

空間距離とバイラテラル差分フィルタを用いた 絵画クラックのインペインティング

吉田大海¹⁾ (正会員)

1) 近畿大学工学部電子情報工学科

Image Inpainting for Paint Crack by Space Distance and Difference of Bilateral Filter

Hiromi Yoshida¹⁾(Member)

1) Department of Electronic Engineering and Computer Science,

Faculty of Engineering, Kindai University

yoshida@hiro.kindai.ac.jp

アブストラクト

本論文では、絵画表面に生じたクラックの仮想修復を目的としたインペインティングを提案する。本研究のインペインティングが対象とする欠損は、油彩画の絵具層に生じる損傷を模した欠損である。具体的には、ひび割れを想定した広範囲・高密度の細長い欠損、一定幅内の絵具の剥落・汚損を想定した欠損である。従来研究において、これらの欠損を含む絵画画像を良好に補完できるインペインティングが提案されていた。しかし、この方式は補完用のテクスチャ抽出にDOGフィルタを用いることで、テクスチャだけでなくエッジ成分も抽出してしまうという課題があった。本研究では、このテクスチャ抽出にDOB(バイラテラル差分フィルタ)を用いることで、テクスチャにエッジ成分が含まれる問題を改善した。さらに、そのテクスチャ選択の方法に空間距離に基づくインペインティングを応用することで、補完に用いるテクスチャ選択はより高精度となった。提案法の有効性は、補完結果を2種類のRMSEによって評価し、色情報とテクスチャ情報の両面から定量的に確認した。

Abstract

This paper proposes a new inpainting method which is aimed at virtual restoration for paint crack. Target images of this research include missing regions which are models for high-density and widespread crack and paint flaking which is beyond a certain size. In conventional research, there is an effective method to restore these missing region. However, its accuracy of texture extraction and texture selection are not enough. Proposed method improved the problem of conventional method that is including edge in texture by using difference of bilateral filter for texture extraction. Additionally, the accuracy of texture selection improved with use of inpainting method based on space distance. Effectiveness of proposed method can be confirmable by evaluating restored images by RMSE in both color and texture.

1. はじめに

1.1 絵画に対する仮想修復の背景

絵画修復は文化財保存において重要な技術である。修復は専門的な知識を有した修復士によって行われるが、修復方針は修復学を踏まえて慎重に検討される。もし、修復対象の絵画をデジタル画像化して仮想的に修復し、修復結果をデジタル画像として確認できれば、修復の一助になると考えられる。また、近年では個人所蔵の絵画を対象とした修復サービスが、スマートフォンの普及で活発化している。具体的には、顧客がスマートフォンで撮影した絵画のデジタル画像を専門業者が分析し、それに基づいて絵画の状況・修復予想を説明する。こうした場合でも、デジタル画像化された絵画を個人が仮想修復できれば、修復サービスの効率化だけでなく、個人的な文化財保存に大きな役割を果たすと考えられる。以上を背景に、絵画の仮想修復を目的としたインペインティングを提案する。

1.2 統計的方式のインペインティング

本節では、インペインティングのルーツと代表的な統計的方式のインペインティングを構造型・事例型に分類して紹介する。インペインティングは、元々アナログ画像を対象とした修復技術である。この技術を、Bertalmio がデジタル画像を対象として自動化した[1]。以下、デジタル画像を対象として自動化されたインペインティングをインペインティングと呼ぶ。インペインティングは、デジタル画像内で既知の欠損領域に対して、非欠損領域等から計算する尤度（もつともらしさ）に基づいて補完していく。この尤度を、対象画像の画素値に基づく統計情報から計算する方式を統計的方式と呼ぶ。これらの従来法としては、画素値の連続性を尤度とした構造型 [2][3][4][5][6]、パターン類似度を尤度とした事例型[7][8][9][10][11][12][13][14]などが提案されている。構造型は、画像のテクスチャが表現できず補完精度は比較的低くなるものの、少量の非欠損領域で尤度計算ができるため、多様な欠損領域を補完できる。したがって、補完精度は低い適用できる欠損の範囲が広い。一方、事例型は構造型と比較して補完精度が高いものの、尤度計算に多くの非欠損領域を必要とするため、欠損領域が広範囲に分布している場合は適用できない。したがって、補完精度は高い適用できる欠損の範囲に限られる。

1.3 機械学習方式のインペインティング

本節では、機械学習によって飛躍的に進歩した近年のインペインティングを機械学習方式として紹介する。なお、前節の統計的方式との違いは、尤度の計算に学習済みデータの情報、すなわち、対象画像以外の情報を用いる点である。機械学習方式 [15][16][17][18]では、膨大な学習データを要求するものの、適切な学習を行えば完全に損失した構造も復元できるという特筆すべき特徴があり、統計的方式の課題を克服している。具体的には、顔画像から目が完全に消失した場合でも、違和感の少ない目を復元できる。さらに、GAN(Generative Adversarial Networks)[19]の登場によって学習に必要なデータ数も大幅に削

減され、汎用性が求められるインペインティングも同様に進歩し、高精度な方式が提案されている[20]。これら機械学習方式は高い補完精度と引き換えに、事例型に次いで多くの非欠損領域を必要とする。つまり、欠損領域が広範囲・高密度に分布している画像には適用できない。したがって、機械学習方式は極めて高い補完精度を持つが、事前に適切な学習データを必要とし、しかも適用できる欠損の範囲に限られる。

1.4 仮想修復としてのインペインティング

絵画画像の仮想修復において、インペインティングに要求される重要な要素を2点述べる。

1 点目：絵画画像の仮想修復で対象とする欠損は、絵画の損傷に基づくものである。具体的には、広範囲・高密度に分布するひび割れを模した細長い欠損、すなわち、絵画クラック、そして絵具の剥落や汚損を模した一定の幅のある欠損である。とくに絵画クラックはクラックリユールに見られるよう画像全体に分布することもあり、インペインティングに求められるのは、少ない非欠損領域でも多様な欠損領域に対応できる汎用性の高さ、すなわち、統計的方式における構造型の性質である。

