

# データサイズに応じた CNN の畳み込み層の深さ分析とカーネルの形状変化による比較

## Analysis of Convolutional Layer Depth in CNN According to Data Size and Comparison of Kernel Shape Transformation

友光 祐輔<sup>1)</sup>望月 久稔<sup>1)</sup>

Yusuke TOMOMITSU Hisatoshi MOCHIZUKI

### 1 はじめに

畳み込みニューラルネットワーク CNN は、深層学習分野の画像認識などにおいて顕著な成果を上げており [1]、畳み込み層を通じてデータから局所的な特徴を効率的に抽出することで、データの重要な情報を捉えることができる。畳み込み層を深くすることにより初期の層で検出した特徴を組み合わせ、より抽象的な表現を学習するが、必要となるデータサイズの大きさも増加する。しかし、畳み込み層の深さとデータサイズの大きさの関係は、詳細な理解が確立されていない。

先の研究 [2] では為替予測を題材に、CNN モデルの一つである EfficientNetB0 [1] と、LSTM [3] の統合モデルの性能を検証した。本研究では、データサイズに応じた EfficientNetB0 の畳み込み層の深さ分析を目的とし、畳み込み層の深さとデータサイズ、それぞれの変化による予測精度への影響を検証する。また、表データの行と列に配置した属性や変数間で弱い相関が生じることを考慮し、相関の弱いデータ間の畳み込み演算を削減するためにカーネルの形状を長方形に拡張する。これにより、畳み込み層の深さとデータサイズ、長方形カーネルを包括的に比較し、最適な組み合わせを検討する。

### 2 畳み込み層の深さとカーネルの形状

畳み込み層の深さとデータサイズ、カーネルの形状の関係を分析する。実験に為替予測のデータを利用する。2020 年の一分足データ [4] を用いて、縦軸が時系列、横軸が為替予測に用いるテクニカル分析指標の表データを作成し、一分後の始値を予測する。

#### 2.1 畳み込み層の深さとデータサイズの定義

EfficientNetB0 における畳み込み層の深さとデータサイズの関係がモデルの性能に及ぼす影響を分析する。まず、縦横の長さを統一した正方形のデータを、サイズが 8, 16, 32, 64 の 4 種類定義する。

次に、EfficientNetB0 における畳み込み層の深さを定義する。EfficientNetB0 は大別すると 6 つの段階で構成される CNN モデルである。畳み込み層の深さを検証するために、1 段階目のみの EfficientNetB0 を 1-1 群、1 段階目から 2 段階目までを 1-2 群、と順に 1-6 群までの 6 つに分類する。EfficientNetB0 の段階と層数、1-4 群の例を図 1 に示す。図 1 より、EfficientNetB0 の特徴として各段階の畳み込み層は後半ほど増加する。1-4 群の場合、各段階の層は 2, 4, 4, 15 層であり、群の層数は計 25 層となる。同様に、各群の層数はそれぞれ、2, 6, 10, 25, 50, 91 層となり、これらの群を EfficientNetB0 における畳み込み層の深さとして定義する。

4 種類のデータサイズと 6 段階ある群の直積である計 24 通りの組み合わせによる予測精度への影響を検証する。

1) 大阪教育大学 Osaka Kyoiku University

### 2.2 長方形カーネルへの拡張

表データは、行と列がそれぞれ異なる属性や変数であるため、行または列同士の相関は弱いと考えられる。例えば、本研究では横軸にテクニカル分析指標、縦軸に 1 分ごとの各テクニカル分析指標のデータを用いるため、縦軸の 1 分ごとの時系列データより、同じ時間内の横軸のテクニカル分析指標の相関が弱い。そこで、相関の弱いデータ間の畳み込み演算を削減するためにカーネルの形状を長方形に拡張する。(縦, 横) が  $(n, 1)$  の長方形カーネル  $k_n$  を式 (1) で定義する。

$$k_n = [a_1, a_2, a_3, \dots, a_n]^T \quad (1)$$

長方形カーネルによる畳み込み演算の例を示す。3 行 2 列のデータに対し、 $n$  が 2 の長方形カーネルで畳み込み演算すると式 (2) となる。大きさの異なる各列のデータに対し、長方形カーネルで演算することで、その列ごとの特徴を抽出できる。

$$\begin{bmatrix} 1 & 20 \\ 3 & 40 \\ 5 & 60 \end{bmatrix} \otimes \begin{bmatrix} 1 \\ 2 \end{bmatrix} = \begin{bmatrix} 7 & 100 \\ 13 & 160 \end{bmatrix} \quad (2)$$

### 3 畳み込み層の深さとデータサイズの関係と長方形カーネルの包括的な比較

畳み込み層の深さとデータサイズ、カーネルの形状の関係を包括的に比較し、最適な組み合わせを検討する。また、先の研究で検証した EfficientNetB0 と LSTM の統合モデルを用いて予測し、最適な組み合わせと一致するかを比較する。決定係数 ( $R^2$ )、平均絶対誤差 (MAE)、二乗平均平方根誤差 (RMSE)、優位度を用いて比較する。ここで優位度は、長方形カーネルを評価するために、重みや層数などのカーネルの形状以外の要因を統一した上で、正方形カーネルより長方形カーネルの予測精度が優位である割合 (%) を算出する。この割合を優位度として式 (3) で定義する。

$$\text{優位度} = \frac{\text{長方形カーネルの精度が優位な回数}}{\text{全ての回数}} * 100 \quad (3)$$

例えば、10 回の実験で、正方形カーネルより長方形カーネルの予測精度が 7 回優位である場合の優位度は 70% となる。



図 1 EfficientNetB0 内部の畳み込み層数

表1 EfficientNetB0における畳み込み層の深さとデータサイズの検証

データ	群	畳み込み層数	$R^2$	MAE	RMSE
(8, 8)	1-1	2	0.62	0.11	0.11
(16, 16)	1-1	2	0.76	0.09	0.09
(32, 32)	1-2	6	0.96	0.03	0.03
(64, 64)	1-2	6	0.58	0.09	0.11

