

# 深層学習を用いたマルチファクター運用の実証分析

## Deep Learning for Multifactor Models in Japanese Stock Markets

阿部 真也<sup>1\*</sup> 中川 慧<sup>1</sup>  
Masaya Abe<sup>1</sup> Kei Nakagawa<sup>1</sup>

<sup>1</sup> 野村アセットマネジメント株式会社  
<sup>1</sup> Nomura Asset Management Co.,Ltd.

**Abstract:** 株価を予測するために、様々なファクターが特徴量として多数提案されてきた。一方で、近年これら大量のファクターを同時に扱うために、機械学習、とりわけ深層学習を用いた株価予測手法が提案されてきた。しかしながら、日々の運用を意識した具体的な実践事例はほとんどない。そこで本稿では、日本株式市場において機械学習を用いたマルチファクターモデルに基づく実運用を意識した実証分析を行う。そして、深層学習の有効性を確認するとともに、分析を通じて得た知見について考察する。

### 1 はじめに

株価を予測するためのアプローチとして、(1) 株価を時系列データとみなして予測する方法、(2) あるクロスセクション (断面) での銘柄間の相対的な順位に基づいて予測する方法の2つがある。一般的な時系列データとは異なり、株価を時系列データとしての予測、すなわち過去の株価を特徴量として利用し、将来の株価を予測するという前者のアプローチは短期的には可能でも、長期的には難しいことが知られている。一方で、後者の複数の株価をクロスセクションデータとして見た中で、どういった銘柄群が相対的にリターンが高くなり、どういった銘柄群が低くなるかは、中長期的な期間である程度明らかにされている。こういったクロスセクションで株価を説明する要因を「ファクター」という。ファイナンスの学術的には、[4]によるFama-Frenchの3ファクターモデルが一般的である。これはベータ、サイズ、バリュウの3つのファクターがクロスセクションで月間の株価変動を説明することを明らかにした。以降、[5]によれば、2012年までの間に316ものファクターが発見された。しかも、これらファクターの大部分は過去10年の間に見つかった。そのため近年、運用者が検討すべきファクターは急速に増大しているものの、「次元の呪い」の問題から316ものファクターを同時に検証することはできない。一方で、ファイナンスにおいては統計的な扱いや理論的な解析が容易であること、結果の頑健性から線形回帰モデルを用いる。実

務的には、これらのうち幾つかのファクターと将来リターンとの回帰 (マルチファクターモデル) から、ある銘柄についての総合的な魅力度を計算し、当該魅力度に基づいてポートフォリオ構築を行う。しかしながら、資産価格変動は非線形性を持つことが古くから知られているため、単純な線形モデルでは予測精度に限界がある。以上の背景から、機械学習の手法を用いてこれらの問題に取り組んでいる研究が学術的には盛んである [2, 3]。

しかしながら、クロスセクションでのマルチファクターモデルの観点から、機械学習を適用する試みは [7, 1, 6] といった少数の例を除くとあまりなく、特に様々なファクターを用い、実運用を意識した分析例は存在しない。そこで、以上の問題設定から本稿では、日本株式市場において機械学習、特に、画像認識、音声認識、自然言語処理など様々なタスクにおいて、優れた非線形関数近似能力を示している深層学習を用いたマルチファクターモデルに基づく実証分析を行う。

### 2 深層学習を用いたマルチファクター運用

実務的にはデータ、特徴抽出、予測モデル構築、ポートフォリオ構築というプロセスで運用を行う (図1)。まず、データとしてPERやROEなどの株価を説明するであろう指標 (ディスクリプター) を幾つか用意する。[4]などのファイナンスの学術研究とは違い、それらのディスクリプターを標準化したものを複数組み合わせる。例えば、株価の割安感を表すバリュウファクターを、PBR、PER、配当利回りを1:1:1

\*連絡先: 野村アセットマネジメント株式会社  
〒103-0027 東京都中央区日本橋1丁目12-1  
E-mail: m-abe@nomura-am.co.jp