2 点目：絵画画像のテクスチャ情報は、絵画の絵具層に生じた凹凸情報であり、これは絵画と描き手の特徴を表わす重要な画像特徴となる。したがって、仮想修復としてのインペインティングにはテクスチャの抽出精度・再現精度が要求される。

以上の2点を踏まえたうえで、まず統計的方式を吟味する。構造型は適用範囲が広く、本研究で想定する欠損に対応できる。しかしながら、構造型は絵画の持つテクスチャを表現できない。一方、事例型は補完精度が高いものの、尤度計算に多くの非欠損領域を必要とするため、本研究で対象とする絵画クラックの様な広範囲・高密度に分布する欠損には適用できない。同様の課題が、絵画の仮想修復を目的とした先行研究 [22][23][24][25][26]にもある。

次に、機械学習方式を吟味する。機械学習方式は事例型以上に高い補完精度が期待できるものの、同様に多くの非欠損領域を必要とするため、絵画クラックのように広範囲・高密度に分布する欠損には適用できない。また、特筆すべき特徴である損失した構造の復元も、真値と大きく異なる点では修復よりも創作に近く、仮想修復の観点では単純にメリットとは言い難い。また、適切な学習を行わなければその効果も発揮できない。

以上の議論を踏まえたうえで、仮想修復として提案されているインペインティングと、提案法について紹介する。絵画クラックの仮想修復に有効なインペインティングが文献[27]で提案されている。この方式は、絵画の損傷を模した多様な欠損領域を補完でき、しかも補完領域に絵画のテクスチャを確認できる方式である。しかしながら、この方式は補完するテクスチャを局所的なフラクタル次元の高さを基準に選択しているため、本来はテクスチャの弱い領域にも強いテクスチャを補完してしまう。さらに、テクスチャの抽出にDOG(ガウシアン差分)フィルタを用いるため、抽出したテクスチャにエッジ成分が含まれてしまい、それが補完結果に現れてしまうことがあった。そこで、本研究ではこの方式に2点の改良を加えることで、より高精度

に絵画クラックを仮想修復できるインペインティングを実現する。1 点目の改良は、テクスチャ抽出に **DOB**(バイラテラル差分) フィルタを用いることである。バイラテラルフィルタは、ガウシアンフィルタの平滑化特性を持ちながら、エッジ成分を保存できる平滑化フィルタである。したがって、従来のテクスチャ抽出精度を維持しつつもエッジ成分を抑制できる。2 点目の改良は、テクスチャの選択基準を最小空間距離とすることである。詳細は 3 章で述べるが、これによって不自然に強いテクスチャの選択を回避できる。以下、本論文の構成について述べる。2 章では、提案法の構成技術について紹介する。3 章では、提案法のアルゴリズムについて述べる。4 章では、提案法の補完精度や性能限界を検証する。5 章では、本研究をまとめる。

2. 提案手法の構成技術

2.1 空間距離に基づくインペインティング

空間距離に基づくインペインティング[21]は、広範囲・高密度の欠損領域を含む画像を対象に提案されたインペインティングである。図 1 に、空間距離に基づくインペインティングの概念図と入出力結果の例を示す。図 1 の記号について述べる。まず、 Ω は欠損領域であり、 Φ は非欠損領域である。また、 d はこの方式の尤度となる空間距離であり、非欠損領域内の任意の画素と欠損領域内の任意の画素とのユークリッド距離を示す。この d が最小となる非欠損領域の画素をそのまま欠損領域に補完することで、インペインティングが達成される。インペインティングの入力と出力の例は、それぞれ図 1 の(b)と(c)に示す通りであり、欠損幅は細いが絵画クラックに見られるような広範囲・高密度に分布した欠損が良好に補完できていることが分かる。式(1)に、 d の定義と、それに基づく補完画素の選択法を示す。

$$I(p_\Omega) = I(\operatorname{argmin}_{p_\Phi} d(p_\Omega, p_\Phi)) \quad \dots\dots (1)$$

$$p_\Phi \in \Phi$$

式(1)で p が空間座標 (x, y) を持つ画素であり、 $I(p)$ は p の画素値である。ただし、 p_Ω は欠損領域 Ω 内の画素であり、 p_Φ は非欠損領域 Φ に含まれる補完候補の画素である。 $d(p_\Omega, p_\Phi)$ は p_Ω と p_Φ の空間距離である。また、補完した画素は p_Φ に含めない。

