1Q-07

レイヤ方向/チャ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†　青木輝勝†
† 東京工科大学バイオ・情報メディア研究科コンピュータサイエンス専攻

キーワード:超解像,　レイヤテンション,　チャネルアテンション

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, 超解像技術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, レイヤ特徴や高周波情報を有効に利用できていないため, 出力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稿では, 新しい超解像手法 CADN (Channel Attention Dense Network)を提案する. CADN は CADB (Channel Attention Dense Block) と呼ぶブロックを導入し, 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をできる畳み込みニューラルネットワークネットワークを構成している. CADB は, RDB（Residual Dense Block）と ECAB（Efficient Channel Attention Block）を組み合わせたレイヤ方向アテンションとチャネル方向アテンションを実現するモジュールである

評価実験の結果, CADN は 4 つのデータセットで既存の手法を上回ることがわかった.

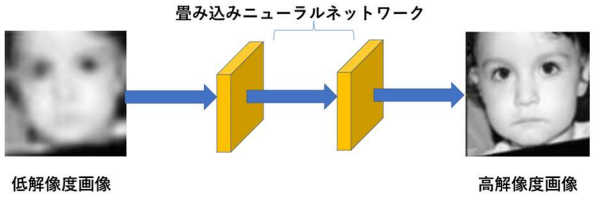

図 1　畳み込みニューラルネットワークによる画像の超解像

2 関連研究

2.1 チャネル方向アテンション(Channel attention)

チャネル方向アテンションは画像の各チャネルの情報の重要度を踏まえて, 適応的に各チャネルに重みを付ける機能を指す. 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てきる[1].

2. 2 レイヤ方向アテンション(Layer attention)

ネットワークモデル内の各畳み込み層の出力をレイヤ位置が離れていても利用することができる機能を本稿では「レイヤ方向アテンション」と呼ぶことにする.

2.3 RDB

RDB は, 複数の残差ブロックを密に結合して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レイヤ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で, チャネル重みを適応的に決定することができるブロックであり, チャネルアテンションを効率的に学習することができる. [2]

3 提案手法

本稿では, ECAB と RDB を組み合わせてチャネル方向のアテンションだけでなく, レイヤ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にしたモジュール CADB を導入する. これにより, RDB が全結合(図 2)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することができ, 1x1 畳み込みによる次元削減を行うことができるからである. 一方で ECAB はパラメータが少ないため, 次元削減をしない. つまり, RDB のように複数の ECAB を全結合で接続する構造を作り

Copyright ©2023 Information Processing Society of Japan.
All Rights Reserved.

出すことによりお互いの欠点を補い合うことができ,結果的に超解像というタスクに対してうまく対応できると考えられる．本稿で提案する CADN はこのような特徴を持つ CADB モジュールを用いて非常に深い畳み込みニューラルネットワークを構築したものである. CADB と CADN の構造を図 2, 図 3 に示す.

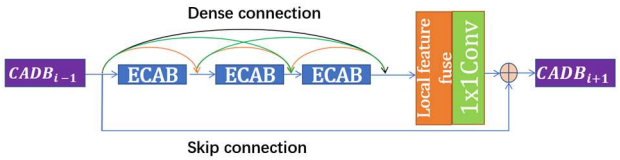

図 2 CADB

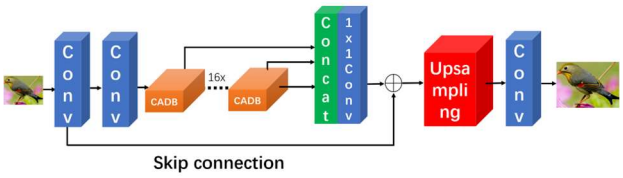

図 3 CADN

4 評価実験

提案手法の有効性を確認するため, 2 倍と 4 倍の超解像実験を行った.

CADN の学習は 91images データセット[12]で行い, 検証は set5 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. 学習の回数は 30 エポックである.

テストで使われるデータセットは Set14, General100, DIV2K, Manga109 です. 結果は PSNR と SSIM で評価した. この結果を図 4 ならびに表 1 に示す.

5 結論

本研究は CADB と呼ばれるレイヤ方向のアテンションとチャネル方向のアテンションを併せ持つ新しい超解像に適するモジュールを提案した. CADB モジュールは少ないパラメータでレイヤの特徴を有効に利用しながら, 異なるチャネルの重要度を基準にして, チャネル重みを適応的に決定してより効率的にチャ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 SRCNN と FSRCNN などの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.

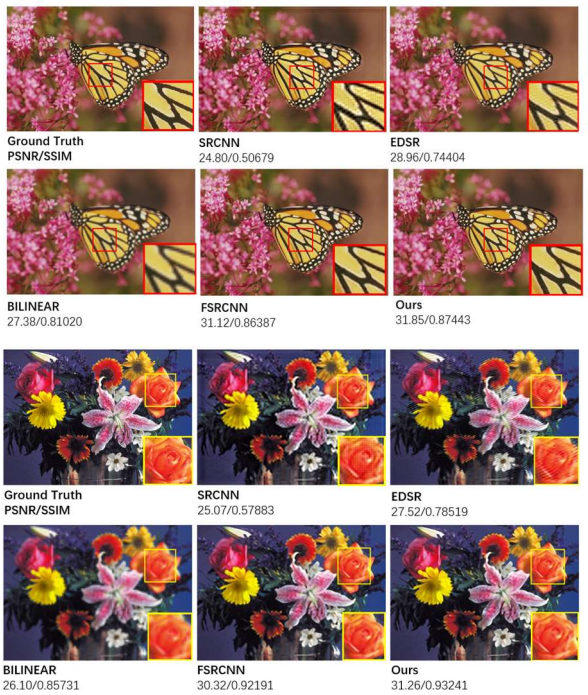

図 4 4 倍超解像の出力画像

Dataset	Scale	SRCNN	FSRCNN	Ours
Set14	2x	32.08/0.90792	32.52/0.91225	**32.69/0.91280**
Manga109	2x	36.00/0.96858	37.39/0.97433	**37.93/0.97693**
DIV2K	2x	34.45/0.93124	34.98/0.93669	**35.13/0.93829**
General100	2x	36.56/0.95538	37.36/0.96046	**37.74/0.96216**
Set14	4x	23.38/0.50682	27.30/0.75776	**27.96/0.75516**
Manga109	4x	22.44/0.45449	27.99/0.85117	**28.93/0.88423**
DIV2K	4x	24.71/0.51914	29.33/0.80714	**29.64/0.81922**
General100	4x	24.21/0.52103	30.25/0.84256	**30.38/0.84746**

表 1. 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 ×2, ×4 での PSNR/SSIM の平均値.

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.

Copyright ©2023 Information Processing Society of Japan.
All Rights Reserved.