

雲のテクスチャ解析と敵対的生成ネットワークの融合による
衛星画像からの薄雲除去

Cloud Removal from Satellite Images Using Fusion of Cloud Texture Analysis and
Generative Adversarial Networks

戸泉 貴裕[†] ジニ シモーネ[‡] 鷲 和俊[†] 金子 瑛士[†] 塚田 正人[†]

Takahiro Toizumi Simone Zini Kazutoshi Sagi Eiji Kaneko Masato Tsukada

1. はじめに

近年、光学衛星画像は防災・災害監視、土木建設、農林水産など様々な分野に活用されている。しかしながら、衛星による撮影頻度は通常 2 週間に 1 回程度であり、さらに雲に覆われている場合が多いため、利用できない衛星画像が存在する。一方、衛星画像中の薄雲領域には地上情報が残存しており、衛星画像から薄雲のみを除去することで、解析可能な衛星画像に変換する薄雲除去技術の要求が高まっている。

衛星画像の薄雲除去技術として、雲スペクトルに基づいた物理モデル方式[1]や雲シミュレーションを用いた学習方式[2]が提案されている。物理モデル方式はスペクトル情報に基づいて薄雲下の画素を再構成するため、スペクトル情報が比較的普遍な自然物の多い領域では良好に動作するものの、都市部では薄雲だけでなく建物などの人工物のスペクトル情報も減衰させてしまう問題がある。また、雲シミュレーションを利用した学習モデルでは、実際の観測シーンを忠実に再現したデータを生成することは難しい。実際に観測された衛星画像を用いる場合、同一地点の雲領域を含む画像と含まない画像を学習データの出入力として学習モデルを適用すればよい。ただし、厚雲のため地上情報が残存しない領域では、学習モデルは入力画像に存在しない情報を学習し、推定時にアーティファクトを生成してしまうため、学習データの整理に時間がかかる問題がある。

本稿では上記の問題を解決するため、テクスチャ解析方法のひとつであるグレーレベル同時生起行列 (GLCM) [3] と、学習モデルである敵対的生成ネットワーク (GAN) [4]を融合した薄雲除去ネットワークの学習方法を提案する。テクスチャ解析によって学習データを自動で生成することで、アーティファクト生成などの不都合な学習を防止しながら GAN の薄雲除去モデルを学習できる。提案法で学習された薄雲除去モデルを用いることで、厚雲領域におけるアーティファクトの生成を避け、さらに都市情報を残した薄雲除去処理が可能となる。実験では検証エリアにおける薄雲除去の評価を行い、物理モデルを用いた場合と比較して性能が改善することを示す。

2. 提案方法

2.1 テクスチャ解析による学習データ生成

雲を検出するためのテクスチャ解析方法として GLCM を用いて、入力された衛星画像ペアから学習データの画像ペアを生成する。入力された衛星画像ペアをグレー画像に

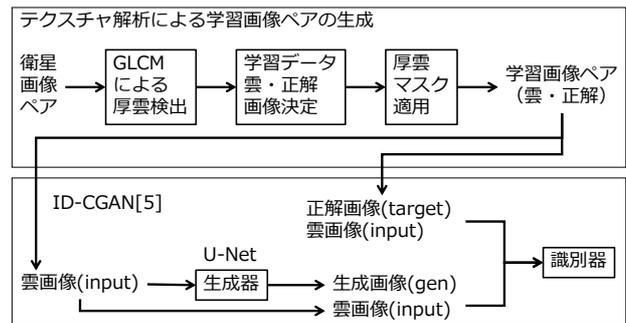


図 1 提案方法の学習フレームワーク

変換し、各画素に対して GLCM mean の値を求める。この値に閾値を設けることで厚雲領域を検出する。次にペアで入力された 2 枚の衛星画像のうち、厚雲領域が大きい方を学習データの雲画像、小さい方を学習データの正解画像として分類する。さらに分類した 2 つの画像の厚雲領域から雲が少ない画像の厚雲マスク M_s と雲が多い画像の厚雲マスク M_l を生成し、(1)式に基づいて雲画像に対するマスク M_a と正解画像に対するマスク M_b を生成する。