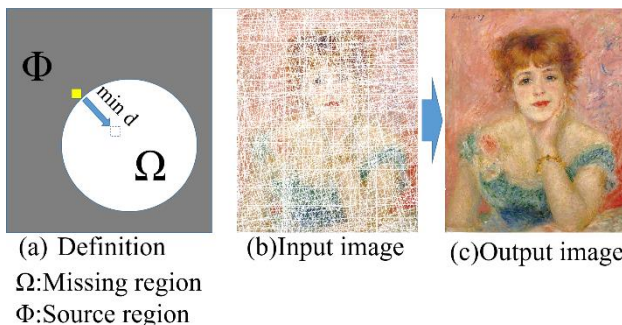


図1. 空間距離に基づくインペインティング。

2.2 DOB フィルタによる絵画テクスチャの抽出

一定幅の絵画クラックを仮想修復する場合、そこに絵画の質

感(テクスチャ)を確認できなければ不自然な補完結果となる。デジタル画像からテクスチャを抽出する場合、一般的にはハイパスフィルタを用いる。先行研究では **DOG**(ガウシアン差分) フィルタを用いてテクスチャを抽出していた[27]。図2に、**DOG** フィルタによるテクスチャの抽出結果を示す。なお、出力結果はマイナス値を含むため127を加算して表示している。図2から、**DOG** フィルタによってテクスチャの抽出が確認できるが、エッジ成分も踏まれているのが分かる。このエッジ成分が補完に反映されると、出力画像に不自然な輪郭が生じる。そこで本研究では、**DOG** フィルタの代わりに **DOB** フィルタを用いる。バイラテラルフィルタはガウシアンフィルタに色空間での平滑化制限を加えることで、エッジを保存する平滑化フィルタである。そのため、**DOB** フィルタでは **DOG** フィルタの特性を維持しつつもエッジ成分を抑制したテクスチャ抽出が期待できる。ガウシアンフィルタを適用された画像を $G(x, y, \sigma)$ 、バイラテラルフィルタを適用された画像を $B(x, y, \sigma_1, \sigma_2)$ としたとき、**DOG** フィルタおよび **DOB** フィルタによる出力画像はそれぞれ式(2)(3)で求められる。ただし、 (x, y) は注目画素の空間座標であり、 $I(x, y)$ は入力画像である。ここで、 σ はガウシアンフィルタのパラメータであり、注目画素を中心とした距離空間における平滑化範囲である。なお、平滑化の係数はガウス分布に基づく。また、 σ_1, σ_2 はバイラテラルフィルタのパラメータであり、それぞれ σ_1 は色空間における平滑化範囲、 σ_2 は距離空間における平滑化範囲である。この係数もガウス分布に基づく。なお、 σ_2 がガウシアンフィルタの σ に相当する。そして σ_1 を調整することで画素値の差が大きい画素同士は除外して平滑化できるため、エッジ成分を保存できる。すなわち、**DOB** フィルタにおいてはエッジ成分の抽出を抑制できることになる。

$$DOG(x, y) = I(x, y) - G(x, y, \sigma) \quad \dots\dots (2)$$

$$DOB(x, y) = I(x, y) - B(x, y, \sigma_1, \sigma_2) \quad \dots\dots (3)$$

図3に、**DOB** フィルタによるテクスチャの抽出結果を示す。図3から、**DOB** フィルタによって良好にテクスチャが抽出されることが確認できる。さらに、図2の **DOG** フィルタの例と比較すると、**DOB** フィルタではエッジ成分が抑制されていることが分かる。以上から、本研究では、絵画画像のテクスチャ抽出に **DOB** フィルタを用いる。この **DOB** フィルタによるテクスチャ抽出が、本研究による1点目の改良となる。




図2. DOB フィルタによるテクスチャ抽出。

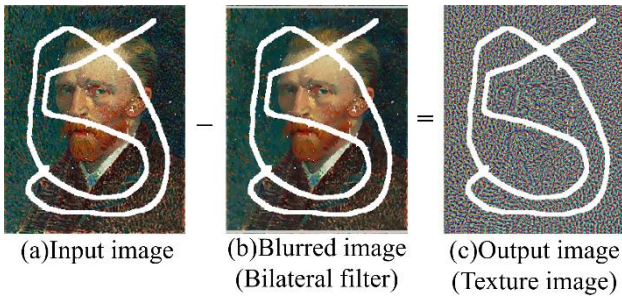


図3. DOBフィルタによるテクスチャ抽出.

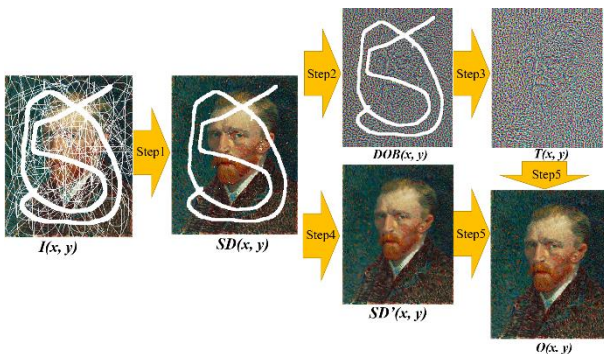


図4. 提案法の流れ.




図5. Step.3の流れ.

3. 提案法

本研究で提案するインペインティングの流れを図4に示す。図の $I(x, y)$ が入力画像、 $O(x, y)$ が出力画像である。図4で示した各画像を獲得するStepについて説明する。

Step.1 : 入力画像 $I(x, y)$ に対して、欠損幅が3画素以下である欠損領域を2.1に示した方式で補完し、画像 $SD(x, y)$ を得る。

Step.2 : 画像 $SD(x, y)$ に対して、式(2)に示したDOBフィルタを適用して画像 $DOB(x, y)$ を得る。

Step.3 画像 $DOB(x, y)$ に対して、欠損領域を含めて画像を 9×9 画素サイズのブロックに分割する。欠損領域を含むブロックに対して、空間距離が最小となる非欠損領域のブロックを選択して補完し、画像 $T(x, y)$ を得る。

Step.4 画像 $SD(x, y)$ の欠損領域を式2.1に示した方式で補完してからガウシアンフィルタで平滑化して画像 $SD'(x, y)$ を得る。(平滑化された非欠損領域は入力画像と同じ状態に戻す)

