

RelayBP を導入した DenseNet

日大生産工 ○原田雄太 日大生産工 山内 ゆかり

1. まえがき

近年、AIの技術が発展したことで、機械学習の活用が積極的に行われている。特に畳み込みニューラルネットワーク (Convolutional Neural Network:CNN)[1]は機械学習分野において、画像・動画認識分野では優れた性能を発揮している。一般的にCNNではネットワークの深さを深くするほど精度が向上するとされているが、誤差逆伝搬(Back Propagation:BP)[2]学習時に、勾配情報が層を遡るにつれて劣化していくことから、発散や収束の遅延、過剰適合のリスクが生じる。そこで、Li Shenらはリレー誤差逆伝搬法 (Relay Back Propagation:Relay BP)[3]を提案した。これはネットワークモデルの中間に中間層を導入することで、下位層のフィルターやバイアスが効果的に学習され識別精度の向上につながった。また、Gao Huangらは Dense Convolutional Network (DenseNet) [4]を提案した。これは層と層の間の情報の伝達を最大化するために、全ての特徴量サイズが同じレイヤーを結合させているもので、これも識別精度向上につながった。

本研究では、DenseNetにRelayBPを導入することで多段学習における過学習の抑制、精度向上を図る。

2. 従来研究

2.1 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (Convolutional Neural Network:CNN)[1]はディープラーニングの一つであり、主に画像認識などで用いられる手法で、畳み込み層、正規化線形ユニット、プーリング層、全結合層で構成されており、これらの作業が繰り返し行われ、層ごとに異なる特徴を識別するように学習することで画像を分類する。

2.2 リレー誤差逆伝搬法

リレー誤差逆伝搬法 (Relay Back Propagation:Relay BP)[3]はLi Shenらによって提案され、目標とする出力に関する勾配情報が層を遡るにつれて劣化していくという誤差逆伝搬 (Back Propagation:BP) の問題を改善したものである。図1はRelayBPを用いた際のCNNを表した図であり、左が前向き演算時で右

が後ろ向き演算時である。一般的なBPと違い、CNNの途中で勾配情報を分岐させ新しく中間セグメントを作り補助出力を出す。さらに、元の全結合層 (Fully-connected Layer:Fc) の出力の伝搬を途中で止め、代わりに補助出力を用いることにより、誤差情報があまり層を遡らず、劣化を抑えることができる。これにより従来のCNNの問題を解決し、効率的な学習をすることができる。

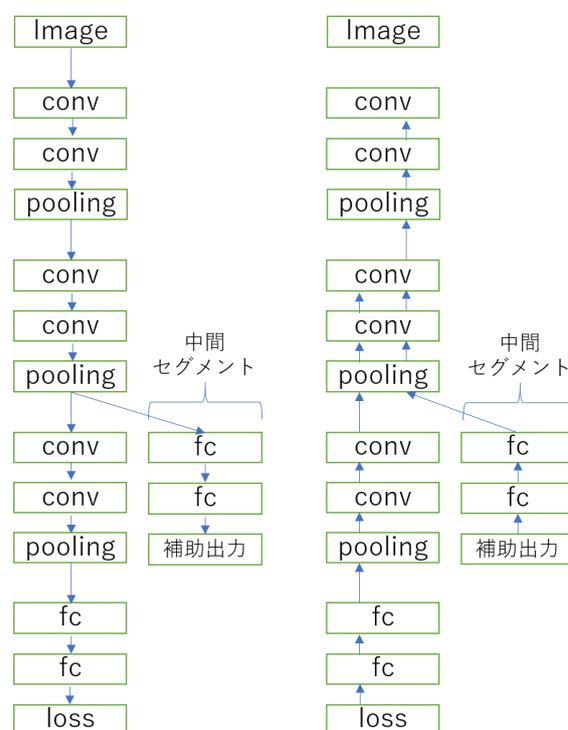


図 1.RelayBP を用いた CNN の例

2.3 DenseNet

Dense Convolutional Network (DenseNet) [4]はGao Huangらによって提案され、“Dense ブロック”と“Transition Layer”を複数用いて、勾配消失問題の緩和、特徴の伝搬の強化、特徴の再利用の促進、パラメータ数の大幅な削減などを可能にしたCNNの設計である。Dense ブロックとはすべての畳み込み層間をスキップ接続し、各特徴マップをチャンネル方向に結合するものであり、Transition LayerとはDense ブロックで増えた特徴量マップのサイズを Pooling層を用いることで減らすものである。図