表2 長方形カーネルの優位度(%)

データ	CNN	群別の EfficientNet					
		1-1	1-2	1-3	1-4	1-5	1-6
(8, 8)	50	47	30	47	50	50	53
(16, 16)	87	70	40	67	50	57	53
(32, 32)	60	58	27	57	37	50	43
(64, 64)	47	45	59	27	31	59	32

### 3.1 畳み込み層の深さとデータサイズの検証

2.1 節で提案した EfficientNetB0 の畳み込み層の深さとデータサイズの関係を検証する。 $R^2$  の最も高かった群と畳み込み層を表1に示す。表1より、データサイズの増加に伴い、適切な層数も2層から6層へと増加した。一般に、データサイズが大きくなるにつれて、データの特徴はより多様で複雑になる。層を深くすることで、短期間のデータにおける増加や減少などの基本的な特徴から、長期間のデータにおける特定の形などの複合的な特徴を学習したと考察する。

また、サイズが8, 16, 32のとき、 $R^2$  はそれぞれ0.62, 0.76, 0.96でありサイズとともに増加し、MAEとRMSEも比例して0.11, 0.09, 0.03へと減少した。データサイズの増加により、モデルはデータのパターンや関係性をより詳細に捉えることができるため、予測精度が向上したと考える。しかし、サイズが64のときの $R^2$  は0.58に減少し、MAEとRMSEはそれぞれ0.09と0.11に増加した。これは、データサイズが過大になるとノイズや無関係な情報が増加し、重要な特徴を抽出できずに予測精度が低下したと考える。

### 3.2 長方形カーネルによる優位度の検証

畳み込み層を評価するために、カーネルの長さを3に固定し、畳み込み層とプーリング層のみのCNNとEfficientNetB0のそれぞれで優位度を比較する。

CNNとEfficientNetB0で比較した結果を表2に示す。まず、CNNはデータサイズが8, 16, 32のときに優位度が50%以上であることから、相関の弱い列同士の畳み込み演算を削減することで精度が向上または変動しなかった。また、サイズが64のときの優位度は47%であり、サイズの増加に伴いモデルがデータの全体像を捉えるために必要なカーネルの長さも増加する可能性がある。

次に表2より、EfficientNetB0の長方形カーネルで最も精度が高かったのはサイズが16の1-1群で、優位度は70%であった。しかし、サイズが32の1-2群と、サイズが64の1-3群の優位度は27%と最も精度が低く、正方形カーネルが73%優位である。EfficientNetB0の内部には畳み込み層やプーリング層以外の層が存在するため、それらの層が関わることで精度向上に寄与しない場合があり、特定のタスクやデータセットにおいてカーネルの形状の効果を適宜分析する必要があると考える。

異なる長さのカーネルを検討する。カーネルの長さを5にしてCNNで実験すると、サイズが64のときのみ優位度が向上し、カーネルの長さを3とした表2中の47%から58%となった。このように、カーネルの長さを変更することで、予測精度が向上する可能性がある。

全体として、長方形カーネルは畳み込み層とプーリング層のみのCNNで特に有効で、それ以外の層を含むEfficientNetB0も場合により有効となることが示唆され

る。また、データサイズの増加に伴い、データの多様で複雑な特徴を捉えるために層を深くする必要があるが、過大なデータサイズではノイズや無関係な情報により予測精度が低下する可能性がある。

### 3.3 EfficientNetB0とLSTMの統合モデルの検証

EfficientNetB0とLSTMの統合モデルで予測した結果を表3に示す。表3より、サイズが16, 32, 64のデータにおいて、 $R^2$  がそれぞれ、0.92, 0.98, 0.97であり、誤差も全て0.05以下に収まったため高い精度で予測できた。LSTMを連結することで時系列情報を適切に学習できたため、EfficientNetB0の単体モデルよりも精度が向上したと考える。また、表1と比較すると、サイズが8と64のデータはそれぞれ、 $R^2$  が0.62から0.13へと低下し、0.58から0.97に向上した。LSTMで学習するとき、データの縦軸が時系列情報であるため、その量が予測精度に影響を及ぼしたと考える。

最後に、表1と表3の群と畳み込み層数を比較すると、データサイズが8と32のときは同一であり、16と64のときは統合モデルの群は大きく、層も多い。これはモデルを統合することでEfficientNetの過学習を抑制しながら単体より複雑な特徴を捉え、時間とともに変化する内容をLSTMで学習できたからであると考察する。

## 4 おわりに

データサイズとEfficientNetB0における畳み込み層の深さ、長方形カーネルを包括的に比較し、統合モデルで予測精度を検証した。データサイズの増加に伴い、適切な層の深さも増加する関連性を確認できた。また、様々なサイズの表データにおける長方形カーネルの有効性も示唆された。

今後の課題として、各データサイズにおける適切なカーネルサイズの検証などが挙げられる。

#### 参考文献

- [1] Tan, M., Le, Q. V.: EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks, (online), DOI: 10.48550/ARXIV.1905.11946, (2019).
- [2] 友光祐輔, 望月久稔: EfficientNetとLSTMの統合モデルに長方形カーネルを導入した為替予測の有効性評価, FIT2023(第22回情報科学技術フォーラム), (2023).
- [3] Hochreiter, S. and Schmidhuber, J.: Long short-term memory, Neural computation, Vol.9, No.8, pp.1735-1780, (1997).
- [4] HistData.com, 入手先 <http://www.histdata.com/>, 参照(2023-06-07).