Step.5 画像 $SD'(x, y)$ に画像 $T(x, y)$ を加算し、出力画像 $O(x, y)$ を獲得する。

上記Stepのうち、Step.1, 4, 5は方式[27]を踏襲している。本研究による改良点2点目に相当するのはStep.3である。ここで、Step.3を図5に基づいて説明する。この処理は、絵画の凹凸情報となるテクスチャ画像 $T(x, y)$ を獲得するための処理であり、一定幅以上の絵画クラックを自然に補完するために必要となる。まず、(a)はStep.2で得る画像 $DOB(x, y)$ のモデルである。それを 9×9 画素サイズのブロックに分割した画像が(b)であり、赤線で囲われた1マスをブロックと見なす。このように、画像の最小単位を画素ではなく複数画素で構成されたパターンとするインペインティングは事例型に多く見られるが、絵画画像に対する有効性も方式[27]で示されている。ここで、(c)は(b)の部分拡大である。いま、(c)の緑色の枠で示した欠損領域を現補完目標とする。そして、水色の4つのブロックが補完に用いる候補となる非欠損領域である。厳密には、非欠損領域に含まれるブロック全てが候補となるが、ここでは簡単のため4つで説明する。ここからブロックを選択する基準、すなわち、インペインティングの尤度は、2.1で示した方式と同様の最小空間距離である。ブロックの中心同士のユークリッド距離を比較し、最小となるブロックを選択する。もし、ブロックを画素とみなせば2.1で示した方式そのままとなる。そして、赤枠で示したブロックが補完用に選択されたブロックであり、このブロックをそのまま欠損領域に補完する。方式[27]では、Step3において局所フラクタル次元に基づくテクスチャの強さを尤度とすることで、凹凸感の強いテクスチャを選択していた。それによって、目視では絵画らしい質感を持った出力結果が得られる一方、本来はテクスチャの弱い領域にも強いテクスチャを補完してしまう。図6にその例を示す。図6において、(a)は入力画像である。また、(b)~(d)がそれぞれ原画像(正解画像)、方式[27]、提案法であり、上段が出力結果である。そして、下段がそのテクスチャ分布を画素値で表現した画像であり、画素値が高いほど周辺のテクスチャが高いことを示している。(b)(c)(d)の上段から、方式[27]と提案法は原画像と比較していずれも良好に補完できていることがわかる。しかし、下段を見ると方式[27]では原画像に比べてテクスチャが全体的に強く出ていることが分かる。一方、提案法のテクスチャ分布はこの点が改善され、原画像のテクスチャ分布に近づいていることが分かる。




図6. テクスチャの選択精度の確認.

テクスチャ選択に局所フラクタル次元を用いることの課題は図6で示したが、次に、絵画画像のテクスチャ選択に最小空間距離を用いる妥当性について考察する。ある画像内で任意の領域を二つ選んでA, Bとすると、AとBの空間距離が近くなるほど、AとBの画像的性質は一般的に近くなる。これは、ガウシアンフィルタの係数やニアレストネイバー補間の考えた方そのものであり、画像処理では公知として扱われる。この空間距離と画像的性質の関係を、絵画画像のテクスチャに限ってさらに検討する。1章でも述べたが、絵画画像のテクスチャ情報は絵具層の凹凸情報であり、それを生成するのは描き手のブラシタッチである。すなわち、この議論は空間距離の近さとブラシタッチの近さに関するかという議論になる。これについて、大域的な視点と局所的な視点の2点から、提案者は次のように考察する。

1: 局所的な視点

ブラシタッチやストロークには連続性があるため、それを保存・再現するには空間距離の近いテクスチャを使用するほうが良い。

2: 大域的な視点

描くコンテンツが変わると、ブラシタッチも変わる可能性がある。したがって、性質の近いテクスチャを選択したいときは同一コンテンツ内のものを用いるほうが望ましい。したがって、その可能性が高まる空間距離の近いテクスチャを使用するほうが良い。

1点目は、Step.3で画像をブロックに分割する理由にもなっている。2点目を具体例で補足する。人物画を例にとると、コンテンツには肌・髪・服などが挙げられ、いずれも現実の質感が異なる。絵画においても質感ごとにブラシタッチを変えて描き分ける可能性が高く、テクスチャの選択は同一コンテンツ内から選択する方が良いと考えられる。以上より、本研究ではテクスチャの選択基準を最小空間距離とした。

4. 補完実験とパラメータの検証

本章では、提案法の主要なパラメータとなる DOB フィルタの σI の検証、および提案法の性能評価を従来法と比較しながら行う。また、最後に提案法の性能限界についても述べる。

4.1. DOB フィルタのパラメータ σI


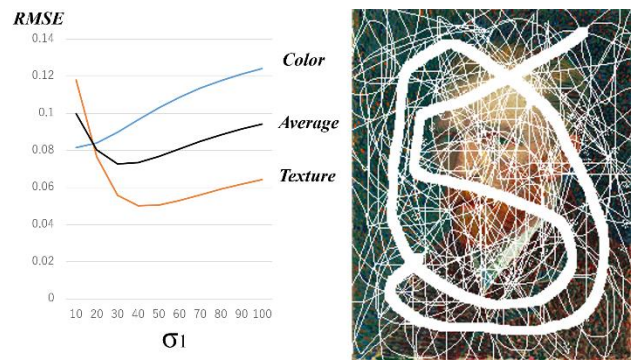
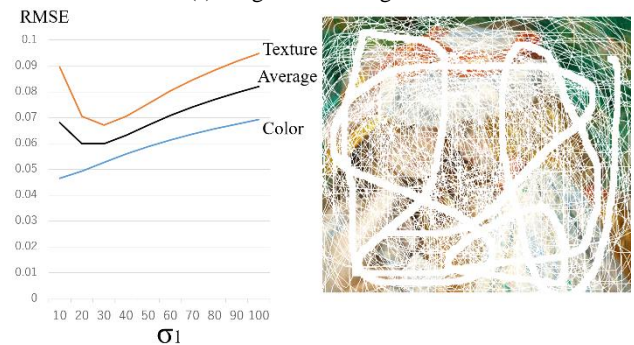