2はDenseNetの例を示す。DenseNetの基本構造はCNNにDenceブロックとTransition Layerを複数入れたものであり、この手法の基となるResNet[5]と違い層を深くするのではなく、特徴の再利用によってよりコンパクトに効率を向上させている。

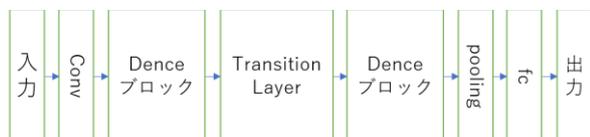


図 2.DenceNet の例

図3にDenceブロックの構造を示す。これはDenseNetの主要な要素であり、前の層の出力すべてを連結した特徴マップを入力としていく畳み込みのブロックのことである。

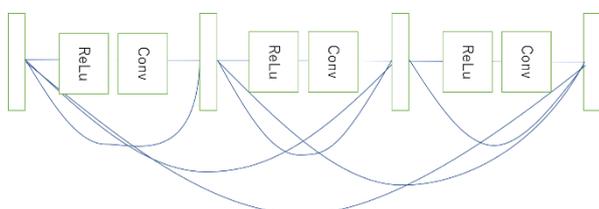


図 3.Dence ブロックの例

また、Denseブロックの中で増やすフィルタ一の数 k は、成長率パラメータ (Growth rate) と呼ばれており、1層におけるDenseブロックの出力値は

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (1)$$

となる。

ここで、 H_l は1層のBatch normalization、ReLU、3*3Convolutionを連続した操作の合成関数を、 $([x_0, x_1, \dots, x_{l-1}])$ は第0層から $l-1$ 層までの特徴マップを連結したものである。

3. 提案手法

本研究ではDenceNetにおけるTransition Layerの後で勾配情報を分岐させRelayBPを取り入れる。図4にDenseNetのネットワーク構造を示す。

4. 実験および検討

DenceNetには勾配消失問題の緩和、特徴マップの伝搬を強化、特徴マップの再利用を促進、効率的にパラメータ数を削減する利点がある。ここにさらにRelayBPを組み込むことで、多段学習における過学習の抑制、精度向上があると考えられる。

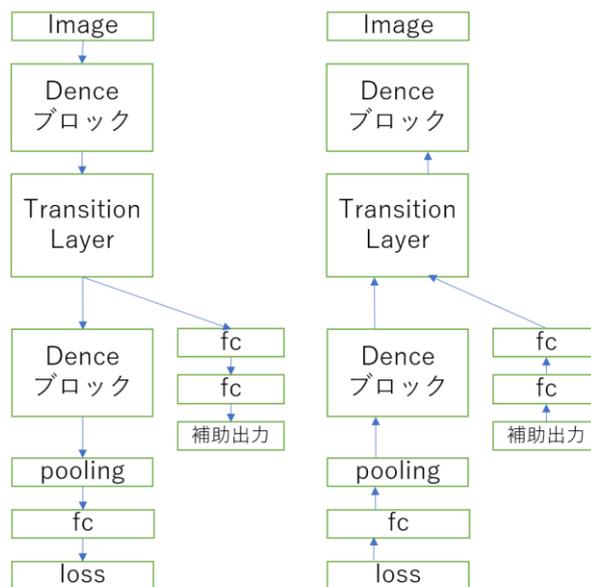


図 4.DenseNet のネットワーク構造

5. まとめ

本論文ではRelayBPをDenseNetに導入することを提案した。これにより、2つの利点を兼ね備えることができ、DenseNetにおける過学習の抑制、精度向上を望める。

参考文献

- [1] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard and L. D. Jackel, "Backpropagation Applied to Handwritten Zip Code Recognition.", *Neural Computation* 1, pp. 541-551, Dec. 1989.
- [2] David E. Rumelhart, Geoffrey E. Hinton and Ronald J. Williams, "Learning representations by back-propagating errors.", *NATURE*, pp. 533-536, Oct. 1986.
- [3] Li Shen, Zhouchen Lin and Qingming Huang, "Relay Backpropagation for Effective Learning of Deep Convolutional Neural Networks.", *European Conference on Computer Vision. Computer Vision – ECCV 2016*, pp. 467-482, Sep. 2016.
- [4] G. Huang, Z. Liu, L. Van Der Maaten and K. Q. Weinberger, "Densely Connected Convolutional Networks," *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 2261-2269, doi: 10.1109/CVPR.2017.243.
- [5] K. He, X. Zhang, S. Ren and J. Sun, *Deep Residual Learning for Image Recognition*, arXiv:1512.03385(2015)