

PALSAR-2 および PlanetScope を用いた GAN による SAR-光学画像変換 SAR-to-Optical Image Translation Using GANs with PALSAR-2 and PlanetScope

菌部 礼
Rei SONOBE

1. はじめに

合成開口レーダ (SAR : Synthetic Aperture Radar) 画像と光学画像は、それぞれ異なる特性を持ち、リモートセンシングにおいて補完的な役割を果たしている。SAR は全天候・昼夜を問わず観測可能であり、地表の構造情報を高精度で取得できる。一方、光学画像は視認性が高く、農作物の生育状況や地表の状態を直感的に把握するのに適している。特に、農業分野では高解像度の光学画像が必要とされる場面が多いものの、天候条件などにより取得が制限されることが課題となっている。

近年、深層学習の進展により、敵対的生成ネットワーク (GAN : Generative Adversarial Network) を用いた SAR-光学画像変換技術が注目されており、SAR 画像から光学画像を生成し、光学データの欠損を補うことが可能になる。しかし、異なる GAN アーキテクチャの適用や最適なモデルの選択については、さらなる研究が求められている。

本研究では、PALSAR-2 による SAR 画像と PlanetScope (SuperDove) 衛星による光学画像を用いて、複数の GAN 手法を適用・評価し、SAR-光学画像変換の精度向上を目指した。本研究の成果は、農業分野だけでなく、災害監視や土地利用解析など、幅広い応用分野に寄与する可能性がある。

2. 解析方法

本研究の対象地は、静岡県静岡市 (Fig.1) である。SAR 画像としては、2024 年 5 月 12 日に ALOS-2/PALSAR-2 の SM2 観測モードで取得した 4 偏波データを使用した。データの処理レベルは Level 1.1 であり、Earth Gravitational Model 2008 に基づく楕円体高を使用して、ピクセル分解能 6m のオルソ画像(後方散乱係数 γ^0)に変換した。光学画像としては Planet 社の SuperDove 衛星に搭載された PSB.SD で取得した画像を使用した。PSB.SD は、従来の PS2.SD の 4 バンド (赤・緑・青・近赤外) に加えて、コースタルブルー・グリーンI・イエロー・レッドエッジの 4 バンドを追加しているが、本研究では赤・緑・青の 3 バンドでカラー合成して使用した。データの処理レベルは Level 3B であり、ピクセル分解能は 3m であるが、SAR 画像に合わせて 6m にリサンプリングした。

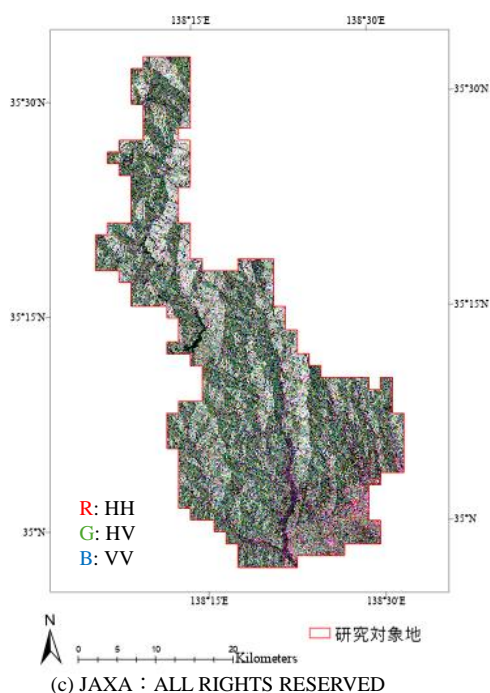


Fig.1 Study area

取得した人工衛星データは450パッチに分割して使用した。各パッチのサイズは、オープンデータセット SEN1-2 dataset と同じ 256×256 ピクセルとした。80%を GAN のチューニングに使用し、残りの 20%を生成画像の評価に使用した。なお、使用したモデルは、Cycle-Consistent Generative Adversarial Networks (CycleGAN), Feature-Guiding Generative Adversarial Networks (FGGAN), Image-to-image translation with conditional adversarial networks (pix2pix), High-Resolution Image Synthesis and Semantic Manipulation with Conditional GANs (pix2pixHD), Exploring Negatives in Contrastive Learning for Unpaired Image-to-Image Translation (PUT), および Query-Selected Attention for Contrastive Learning in I2I Translation (QS_Attn)である。

GAN によって生成した画像と SuperDove 画像の類似性を評価するため、構造類似度指数 (SSIM: Structural Similarity Index Measure)を用いた。SSIM の値が 1.0 に近いほど、生成画像と実際の光学画像が類似していることを示す。

3. 結果及び考察

Fig. 2 はパッチごとに算出した SSIM の分布である。生成画像の青バンドの SSIM はすべての GAN で小さい傾向が確認されたが、GAN のチューニング時にペアとなるデータを必要とする 3 手法 (FGGAN, Pix2pix, Pix2pixHD) の SSIM はペア画像を必要としないその他の 3 手法よりも高い傾向を確認することができた。

農地と森林域が隣接するパッチにおいて、実際に取得された光学画像、生成に使用した SAR 画像および GAN による生成画像は Fig.3 に示すとおりである。GAN のチューニング時にペア画像を必要としない手法による生成画像は森林域と農地の境界を正確に表現できていないどころか、農地を森林のように表現せいているケースも確認された。5 月時点では森林では体積散乱成分が多いと考えられる一方、農作物はあまり成長しておらず、農地では地表などの境界面で生じる表面散乱成分が主と考えられる。後方散乱強度ではなく、偏波の成分分解を活用することで、生成画像の品質が向上する可能性がある。

4. 今後の予定

本研究は 5 月に取得された画像のみを活用しているが、他時期のデータも活用し、生成画像の品質を評価する予定である。また、SAR 画像から、植生の評価に有効な近赤外画像の生成の可能性も検討する。

謝辞 本研究は JSPS 科研費 25K09353 の助成を受けたものです。

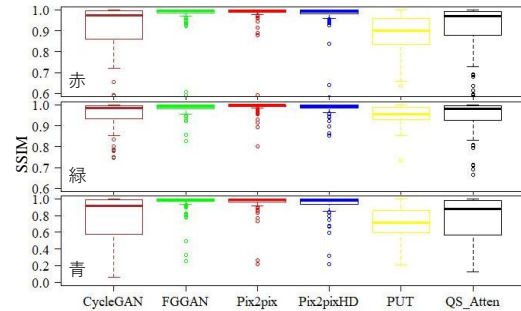


Fig. 2. Boxplots of SSIM PSNR for the six GAN architectures.




Fig. 3. Actual optical image, SAR image used for generation, and GAN-generated image.