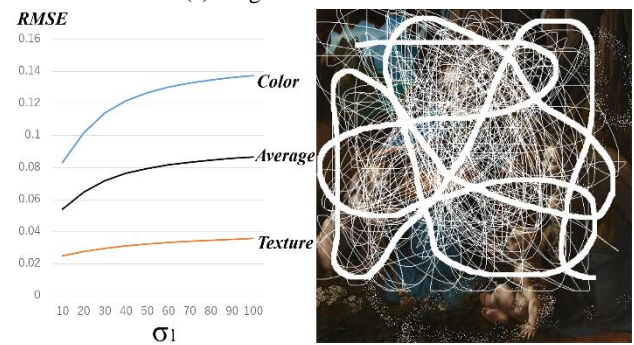
図7. σI の変化とDOBフィルタによるテクスチャ抽出の変化。



(a) Image with a strong texture



(b) Image with a middle texture



(c) Image with a weak texture

図8. σI による補完精度の変化

式(3)の σI は色空間における平滑化範囲を決定するため、値を大きくするほどテクスチャの抽出量が増える。すなわち、画素値の差を跨いだ平滑化を行うためガウシアンフィルタに近くなる。したがって、 σI の設定が提案法の品質を左右する重要なパラメータとなる。図7に、 σI の値と DOB フィルタによって抽出されるテクスチャの変化の例を示す。図7から、 σI の値(画像下の数値)が大きくなるほどテクスチャの抽出量が増えていることが分かる。一方で、 σI が大きくなるに連れて DOB フィルタに見られた課題のようにエッジ成分も含まれてくることが分かる。そこで、本研究では適切な σI の値域を推定するため、 σI を変えながら絵画画像の補完実験を行い、原画像に対する誤差を検証した。その評価結果と入力画像を図8に示す。図8(a)はテクスチャの強い画像であり、(c)はテクスチャの弱い画像である。そして、(b)は二つの中間程度のテクスチャを持つ画像である。図のグラフは、横軸が σI であり、目盛幅は10である。縦軸が正規化した二乗誤差(RMSE)であり、誤差が大きいほど1に近付き、誤差が小さいほど0に近づく。グラフ

内の **Color** は画素値の **RMSE** であり、補完された色情報の精度を示す。また、**Texture** は補完画像をブラケット法[28]によりテクスチャ画像化した画像の **RMSE** であり、補完されたテクスチャの精度を示す。**Average** は **Color** と **Texture** の平均であり、補完精度の総合評価である。実験の結果、**Color** が最も高精度(最低値)を示した $\sigma 1$ は(a)が 10, (b)が 10, (c)が 10 となった。すなわち、色情報の補完精度を重視する場合、いずれの画像においても $\sigma 1$ は最低値、つまりテクスチャは付加しない方が良いことが分かる。一方、**Texture** が最も高精度(最低値)を示した $\sigma 1$ は (a)が 40, (b)が 30, (c)が 10 となった。すなわち、テクスチャの補完精度を重視する場合、中程度以上のテクスチャを含む画像には 30~40 程度の $\sigma 1$ を設定すると良いことが分かる。最後に、**Average** が最も高精度(最低値)を示した $\sigma 1$ は(a)が 30, (b)が 20, (c)が 10 となった。すなわち、色情報と質感の精度を両立させたい場合は、中程度以上のテクスチャを含む画像には 20~30 程度の $\sigma 1$ を設定し、テクスチャの弱い画像にはテクスチャを付加しない方が良いことが分かる。本研究では、この実験結果を踏まえて $\sigma 1$ の推奨値を 30 とする。しかし、補完結果を目視で確認すると 30 では原画像と比較してテクスチャが弱く見える領域も多かったため、**RMSE** の補完精度よりも目視の質感を重視する場合は 40 を推奨値とする。

4.2. 補完実験による定量的な評価

表 1. 絵画画像 (50 枚) を対象とした補完精度評価

	Color	Texture	Average
Proposed	0.0438	0.0645	0.0542
Conventional[27]	0.0552	0.1076	0.0814
Brtalmio[5]	0.0410	0.1100	0.0755
Telea[6]	0.0463	0.1125	0.0794

提案法の定量的な精度評価として、絵画画像 50 枚を対象とした補完実験を行った。比較として従来研究となる方式 [27]を加え、さらに絵画の損傷を模した欠損にも適用できる構造型から代表的な方式である Bertalmio の方式 [5], Telea の方式 [6] を取り上げ、同様に補完実験を行って比較した。その評価結果を表 1 に示す。表 1 から **Texture**, **Average** において提案法が最も精度が高く、また **Color** では提案法が 2 番目に高い精度を示していることが分かる。

4.3. 補完領域の目視による考察

本節では、補完領域に対して目視による定性的な考察を行う。各方式によって補完された絵画画像の一例を取り上げ、細部を拡大したものを図 9 に示す。取り上げた例は中程度のテクスチャを持つ絵画画像であり、とくに提案法の **DOB** フィルタによる効果を確認しやすい画像を選んだ。図を確認すると、Bertalmio の方式、Telea の方式は色情報が良好に補完できているが、テクスチャがないためボケた印象が強い。これは、構造型

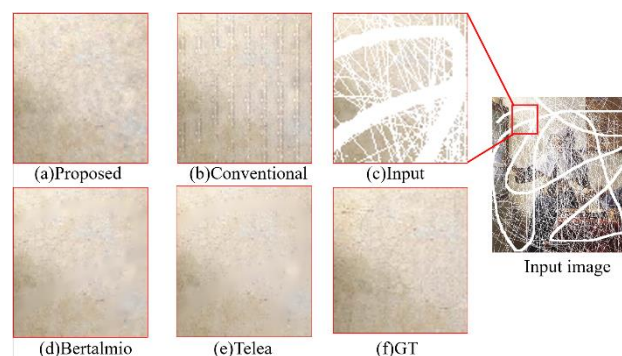


図 9. 補完領域の細部比較。




図 10. 事例型の方式と機械学習方式による自然画像の補完例。



図 11. 事例型と機械学習方式の性能限界。

に共通する性質である。一方、方式 [27] は色情報の補完結果が良好であり、テクスチャも確認できる。しかし、この方式はテクスチャ抽出に **DOG** フィルタを用いているため、図の画像例では縦のエッジ成分が不自然に生じていることが分かる。提案法は色情報も良好であり、テクスチャも良好に確認できる。さらに、エッジ成分も含まれていないため、自然な補完結果となっていることが分かる。

