

## GANによる画像補完領域拡大時の整合性改善

日大生産工 ○宇野 浩太 日大生産工 山内 ゆかり

## 1. まえがき

近年、スマートフォンの普及により、SNSが発達してきた。特に多いのは、Twitter等といった、写真を投稿するタイプである。これにより誰でも写真を扱うことが増えた。しかし、一般人には高度な画像の編集、加工などは出来ない。そこで、誰でも簡単に学習編集が出来るようにサポートできる人工知能が必要になると考えた。

秋元氏らはGAN<sup>1)</sup>によるカラー調整と画像補完の同時実行を提案し、実際に、画像の合成と、合成部分のノイズ修正などを行える人工知能の制作が成功していることが報告がされている。しかし、挿入画像が大きすぎると、補完が上手くいかないという問題がある。

本研究では、この問題において境界領域と中心領域の分割による段階的補完を提案し、Place2データセットにおける計算機実験により提案手法と従来手法を比較し、提案手法の有効性について報告する。

## 2. 従来研究

## 2.1 GAN

GANとは、Generative Adversarial Network、敵対的生成ネットワークのことである。GANには、二つのネットワークがあり、それぞれ、生成ネットワークと識別ネットワークである。生成器は、参考となる画像を学習し、それらの特徴を踏まえた新たな画像を生み出すことができる。識別器は、入力されたデータがオリジナルか、偽物かを判断するものである。例えるならば、生成器は偽札を上手く作り出す犯罪者、識別器はそれの真偽を見極める警察、といったものである。GANはこの生成と識別を繰り返して、それぞれのネットワークを学習させるものである。




Figure 1 GANの仕組み

## 2.2 合成ネットワークと識別ネットワーク

秋元氏らが制作したGANは、CNNを元とした合成ネットワークで行われている。合成ネットワークの学習手順は、大きく分けて4つの段階に分けられ、合成ネットワークに入力する画像の作成、合成ネットワークでの合成画像の生成、識別ネットワークによるAdversarial lossの算出、そして誤差逆伝播法によるパラメータ更新である。

1段階目では補完とカラー調整の両方を行うよう学習をするための準備で、2段階目では画像の一部分にマスクと言われる補完箇所を指定するものをかけ、その部分を補完する。3段階目では後述するAdversarial lossの計算を識別ネットワークにさせ、4段階目では誤差がより小さくなるようネットワーク各層のパラメータ調整を行う。



Figure 2 秋元氏らの学習システムの概要とテスト手順

Adversarial lossは識別ネットワークを通して算出され、これを用いた目的関数は

$$F_{adv} = \min_G \max_D \mathbb{E}[\log D(x, M_G) + \log(1 - D(G(\tilde{x}_f, x_b), M_G))] \quad (1)$$

で表される。

MSE lossは、合成ネットワークの学習にAdversarial lossと共に利用し、前景画像と出力画像のピクセルごとの差を評価しており、

$$L(x, M_G, \tilde{x}_f, x_b) = \|M_G \odot (G(\tilde{x}_f, x_b)) - x\|_2^2 \quad (2)$$

で表される。そして、このMSE lossを併用することによってGANの学習を安定させることができる。

Improved Consistency of Expanding the Image Completion Area  
by Generative Adversarial Networks

Kouta UNO and Yukari YAMAUCHI

最終的な目的関数は、

$$F_{MSE+adv} = \min_G \max_D \mathbb{E} [L(x, M_G, \tilde{x}_f, x_b) + \log D(x, M_G) + \alpha \log(1 - D(G(\tilde{x}_f, x_b), M_G))] \quad (3)$$

となり、 $\alpha$ はMSE lossとAdversarial lossのバランスを決めるハイパーパラメータである。これらの損失関数と入出力画像の操作方法によって、二つのネットワークを学習することが出来る。

### 3. 提案手法

従来手法では、入力画像が元画像に比べてサイズが1/4以下になる様に設定されていたため、それ以上のサイズを入力すると、補完が上手くいかなかった。そこで私は、補完を二つのステップに分けることにした。1ステップ目では、入力画像と元画像の境界線近くのみを補完する。そして2ステップ目で、全体的な補完を行う。一度に大きく修正するのではなく、2段階に分けることで、大きな入力に対して補完の不具合が出るのを防げると考えた。



Figure 3 提案手法

### 4. 実験および検討

今回の実験において、学習のための画像はPlace2という場所や風景等の画像が集まったデータセットを使い、プログラミングはVisualStudio2017上でC言語を用いて行った。

提案手法による補完方法の1ステップ目では合成箇所の境界線から、一定の距離までを見て、補完を行う。調整する境界線からの距離は実験しながら調整していく。

次に2ステップ目では、補完する範囲を入力画像全体にする。しかしここでは1ステップ目に比べて補完するRGB値の範囲を狭くする。入力画像に、元画像の影響が出過ぎないようにするためである。この工程を繰り返しながら、学習と補完を繰り返していく。

それぞれ従来手法と提案手法の、ピクセルごとの画素値の差から計算したRMSE値の測定を行い、従来手法と提案手法のこの値を比較していく。RMSE値を算出する領域は「カラー調整と補完両領域」と「補完領域のみ」、「カラー調整領域のみ」の三つに分ける。

### 5. まとめ

本稿では、補完領域が大きい時に発生する不自然なカラー調整を解決する手法として、補完を2段階にする手法を用いた。目的として提案手法は入力画像を元画像と比べて1/4以上のサイズを入れることとしていたが、RMSE値の測定による評価がしにくいことが分かった。これは従来手法にあるような失敗例の方が、入力画像へ不自然な補完をしてしまっても、元画像の色合いに近づくためである。

今後の展望として、画像編集に関わるものにさらに貢献できるものと実感している。特別な技術を持たない人でも、アプリケーションという形で運用することができるのではないかと考えている。

#### 参考文献

1) Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio, "Generative Adversarial Networks", arXiv(2014) 1406-2661

2) 秋本 直郁, 林 昌希, 秋月 秀一, 青木 義満, "GANによるカラー調整と画像補完の同時実行", 精密工学会誌, 2018年 84巻 12号 p. 1033-1040