本稿の内容は筆者らが所属する組織を代表するものではなく、本稿の全ての誤りは、筆者らの責に属するものである。

で組み合わせて作る。そして複数のファクターから回帰モデルで株式リターンを予測する。最後に予測された株式リターンとリスクを用いてポートフォリオを構築する。

従来はディスクリプターからファクターの作成、そしてどのファクターをいくつ使うのかを人が選択していたため、モデルの見直し・チューニングには非常に多くの時間がかかった。またそれらの多くは運用者であるファンドマネージャーの経験によって決定されていた。しかしながら、ディスクリプターから株式リターンの予測を表現力に優れた深層学習を用いて置き換えることで、長年の経験をパラメータチューニングに置き換えることができる。

具体的には、ディスクリプターをインプットとして与え、アウトプットとして将来リターンを与える。すると隠れ層にはこれらディスクリプターが非線形に合成された「ファクター」が表現される。

### 3 実証分析

#### 3.1 データセット

ここでは日本株式市場を対象に分析を行う。分析のユニバースとして、機関投資家の投資対象として使用されることの多い TOPIX500 指数構成銘柄とした。TOPIX500 指数は東証 1 部上場株式の時価総額の 90% 程度をカバーする株式指数である。特徴量として用いるディスクリプターは表 1 の通りである。これらのディスクリプターの計算のため、予想利益と目標株価 (No.13-18) は I/B/E/S から、その他のデータは Factset、WorldScope と Reuters Fundamentals から取得した。ただし、No.19 以降は毎月末に値が変わる月次データとして扱った。これらのディスクリプターはすべて実務でよく使用されるものである。

#### 3.2 分析方法と考察

実際の運用を見据え、毎営業日ポートフォリオを入れ替える実証分析を行う (図 2)。特徴量として、表 1 を用い、教師データは翌営業日の寄りから 5 営業日先までのリターンとする。また各データは時点毎に 0 から 1 のパーセンタイル化の前処理を行っている。訓練データセット数は直近過去 1,000 個を用いる。これを用いてモデルの学習を行い、各銘柄の予測スコアを算出する。なお、モデルの学習間隔は 5 営業日としている。検証期間は 2012 年 12 月 28 日～2017 年 12 月 29 日であり、直近の特徴量をモデルに与え、毎日引け後に予測スコアを出す。そしてリバランスのタイミングによる影響を減らすために、5 営業日サイクルで 5 本の

ポートフォリオを構築する。これらをポートフォリオ 20% ずつ保有する。各ポートフォリオは予測スコア上位 5 分位の買いの等ウェイト (5 分位ポートフォリオ)、または予測スコア上位 5 分位の買い、予測スコア下位 1 分位の売りの等ウェイト (5 分位-1 分位ポートフォリオ) として構築される。流動性の観点からポジション構築タイミングは予測スコア計算の翌営業日の寄りとする<sup>1</sup>。したがって、日々のパフォーマンスの計測も寄り基準としている。5 分位-1 分位ポートフォリオは、5 分位ポートフォリオから 1 分位ポートフォリオのリターンを引いて、5 分位ポートフォリオは TOPIX500 の等ウェイトリターンを引いてポートフォリオのリターンを計測する。

