

# DNN の層別重み係数量子化と画像認識精度との関係 A Consideration on Relationship between Weighting Coefficient Quantization for Each Layer of DNN and Image Recognition Accuracy

青柿 亮太<sup>†</sup>      八島 由幸<sup>†</sup>  
Ryota Aogaki    Yoshiyuki Yashima

## 1. はじめに

近年、深層学習(以降 DNN)は画像認識、画像生成、雑音除去等に対して優れた性能を与えるツールとして研究が進んでおり、様々な産業分野での応用が期待されている。一方、IoT の進展に伴い、DNN をスマートフォンや超小型デバイス等のハードウェア性能が限られた端末に実装したり、インターネットを介して DNN そのものを伝送したりする必要性が高まると考えられる。しかし、DNN は層が深くなると重み係数の数が膨大となり、その表現には大きな情報量が必要になるとともに、計算時に大量のメモリを消費するなどの問題を抱えている。これを解決するため、ユニットの消去やリンクの枝切りによってネットワークを再学習する手法[1]、特異値分解と量子化を全結合層に適用する手法[2]、係数を周波数変換する手法[3]等が提案されている。本研究では複数の学習済み DNN の各層の重み係数に着目し、各層で量子化処理を行った際の画像認識精度の影響とともに、各層に対して効率的な量子化手法を試みる。

## 2. 重み係数の分布特徴

圧縮処理を施す場合、まず重み係数がどのような統計的性質を持っているかを知ることが重要である。そこで、クラス分類用学習データ cifar10 を用いて設計した VGG16, ResNet18, ResNet34 の 3 つのネットワークに対して、各層の重み係数の分布状態を調べた。ここで、cifar10 は画像サイズが小さいため、学習を行う際に、VGG16 では全結合層のノード数を 4096 から 1024 に変更している。また、ResNet に関しても畳み込み層 1 層のフィルタサイズを 3×3、ストライドを 1、プーリング層なし、各層の出力次元数を全て半分に変更している。VGG16 及び ResNet34 の重み係数の分布の例を図 1 に示す。VGG16 では前半の層はガウス分布を模したような分布になっており、後半の層は正側に寄った分布となっている。一方、ResNet では後半の層ではより多く 0 に集中するような分布となっている。ResNet は学習させる際に勾配消失を防ぐために正則化を行うようにする為、各層で分布の差が大きくなると考えられる。

## 3. 重み係数の量子化

量子化処理は、Midtred 型量子化と、Lloyd-Max 量子化の 2 種類を検討する。Midtred 型量子化は、重み係数  $w$  に対して、以下の式(1)のように 0 を中心としたデッドゾーンなしの量子化手法である。

$$\hat{w} = \text{sign}(w) \times \left\lfloor \frac{|w| + 2/QP}{QP} \right\rfloor \times QP \quad (1)$$

ここで、 $\hat{w}$  は量子化代表値、QP は量子化幅を示す。また、

<sup>†</sup> 千葉工業大学情報科学研究科, Graduate School of Information and Computer Science, Chiba Institute of Technology

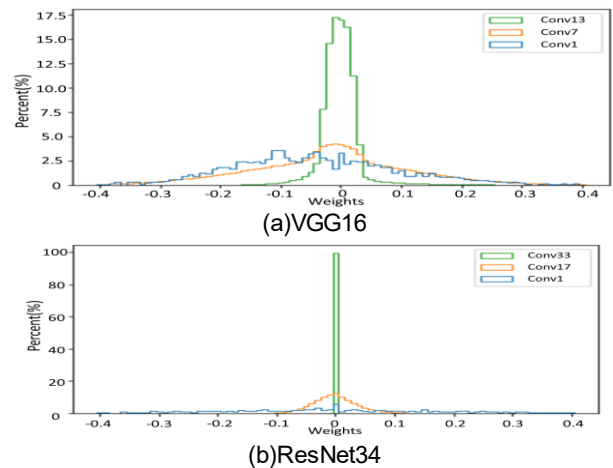


図 1 DNN の重み係数の分布

Lloyd-Max 量子化(以降 Max 量子化)は、レベル数  $k$  を与えたときに、式(2), (3)を満たすように量子化範囲  $t_q \sim t_{q+1}$  と量子化代表値  $\hat{w}_q$  を設定するものであり、量子化代表値と真値との二乗誤差を最小にすることができる。

$$t_q = \frac{1}{2}(\hat{w}_q + \hat{w}_{q+1}) \quad (2)$$

$$\hat{w}_q = \frac{\int_{t_q}^{t_{q+1}} x f_X(x) dx}{\int_{t_q}^{t_{q+1}} f_X(x) dx} \quad (3)$$

