 4 枚の場合の回転量についてのみ、領域 1 を用いるより領域 2 を用いる方が推定誤差が大きくなっているが、これは実験セット数が十分大きくないことによるばらつきと考えられる。また、領域 1 を用いる場合、Cameraman, Lenna, Koi のいずれの画像においても、3 種類すべての位



(a) 領域 1 での結果 (b) 領域 2 での結果

図 19 観測画像 10 枚の場合の推定画像 (Cameraman, 200×200 px)

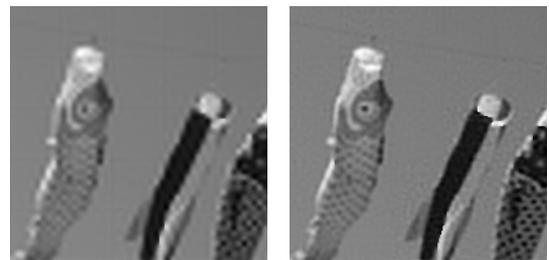
Fig. 19 Estimated images using 10 observed images (Cameraman, 200×200 px).



(a) 領域 1 での結果 (b) 領域 2 での結果

図 20 観測画像 10 枚の場合の推定画像 (Lenna, 200×200 px)

Fig. 20 Estimated images using 10 observed images (Lenna, 200×200 px).



(a) 領域 1 での結果 (b) 領域 2 での結果

図 21 観測画像 10 枚の場合の推定画像 (Koi, 200×200 px)

Fig. 21 Estimated images using 10 observed images (Koi, 200×200 px).

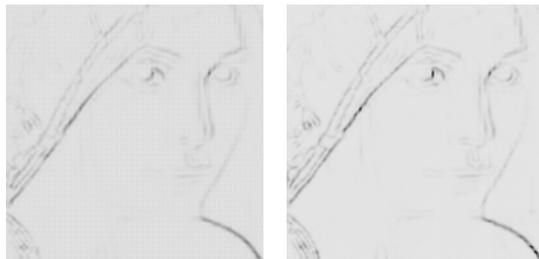


(a) 領域 1 での結果 (b) 領域 2 での結果

図 22 隠れ変数の推定値 (観測画像 10 枚の場合, Cameraman, 200×200 px)

Fig. 22 Estimated latent variables (10 observed images, Cameraman, 200×200 px).

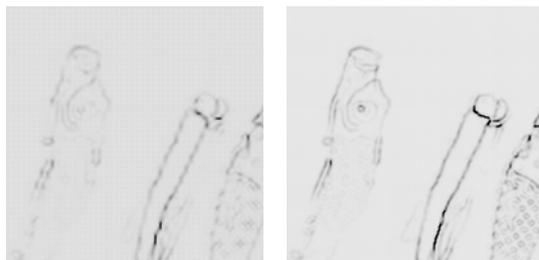
置ずれパラメータの推定誤差が、観測画像 4 枚の場合より 10 枚の場合の方がわずかながら大きくなっている。この理



(a) 領域1での結果 (b) 領域2での結果

図 23 隠れ変数の推定値 (観測画像 10 枚の場合, Lenna, 200 × 200 px)

Fig. 23 Estimated latent variables (10 observed images, Lenna, 200 × 200 px).



(a) 領域1での結果 (b) 領域2での結果

図 24 隠れ変数の推定値 (観測画像 10 枚の場合, Koi, 200 × 200 px)

Fig. 24 Estimated latent variables (10 observed images, Koi, 200 × 200 px).

表 3 位置ずれパラメータ推定誤差平均量

Table 3 Average of estimation errors of registration parameters.

原画像	観測画像の 枚数, 領域	位置ずれパラメータ 推定誤差平均量		
		平行移動量 [px]		回転量 [rad]
		縦	横	
Camera- man	4 枚, 領域 1	0.233	0.228	0.0039
	4 枚, 領域 2	0.235	0.148	0.0029
	10 枚, 領域 1	0.240	0.265	0.0042
	10 枚, 領域 2	0.101	0.109	0.0028
Lenna	4 枚, 領域 1	0.232	0.223	0.0037
	4 枚, 領域 2	0.199	0.155	0.0098
	10 枚, 領域 1	0.239	0.24	0.0042
	10 枚, 領域 2	0.185	0.140	0.0031
Koi	4 枚, 領域 1	0.233	0.228	0.0037
	4 枚, 領域 2	0.151	0.132	0.0024
	10 枚, 領域 1	0.240	0.265	0.0042
	10 枚, 領域 2	0.111	0.100	0.0018

由は現時点では明らかではないが, 特徴の乏しい領域 1 による位置ずれの推定はもともと困難であるため, 観測画像が多いほど推定の精度が向上するという自然な結果が必ずしも現れていないものと考えられる。

また, 表 4 から, 位置ずれパラメータの推定誤差の減少にともない, 領域 1 よりも領域 2 を用いた場合の ISNR が向上していることも分かる。よって, 画像の中心部の領

表 4 観測画像の枚数別 ISNR

Table 4 Numbers of observed images and ISNR (average of 10 sets).