4.4. 事例型および機械学習方式との比較

1 章で述べた通り、統計的方式の事例型と機械学習方式は補完に多くの非欠損領域を必要とするため、本研究が対象とする絵画クラックのように画像全体に広範囲・高密度に分布するような欠損は補完できない。そこで、本節では事例型や機械学習方式が補完できる欠損を対象として、提案法と比較実験を行う。比較する方式について述べる。事例型からは Barnes らの PatchMatch [14] を取り上げる。この方式は Adobe の Photoshop (CS5 以降) にも画像修復機能として実装されており、認知度と実用性が事例型の中で極めて高く、比較対象とした。機械学習方式からは Liu らの Partial Convolution を用いた方式

[17]を取り上げ、ここでは自然画像を想定した事前学習済みモデルを使用する。この方式は機械学習方式の中でも新規性が高く、近年の方式としては被引用数も多いため、比較対象とした。参考として、自然画像からの人物消去例を用いて両方式の補完性能を定性的に示す。図10から、大きな欠損にも関わらず両方で高精度な補完結果を確認できる。


補完実験の前に、まずは両方式の性能限界について述べる。4.2の補完実験で用いた絵画画像は、事例型のPatchMatch [14]と機械学習方式のLiuらの方式[17]いずれもが補完できなかった。そこで、実行不能とならない程度に非欠損領域の割合を増やして適用した例を、提案法の結果と共に図11に示す。PatchMatchでは補完領域の違和感が強く、Liuらの方式では不自然な黒い領域が生じている。これらの結果は、非欠損領域の不足だけでなく、欠損形状の複雑さも一因と考えられる。

ここから比較実験について述べる。実験では、非欠損領域の割合と欠損領域の形状を調整し、両方式がそれぞれ本来の補完性能を発揮できる絵画画像(10枚)を用意した。さらに、PatchMatchでは違和感のあるコンテンツが補完された場合は手動でその領域を再指定し、消失するまで適用した。まず、事例型であるPatchMatchとの比較結果を図12に一覧で示す。図の(a)が入力画像、(b)がPatchMatch、(c)が提案法である。入力画像(a)では、PatchMatchが事例型としてパターン類似度を尤度とする点を踏まえ、パターンが十分に確保できるよう広範囲に分布する欠損領域を少なくし、さらに欠損形状も事例型の性質に合わせて大きくした。補完結果の図12(b)では、図11(b)に見られたような違和感はなく、方式本来の良好な補完結果を確認できる。提案法との比較を含めた定量的評価を表2に示す。評価基準は表1と同様である。表2から、*Color*、*Texture*、*Average*の全てで提案法の方が高い精度となったことが分かる。また本比較実験において、事例型の利点を示す代表的な例が確認できたため、趣旨から外れるが参考として図13に示す。赤枠で強調した補完結果に着目すると、図13(c)にはパターンを保存するように補完できているが、提案法の図13(d)にはなく、違和感を生じている。この画像の*Texture*評価は提案法が0.1122、PatchMatch[14]が0.060であり、定量的にも事例型の優位となった。本例のように非欠損領域が十分かつ欠損が広範囲に分布していない場合、事例型は欠損幅が大きくとも有効に絵画画像を補完できることがわかる。


次に、機械学習方式との比較実験の結果を同様に一覧として図14に示す。Liuらの方式は、欠損領域がある程度広範囲に分布した場合でも有効に補完できたため、入力画像(a)は本研究が対象とする絵画クラックの形状により近い欠損を含めた。補完結果の図14(b)では、図11(c)に見られたような不自然な領域はなく、方式本来の良好な補完結果を確認できる。

表2. 事例型の方式との比較実験結果


	<i>Color</i>	<i>Texture</i>	<i>Average</i>
Proposed	0.0804	0.0949	0.0877
PatchMatch [14]	0.0989	0.1121	0.1055



(a) Input images



(b) PatchMatch [14]



(c) Proposed

図12. 事例型の方式との比較実験で用いた画像一覧.




(a) Input image (b) GT (c) PatchMatch [14] (d) Proposed

図13. 提案法の課題と事例型の方式の利点.


本比較実験の定量的評価を表3に示す。表3から、*Color*ではLiuらの方式が優位となったが、*Texture*、*Average*では提案法の方が優位となったことが分かる。目視で確認すると、Liuらの方式は非欠損領域が少ないにも関わらず、補完結果にはパターンの再現やエッジの整合性を確認できた。これは機械学習方式の特性と言える。一方、それが必ずしも真値と近くなかった点、つまり、修復よりも創作に近いという点もまた特性と言える。



(a) Input images



(b) Liu et al. [17]



(c) Proposed

図14. 機械学習方式との比較実験で用いた画像一覧.

表 3. 機械学習方式との比較実験結果

	<i>Color</i>	<i>Texture</i>	<i>Average</i>
Proposed	0.0711	0.0863	0.0787
Liu et al. [17]	0.0653	0.1137	0.0888

4.5. 欠損幅の変化に対する補完精度の変化

3章で示したように、提案法は欠損幅に応じて補完処理が変化するが、欠損幅に応じて補完精度がどのように変化するかを確認するため、次のような実験を行った。図15にその概要を示す。実験に用いた画像は3種類(250×250サイズ)であり、それぞれ(a)テクスチャの強い画像、(b)中程度のテクスチャを持つ画像、(c)テクスチャの弱い画像である。これらに適用する欠損領域として、(d)のような白い格子状の欠損領域(縦9本・横9

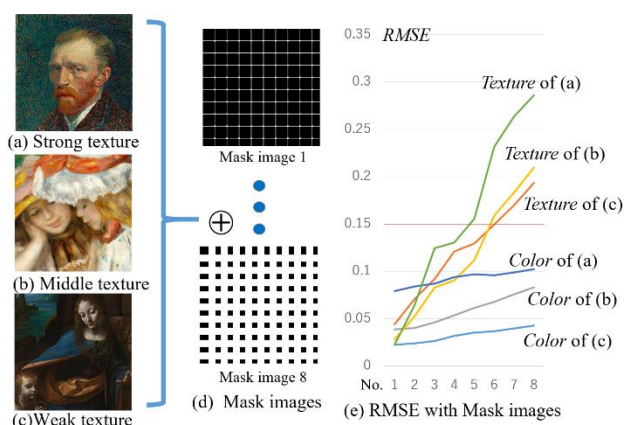



図15.欠損幅の変化による補完精度の変化.


