

## 修士論文要旨(2021 年度)

### CycleGAN による色変換した画像を用いた霞除去

# Haze Removal Using Color-Converted Images Via Cycle Generative Adversarial Network

電気電子情報通信工学専攻 橋本 峻吾

## 1. まえがき

近年、自動運転の分野の発展において画像認識技術が活用されており、画像を高品質で撮影することが求められている。しかし、カメラは屋外で使用されるため、周囲の環境によっては画像の品質が低下してしまう。その原因の一つに霞がある。霞は大気中に粒子が存在することによって発生する。大気中の粒子は、撮影するシーンから反射された光を吸収、散乱させるだけでなく、環境光を散乱させカメラに入り込ませてしまう。そのため、撮影された画像は、物の特徴や見た目を表すテクスチャ情報が失われ、コントラストが低下してしまう。これは、特徴抽出や物体認識などのコンピュータビジョンにおいて、精度を低下させる原因となってしまう。また、この霞は光の散乱現象によって発生するため、写りこみ自体を防ぐことは困難である。そのため、一般的には撮影した画像に対して、霞を取り除く Dehazing 手法を施すことで、コントラストの回復を行う。

従来の研究としては、大気散乱モデルとして知られている、物理モデルのパラメータを推定することに基づく。このモデルはシーンの大気状況に依存し、式(1.1)のように表すことができる。

$$I(x) = J(x)t(x) + A(1 - t(x)) \quad (1.1)$$

ここで  $I(x)$  は霞画像、 $J(x)$  は霞のない画像またはシーンの放射輝度、 $t(x)$  は中間の透過マップ、 $A$  は各ピクセル座標上の全球大気光を表し、 $t(x)$  は次の式で表せる。

$$t(x) = e^{-\beta d(x)} \quad (1.2)$$

$d(x)$  は物体とカメラまでの距離、 $\beta$  は大気散乱係数を表す。例えば He らの手法[1]は鮮明な画像の dark channel の値をほぼ 0 に近いと仮定し、それを使用して透過マップを推定する。しかしながら、大気光に似た scene objects には適していない。深層学習ベースの方法は、まず透過マップを推定するために畳み込みニューラルネットワークを使い、それから鮮明な画像を復元するために大気光を推定する。しかし透過マップが十分に推定されていなかった場合、大気光の推定に干渉する。したがって最終的に復元された画像は大抵色の歪みが含まれる。

そこで本研究では、高品質な画像の生成、またはシマウマから馬の画像を変換するといった画像からの翻訳をもつ GAN に着目し、ペアの画像なしすなわち教師なしで行える CycleGAN[2]を用いて霞除去を行う。さらに[2]では学習データセット[3]は RGB 画像で用意されるが、それに加え Lab 色空間など違う色空間に変えたデータセットを用いて学習を行い霞除去の研究に取り組む。

## 2. 提案手法

提案手法の概要と各手法の詳細について述べる。提案手法では、霞画像から鮮明な画像を復元するために、CycleGAN を用いて行う。図 2.1 に提案手法の概要を示す。まず、今回データセットには Realistic Single Image Dehazing というデータセットを用意する。このデータセットの画像は合成霞画像と霞なし画像を含んでおり RGB

画像である。このRGB画像をopen CVを用いてHSV、HLS、LAB色空間に変換する。次にLanczos法を用いてデータセットの画像を256×256のサイズに変換する。CycleGANを用いて、各色空間に変更したデータセットで学習を行い、さらに学習時と同じ色空間でテストを行う。テストで霞除去された画像は各色空間で出力されるため、それをさらにRGB色空間に変換しPSNR、SSIMといった方法で霞除去された画像の評価を行う。

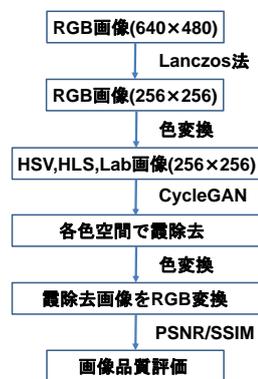


図 2.1 提案手法の概要。

## 2.1 RESIDE

本研究では合成で作られた霞画像と現実の霞画像の両方で構成された Realistic Single Image Dehazing (RESIDE) と呼ばれるデータセットを用いる。このデータセットは多様なデータソースと画像コンテンツを用意し、5つのデータセットに分けられており、その中の ITS、OTS、SOTS という三種類のデータセットを用いる。

