

量子化幅適応型ディープラーニングを用いた H.265/HEVC 符号化雑音除去 A Noise Reduction Method for H.265/HEVC Compressed Image based on Quantization-width-dependent Deep Learning

神保 悟[†] 王 冀[†] 八島 由幸[†]
Satoru Jinbo Ji Wang Yoshiyuki Yashima

1. はじめに

近年、深層学習による画像処理手法は、物体認識にとどまらず、雑音除去、超解像、彩色、画像補完など様々な応用が検討されている。その一例として、圧縮符号化を施した後の復号画像に含まれる雑音を深層学習によって取り除く手法[1][2]が提案され、従来よりも優れた性能効果を発揮することが示されている。これらの手法では、畳み込みニューラルネットワーク (CNN) を設計する際に、量子化の細かさを決める量子化パラメータをすべてのブロックで同一とした前提で検討が行われている。本研究では、CNN 出力の相関関係を用いることで、ブロックごとに量子化パラメータを適応化して符号化された画像についても良好に適応する符号化雑音除去手法を提案する。

2. CNN による符号化雑音除去

文献[1][2]では、式(1)(2)のように入力画素 x に対して重み w を畳み込み、バイアス b を加算した上で、活性化を行う層を積み重ねた CNN を用いている。復号画像を CNN に入力し、CNN の出力画像と符号化前の原画像との誤差を損失関数とし、損失関数が小さくなるように重みの更新を行うことで、原画像を推定する CNN を設計する。

$$y = x * w + b \quad (1)$$

$$z = \max(0, y) \quad (2)$$

また、文献[2]では、CNN の出力として原画像を直接推定するのではなく、原画像と復号画像の差分画像を生成した後これを復号画像に加算することで、雑音除去を行う。これらの手法では、量子化パラメータ (以降 QP, QP が小さいほど量子化幅が細かい) は画像全体で一つの値に固定して検討を行っている。しかし、H.265/HEVC をはじめとする国際標準符号化方式ではブロックごとに QP を変更することができ、視覚的な画質を向上する目的で、多くのエンコーダがこの仕組みを利用している。このような画像に対しては、QP 固定で設計された従来の CNN では十分な性能が得られないため、新たな手法を検討する必要がある。

3. 提案手法

本検討を進めるため、CNN 設計時の QP と、符号化時の QP が異なる場合に雑音除去性能がどのように変化するかを調べた。符号化手法は H.265/HEVC を用いた。本検討の CNN は[1][2]の手法を組み合わせ、図 1 のような 4 層の畳み込み層を持ち、入力画像 (復号画像) と原画像の推定誤差画像を出力するように構築した。出力層では式(2)は行わずに出力する。

すべてのブロックを QP=32 として符号化した画像を用いて訓練を行って得られた CNN を用い、様々な QP で符号化した画像をその CNN に入力して得られる雑音除去画像の PSNR を測定した。図 2 は、雑音除去を施さない場合の PSNR に対する改善量を示す。QP を CNN 設計時と同一にした場合が最も効果が高く、設計時よりも大きい QP で符号化した画像では雑音除去効果が緩やかに減少する。また、設計時よりも小さい QP で符号化した画像に対しては、雑音除去効果は急激に減少し、復号画像そのものよりも大きく劣化してしまうことが確認できる。訓練時の QP を 27 と




図 1 実験に用いた CNN

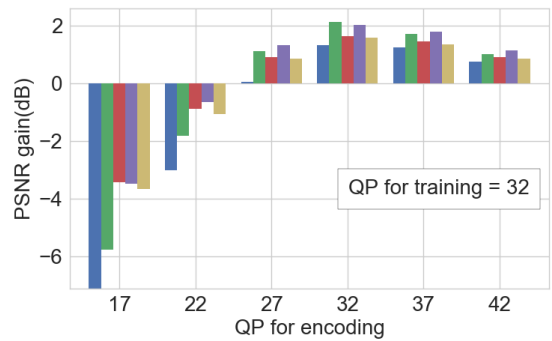


図 2 雑音除去を施さない場合の PSNR に対する改善量

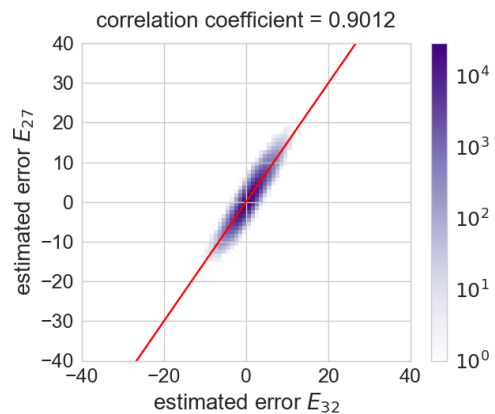


図 3 2つの CNN の推定誤差の 2 変量ヒストグラム

[†] 千葉工業大学大学院情報科学研究科

[†] Graduate School of Information and Computer Science, Chiba Institute of Technology