具体的なモデルとして下記を用いる。

1. 深層学習 (DNN): パッケージ TensorFlow を用いて実装を行った。7 層の全結合型の構造で、活性化関数は全て ReLU 関数を用いた。隠れ層およびドロップアウトの構造とエポック数は表 2 の通り。最適化アルゴリズムに学習率 0.001 の Adam を用い、ミニバッチサイズは 500 とした。バイアスの初期値を 0、そしてウェイトの初期値を TensorFlow の関数 `tf.truncated_normal` の平均 0、標準偏差を  $\sqrt{2/M}$  として与えた。ただし、M は前層のユニットのサイズである。
2. ランダムフォレスト (RF): パッケージ `scikit-learn` のクラス `sklearn.ensemble.RandomForestRegressor` を用いて実装を行った。パラメータについては特徴量の数 (`max_features`) を 11 (=33/3)、木の数 (`n_estimators`) を 1,000、深さ (`max_depth`) を {3, 5, 7} とした。深さの浅い順にそれぞれ RF\_1 から RF\_3 とする。
3. リッジ回帰 (RR): パッケージ `scikit-learn` のクラス `sklearn.linear_model.Ridge` を用いて実装を行った。正則化パラメータ (`alpha`) は {0.1, 1, 10} とした。正則化パラメータの小さい順にそれぞれ RR\_1 から RR\_3 とする。

#### 3.3 分析結果

5 分位-1 分位ポートフォリオ、5 分位ポートフォリオの結果のサマリーがそれぞれ表 3、4 である。年率リターン、リスク、リターン/リスク比 (R/R)、最大ド

<sup>1</sup>引けまでのデータを用いて、予測スコアを計算し、引けでリバランスを行う研究もあるが、これは実際には不可能である。また日々の出来高は寄りが最も多い傾向があるため、寄りでのリバランスを想定している。

