

学習型超解像と再構成型超解像の異なる組み合わせ順による 時系列画像の画質改善

Image Quality Improvement of Sequential Images by Different Combination Orders of Learning-based and Reconstruction-based Super Resolution

堀隼也[†] 加藤裕也[†] 渡辺裕[†]
Toshiya HORI[†] Yuya KATO[†] Hiroshi WATANABE[†]

[†] 早稲田大学大学院基幹理工学研究科
[†] Graduate School of Fundamental Science and Engineering, Waseda University

Abstract When we apply a super resolution (SR) and a sequential images reconstruction, there are 2 orders of their combination. We combine these two orders and create five SR images from three low resolution images and we'll average them and improve PSNR.

1. はじめに

近年、出力デバイスの高解像化に伴い、低解像度のコンテンツを高解像度のデバイスに出力する際、そのアップスケーリングの方法が重要となっている。増加した画素を線形的に補間すると高周波成分が失われ、ぼやけた画像となってしまう。そこで、異なる解像度の同じ画像のペアを小領域ごとのパッチに分け、低解像度パッチと高解像度パッチとを学習させた学習型超解像や、前後フレームから標本点を集め、画素数を増加させる時系列超解像などの超解像技術が考案されている。近年ではこれらの超解像技術に対し深層学習が適用され、超解像の精度を向上させている。なかでも ResNet の構造を改良した EDSR^[1]では残差信号を伝搬させることでより深い層まで学習をさせることが可能となった。また、深層学習は様々なコンピュータビジョンのタスクに用いられており、オプティカルフローの予測についても、深層学習を用いることで画素ベースから特徴空間ベースでオプティカルフローを予測することができ、精度が向上している。本稿では、超解像技術とオプティカルフロー予測を用いて、時系列画像をアップスケーリング、時系列再構成を行い、これらの適用の順番を変化させることで、超解像の出力結果を向上させる手法を提案する。

2. 符号化された時系列画像の加算平均

符号化された時系列画像を、オプティカルフローを用いて再構成し、該当フレームと再構成フレームの加算平均をとると、符号化によって生じたノイズが打ち消し合い、時系列画像の画質向上が見られる^[2]。また、学習型超解像の主な手法ある SRCNN, EDSR, A+は入力画像の角度を変えて入力し、その出力画像の角度を元に戻すと異なる出力画像が得られる^[4]。これは学習

したパッチに基づいて低解像から高解像に置き換えており、角度が変わると適用されるパッチの種類が変わることに起因している。また、入力画像の角度を変えて作成した超解像画像を加算平均することで、アップスケーリングによって生じるノイズを打ち消し合い、超解像画像品質が向上する。

3. 提案手法

本稿では符号化画像をアップスケーリングする際の画質改善について検討する。符号化画像をアップスケーリングする際に、前述の時系列画像を再構成し画素平均をとる手法と学習型超解像を用いたアップスケーリングを適用するとする。この際にこれらを組み合わせる方法は、以下の二つに分類される。

- 1.) 時系列再構成した後、学習型超解像を施す
- 2.) 学習型超解像を用いた後、時系列再構成を施す

これら二つを組み合わせた手法のブロック図を図 3.1 に示す。本手法では、3枚の連続した低解像度画像 (LR) を入力とし、LR 間で k フレームへの再構成画像 (LR Predicted) を生成する。その後、LR と LR Predicted の合計 5 枚を EDSR により超解像を行いそれぞれ HR, HR predicted^②を得る。その後、HR 3枚からそれぞれ k フレームへの再構成画像 (HR predicted^①) を作成し、HR predicted $_{k-1 \rightarrow k}$ ^{①, ②}, HR predicted $_{k+1 \rightarrow k}$ ^{①, ②}, HR の合計 5 枚の加算平均をとる。また、オクルージョン部の平均を取る際、EDSR のみで作成した画面との差分が閾値以上の場合その部分をオクルージョンと判断し、その部分の重みを 0 として平均を計算する。

