

学位申請論文

日本の株式市場における資産運用の新潮流に関する

実証研究と事例研究

南正太郎

目次

序論	1
第1章 バリュエーション効果の持続性及び循環性のグローバル比較分析	4
1. はじめに	4
2. プロダクションベースモデルに基づく企業価値と株価との関係	5
2.1 企業価値モデル	5
2.2 モデルに基づく仮説	7
3. 検証手法について	8
4. アルファテストによる検証	10
4.1 検証1：バリュエーション効果の検証	11
4.2 検証2：高PBR株の市場模倣	12
4.3 検証3：キャッシュフロー・ファクターのプレミアム	12
5. バリュエーション効果の循環性とトレンド	13
5.1 バリュエーション効果に内在する合理的投資家の投資行動	13
5.2 バリュエーション効果の循環性	14
5.3 バリュエーション効果のトレンドとトレンドの減少	16
6. まとめ	17
第2章 日銀のETF買入が現物株市場に及ぼす影響の一考察	28
1. はじめに	28
2. 日銀のETF買入と株価上昇との関係	28
3. ETF市場への影響	29
4. 現物株市場への影響	30
5. まとめ	32
第3章 エンゲージメント効果の測定—投資ファンドのパフォーマンス評価とエンゲージメントの事例研究—	43
1. はじめに	43
2. リサーチデザインと先行研究	43
3. エンゲージメント・ファンドのパフォーマンス評価	46
4. エンゲージメント効果の事例分析	49
4.1 個別銘柄のアルファの算出方法について	50
4.2 育児用品会社の事例	50
4.3 在宅介護関連企業の事例	52
4.4 2社の事例より	53
5. まとめ	53
第4章 AIの資産運用への応用可能性と限界	67

1.	はじめに	67
2.	AI の基本的手法とその応用	67
2.1	機械学習としての AI	67
2.2	AI 手法の事例と応用の仕方	68
3.	応用事例 1 : マルチファクターモデルへの応用	74
3.1	はじめに	74
3.2	関連研究と手法の基本的概念	76
3.3	リターン・モデルへの応用	78
3.4	考察	79
4.	応用事例 2 : ディープラーニングを用いたイベント考慮後の株価予測	80
4.1	背景	80
4.2	先行・関連研究	81
4.3	分析	81
4.4	考察	83
5.	まとめ	84
	結語	96

序論

本論文の目的は、“日本の株式市場における資産運用の新潮流“に関連する諸問題を解決する、または新しい研究につながる架け橋として貢献することである。潮流とは、ある時代における流行や趨勢を意味するが、株式市場の資産運用に焦点を当てるならば、その潮流とは、現実の経済活動における構造を伴う変化や社会全体および時代が求める課題、ニーズ、変革などを意味することになる。なぜならば、株式は企業の価値そのものを表し、企業を取り巻くステークホルダー（消費者、株主、債権者、地域社会、行政機関など）にとって最大の関心事の一つであり、株式市場は現実の経済活動と表裏一体だからである。

本論文はいくつかの潮流に着目している。一つは、2012年12月に発足した安倍内閣の第3の矢となる「日本再興戦略」における動きである。2014年2月に日本版スチュワードシップコードが導入され、2015年には日本版コーポレートガバナンスコードが導入された。これらは、企業価値の向上と持続的成長をいかにして図っていくのかを構造変化によってもたらすことを目的とした施策である。これら2つのコードは企業と投資家との間で企業価値向上の共通認識のもと”目的を持った対話（エンゲージメント）”を行うことが重要であるとされている。執筆時点（2017年）は、2つのコードの施行後、企業の変革の効果が徐々に始まってきている時期であり、コードについての議論や課題に関する報告が企業をはじめ、様々な形でなされている。例えば、統合報告書を導入する企業が増えたことに加え、優れた統合報告書を評価する機関（WICI ジャパンなど）の登場や、日本経済新聞による年次報告書のアワードなどは事例の一つであろう。このように施策の効果が一定程度でできたとの認識は多くの関係者にとっては共通のものになりつつある。一方で、別の課題も出てきている。それはどのように対話（エンゲージメント）の効果を測定・評価すればよいのかという点である。目に見える形で、ROE 目標を達成する企業が出てきたり、オムロンやエーザイのように日本版コーポレートガバナンスコードの先進企業として社会的に注目される企業が増えてきたりしたことは、効果の一つであろう。一方、インベストメント・チェーンに目を向けた場合、アセットオーナーはいかにして運用会社の「対話」を評価すべきだろうか、また、運用会社は何を尺度として「対話」を成果として主張できるのだろうかなどについていまだ解決の糸口は出てきていない。