Max 量子化は、確率密度関数  $f_X$  が正規分布等に従う場合に有効である。

## 4. 実験結果と考察

### 4.1 各層の量子化と認識率への影響

各層の量子化が認識率に与える影響を調べるため、ある一つの層だけを量子化し、他の層は量子化を施さない場合に、どの程度認識率が変化するかの実験を行った。図 2 は、Midtred 型量子化で、一つの層を QP=0.2 と設定した場合の認識率の変化を示す。なお、それぞれの量子化を施さない場合の各 CNN の画像認識精度は 92.80%, 93.30%, 93.91% である。図 2 より、VGG16 では 13 層ある畳み込み層のうち最初と最後の層で大幅に精度が劣化している。また、ResNet18 では第 1 層と中間の層で精度劣化が見られる。ResNet34 でも同様に、中間層での精度劣化が現れている。

### 4.2 Midtred 型量子化による実験

3 つの学習済み DNN に対して Midtred 型量子化を行い、量子化幅 QP を 0.4~0.01 の範囲で変化させて認識率がどのように変わるかを測定した。また、層ごとに係数分布が異なることから、1 係数当たりのエントロピーを次式によって算出した。

$$H = \frac{\sum_k E(k)N(k)}{N} \quad (4)$$

ここで  $E(k)$ ,  $N(k)$  はそれぞれ第  $k$  層のエントロピー及び係数の個数,  $N$  は全係数の個数である. また,  $E(k)$  は次式で計算される.

$$E(k) = - \sum_v p_k(v) \log_2 p_k(v) \quad (5)$$

ここで,  $p_k(v)$  は第  $k$  層における量子化代表値  $v$  の発生確率である. 測定結果を図 3 に示す. なお, 量子化前の係数は 1 係数当たり 32bit で表現されているので, 各 DNN は約 1/6, 1/19, 1/34 に圧縮されている. 図 3 より, いずれも量子化がある程度より粗くなると急激に認識率が低下することが分かる. ResNet は VGG16 に比べてエントロピーが小さい. これは, 2 章で述べたように ResNet のほうがより値が集中する傾向にあることに起因する. 一方, 係数の総数は, VGG16 を 1 とすると, ResNet18 は 0.25, ResNet34 は 0.48 程度であり, VGG16 はエントロピーも大きいためネットワーク全体の符号量からみてもパフォーマンスは相当に低いと言える. 図 4 に, ResNet18 と ResNet34 のネットワーク全体の符号量での比較を示す. 図 4 より, ResNet34 のほうが ResNet18 より符号量が多いことが分かる. また, QP が小さくなるにつれ, 全体の符号量が多くなることがわかる.

#### 4.3 Lloyd-Max 量子化の適用

Midtreid 型量子化に加えて Max 量子化を適用する実験を行った. ResNet18 を例にレベル数 6 で全層に Max 量子化を適用したところ, エントロピー 1.75bit で認識精度が 10.38% と大幅に精度が低下した. この理由として, Max 量子化は正規分布に対して有効とされているため, 正規分布からはずれる層に適用すると精度を欠く場合があると考えられる. 正規分布近似の割合は平均値から正負の標準偏差  $\sigma$  の範囲に約 68%,  $2\sigma$  の範囲に約 95%,  $3\sigma$  の範囲に約 99.7% の要素が含まれるとされている. そこで, 本実験では, 係数分布の  $\sigma$ ,  $2\sigma$ ,  $3\sigma$  の範囲に含まれる要素が正規分布に対して 3% の以内の誤差である場合は Max 量子化, そうでない場合は Midtreid 量子化を利用する. また, 畳み込み層第 1 層に関しては精度を十分に保持するために Midtreid 量子化 (QP=0.01) で固定する. その結果を図 3 にプロットして記載する. VGG16 では 15 層中 8 層, ResNet18 では 20 層中 3 層, ResNet34 では 36 層中 2 層に Max 量子化が適用されている. ResNet に関してはチャンネル数を合わせる際に用いるショートカットの畳み込み層も含まれている. 図 3 より, VGG16 では精度劣化を 1% 以内に抑えエントロピーも Midtreid 量子化のみよりも抑えられている. ResNet18 では Midtreid 量子化のみの場合と比較すると十分な結果は得られなかった. ResNet34 の場合, エントロピーは僅かに増えたが Midtreid 量子化のみの場合よりも精度の劣化は抑制されている.