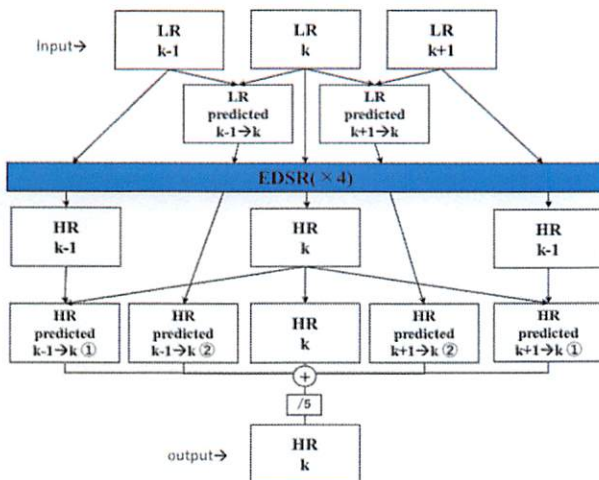


図 3.1 提案手法のブロック図

4. 結果

提案した手法をデータセット MPI Sintel Flow Dataset^[5]の12個のテストシーケンスに対し適用し、入力画像の縦横それぞれを4倍に拡大した出力画像のPSNRを測定した。また、単純にEDSRのみで拡大した場合、 $\text{predicted}_{k-1 \rightarrow k} \textcircled{1}$, $\text{HR predicted}_{k+1 \rightarrow k} \textcircled{1}$, HRの3枚で加算平均をとった場合、 $\text{HR predicted}_{k-1 \rightarrow k} \textcircled{2}$, $\text{HR predicted}_{k+1 \rightarrow k} \textcircled{2}$, HRの3枚で加算平均をとった場合と本手法を比較した。この結果を表4、生成した画像を図4.1に示す。

単純にEDSRのみを使って超解像を施した場合と本手法とを比較すると、PSNRに大きな変化は見られなかった。また、PSNRの向上が見られた“bamboo_3”, “market_1”, “market_4”, “mountain_2”, “tiger”のシーケンスはその他のシーケンスと比較し、大きな動きが少ない、画面が明るくフレーム間の変化がわかりやすい、

表4 提案手法のPSNRの比較

PSNR[dB]	EDSR	5 images average	3 images average①	3 images average②
ambush_1	36.61010	-0.05943	0.07481	0.05523
ambush_3	35.36956	-0.07650	-0.02904	-0.11700
bamboo_3	27.70198	0.02648	0.03577	0.01948
cave_3	32.66400	-0.06250	-0.03073	-0.07944
market_1	32.00046	0.02025	0.06481	0.00644
market_4	30.26469	0.02975	0.03027	0.02056
mountain_2	37.98242	0.02025	0.06481	0.00644
PERTURBED_market_3	34.20415	-0.02429	0.06173	-0.08575
PERTURBED_shaman_1	37.14779	-0.21771	-0.06460	-0.36590
temple_1	28.65075	0.00100	0.00100	-0.00200
tiger	30.86817	0.01569	0.03054	-0.00240
wall	39.96904	-0.32731	-0.03919	-0.61340

5 images average : average of HR predicted①② and HR

3 images average①: average of HR predicted① and HR

3 images average②: average of HR predicted② and HR




図 4.1 提案手法の出力結果

フレーム間に連続性があるといった傾向があり、オプティカルフローの予測のしやすさに結果が依存すると考えられる。また、HRから作成した予測フレームとHRの平均画像である“3 images average①”のPSNRが表中の他の平均画像よりも高い傾向がある。一方でLRから作成した予測フレームの超解像画像とHRの平均画像である“3 images average②”は、PSNRが低い傾向があり、低解像画像で再構成しているため情報が失われ、かえってノイズとなっている可能性が考えられる。

5. むすび

本稿では時系列再構成と学習型超解像の組み合わせ順による出力結果の画質変化について実験した。再構成部でのノイズの影響により十分な効果を得られたとは言えないが、オクルージョンの処理を含むオプティカルフローの精度がさらに向上することで本手法の有効性を十分に示すことができると考えられる。

文 献

- [1] Lim, Bee and Son, Sanghyun and Kim, Heewon and Nah, Seungjun and Lee, K. Mu : “Enhanced Deep Residual Networks for Single Image Super-Resolution”, The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, (July.2017)
- [2] Tak-Wai Hui and Xiaoou Tang and Chen Change Loy : “LiteFlowNet: A Lightweight Convolutional Neural Network for Optical Flow Estimation”, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 8981--8989, (June. 2018)
- [3] 堀隼也, 渡辺裕 : “超解像を用いた時系列画像の画質改善”, 電子情報通信学会総合大会, D-11-6, (March.2019)
- [4] 矢野仁愛, 梅田聖也, 渡辺裕, 猪飼知宏, 中條健, 伊藤典男 : “画像の方向性を考慮した超解像処理技術”, 映像情報メディア学会冬季大会, 14B-2, (Dec.2017)
- [5] D. J. Butler, J. Wulff, G. B. Stanley, and M. J. Black: “A Naturalistic Open Source Movie for Optical Flow Evaluation” European Conf. on Computer Vision (ECCV), pp. 611-625, (2012)

† 早稲田大学基幹理工学研究科 情報理工・情報通信専攻

〒169-0072 東京都新宿区大久保 3-14-9

早大シルマンホール 401号室 TEL.03-5286-2509