潮流の二つめは、アベノミクス第二ステージの重点政策「日本再興戦略 2017」及び「未来投資戦略 2017」の主要政策のテーマに上げられている“第4次産業革命”及び“FinTech”である。これらは、海外に出遅れないためのイノベーションの創出や生産性の改善・企業活動活性化を促すためのものであり、官民挙げてIoT、AI、ロボット、ビッグデータ等の最新技術の社会実装の加速が求められている。資産運用業において、投資理論・計量分析といった従来の考え方に先端のAI技術をどのように応用することができるのかは重要な関心事の一つである。単に、AIの技術を使うのではなく、従来の資産運用技術や考え方に基づいた応用の仕方について求められている。社会的に今後必要とされる分野であることは間違いない

いであろう。

本論文は、これまで挙げた潮流に関連して研究した実証分析及び事例研究をまとめたものである。研究及び事例分析のための基本的なツールとしてマルチファクターモデルを用い、投資スタイル（ファクター）の考え方を踏襲しているが、運用実務で用いられる計量分析手法及び考え方は実証分析を行う上で強力な分析手法になる。このような考え方を応用することによって潮流に関連した諸問題について解決することができるのではないかというのが本研究の動機である。

本論文の前提として効率的市場仮説は部分的には成り立たないとの考え方に立脚している。仮に効率的市場仮説に基づくならば、株価はあらゆる将来の情報を織り込んだ上で形成されており、市場にある情報や銘柄属性、投資スタイルにより市場以上のリターンを得ることはできず、本研究とは矛盾することになる。加えて、本研究の実証分析は実際の市場で観測されたデータに基づいたものであり、実務上生じた課題に対する研究であることから市場は部分的には効率的でない側面を持つとしている。

このような立場から研究を行った本論文の構成と結果の要約は以下である。第1章は、バリュー効果の持続性と循環性について、プロダクションベースモデルといわれるリアルオプションを企業価値評価に用いたモデルに基づき仮説を立て、仮説ごとに検証を行っている。結果として、バリュー効果は短期的には循環性を持っており、長期的には低下しつつあることが分かった。今後、より一層のグローバル化が進み市場がさらに効率的になるのであれば、バリュー効果の長期的な低下傾向は続く可能性がある。第2章では、アベノミクスの景気浮上政策の一環である日銀のETF(Exchange Traded Funds)買入政策が現物市場に与える影響について分析した。日銀のETF買入政策が株式市場を歪めるとされるメカニズムは実際には生じず、むしろ、ETF買入をきっかけとして市場が自ら歪みを是正する方向に働くことが示唆された。第3章では、企業と投資家の対話（エンゲージメント）の効果の測定についてモデルを設定し実証研究と事例分析を行っている。スタイル・インデックスによって説明できないアルファにはエンゲージメント活動による効果の一部が含まれており、この投資スタイルの効果を取り除いたアルファの振る舞いとエンゲージメント活動との関係を見ることで、エンゲージメント活動の効果を部分的には測定できることがわかった。第4章ではAIの基本的な手法や考え方を説明した上で、資産運用実務においてどのように応用できるのかを具体的な事例を用いて検証している。加えて現時点におけるAIの限界について論じたうえで、今後の資産運用実務に関わる人に求められる能力について考察した。応用事例の一つとして、株式収益率はファクターの線形結合により説明されるとするマルチファクターモデルの代わりにAI技術を置き換えた場合の検証をしている。AI技術を用いることで、マルチファクターモデルの説明力よりも優れた結果が得られたことから、非線形結合による株式収益率の関係性の存在が示唆された。別の応用事例では、AI技術を用いてコーポレートアクション（決算報告、プレスリリースを含むイベント）を株価予測に応用する手法について検証している。イベントを考慮することで予測精度が高まる結果が出ている。

【引用文献】

内閣官房日本経済再生総合事務局 [2017] 「未来投資戦略 2017 Society5.0 の実現に向けた改革」『未来投資会議配布資料』2017年6月, 60-64 頁.