	原画像	基準画像	平均画像		bilinear	
		観測 [枚]	4	10	4	10
ISNR 平均値 [dB]	Camera- man	領域 1	2.53	2.59	1.65	1.73
		領域 2	4.07	4.55	3.23	3.78
	Lenna	領域 1	2.69	3.04	1.75	2.10
		領域 2	3.12	3.87	2.16	2.98
Koi	領域 1	1.52	1.56	1.27	1.32	
	領域 2	2.65	3.54	2.37	3.25	

域において特徴がなく, 良好な位置ずれパラメータ推定が望めない場合でも, 特徴のある他の領域を用いることで良好な位置ずれパラメータ推定と高解像画像推定の実現が可能であることが分かる。また, 図 19~図 21 の推定画像の人物と背景の間等のエッジの表現や, 図 22~図 24 において, 領域 1 の場合よりも領域 2 の場合の方がエッジが濃く表現されていることから, 領域 2 の場合は領域 1 の場合よりも画像中のエッジの再現も行われており, 位置ずれパラメータが良好に推定されていることが影響していると考えられる。

5. おわりに

本論文では, 画像を分割することにより, Kanemura らによる複層ベイズ超解像を大画像に適用した。これを実現するために回転の中心を一般化する手法を導入した。これにより, 画素値に大きな変化がある領域を位置ずれパラメータの推定に用いることが可能となった。さらに, どの小領域に対しても回転を適用することが可能となり, 大画像においても良好な高解像画像の推定が可能となった。今後の課題としては, 位置ずれ推定に用いる領域の自動選択や小領域のサイズが計算量や画質に与える影響の検討があげられる。

謝辞 日頃より御議論いただく東大岡田真人教授に感謝する。本研究の一部は科学研究費補助金 (24360152, 21500228) による。

参考文献

- [1] Park, S.C., Park, M.K. and Kang, M.G.: Super-Resolution Image Reconstruction: A Technical Overview, *IEEE Signal Processing Magazine*, Vol.20, No.3, pp.21-36 (2003).
- [2] 奥富正敏, 田中正行, 竹島秀則, 松本信幸: 画像超解像処理技術の最新動向, 電子情報通信学会誌, Vol.93, No.8, pp.693-698 (2010).
- [3] Freeman, W.T., Jones, T.R. and Pasztor, E.C.: Example-based Super-resolution, *IEEE Comput. Graph. Appl.*, Vol.22, No.2, pp.56-65 (2002).
- [4] 松本信幸, 井田 孝: 画像のエッジ部の自己合同性を利用した再構成型超解像, 電子情報通信学会論文誌, Vol.J93-D, No.2, pp.118-126 (2010).

- [5] Tsai, R.Y. and Huang, T.S.: Multiframe Image Restoration and Registration, *Advances in Computer Vision and Image Processing*, Vol.1, pp.317–339, JAI Press (1984).
- [6] Tipping, M.E. and Bishop, C.M.: Bayesian Image Super-resolution, *Advances in NIPS 15*, pp.1279–1286 (2003).
- [7] Kanemura, A., Maeda, S. and Ishii S.: Superresolution with Compound Markov Random Fields via the Variational EM Algorithm, *Neural Networks*, Vol.22, pp.1025–1034 (2009).
- [8] Katsuki, T., Torii, A. and Inoue, M.: Posterior-mean Super-resolution with a Causal Gaussian Markov Random Field Prior, *IEEE Trans. Image Process.*, Vol.21, No.7, pp.3182–3193 (2012).
- [9] Babacan, S.D., Molina, R. and Katsaggelos, A.K.: Variational Bayesian Super Resolution, *IEEE Trans. Image Process.*, Vol.20, No.4, pp.984–999 (2011).
- [10] 木下俊貴, 三好誠司: 大画像の複層ベイズ超解像と位置ずれ推定に関する検討, 電子情報通信学会技術研究報告, Vol.112, No.279, IBISML2012-85, pp.367–372 (2012).
- [11] 福田航, 兼村厚範, 前田新一, 石井信: ベイズ超解像における複数パッチを用いたレジストレーション, 日本神経回路学会第19回全国大会, pp.150–151 (2009).
- [12] Bishop, C.M.: *Pattern Recognition and Machine Learning*, Springer, New York (2006).
- [13] Bishop, C.M. (著), 元田 浩ほか (訳): パターン認識と機械学習 (上・下), シュプリンガー・ジャパン, 東京 (2008).
- [14] Geman, S. and Geman, D.: Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images, *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol.PAMI-6, No.6, pp.721–741 (1984).
- [15] Bishop, C.M.: *Neural Networks for Pattern Recognition*, Oxford Univ. Press (1995).
- [16] Schultz, R.R. and Stevenson, R.L.: Extraction of High-resolution Frames from Video Sequences, *IEEE Trans. Image Process.*, Vol.5, No.6, pp.996–1011 (1996).



三好 誠司

1963年生。1986年京都大学工学部電気工学科卒業。1988年同大学大学院修士課程修了。同年日本電気(株)入社。1994年神戸市立工業高等専門学校電子工学科講師。同助教授, 教授を経て, 2008年より関西大学システム理工学部准教授。2010年より同教授。1998年金沢大学大学院自然科学研究科博士後期課程修了。博士(工学)。統計力学的手法を用いた学習, 記憶, 信号処理に関する理論的研究に従事。電子情報通信学会シニア会員。日本神経回路学会, 日本物理学会, IEEE各会員。



木下 俊貴

1987年生。2011年関西大学工学部電子情報システム工学科卒業。現在, 同大学大学院理工学研究科博士前期課程在学中。ベイズ推定の手法を用いた超解像に関する研究に従事。