して実験を行った場合にも、同様の傾向があることが確認できた。よって、訓練時と符号化時の QP の違いを吸収する仕組みが必要である。

一方、図 3 は、原画像 $img1$ を $QP=32$ で符号化した画像を、 $QP=32$ および $QP=27$ で訓練したそれぞれの CNN に入力した際の出力 E_{32} 、 E_{27} に対して、推定誤差画像 E_{32} と E_{27} の 2 変量ヒストグラムを示したものである。図 3 から、2 つの CNN の出力には相関関係があることが確認できる。また、赤色の直線は、原画像と $QP=32$ の符号化画像との平均絶対誤差(MAD)と、原画像と $QP=27$ の符号化画像との MAD の比を係数とした直線であり、その傾きは実測ヒストグラムの分布と強い相関を示す。

以上より、符号化時の QP がブロックごとに異なる画像に対する雑音除去として、以下の手法を提案する。事前に、画像全体で固定の QP (=QPO) を用いて符号化した画像を用いて訓練を行い原画像との差分値を推定する CNN を設計しておく。符号化雑音除去については、まず、ブロックごとに異なる QP 値で符号化した画像を CNN に入力し、推定誤差画像 E を出力させる。次に、推定誤差画像のブロック E_b を以下の式(3)で補正する。ただし、 MAD_t は $QP=QPO$ で符号化した画像と原画像との MAD、 MAD_b はブロックに設定された QP で符号化した画像と原画像の MAD である。

$$E_b' = \frac{MAD_b}{MAD_t} E_b \quad (3)$$

すべてのブロックに対してこの処理を行い、得られた E' を入力画像に加算することで、雑音除去を行う。

4. 実験と考察

4.1 実験条件

H.265/HEVC 符号化時に、画面全体の基準となる QP に対して、 n 番目のブロックの量子化パラメータ $QP'(n)$ を式(4)(5)のように計算し、ブロックごとに変化させた。

$$QP'(n) = r_n \times QP \quad (4)$$

$$r_n = \frac{2 \times \sigma_n^2 + \sigma_M^2}{\sigma_n^2 + 2 \times \sigma_M^2} \quad (5)$$

σ_n^2 は n 番目のブロックの画素値分散を表し、 σ_M^2 は画像内のすべての σ_n^2 の平均を表している。今回の実験では基準の QP、CNN 訓練に用いる符号化画像の QP はともに 32 とした。また、本実験では式(3)を計算する際、ブロックごとに MAD を計算するのではなく、あらかじめ大量の画像を用いて MAD を計算しておき、最小 2 乗法を用いて QP と MAD の関係の近似式を求め、近似式にブロックの QP を代入することで MAD を得ている。

本実験の訓練には、ハイビジョン・システム評価用標準動画第 2 版 (960×512pixel に縮小したもの) から 20 種類の画像を用い、雑音除去実験には訓練データ以外の 5 種を用いた。なお、損失関数は、原画像と出力画像の差分絶対値和、CNN の学習率は 0.0001、訓練回数は 10 万回とした。

4.2 実験結果

図 4 は実験結果画像の一部を拡大したものであり、CNN から出力された推定差分画像をそのまま入力画像に加算する従来手法 (図 4(c)) だと、復号画像では存在していた床の線が消えてしまうが、MAD の比を推定差分画像に乗算する提案手法 (図 4(d)) では、床の線を保持できていることが確認できる。また、図 5 は推定差分画像をそのまま加




図 4 符号化雑音除去処理結果

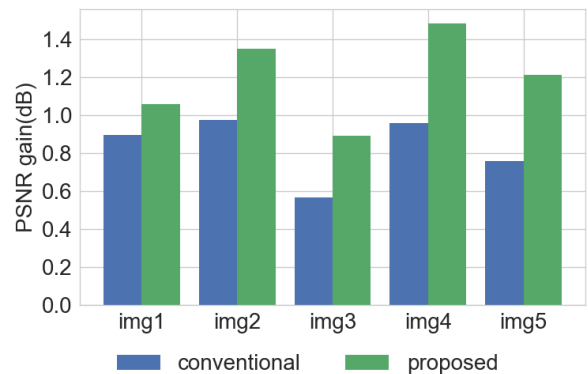


図 5 PSNR の改善量

算したときの画像と、MAD の比を乗算したときの画像の原画像に対する PSNR が、雑音除去を施さない場合に比べてどれだけ改善するかを測定したものである。図 5 からいづれの画像に対しても提案手法の有効性が確認できる。

5. おわりに

本論文では、ブロックごとに量子化パラメータを適応化して符号化された画像に対して、従来よりも高い性能を与える CNN 符号化雑音処理手法を提案した。今後の課題として、符号化時のブロックサイズが領域によって異なる画像について効果的に雑音除去を行うことが挙げられる。

参考文献

- [1] C.Dong, Y.Deng, C.C.Loy, X.Tang, "Compression Artifacts Reduction by a Deep Convolutional Network", 2015 IEEE International Conference on Computer Vision, pp. 576–584, Dec., 2015.
- [2] W.Park, M.Kim, "CNN-Based In-Loop Filtering for Coding Efficiency Improvement", 2016 IEEE 12th Image, Video, and Multidimensional Signal Processing Workshop, 2016.