

GANを用いた画像の輪郭線に着目した画像修復

皆藤 優太[†] 田村 仁[‡]日本工業大学大学院工学研究科機械システム工学専攻[†]日本工業大学先進工学部ロボティクス学科[‡]

1. はじめに

画像修復とは、画像内に入り込んだノイズや画像の欠損箇所を修復する技術の一つである。

本研究では、画像の欠損箇所の修復を扱う。

近年主流となっている深層学習を用いた画像修復手法は、非常に自然な修復が可能である。

しかしながら、輪郭線(高周波成分)の生成に問題がある。

そこで、輪郭線を先に再現した上で着色することでこの問題の解決を図る。

現在主流である手法に限らず、深層学習を用いて欠損箇所の修復器を作成する手法は、損失関数として訓練画像(修復器への入力画像)と正解画像(訓練画像から修復器が出力する画像の目標画像)との誤差を本質的に用いている。多くの場合、損失関数は画素ピクセルの平均誤差を最小化するように設定されているため、輪郭線がぼやけた画像を出力するように修復器の学習が進む傾向が見られる。

本稿の目的は、輪郭線を修復する修復器を学習する際に用いる損失関数を検討し、輪郭線修復に特化した画像修復手法の提案である。

2. 関連研究

近年、輪郭線の修復を強化するため輪郭線に着目した画像修復手法が提案されている。

現在主流となっている画像の欠損領域を修復する手法は、画像の欠損領域内の輪郭線と色情報を同時に修復するContextual Attention(CA) [1]やGlobally and Locally Consistent Image Completion(GLCIC) [2]のような手法である。

それらに対し、輪郭線に着目した画像修復手法は画像の欠損領域内の輪郭線を修復した後に着色を施す。

そのため、画像修復フレームワーク内に2種類の修復器を用意する必要がある。1つは輪郭線修復を行い、もう1つは着色を行う。2種類の修復器を用意することにより、輪郭線に着目した画

Image inpainting focusing on the outline of the image using GAN

[†] Yuta Kaito, Graduate School of Eng., Dept. of Mechanical Systems Eng., Nippon Institute of Technology.

[‡] Hitoshi Tamura, Dept. of Robotics, Faculty of Advanced Eng., Nippon Institute of Technology.

像修復を実現する。関連研究として、L. Liao et al.らのEdge-aware context encoder for image inpainting[3]や、K. NazariらのEdgeConnect (EG) [4]といった研究がある。

3. 提案手法

本稿の直接的な先行研究であるImage Inpainting Focusing on Edge of Images Using GAN(IIE) [5]では、2値化された修復画像をDiscriminatorへ入力する処理を持つpix2pix[6]と、Wasserstein距離(確率分布間距離の一つ)のみを損失関数に持つWGAN[7]のどちらが輪郭線修復に向いているか調査する実験を行った。結果として、WGANが向いているということを得た。

本稿では[5]の結果を踏まえ、輪郭線修復器の学習を行う際、Wasserstein距離以外の損失関数を加えることによって輪郭線修復の能力向上を図る。

加える損失関数は、輪郭線修復時に輪郭線をはっきり出力させ、輪郭線修復を面的ではなく線的に修復するように修復器の学習が進むような要素を持つと考えられる式(1)から(3)に示す損失関数を用意した。

$$\mathcal{L}_c = \frac{L_{max} - L_{min}}{L_{max} + L_{min}} \quad (1)$$

$$\mathcal{L}_{RCL} = \sum |P_{max} - G| \quad (2)$$

$$\mathcal{L}_s = \lambda_c \mathcal{L}_c + \lambda_{RCL} \mathcal{L}_{RCL} \quad (3)$$

式(1)の損失関数 \mathcal{L}_c は、修復画像のコントラストを求めている。 L_{max} は輝度の最大値、 L_{min} は輝度の最小値を表す。 \mathcal{L}_c はコントラスト値と比例する。

式(2)の損失関数 \mathcal{L}_{RCL} は、輪郭線を示すピクセル値の和を求めている。 P_{max} は任意の画素値、 G は実際に修復した輪郭線の線画画像を表す。本稿では輪郭線を黒線で表現している。 \mathcal{L}_{RCL} は黒色画素値の総和と比例する。