## 2.2 Lanczos 法

画像のサイズ変更にLANCZOS法を用いる。今回RESIDEの画像は640×480であったが、CycleGANを使うときに入力画像が256×256に指定されているため、256×256にダウンスケーリングした。リサンプリングする際に使用されるフィルタは、NEAREST、HAMMING、BICUBIC等が

他にあるが、時間はかかるが品質が最も高いLANCZOS法を用いて行った。

## 2.3 色空間

本研究ではRGB画像をLab、HSV、HLS色空間に変換して学習を行う。Lab色空間(CIE $L^*a^*b^*$ 表色系)はRGBやCMYKとは異なり、人間の視覚を近似するような設計をされている。知覚的近等性を重視しており、L成分値は人間の明度の知覚と極めて近い。 $L^*$ 、 $a^*$ 、 $b^*$ 、はそれぞれ明度( $L^*=0$ :黒、100:白)、赤-緑軸( $a^*$ の正值:赤、負値:緑)、黄-青軸( $b^*$ の正值:黄、負値:青)に対応し、反対色に基づく色空間となる。本研究では、cv2.cvtColorメソッドを用いて変換するため値の範囲は、 $0 \leq L \leq 255$ 、 $0 \leq a \leq 255$  および  $0 \leq b \leq 255$  となる。

## 2.4 CycleGAN

CycleGANは図2.2のように二組のDiscriminatorとGeneratorを用いて変換及び逆変換を行なっている。Generator Gはdomain Xの画像xをdomain Yの画像yへ変換し、Discriminator  $D_Y$ は画像yが本物のdomain Yの画像かどうかを識別することを目的としている。対してGenerator Fはdomain Yの画像yをdomain Xの画像xへ変換し、Discriminator  $D_X$ は画像xが本物のdomain Xの画像かどうかを識別することを目的としている。また一度Gによって変換された画像は、再度Fによって逆変換がなされ、変換前の画像と一致させるようにトレーニングを行う(初めにFによって変換された画像についても同様である)。

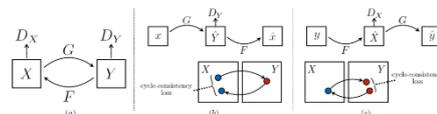


図 2.2 CycleGAN の仕組み。

## 2.5 画像品質評価

画像の評価方法には主観評価と客観評価の2種類がある。主観評価は画像を見た人が自分の感覚に基づいて評価値を決める方法で、客観評価は圧縮符号化により生じた雑音をPSNR、SSIMの手法で定量的に表す方法であり、本研究ではPSNR、SSIMで画像の品質評価を行う。また、画像の数値評価法として良く使われるのが平均二乗誤差(Mean Square Error)、MSEである。MSEは原画像と処理画像との差の2乗誤差である。MSEが小さければ小さいほど原画像に近い画像であり、主に復元などの処理の評価に用いられる。

## 3. 実験評価

### 3.1 はじめに

実験ではRESIDEという霞画像を含む屋外画像のOTSと屋内画像のITSという二つの学習データセットを用いCycleGANで学習し、テストデータに屋外画像、屋内画像それぞれSOTSというデータセットを用い、霞除去を行った結果を述べる。

### 3.2 屋外画像

各色変換の霞除去画像を図3.1に示す。またその各画像のPSNR、SSIM値をまとめた表を表3.1に示す。さらに今回492枚でテストを行ったためその492枚のPSNR、SSIMの平均値を表3.2に示す。