$$\begin{aligned} M_a &= M_s \\ M_b &= M_s \cup M_l \end{aligned} \quad (1)$$

最後にマスクによって厚雲領域の各色の画素値を全て 255 の白色に変換した学習データ画像のペアを出力する。本提案における学習フレームワークを図 1 に示す。

2.2 GAN による薄雲除去モデルの学習

薄雲を除去するネットワークとして ID-CGAN [5]を用いる。ID-CGAN は画像から雨や雪などの前景ノイズを除去して背景を強調するネットワークであり、これを用いて薄雲を除去する。推定時には生成器が雲画像から前景ノイズである薄雲を除去した画像を生成する。

ID-CGAN の生成器は U-Net 構造を持つ。また、生成器を学習するための損失関数として画素毎の Euclidean loss L_e 、識別器の出力から計算する Adversarial loss L_a 、VGG の 2_2 層 ReLU 出力の perceptual loss L_p [6]の和を用いる。 L_e と L_p は画素とチャンネル毎の平均二乗誤差とする。 L_a は binary cross entropy とする。

$$L = L_e + \lambda_1 L_a + \lambda_2 L_p \quad (2)$$

識別器は正解画像と生成画像を識別する。識別器の入力は正解画像-雲画像ペアもしくは生成画像-雲画像ペアであり、出力は入力の 1/8 のサイズの特徴マップである。学習時には特徴マップの画素毎に正解か生成物かを識別し、画素毎の binary cross entropy を合計した値を、識別器を学習するための損失関数とする。

[†] NEC

[‡] University of Milano Bicocca

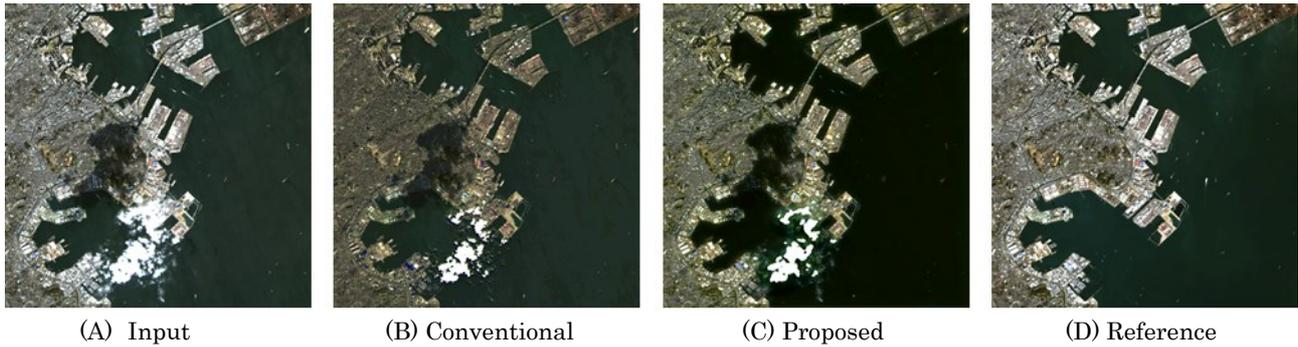


図2 都市部の衛星画像に対する薄雲除去処理の推定結果の比較

3. 実験

実験で用いる衛星画像データは Landsat 8 のマルチスペクトル画像であり、オリジナルは約 8000×8000 画素と7バンドの色チャンネルを持つ。衛星画像データセットの撮影日時を表1に示す。衛星画像ペアは、季節が一致するように撮影日時を選択する。

オリジナルの衛星画像から同じ領域の衛星画像ペアを 256×256 の画素サイズでランダムに切り出す。切り出した画像ペア数は 1500 ペアであり、これらの画像ペアの中には、薄雲と晴れの画像ペアだけでなく晴れと晴れの画像ペアや雲と雲の画像ペアも含まれる。最初に衛星画像を選択する以外には、手動による学習画像のスクリーニングはせずに実験を行う。実験に用いるマルチスペクトルのバンドは Blue, Green, Red, NIR, SWIR2, SWIR3 の6バンドとする。