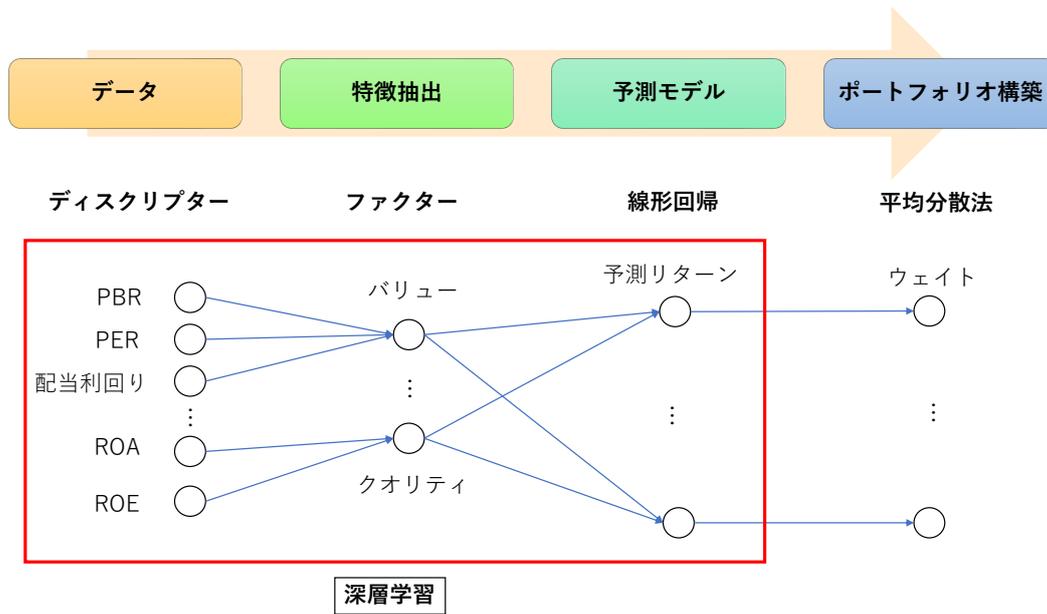


図 1: 深層学習を用いた株価予測のアプローチ

表 1: 使用したディスクリプターの定義

No	ディスクリプター	内容
1	当日リターン	-
2	対 2 日前リターン	-
3	対 3 日前リターン	-
4	対 5 日前リターン	-
5	対 10 日前リターン	-
6	対 20 日前リターン	-
7	対 40 日前リターン	-
8	対 60 日前リターン	-
9	過去 60 日の平均売買金額	-
10	過去 5 日/過去 60 日の売買金額	-
11	過去 10 日/過去 60 日の売買金額	-
12	過去 20 日/過去 60 日の売買金額	-
13	営業利益予想の変化 (対 5 日前)	-
14	営業利益予想の変化 (対 10 日前)	-
15	営業利益予想の変化 (対 20 日前)	-
16	目標株価の変化 (対 5 日前)	-
17	目標株価の変化 (対 10 日前)	-
18	目標株価の変化 (対 20 日前)	-
19	B/P	総資産/時価総額
20	E/P	当期純利益/時価総額
21	D/P	配当/時価総額
22	S/P	売上高/時価総額
23	CF/P	営業キャッシュフロー/時価総額
24	ROE	純利益/純資産
25	ROA	営業利益/総資産
26	ROIC	税引後営業利益/(有利子負債+株主資本)
27	アクルーアルズ	-(流動資産の変化+現金の変化-流動負債の変化-減価償却費)/総資産
28	総資産回転率	売上高/総資産
29	流動比率	流動資産/流動負債
30	自己資本比率	純資産/総資産
31	総資産成長率	総資産の前期からの成長率
32	CAPEX 成長率	資本的支出の前期からの成長率
33	Investment to Asset	有形固定資産の取得による支出の前期からの成長率/総資産



図 2: ポートフォリオの構築例

表 2: 深層学習の構造

モデル	隠れ層 (ドロップアウト)	エポック数
DNN_1	500-200-100-50-10 (50%-40%-30%-20%-10%)	20
DNN_2	500-200-100-50-10 (50%-40%-30%-20%-10%)	30
DNN_3	200-200-100-100-50 (50%-50%-30%-30%-10%)	20
DNN_4	200-200-100-100-50 (50%-50%-30%-30%-10%)	30
DNN_5	300-300-150-150-50 (50%-50%-30%-30%-10%)	20
DNN_6	300-300-150-150-50 (50%-50%-30%-30%-10%)	30

ローダウン (最大 DD)<sup>2</sup> を評価指標とする。なお、表中の太字は DNN, RF, RR それぞれの手法内で最も良いものを表している。

表 3, 4 とともに、DNN はモデルのパラメータの違いによるリターンとリスクの差が大きい。これは DNN の構造設定における自由度の高さを始め、調整すべき (ハイパー) パラメータの数が多いことが要因として考えられる。学習度合いとなるエポック数で比較すると、20 の方が 30 のケースよりも全体的にパフォーマンスが良く、今回検証した DNN は、30 まで学習させると過学習してしまう結果となった。RF と RR については、DNN に比べて調整するパラメータの自由度が低いため、パラメータによる差が小さい。特に RR についてはほぼ同等である。RF はほぼすべてのモデルで DNN に劣後しているものの、RR はパラメータによっては DNN を上回っている。特に買いのみの表 4 で DNN を上回っているケースが多い。パラメータ調整や学習の容易さを考えると、買いのみの 5 分位ポートフォリオでは DNN より RR が好ましいといえる。ただし、年

<sup>2</sup>リターンの最大収益時からの下落率をドロウダウンという。そのドロウダウンが最大のケースを最大ドロウダウンといい、リスク指標として用いられる。

表 3: 5 分位-1 分位ポートフォリオの結果

モデル	年率リターン	年率リスク	年率 R/R	最大 DD
DNN_1	8.74%	6.04%	1.45	-7.00%
DNN_2	6.83%	<b>5.56%</b>	1.23	<b>-6.01%</b>
DNN_3	11.37%	7.23%	1.57	-10.34%
DNN_4	10.00%	6.63%	1.51	-10.40%
DNN_5	<b>11.42%</b>	6.46%	<b>1.77</b>	-8.42%
DNN_6	8.97%	6.13%	1.46	-8.26%
RF_1	<b>7.28%</b>	9.38%	<b>0.78</b>	-20.86%
RF_2	6.69%	9.28%	0.72	-19.56%
RF_3	6.86%	<b>9.23%</b>	0.74	<b>-17.88%</b>
RR_1	10.98%	8.50%	1.29	-13.37%
RR_2	<b>10.98%</b>	<b>8.50%</b>	<b>1.29</b>	-13.36%
RR_3	10.96%	8.50%	1.29	<b>-13.36%</b>