#### 5. おわりに

本研究では複数の DNN に対して, 重み係数を Midtreid 型量子化及び Max 量子化を用いて量子化した場合の画像認識精度を比較し, 層別に量子化を行うことで認識精度劣化を抑制しつつ, 情報量削減を図ることが可能であることを明らかにした. 今後は他の種類の DNN での検証, 他のデータセットで生成された重み係数の特性に基づく検討が必要




図 2 層別量子化による認識精度の劣化

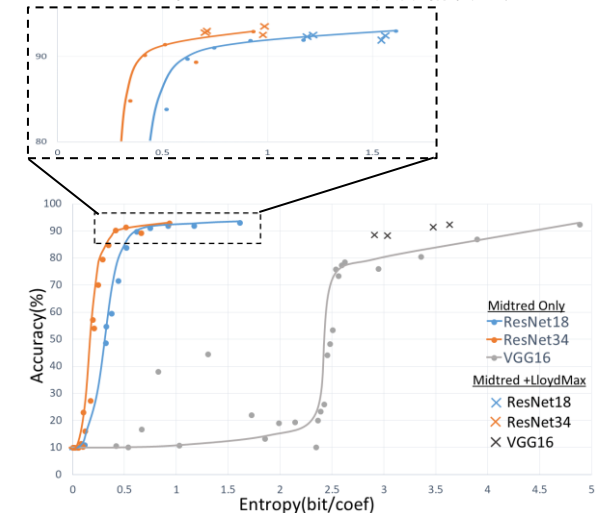


図 3 量子化による各 DNN の認識精度

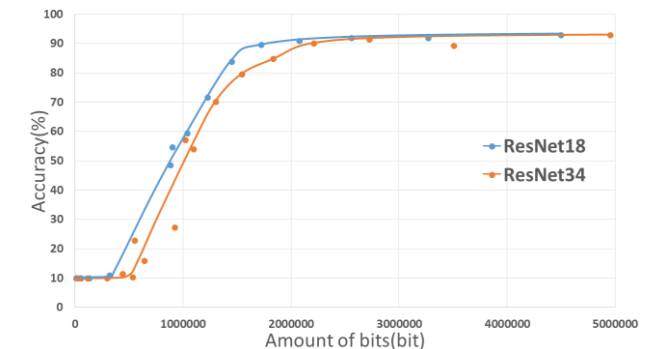


図 4 Midtreid 量子化による ResNet の総情報量

である. また, 層ごとに量子化幅を適応的に変化させるような手法についても検討を進める予定である. なお, 本研究は JSPS 科研費 JP18K11360 の助成を受けて行った.

#### 参考文献

- [1] S. Han, H. Mao, and W. J. Dally, "Deep Compression: Compressing Deep Neural Networks with Pruning, Trained Quantization and Huffman Coding," International Conference on Learning Representations, (ICLR 2016).
- [2] 青柳亮太, 八島由幸, 特異値分解と量子化による DNN 全結合層係数の情報圧縮, 2019 年画像符号化/映像処理シンポジウム, P-1-12, Nov., 2019
- [3] Y. Wang, C. Xu, S. You, D. Tao and C. Xu, "CNNpack: Packing Convolutional Neural Networks in the Frequency Domain," 30th Conference on Neural Information Processing Systems (NIPS 2016)