

敵対的生成ネットワークと光学情報を用いた SAR 衛星画像の超解像 Super Resolution of SAR Satellite Image using Generative Adversarial Networks and Optical Data

菅家 遼平[†]
Ryohei Kanke

高橋 正信[†]
Masanobu Takahashi

1. はじめに

Synthetic Aperture Radar (SAR) 衛星画像は災害時の被災状況の把握や地上のモニタなど様々な用途で利用されており、正確な情報を得るため、より高解像度の画像が望ましい。しかし、高解像度画像を得るためには観測域を狭める必要がある。また、観測機器を更新する場合も大きなコストがかかる。そこで、得られた低解像度の SAR 画像の高解像度化（超解像：SR）が試みられている[1]。

SAR 画像の高解像度化には一般的には SAR 画像のみが用いられるが、我々は他の情報を追加することで精度を改善できると考えた。具体的には、SAR 画像とともに光学画像が入手できる状況では、光学画像を追加することで精度を改善できる可能性がある。また、CNN（畳込みニューラルネットワーク）を用いた超解像において GAN を利用することで結果を改善できることが示されているが[2]、GAN のネットワークを変更することでさらなる改善が期待できる。さらに、実際に超解像を行い、低解像度画像と超解像された高解像度画像の同じ領域の平均画素値を比較すると、両者が一致しない問題があることがわかった。図 1 右は、図 1 左の低解像度画像を用いた場合の両者の平均画素値の差（高解像度画像 - 低解像度画像）であり、複数の画素で誤差が生じることが分かった。




図 1 超解像前後の平均画素値の不整合

そこで本研究では、①光学画像の追加利用、②GAN のネットワーク変更、③超解像前後の画素値の不整合の補正、の 3 つのアプローチにより、SAR 画像超解像の精度改善を試みた結果、良好な結果が得られたので報告する。

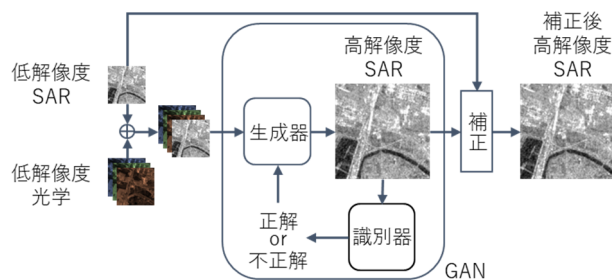


図 2 提案手法の概要

2. 提案手法

SAR 画像の超解像について、以下の 3 点による改善を試みた。手法の概要を図 2 に示す。

① 光学画像の追加利用：SAR 画像の超解像を補助するため、光学画像を SAR 画像に対しチャンネル方向に結合した SAR/R/G/B の 4 チャンネルの画像をネットワークの入力に用いた。

② GAN のネットワーク変更：入力された低解像度画像から高解像度画像を生成する超解像ネットワークを生成器、生成された高解像度画像が正解の高解像度画像か生成された高解像度画像かを識別するネットワークを識別器として学習を行った。

生成器のネットワークを RCAN[3]に変更した。RCAN は Channel Attention を用いることで、特徴量のどのチャンネルに注目すべきか、という重みを学習し、高精度な超解像を実現しており、精度改善が期待できる。RCAN のネットワーク構成を図 3 に、Channel Attention のイメージ図を図 4 に示す。

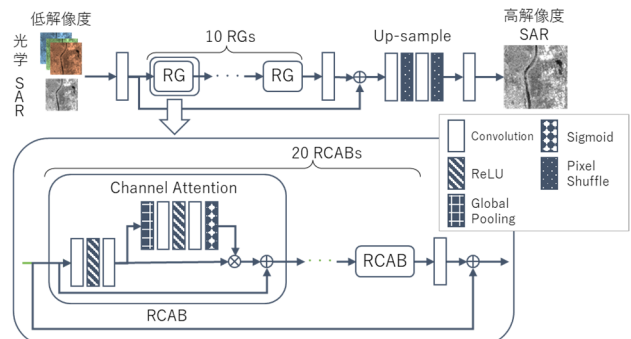


図 3 超解像ネットワークモデル RCAN (RG: Residual Groups, RCAB: Residual Channel Attention Blocks)



図 4 Channel Attention のイメージ

識別器には、その効率の良さから多くの研究で用いられる ESRGAN[4]の Discriminator を採用した。2 つの 3×3 の Convolution 層からなる Convolution ブロックを複数持ち、各ブロックで、特徴量マップの次元を倍にしていき、一方で特徴量サイズは半分に縮小していく。最後に Convolution 層を適応し $n \times n$ のパッチを得る。画像の小領域ごとに本物らしさを判定することで、詳細な部分についての本物らしさを学習することができ、騙されにくくなる。

[†] 芝浦工業大学 Shibaura Institute of Technology

③ 超解像前後の平均画素値の不整合の補正：ネットワークの出力(高解像度画像)に対し、低解像度画像と同じ領域の平均画素値が等しくなるように補正を行った。具体的には、低解像度画像の画素値と高解像度画像の対応する領域の平均画素値の差分を求め、各画素に加算して最終的な高解像度 SAR 画像とした。図 5 に補正処理の例を示す。