式(3)の損失関数 \mathcal{L}_s は、 \mathcal{L}_c と \mathcal{L}_{RCL} の和を求める損失関数である。 λ_c 、 λ_{RCL} は任意の係数を表している。

式(3)の損失関数 \mathcal{L}_s とWasserstein距離損失関数との和を輪郭線修復器の損失関数とした。

4. 実験

CelebA[8]データセットから約17万枚の画像を用いて修復器の学習用データセットを作成した。輪郭線修復器用のデータセットに用いる輪郭線画像を作成する際にHED法[9]を用いた。また、画素の欠損領域を作成するために[10]のマスキング画像を用いた。

輪郭線修復器の学習に対して損失関数 \mathcal{L}_s を加えたWGANフレームワークを用い、着色器はpix2pixフレームワークにて学習した。それぞれ約17万枚の画像を用いて400エポック分学習した。また、 $\lambda_c=1.0$, $\lambda_{RCL}=1.0$, $P_{max}=-1.0$ とした。

5. 実験結果

学習前に学習用データセットから数枚をランダムに抜き出し、それらを用いて定量評価を行った。定量評価に用いたマスキング画像は、画像全体の約1%~10%を画素値の欠損領域とするものを使用した。SSIM値, PSNR値を用い, CA, GLCIC, EG, IIE[5], 本稿手法(Ours)を比較した定量評価の結果を表1に示す。CA, GLCIC, EGの評価値は[4]より引用した。また, 表1のIIEは画像の25%を占めるサイズのマスキング画像を用いた輪郭線の線画画像に関する評価値である。他手法とIIE間でマスキング画像のサイズが異なるが, 他手法にてマスキング画像のサイズを大きくした際も手法間での評価値の関係性は変化しないと考える。

表1 SSIM値, PSNR値を用いた定量評価値

	SSIM	PSNR[dB]
CA[1]	0.947	31.16
GLCIC[2]	0.947	30.24
EG[4]	0.985	39.60
IIE[5]	0.825	12.13
Ours	0.978	36.89

評価値であるSSIM値, PSNR値は高いほどよい。

また, 本稿手法の修復器への評価用入力画像と修復器から出力された画像を図1に示す。

6. まとめ

実験結果より, 輪郭線へ意図的に着目することで, そうでない手法に対して欠損領域の修復性能の向上が確認できた。

また, 表1より関連研究であるEGに対して定量評価値が及ばなかった。これは, 図1の出力画像から本稿で用いた着色器の着色能力によるものと考えている。

損失関数は対象とするデータの属性などによって変更することが一般的である。輪郭線専用の修復器に対しても同様であると, 今回の結果

から考えている。

今後は輪郭線修復器のみならず, 着色器に対しても着色に特化した損失関数を調査し, 画像修復の性能向上を目指す。




図1 本稿手法にて実際に修復した画像

参考文献

- [1] J. Yu et al.:Generative Image Inpainting with Contextual Attention, arXiv preprint arXiv:1801.07892, 2018.
- [2] S. Iizuka et al.:Globally and locally consistent image completion, ACM Transactions on Graphics(TOG), 36(4):107, 2017.
- [3] L. Liao et al.:Edge-aware context encoder for image inpainting, 2018.
- [4] K. Nazeri et al.:EdgeConnect:Generative Image Inpainting with Adversarial Edge Learning, arXiv:1901.00212v3, 11 Jan 2019.
- [5] 皆藤優太, 田村仁:GANを用いた画像の輪郭線に着目した画像修復, 情報処理学会第82回全国大会講演論文集, Vol. 2020, No. 1, pp.129-130(2020).
- [6] Isola et al.:Image-to-Image Translation with Conditional Adversarial Networks, arXiv:1611.07004, 21 Nov 2016.
- [7] M. Arjovsky et al.:Wasserstein GAN, arXiv:1701.07875v3, 6 Dec 2017.
- [8] Liu et al.:Deep Learning Face Attributes in the Wild, Proceedings of International Conference on Computer Vision(ICCV), Dec 2015.
- [9] S. Xie et al.:Holistically-Nested Edge Detection, 1504.06375v2, Oct 2015.
- [10] G. Liu et al.:NVIDIA Irregular Mask Dataset, <https://nv-adlr.github.io/publication/partialconv-inpainting>, 2018.