

## 段階的に成長する SparseNet

日大生産工 ○中村 匠海 日大生産工 山内 ゆかり

### 1 まえがき

Convolutional Neural Network (CNN)[1]は画像識別等で用いられる機械学習の一種である。近年の研究により、CNNの性能には、ネットワークの深さ、一層あたりの幅、ショートカット接続の全てがその性能に必要であることが示されている。

そこで、Gao Huangらは、先行する全ての層の特徴マップを入力として、ショートカット接続する Dense Convolutional Network (DenseNet)[2]を提案した。このモデルでは、勾配消失問題の緩和、特徴伝搬能力の強化、特徴再利用の促進、パラメータ数の大幅な削減などの魅力があった。しかし、過剰なショートカット接続は、ネットワークの計算効率やパラメータ効率を低下させるほか、過学習を起しやすくすることがわかっている。

そこで、Wenqi Liuらは、Sparse DenseNet (SparseNet) [3]を提案した。SparseNetは、先行する層のうち、最も遠い層のいくつかと、最も近い層のいくつかを入力として、ショートカット接続するものである。これにより、ショートカット接続の数を従来のものより減らすことができ、ネットワークをより深く、より広くすることが可能になった。さらに、SparseNetでは各Sparse blockでの層数を初めは少なく、最後に向けて大きくすることにより、計算量の削減と精度の向上を達成した。

本研究では、SparseNetのSparse blockごとに層数を増やす特徴に対して、成長率つまり、幅を増やす手法を提案する。MNISTデータセットを用いた計算機実験により提案手法との精度、処理時間を比較し、計算効率向上したかどうかについて報告する。

### 2 従来研究

#### 2.1 Convolutional Neural Network

Convolutional Neural Network (CNN)[1]は、フィルターを用いた畳み込み処理を行う Neural Network (NN)である。CNNは、畳み込み層、プーリング層、全結合層から成る。まず、畳み込み層では、フィルターを用いた畳み込み処理を行い、特徴を抽出した特徴マップを作る。この畳み込み層を式に直すと式(1)となる。 $x_i$ は

$i$ 層目の畳み込み層の出力である。 $H$ は畳み込み層である。

$$x_i = H(x_{i-1}) \quad (1)$$

この畳み込み層が作った特徴マップを特定のルールに基づいて、圧縮するのがプーリング層である。最後に、マップを一次元に直し、全結合Multi-Layer Perceptron (MLP)で処理するのが全結合層である。

#### 2.2 Dense Convolutional Network

Dense Convolutional Network (DenseNet) [2]はCNNの一種であり、Dense blockとTransition layerから出来ている。DenseNetの構造をFigure1に示す。




Figure 1 DenseNet

Dense blockは、バッチ正規化層とReLU活性化関数、畳み込み層からできており、先行する全ての層の特徴マップを連結し入力とする。Dense blockの構造をFigure2に示す。




Figure 2 Dense block

これを式に直すと式(2)となる。 $[x_0, x_1, x_{i-1}]$ は先行する全ての層の特徴マップを連結したものである。

$$x_i = H([x_0, x_1, x_{i-1}]) \quad (2)$$

また、各畳み込み層の出力する特徴マップ数は同じであり、これを成長率と呼ぶ。

Transition layerは、Dense block同士の間であり、特徴マップのサイズを圧縮する役割をも

つ。この役割により、基本的には特徴マップのサイズは $\frac{1}{4}$ となる。

### 2.3 Sparse DenseNet

Sparse DenseNet (SparseNet)[3] は DenseNetを基としたCNNの一種であり、Sparse blockとTransition layerから成る。SparseNetの構造をFigure3に示す。




Figure 3 SparseNet

Sparse blockは、DenseNetのDense blockと同様に、バッチ正規化層とReLU活性化関数、畳み込み層から成る。しかし、Dense blockとは異なる点もある。Dense blockは、先行する全ての層の特徴マップを入力としていた。対して、Sparse blockでは、中間層からの接続を取り除き、最も遠いいくつかの接続と最も近いいくつかの接続のみを利用する。Sparse blockの構造をFigure4に示す。




Figure 4 Sparse block (path = 2)

Figure4の例では、1つの層は2つの層から特徴マップを受け取る。一つの層に繋がるショートカット接続の数をpath(n)という。これを式にすると、式3となる。

$$x_i = H([x_0, x_1, \dots, x_{n/2}, x_{i-n/2}, \dots, x_{i-1}]) \quad (3)$$

そして、SparseNet内の畳み込み層の出力する特徴マップ数、つまり成長率は、DenseNetと同じ同数である。

また、SparseNetでは、入力層に近いSparse block内の畳み込み層の数を少なく、全結合層に近いSparse block内の畳み込み層を多くしている。これにより、計算量の削減と精度の向上を達成している。

### 3 提案手法

SparseNetでは、各ブロックでの層数を初めは少なく、最後に向けて大きくすることによって、計算量の削減と精度の向上を達成した。対して、

本研究では、各ブロックの成長率を変動させる手法を提案する。Figure5にイメージ図を示す。

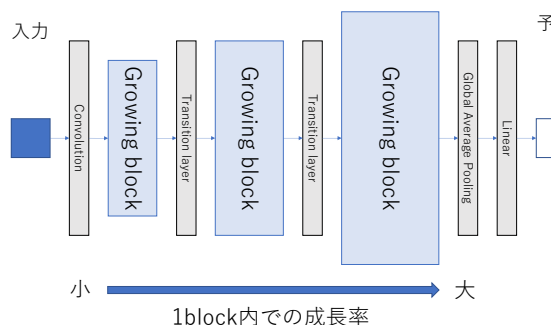


Figure 5 Gradually Growing SparseNet (proposed)

まず、マップサイズが大きいため、畳み込み処理による計算量が多くなる序盤の成長率を小さくする。また、全結合層に近い終盤での成長率を大きくすることで、全結合層に渡る次元数を多くすることができる。これらにより、精度の向上しつつ、計算量を削減できると考えられる。

### 4 実験および検討

MNISTの画像データを用い、DenseNetとSparseNet、提案手法の精度を比較する。また、処理に要した時間を比較し、計算量削減の効果があつたかどうか検証する。

### 5 まとめ

本研究では、ブロックごとに成長率を増やす手法を提案した。これにより、マップサイズの大きい序盤の計算量を削減しつつ、マップサイズが小さく、全結合層に近い、終盤のマップ数を増やし、精度を上げることができると考えられる。

### 参考文献

- [1] Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, "ImageNet Classification with Dee Convolutional Neural Networks", Proc NIPS (2012)
- [2] Gao Huang, Zhuang Liu, Laurens van der Maaten, Kilian Q. Weinberger, "Densely Connected Convolutional Networks", Proc CVPR(2017)
- [3] Wenqi Liu, Kun Zeng, "SparseNet: A Sparse DenseNet for Image Classification", Proc arXiv(2018)