図 5 補正処理の例 (拡大率 2 倍)

3. 実験

実験には SEN12MS[5]のデータセットを用いた。これは Sentinel 1, Sentinel 2 のデータで構成されており、8bit, 256 × 256 画素、地上分解能 10 × 10m に統一されている。この内、単偏波 VV の SAR 画像と、可視光にあたるバンド 4, 3, 2 (RGB) の光学画像を用いた。全データの内、重ならない 10,409 ペアの画像を用い、8 割を学習に、2 割をテストに用いた。学習用画像にはデータ拡張として上下左右反転、90/180/270 度回転を行った。

拡大率は 4 倍とし、低解像度画像は高解像度画像の 4 × 4 画素の平均画素値を求めて作成した。入力サイズは 4 (SAR/R/G/B) × 64 × 64 とした。損失関数には Mean Squared Error Loss と敵対性損失を用いた。評価指標には PSNR (Peak Signal-to-Noise Ratio) と SSIM (Structural Similarity Index) を用いた。比較対象に、SAR 衛星画像の超解像タスクに GAN を導入した SRGAN[2]と Bicubic 補間により高解像度化した場合についても高解像度化を行った。




図 6 左：低解像度画像，中：Bicubic 補間による高解像度画像，右：提案手法①②③による高解像度画像

表 1 各手法における平均 PSNR, SSIM (TOP 1 : 太字, TOP 3 : 下線)

光学	PSNR [dB]		SSIM	
	補正なし	補正あり	補正なし	補正あり
Bicubic	-	22.5235	0.5344	0.5858
SRGAN (baseline)	×	22.9274	0.5981	0.5983
SRGAN	○	22.9591	0.6010	0.6008
RCAN	×	22.9431	0.5992	0.5994
RCAN	○	22.9957	0.6024	<u>0.6037</u>
RCAN GAN	×	22.9416	0.5994	0.5994
RCAN GAN	○	<u>22.9995</u>	0.6039	0.6038

4. 結果と考察

表 1 に実験結果を、図 6 に超解像結果の例を示す。提案手法①②③全てを採用することで、既存手法の SRGAN から PSNR が 0.0733[dB], SSIM が 0.0057 改善された。

手法ごとの効果について検討すると、まず提案手法① (光学画像の追加利用)により、SRGAN (従来ネットワーク, GAN 利用), RCAN (ネットワーク変更, GAN 無し), RCAN GAN (ネットワーク変更, GAN 利用) の全ての場合について PSNR と SSIM は改善され、光学画像の利用は精度改善に有効であった。SAR 衛星は他の偏波を観測でき、また光学衛星は可視光以外の波長も観測できるため、他の偏波、波長の利用によりさらに改善できる可能性がある。

提案手法② (GAN のネットワーク変更)で生成器を RCAN にすることで、PSNR は 0.0404~0.0134[dB], SSIM は 0.0030~0.0011 改善された。SAR 衛星画像においても、Channel Attention を備える RCAN が優れた結果を示すことが分かった。GAN の利用によっても基本的に精度が改善されたが、SAR 画像のみで RCAN を用いた場合だけ SSIM にほとんど改善が無く PSNR はわずかに劣化した。これは GAN の学習の不安定性から良好に学習できなかったからと考えている。

提案手法③ (超解像前後の平均画素値の不整合の補正)により、SSIM についてはほとんど改善がなかったが、PSNR は 0.0033~0.0003[dB]改善された。SSIM は人の知覚に近い評価指標であるため、知覚的には改善がほとんど無いことになるが、画素値の誤差を反映する PSNR が改善されたことから、画素値自体はより正確になったと言える。

5. おわりに

光学画像をネットワークの入力に追加することで、SAR 衛星画像の超解像の精度 (PSNR, SSIM) を改善できた。また、超解像前後での平均画素値の整合性を保つために、画素値の補正を行うことで SSIM を保ちつつ PSNR を改善できた。さらにネットワークの生成器に RCAN を採用することでも精度を改善できた。

本研究では偏波 VV の SAR 画像とバンド 2, 3, 4 の光学画像のみを用いたが、今後は他の偏波や波長のデータも利用することで改善できないか検討するとともに、GAN の学習の安定化や超解像ネットワークの改善による精度改善にも取り組みたい。

参考文献

- [1] H. Shen, et al., "A residual convolutional neural network for polarimetric SAR image super-resolution", ISPRS Journal of Photogrammetry and Remote Sensing, Vol.161, pp.90-108 (2020).
- [2] C. Ledig, et al., "Photo-realistic single image super-resolution using a generative adversarial network", Proc. of the IEEE conf. on CVPR, pp. 4681-4681 (2017).
- [3] Y. Zhang, et al., "Image super-resolution using very deep residual channel attention networks", Proc. of the ECCV, pp. 286-301 (2018).
- [4] M. Schmitt, et al., "SEN12MS--A Curated Dataset of Georeferenced Multi-Spectral Sentinel-1/2 Imagery for Deep Learning and Data Fusion", arXiv:1906.07789 (2019).
- [5] X. Wang, et al., "EsrGAN: Enhanced super-resolution generative adversarial networks", Proc. of the ECCV workshops, pp. 63-79 (2018).