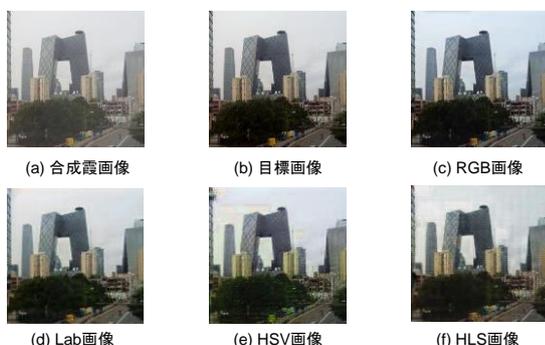


図 3.1 屋外画像霞除去例。

表 3.1 図 3.1 の画像品質評価。

	RGB	Lab	HSV	HLS
PSNR	28.44	26.60	24.85	25.28
SSIM	0.912	0.808	0.723	0.745

表 3.2 492 枚の画像品質評価平均。

	RGB	Lab	HSV	HLS
PSNR	23.16	21.86	20.94	21.20
SSIM	0.863	0.757	0.686	0.735

図 3.1 より RGB 画像で霞除去を行うと、霞が全体的に取れ画像もぼやけることがないが、Lab 画像で霞除去を行い RGB 画像に変換した画像と比べると、目標画像の空の色に対し、青く戻りすぎていることが分かる。表 3.1 は図 3.1 の PSNR、SSIM 値を表すが、従来手法である RGB 画像が PSNR、SSIM 値共に最大となることが分かる。次に Lab 画像で学習し RGB 画像に変換した画像が PSNR、SSIM 共に良い値となった。表 3.2 は 492 枚で霞除去を行い、各画像の PSNR、SSIM の平均値を表すが、表 3.1 と同様な結果になった。

### 3.3 屋内画像

各色変換の霞除去画像を図 3.2 に示す。またその各画像の PSNR、SSIM 値をまとめた表を表 3.3 に示す。さらに今回 500 枚でテストを行ったためその 500 枚の PSNR、SSIM の平均値を表 3.4 に示す。



図 3.2 屋内画像霞除去例。

表 3.3 図 3.2 の画像品質評価。

	RGB	Lab	HSV	HLS
PSNR	20.64	22.80	20.56	15.56
SSIM	0.778	0.798	0.703	0.516

表 3.4 500 枚の画像品質評価平均。

	RGB	Lab	HSV	HLS
PSNR	18.28	18.81	17.76	17.13
SSIM	0.751	0.769	0.703	0.614

図 3.2 より RGB 画像で霞除去を行った画像では全体的に霞が取れており、黒ずむところがなかったが、HSV 画像で霞除去を行い RGB 画像に変換した画像は、黒ずむところがある代わりに奥の方の霞が取れていることが分かる。また HSV 画像で霞除去を行い RGB 画像に変換した画像は、額縁に青みがかかるともなく目標画像に一番近い画像になっていることが分かる。表 3.3 は図 3.2 の PSNR、SSIM 値を表すが、Lab 画像で学習し、RGB 画像に変換した時が PSNR、SSIM 値共に従来の手法である RGB 画像で学習した時の霞除去画像の PSNR、SSIM を超えて、最大となることが分かる。表 3.4 は 500 枚で霞除去を行い、各画像の PSNR、SSIM の平均値を表すが、表 3.3 と同様な結果になった。

#### 4. おわりに

本論文では、RGB 画像から他の色空間に変えて学習・テストし霞除去をする手法を提案した。提案手法では、画像を屋内画像と屋外画像に分け、画像を色変換して行った。結果として屋外画像では従来の手法である RGB 画像で学習した方が平均で一番良い値となったが、屋内画像では Lab 色空間に変換して学習した方が平均して RGB 画像で学習した時の値を超えた。また Lab 画像は空などの青色の空間において RGB 画像よりもよく復元すること分かった。

今後は Cyclic perceptual-consistency loss という損失を CycleGAN[2]の損失に取り入れることでテクスチャ情報を復元できると考える。また、学習データにおいてうまく霞画像を生成しているようには主観的に見てできていなかったため、合成霞画像の改善を検討する必要があると考えられる。

#### 参考文献

- [1] K. He, J. Sun and X. Tang, "Single image haze removal using dark channel prior," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 33, no 12, pp. 2341-2353, 2011.
- [2] J.-Y. Zhu, T. Park, P. Isola and A. A. Efros, "Unpaired image-to-image translation using cycleconsistent adversarial networks," in IEEE International Conference on Computer Vision (ICCV), 2017.
- [3] Li, Boyi and Ren, Wenqi and Fu, Dengpan and Tao, Dacheng and Feng, Dan and Zeng, Wenjun and Wang, Zhangyang, "Benchmarking Single-Image Dehazing and Beyond," in IEEE Transactions on Image Processing, vol. 28, no. 1, pp. 492-505, Jan. 2019.