表1 学習に用いた衛星画像データセットの撮影日時

撮影領域	Input 1	Input 2
都市部：関東(日本)	2015/09/23	2015/10/09
都市部：関東(日本)	2014/06/16	2016/07/07
山森部：キャンベラ (オーストラリア)	2013/09/09	2017/10/22
山森部：ペインズビル (オーストラリア)	2018/01/17	2018/01/17

学習データの生成では、GLCM のパラメータをカーネルサイズ 5×5 、生起行列サイズ 8×8 として厚雲領域の抽出を行う。ID-CGAN のアーキテクチャは[5]で使われているものをそのまま利用する。ID-CGAN の生成器と識別器は Adam optimizer の学習率を 2×10^{-4} として学習する。生成器の損失関数の重みは $(\lambda_1, \lambda_2) = (6.6 \times 10^{-3}, 1.0)$ とする。

4. 結果

図2に都市部における薄雲除去の適用結果を示す。検証データは表1の学習データに含まれる横浜付近で、学習データとは異なる時期の衛星画像を用いる。(A)が入力画像、(B)が従来法[1]の結果、(C)が提案法の結果、(D)が晴天時の参照衛星画像であり、全て RGB の3バンドで表示する。まず、入力画像(A)の下側の海上にある薄雲は従来法と提案法の両方で除去できていることがわかる。しかし、画像左側の都市部をみると、従来法の結果(B)は薄雲を除去できてはいるが同時に都市部の白色の建物の色に変化している。提案法(C)では完全ではないものの、従来法(B)と比較

して、都市部の建物の白色を残しつつ薄雲を除去していることがわかる。

表2に山森部と都市部における薄雲除去適用の PSNR を用いた定量評価の結果を示す。山林部の衛星画像は表1の学習データに含まれるキャンベラ付近で時期が異なる検証データを用いる。都市部の検証データは図2と同じものを用いる。提案法は従来法に比べて山森部では性能は低いものの、都市部での性能は従来法の薄雲除去法に比べて PSNR で 2.1 dB 改善する。

表2 PSNRによる定量評価の結果

Input	Conventional [1]	Proposed
山森部	31.94	28.49
都市部	26.36	28.43

今回の実験では 1500 ペアと比較的少数の衛星画像ペアで検証を行ったため、山森部での PSNR の値が従来法より悪かった。しかし提案法を用いれば学習データを増やすことは容易であるため、山林部においても PSNR の値のさらなる改善が期待できる。また、学習データが少なかったのは都市部でも同様であるため、都市部の PSNR の値も学習データを増やすことでさらに改善できる可能性がある。

5. おわりに

本稿では雲のテクスチャと GAN の融合による衛星画像の薄雲除去を提案した。本提案では、雲のテクスチャに基づいて訓練画像ペアを実観測画像から自動生成することで、厚雲領域のアーティファクトを抑制し、都市部の建物の色の減衰を抑制する GAN の薄雲除去モデルを学習した。実験にて都市部で薄雲除去を行った際の PSNR の値が従来方式と比較して改善することを示した。

参考文献

- [1] Nagare, M. et al., "A unified method of cloud detection and removal robust to spectral variability", IGARSS, 2017.
- [2] Enomoto, K. et al., "Filmy Cloud Removal on Satellite Imagery with Multispectral Conditional Generative Adversarial Nets", In CVPR workshops, 2017.
- [3] Haralick, R. M. et al., "Textural Features for Image Classification.", IEEE Trans. on systems, man, and cybernetics., no. 6, pp. 610-621, 1973.
- [4] Goodfellow, I. et al., "Generative adversarial nets", In Advances in NIPS, 2014.
- [5] Zhang, H. et al., "Image de-raining using a conditional generative adversarial network", arXiv preprint arXiv:1701.05957., 2017.
- [6] Johnson, J. et al., "Perceptual losses for real-time style transfer and super-resolution", In ECCV, 2016.