

## 1. はじめに

Deep Convolutional Neural Network (DCNN) は、画像認識の分野において高い性能を達成している。しかし、多くのメモリと計算リソースが必要のため、組み込み機器やモバイル端末への導入が困難である。Binary-decomposed DCNN (B-DCNN)[1] は、DCNN のパラメータを二値で表現することで、高速化とモデル圧縮が可能である。B-DCNN は、推論時に Quantization sub-layer において特徴マップを二値化する。このとき、各層の最適な量子化ビット数  $Q$  を手動で設定する必要がある。本研究では、B-DCNN の Quantization sub-layer で用いる量子化ビット数  $Q$  を自動で最適化する手法を提案し、更なる処理速度の高速化を図る。

## 2. B-DCNN の特徴マップの量子化

B-DCNN は、特徴マップを量子化して二値に変換する Quantization sub-layer を導入している。Quantization sub-layer では、特徴マップ  $\mathbf{h}$  の最小値が 0 になるように  $\mathbf{h}$  をシフトし、量子化して量子化ビット数  $Q$  の二値にする。量子化ビット数  $Q$  が大きい場合、特徴マップの表現力が高く、識別精度が向上する。しかしながら、処理速度は低下する。一方で、量子化ビット数  $Q$  が小さい場合、処理速度が高速になるが特徴マップの表現力が乏しいため、識別精度が低下してしまう。




図 1：特徴マップの量子化 [1]

## 3. 提案手法

本研究では、Quantization sub-layer における最適な量子化ビット数  $Q$  を指定した精度を保持しつつ、自動的に決定する方法を提案する。AlexNet を対象とする場合、畳み込み層の  $Q$  の組み合わせは  $16,807C_5$  と膨大である。提案手法では、前後の層の  $Q$  値を固定した時の精度の変化に着目し、以下の Algorithm1 により決定する。また、各層の  $Q$  値を選択する流れを図 2 に示す。

### Algorithm 1 提案手法

Require:  $\mathbf{A}$ ,  $\mathbf{T}$ ,  $D$ ,  $I$ ,  $Q$ ,  $R$

Initialize:  $\mathbf{T}$ ,  $S$ ,  $\mathbf{a}$

```

for  $i = 1$  to  $I$  do
  for  $q_i = 2$  to  $Q$  do
    for  $q_{i-1} = 2$  to  $Q$  do
       $S \leftarrow SA(i, q_{i-1}, q_i)$  //  $i$  層の予想精度
      if  $R - S < D$  then
        // 予想精度低下率が許容値より小さい
         $\mathbf{T}_{q_{i-1}, q_i}^i \leftarrow S$  // スタックする
      end if
    end for
  end for
end for
for  $i = I$  to 1 do
   $\mathbf{a}_i \leftarrow \operatorname{argmin}_{q_i} \mathbf{T}^i$  // 最小の  $Q$  値を取得
end for
return  $\mathbf{a}$ 

```

ここで、 $\mathbf{A}$  は各層の精度低下率、 $\mathbf{a}$  は最適な量子化ビット数の組み合わせ、 $\mathbf{T}$  は予想精度のスタック、 $D$  は精度低下許容値、 $I$  は対象となる層数、 $Q$  は最大の量子化ビット数、 $R$  は量子化前の精度である。精度低下許容値  $D$  は事前に設定しておく。 $\mathbf{T}$  と  $S$  は最初に初期化する。次に、量子化前の精度から  $i$  層の予想精度を減算し、予想精度低下




図 2： $Q$  値を選択する流れ

率を求める。さらに、予想精度低下率が  $D$  より小さいとき、 $S$  を  $\mathbf{T}_{q_{i-1}, q_i}^i$  にスタックする。最後に、各層ごとに  $Q$  が最も小さくなる値を選択する。

## 4. 評価実験

提案手法の有効性を確認するために、評価実験を行う。

### 4.1. 実験概要

ImageNet Dataset を用いて、提案手法を適用した際の識別精度と処理速度を評価する。検証サンプル 2,000 枚の Top-5 accuracy で評価する。ネットワークモデルには AlexNet を用いる。各モデルのパラメータには公開されている学習済みモデルを使用する。

### 4.2. 実験結果

提案手法を用いた B-DCNN と  $Q$  値を固定した B-DCNN の識別精度と処理速度を図 3 に示す。ここで、提案手法\*は指定した  $Q$  値に対する予想精度、提案手法は実際に識別を行った際の精度である。 $Q$  値を固定した B-DCNN は、任意に指定する精度に対して細かい調整ができず、B-DCNN ( $Q=3$ ) と B-DCNN ( $Q=4$ ) のときに精度に大きな差が生まれている。提案手法は、任意に指定した精度に対して約 2% 程度の誤差が生じるが、指定された精度を満たす  $Q$  値を選択して高速化を実現している。 $D$  が 8 と 9 のとき、B-DCNN ( $Q=3$ ) と比較して識別精度を維持しつつ、処理速度が向上していることがわかる。




図 3：処理速度と識別精度の比較

選択された  $Q$  値は、conv1 や conv2 のような浅い層では 4, 5 と大きく、conv3 や conv4, conv5 などの深い層では 2, 3 と小さい傾向が見られた。

## 5. おわりに

本研究では、各層で量子化ビット数  $Q$  を変更することで、識別精度と処理速度の向上を実現した。今後は、Fine-tuning による Quantization sub-layer と重みの基底数の、最適な値を調整する方法を模索する。

## 参考文献

- [1] R. Kamiya, et al., "Binary-decomposed DCNN for accelerating computation and compressing model without retraining", ICCV Workshop, 2017.