本)を持つマスク画像(No.1.....8)を用意した。マスク画像はNoが大きくなるほど格子の幅、すなわち、欠損幅が大きくなる。幅はNo.1で1画素(画像一辺の0.4%)であり、Noが一つ増えるごとに左右一画素ずつ増えていき、No.8で15画素(画像一辺の6%)となる。これらを(a)(b)(c)の画像3枚に全て適用し、欠損幅に対する **RMSE**の変化を確認した。その結果をグラフ化したものが(e)となる。グラフから、テクスチャの強い画像ほど **RMSE**が大きくなり、またどの画像においても **Color**よりも **Texture**の方が大きくなっていることが分かる。これは、またまった非欠損領域の割合が少なくなるに連れ、**DOB**フィルタで抽出できるテクスチャ情報が減少するためだと考えられる。この点は事例型にも共通する性質である。定性的ではあるが、**RMSE**が0.15を超えた場合にはどの画像でも目視時に強い違和感を覚えたため、目安としてグラフに赤線で記した。目安の赤線より、マスクNo.4に相当する7画素まで、または、画像一辺の3%程度までの幅を持つ欠損を、本研究では有効な修復対象、すなわち、適用できる絵画クラックの範囲としたい。

4.6. 提案法の性能限界

本節では、提案法の性能限界について述べる。まず、提案法は欠損に対する適用範囲の広さが特徴的方式[21]で領域全体を補完するため、絵画クラックのように画像全体に分布する欠損を含む絵画画像にも適用できる。図16にその例を示す。図の入力画像は画像面積の72%が欠損しており、描かれた人物の情報がほとんど得られない。しかし、出力画像では人物とその表情が確認できるようになっている。このように、提案法は画像内の欠損が広範囲・高密度に分布していても、その幅が一定内であり、かつ目や鼻といった構造の全体が欠損していなければ、一定の精度で補完することができる。一方、画像から構造全体が欠損している場合は、その構造を復元することはできない。この点は事例型も含めた統計的方式全体の特徴である。図17にその例を示す。図の入力画像では人物の両目の構造全てが欠損しており、出力画像でもその構造が復元されないまま補完されている。これらの点が提案法の性能限界であり、そして特性となっている。こうした構造の欠損を復元する場合は機械学習方式の利用が考えられるが、データ収集と学習法が課題となる。




(a) Input image



(b) Output image

図16. 広範囲・高密度の欠損に対する提案法の有効性.



(a) Input image

(b) Output image

図17. 構造全体(目)の欠損に対する提案法の性能限界.

5. 結論

本研究では、絵画クラックの仮想修復を目的としたインペインティングを提案した。提案法では、テクスチャ抽出にDOBフィルタを用いることで、抽出するテクスチャにエッジ成分が含まれる問題を改善した。さらに、テクスチャの選択に最小空間距離を用いることで、選択されるテクスチャの精度を向上させた。補完精度は、原画像とのRMSEを評価することで、色情報とテクスチャ情報の両面から定量的に確認した。また、性能限界については欠損幅の観点から定量的に、構造の状態からは定性的に示した。現時点での課題は、step.1, 3のパラメータを画素

数で指定していることである。この点を画像面積に対する比率で指定できれば、解像度の変化に対して汎用性が向上すると考えられる。この点は4.5の実験結果を踏まえて追求したい。また、step.4では事例型や機械学習方式を適用できる程度に非欠損領域と欠損形状が改善した画像もあるため、これらの方式を応用したより高精度で汎用性の高い方式を追求したい。

最後に、今後の展望について修復学の観点を参考にしながら述べたい。絵画の修復学では、年代を基準として三つの時代に分けられるとする考え方がある[29]。最初の時代が1870年から1946年までの期間であり、この時代の修復学は完全補彩と復元補彩を主な技法としている。これは、損傷した領域を可能な限りオリジナルに近付ける、見分けがつかないように修復するという点で、本研究を含む従来のインペインティングは、この時代の修復学に合致すると考えられる。しかしながら、修復学ではこの後、このような技法に対して贋作作成や作品改変を懸念して批判的な立場をとり、新たな思想を持つ修復技法を提示している。今後、絵画画像のインペインティングをさらに進展させる際は、こうした修復学に配慮した手法を提案していきたい。また、絵画に限らず写真が対象となっても、修復学を踏まえることは本分野全体を発展させる重要な要素になると考えられる。近年はリアルな画像加工から情報発信までを個人が行える時代となり、虚実が混交とした視覚情報が溢れている。その状況化下で生じる諸問題の解決や、取り組み方の指針としても、加工領域とオリジナル領域の関係について深く考察した修復学は、重要な役割を果たすと考えられる。今後は、オリジナルの復元や違和感の少なさを最上とする、既存のインペインティングの枠組みに囚われない研究にも取り組みたい。