率のリスクと最大ドロウダウンに着目すると、DNN は小さい傾向であり、リスクを回避した運用を行う場合には DNN の方に優位性がある。一方で、買いと売りの表 3 では、RR よりも DNN が比較的良い。これは一般に買い側と売り側で魅力的な銘柄が異なるため、非線形性を考慮できる DNN が売り側でも収益を獲得できていると考えられる。なお、回転率については、いずれもモデルも一度のリバランスで 50% 前後となっており、DNN はその他のモデルよりも 5% 程度高い。しかしながら、取引コストを考慮しても、今回の考察の結論は変わらない。

## 4 おわりに

本稿では、深層学習を用いた株価予測モデルを実際の運用と同様の条件で検証を行った。TOPIX500 を対象とした実証分析の結果、以下の知見が得られた。

- 深層学習による株価予測モデルはランダムフォレストやリッジ回帰に比べパラメータによるパフォーマンスの差が大きい。
- 深層学習モデルは買い、売りの両方で収益獲得の機会がある。

表 4: 5 分位ポートフォリオの結果

モデル	年率リターン	年率リスク	年率 R/R	最大 DD
DNN_1	4.24%	3.06%	1.39	<b>-3.15%</b>
DNN_2	3.36%	3.07%	1.09	-4.01%
DNN_3	<b>5.15%</b>	3.53%	1.46	-3.84%
DNN_4	4.40%	3.21%	1.37	-6.08%
DNN_5	5.11%	3.01%	<b>1.70</b>	-3.46%
DNN_6	4.00%	<b>2.86%</b>	<b>1.40</b>	-4.14%
RF_1	<b>3.02%</b>	<b>4.47%</b>	<b>0.68</b>	<b>-8.23%</b>
RF_2	3.02%	4.49%	0.67	-8.75%
RF_3	2.68%	4.46%	0.60	-9.72%
RR_1	5.95%	3.82%	1.56	-4.03%
RR_2	<b>5.96%</b>	<b>3.82%</b>	<b>1.56</b>	<b>-4.03%</b>
RR_3	5.95%	3.82%	1.56	-4.04%

- 低リスクという観点で、深層学習モデルは優れている。

## 参考文献

- [1] Masaya Abe and Hideki Nakayama. Deep learning for forecasting stock returns in the cross-section. In *Pacific-Asia Conference on Knowledge Discovery and Data Mining*, pp. 273–284. Springer, 2018.
- [2] Arash Bahrammirzaee. A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. *Neural Computing and Applications*, Vol. 19, No. 8, pp. 1165–1195, 2010.
- [3] Rodolfo C Cavalcante, Rodrigo C Brasileiro, Victor LF Souza, Jarley P Nobrega, and Adriano LI Oliveira. Computational intelligence and financial markets: A survey and future directions. *Expert Systems with Applications*, Vol. 55, pp. 194–211, 2016.
- [4] Eugene F Fama and Kenneth R French. The cross-section of expected stock returns. *the Journal of Finance*, Vol. 47, No. 2, pp. 427–465, 1992.
- [5] Campbell R Harvey, Yan Liu, and Heqing Zhu. ... and the cross-section of expected returns. *The Review of Financial Studies*, Vol. 29, No. 1, pp. 5–68, 2016.
- [6] Kei Nakagawa, Takumi Uchida, and Tomohisa Aoshima. Deep factor model. In *MIDAS 2018 : MIDAS @ECML-PKDD 2018 - 3rd Workshop on Mining Data for financial applicationS*, 2018.

- [7] 杉友盛佑, 南正太郎. ファンダメンタルファクターモデル (リターンモデル) における機械学習手法の応用可能性検証. 人工知能学 金融情報学研究会 (SIG-FIN), 2017.