

レイヤー方向のアテンションとチャンネル方向のアテンションに基づく畳み込みニューラルネットワークによる画像超解像に関する研究

Image Super-Resolution Based on Layer-and Channel-Attention Convolutional Neural Network

セキユンコウ

指導教員 青木輝勝

東京工科大学 コンピューターサイエンス専攻 青木研究室

超解像, layer attention, channel attention

1 はじめに

近年, ディープラーニングの急速な発展に伴い, 画像の超解像に関する研究が飛躍的に進展している. しかし, 既存のアルゴリズムでは, レイヤー特徴や高周波情報を有効に利用する機能がない. その結果, 再構成された高解像度画像の品質は実用上十分なものではない. この問題を解決するために, 本研究では, CADN (Channel attention Dense Network) と呼ばれる新しい超解像手法を提案する. CADN は低解像度画像から高解像度画像へのエンドツーエンドの学習マッピングができる畳み込みニューラルネットワーク. CADN は, RDB (Residual Dense Block) と ECAB (Efficient Channel Attention Block) を組み合わせたレイヤー方向のアテンションとチャンネル方向のアテンションに基づく CADB (channel attention Dense Block) に構成された. 実験の結果によると CADN は 5 つのデータセットで既存の手法を上回る.

2 関連研究

2.1 チャンネル方向のアテンション(Channel attention)

チャンネル方向のアテンションは画像の各チャネルの情報価値を踏まえて, 適応に各チャネルに重みを付ける. これにより, 畳み込みニューラルネットワークの性能を向上させることができる [1].

2.2 レイヤー方向のアテンション(layer attention)

ネットワークモデル内の各畳み込み層の出力を漏れなく効率的に利用し続けることができる機能は本論文でそれを「レイヤー方向のアテンション」と呼ぶ.

2.3 RDB

RDB は複数の残差ブロックを密に連結して (dense connection) 各層からの出力を後続の畳み込み層に渡すことで, 各層からの出力を確実に有効活用できるようにしたレイヤー方向のアテンションに基づくモジュールである [1].

2.4 ECAB

ECAB は任意のチャネルとそれに接続された k 個のチャネルの間の関連性を通して, チャネル重みを適応的に決定することでチャネルアテンションを効率的に学習できる軽量化のモジュールである [2].

3 提案手法

本研究では, ECAB と RDB を組み合わせてチャンネル方向のアテンションだけでなく, レイヤー方向のアテンションも効果的に利用することができるよう CADB を構成した. その主な理由は RDB が dense connection (図 1) によってモジュール内の各畳み込み層の出力特徴の利用を強化でき, 1×1 畳み込みによる次元削減を行うからである. 一方, ECAB はパラメータが少ないため, 次元削減をしない. 従って, RDB のように複数の ECAB を densely connect する構造は, お互いの欠点を補い合うことができ, 結果として超解像再構成にうまく対応できるのではないかと考えている. 最終的には, CADB モジュールで非常に深い畳み込みニューラルネットワーク CADN を構築した. CADB と CADN

の構造は図 1, 図 2 に示す.

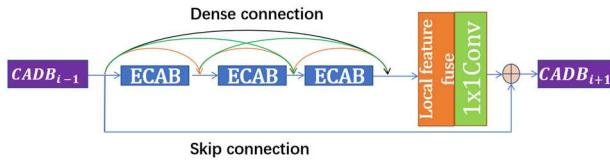


図 1: CADB

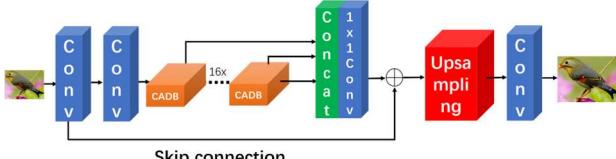


図 2: CADN

4 実験

この提案手法の有効性を確認するため, 4 倍の超解像再構成実験を行った.

CADN の学習は 91 images データセット [12] で行い, 検証は set5 のデータセットで行った. ネットワークモデルが畳み込み層で構成されていることを考慮し, 学習セットから一度に 64 枚の画像を抽出し, ハイパーパラメータ $1e-3$ の adam optimizer 用いて最適化した. 学習には 30 エポックを要する.

テストで使われるデータセットは Set14, General100, BSD300, DIV2K, Manga109 です. 結果は PSNR と SSIM で評価し, 表 1 に示す.

Dataset	Scale	SRCCNN	EDSR	FSRCNN	My
Set14	4x	23.38/0.5 0682	25.57/0.6 4105	27.30/0.7 5776	27.96/0.7 5516
Manga109	4x	22.44/0.4 5449	25.60/0.6 9699	27.99/0.8 5117	28.93/0.8 8423
BSD300	4x	24.10/0.5 2185	25.94/0.6 2898	27.76/0.7 4643	27.96/0.7 5516
DIV2K	4x	24.71/0.5 1914	27.19/0.6 8280	29.33/0.8 0714	29.64/0.8 1922
General100	4x	24.21/0.5 2103	27.39/0.7 0817	30.25/0.8 4256	30.38/0.8 4746

表 1: set5, set14, Manga109, DIV 2K, General100 での比較結果, 赤がベストパフォーマンス. スケーリングファクター $\times 2$, $\times 4$ での PSNR/SSIM の平均値.

5 結論

本研究では CADB と呼ばれるレイヤー方向のアテンションとチャンネル方向のアテンションを用いた新しい超解像に適するモジュールを提案した.

このモジュールは少ないパラメータでレイヤーの特徴を有効に利用しながら, 異なるチャンネルの重要度を見極めて, チャンネル重みを適応的に決定してより効率的にチャンネル方向のアテンションを学習させることができる. さらに, 画像超解像処理のための超深層ネットワークモデル CADN を構築した. 実験結果により, CADN は FSRCNN や EDSR といった既存の手法よりも優れた性能を発揮することが示された.



図 3: 実験結果の画像

6 参考文献

- [1]. Qilong Wang, Banggu Wu, Pengfei Zhu, Peihua Li, Wangmeng Zuo, Qinghua Hu. ECA-Net: Efficient channel attention for Deep Convolutional Neural Networks. arXiv:1910.03151v4 [cs.CV] 7 Apr 2020
- [2]. Zhang Y, Tian Y, Kong Y et al. Residual Dense Network for Image Super-Resolution[J]. IEEE, 2018.