参考文献

- [1] M. Bertalmio, G. Sapiro, V. Caselles and C. Balleste, Image Inpainting, Proc. ACM Siggraph, 2000, pp.417-424, 2000.
- [2] S. Masnou and J.M. Morel, Level Lines Based Disocclusion, Proc. IEEE Int. Conf. on Image Processing, Vol. 3, pp.259-263, 1998.
- [3] C. Ballester, M. Bertalmio, V. Sapiro, and J. Verdera, Filling-In by Joint Interpolation of Vector Fields and Gray Levels, IEEE Trans. on Image Processing, Vol. 10, No. 8, pp.1200-1211, 2001.
- [4] T. Chan and J. Shen, Non-texture Inpainting by Curvature-Driven Diffusions(CDD), Journal of Visual Communication and Image Representation, Vol.12, No.4, pp.436-449, 2001.
- [5] M. Bertalmio, A. L. Bertozzi, and G. Sapiro, Navier-Stokes, Fluid Dynamics, and Image and Video Inpainting, IEEE CVPR, 2001
- [6] A. Telea, An Image Inpainting Technique Based on the Fast Marching Method," JGT, vol.9, no.1, pp.25-36, 2004
- [7] A.A.Efros and T.K.Leung, "Texture Synthesis by Non-parametric Sampling, Proc. IEEE Int. Conf. on Computer Vision, pp. 1033-1038, 1999.
- [8] R. Bornard, E. Lecan, L. Laborelli and J. Chenot, Missing

Data Correction in Still Image and Image Sequences, Proc. ACM Int. Conf. on Multimedia, pp.335-361, 2002.

[9] A. Criminisi, P. Perze and K. Toyama, Region Filling and Object Removal by Exemplar-Based Image Inpainting, IEEE Trans. on Image Processing, Vol.13, No.9, pp.1200-1212, 2004.

[10] B.Li, Y.Qi and X. Shen, An Image Inpainting Method, Proc. IEEE Int. Conf. on Computer Aided Design and Computer Graphics, pp.531-536, 2005.

[11] N. Komodakis and G. Tziritas, Image Completion Using Global Optimization, Proc. IEEE Conf. on Computer Vision and Pattern Recognition, pp.442-452, 2006.

[12] Y.Wexler, E.Shechtman and M. Irani, Space-Time Completion of Video, Trans. on Pattern Analysis and Machine Intelligence, Vol. 29, No. 3, pp.463-476, 2007.

[13] 河合紀彦, 佐藤智和, 横矢直和, テクスチャの明度変化と局所性を考慮したパターン類似度を用いたエネルギー最小化による画像修復, 電子情報通信学会論文誌. D, 情報・システム J91-D(9), 2293-2304, 2008.

[14]C.Barnes, E.Shechtman, A.Finkelstein, D.Goldman, PatchMatch: A Randomized Correspondence Algorithm for Structural Image Editing, ACM Transactions on Graphics, 2009.

[15]R.Kohler, C.Schuler, B.Scholkopf, S.Harmeling, Mask-Specific Inpainting with Deep Neural Networks, German Conference on Pattern Recognition, 2014.

[16]C.Yang, X.Lu, Z.Lin, E. Shechtman, O.Wang, H.Li, High-Resolution Image Inpainting using Multi-Scale Neural Patch Synthesis, 2017 IEEE Conf on CVPR, pp.4076-4084, 2017.

[17]G.Liu, F.Redal, K.Shih T.Wang, A.Tao B.Catanzaro, Image Inpainting for Irregular Holes Using Partial Convolutions, ECCV2018:Computer Vision-ECCV2018, pp.89-105,2018.

[18]J.Yu, Z.Lin, J.Yang, X.Shen, X.Lu, T.Huang.: Generative Image Inpainting with Contextual Attention,Proc on CVPR 2018, pp.5505-5514,2018.

[19] I.Goodfellow, J.Pouget-Abadie, M.Mirza, B.Xu, D.Warde-Farley, S. Ozair, A.Courville, Y.Bengio, Generative adversarial nets, Proc of NIPS 2014, pp.2672-2680,2014.

[20]S.Iizuka, E.Simo-sera, H.ishikawa, Globally and Locally Consistent Image Completion, ACM Transactions on Graphics, Article No.107, 2017.

[21] 吉田 大海, 飯國 洋二, 空間距離に基づくスクラッチ欠損補完, 画像電子学会誌 第43巻 第3号, pp374-382, 2014.

[22] 吉田 英一郎, 天野 敏之, 佐藤 幸男, 風化により劣化した絵画のデジタルメディア上での復元, 情報科学技術フォーラム一般講演論文集 2002(3), pp125-126, 2002.

[23]吉田 英一郎, 天野 敏之, 佐藤 幸男, 仮想修復による劣化した絵画の修復支援, 画像電子学会研究会講演予稿200, pp153-160, 2003.

[24]薫田 悟志, 天野 敏之, ブラシストロークを利用した絵画の仮想修復, 電子情報通信学会総合大会講演論文集2004年情報・システム(2), pp.329, 2004.

[25] P. Purkait, B. Chanda, Digital restoration of damaged mural images, Proceedings of the Eighth Indian Conference on Computer Vision, Graphics and Image Processing, No.49, pp.1-8, 2012.

[26] B. Comelis, T. Ruzic, E. Gezels, A. Doooms, A. Pizurica, L. Platisab, J.Comelis, M. Martens, M. De Mey, I. Daubechies, Crack detection and inpainting for virtual restoration of paintings:The case of the Ghent Altarpiece, Signal Processing, Signal Processing93, pp.605-619, 2013.

[27]吉田大海, 絵画の質感を考慮したインペインティング, 画像電子学会誌, Vol.44, no.1, pp.77-84, 2015.

[28] S. Peleg, J. Naor, and R. Hartley, D. Avnir, Multiple resolution texture analysis and classification, IEEE Trans. Pattern Analysis and Machine Intelligence, vol6 no.4, pp.518-523, 1984.

[29] 田口かおり, 保存修復の技法と思想 古代芸術・ルネサンス 絵画から現代アートまで, 平凡社, pp.47-144, 2015.

吉田 大海



2012年 神戸大学大学院海事科学研究科博士課程修了。2012年 神戸大学大学院海事科学研究科学術推進研究員。2013年 大阪大学大学院基礎工学研究科助教。2019年 近畿大学工学部電子情報工学科 専任講師。画像処理に関する研究に従事。レンダリングや絵画修復など芸術分野と情報技術の接点に興味を持つ。画像電子学会会員 芸術科学会会員。