内閣官房日本経済再生総合事務局 [2014] 「日本再興戦略改訂 2014 年—未来への挑戦—」『未来投資会議配布資料』2014年6月, 29-32 頁.

内閣官房日本経済再生総合事務局 [2013] 「日本再興戦略—JAPAN is BACK—(2013 年)」『未来投資会議配布資料』2013年6月, 11-13 頁.

日本証券アナリスト協会編 [2017] 『企業・投資家・証券アナリスト 価値向上のための対話』日本経済新聞出版社.

みずほフィナンシャルグループ リサーチ&コンサルティングユニット [2017] 「未来投資戦略 2017 を読み解く～注目政策と<みずほ>の見方～」『One シンクタンクレポート』No.11, 3-54 頁.

第1章 バリューストック効果の持続性及び循環性のグローバル比較分析

1. はじめに

株式の資産運用において広く知られている投資手法にバリューストック投資がある。バリューストック投資とは、通常、PER や PBR などの株価属性指標において低い評価を受けている銘柄を選択し投資する手法である。これまでの数多くの実証研究によって、バリューストック投資が株式市場の平均リターンに比べ、安定的に高いリターンをもたらすことが知られている。例えば、Lakonishok et al. [1994]は、株価をグロースとバリューストックに分けてポートフォリオを作りポートフォリオのリターンを比較することで、バリューストック株で構成されるポートフォリオのリターンがグロース株で構成されるポートフォリオのリターンを大幅にアウトパフォームすることを示した。この理由として、企業の過去の株価リターンに対する投資家の過剰反応がもたらしたものと述べている。そのほかの事例として日本国内の研究としては、西岡 [2008]は PBR 効果を構造的バリューストックと一時的バリューストックに分けた分析を行い、日本の PBR 効果のほとんどが一時的バリューストックによるものと結論づけている。これらの論文が示すようにバリューストック効果の存在は認識されているものの、運用実務に目を向けるとバリューストック効果が見られないとの声が上がることがある。事実、Fama and French [2012]では、グローバル市場を対象に3ファクター・モデル及び、4ファクター・モデルを用い、1989年から2011年までの北米、ヨーロッパ、日本、日本を除くパシフィックの市場において検証した結果、日本市場を除けばバリューストックプレミアムとモメンタム効果が見られるものの、日本市場には見られないという市場の特異性を指摘した。また、規模が増大するにつれて、バリューストック効果が低下することも併せて述べており、グローバルに統合された資産評価モデルは機能していないことも指摘している。本研究では、バリューストック効果の低下という現象に着目し、モデルから導かれる仮説の検証を通じて日本及びグローバルの市場におけるバリューストック効果の確認とバリューストック効果が低下している状況について検証している。バリューストック効果が集約される Information Coefficient (情報係数) の時系列データを用いて時系列解析を行った研究はなく、バリューストック効果の循環性とトレンドについての時系列な振舞いを明示的に示した点が本研究の最大の貢献である。

本研究で用いるプロダクションベースモデルは、リアルオプションの手法を用いてより現実的な特徴を株価リターンに反映しようとするものであり、従来の配当割引モデルを中心とするバリューストック理論では捉えられなかったキャッシュフローの確率性や投資機会の意思決定などを考慮している。従来バリューストック効果に関する研究が示している結果はアノマリーとしてこれまで扱われてきたが、先のLakonishok et al. [1994]は、行動ファイナンスと呼ばれる分野において、投資家の非合理的な側面(ミスプライシング)にてバリューストック効果を捉えようとしている一方で、Fama and French [1996]はリスクプレミアムとして説明しており現在に至るまで、両説の優劣については結論が出ていない。どちらの説明にしても確か

な結論が出ていない中、登場してきたのが、バリュエーション効果を合理的な投資家のプライシングの問題として説明するこのプロダクションベースモデルである。以下では、このプロダクションベースモデルに基づき仮説を立て、検証することを通して構造的にバリュエーション効果がもたらされ、トレンドと循環性が存在することについて検証する。

2. プロダクションベースモデルに基づく企業価値と株価との関係

以下では、Berk et al. [1999]で発表されたプロダクションベースモデルについて簡単に説明する¹。このモデルでは、リアルオプション理論などを企業価値評価に応用することによって、現実的な特徴をとらえることができる。その結果、企業価値と株価リターンが関連付けられるようになってきている。

2.1 企業価値モデル

プロダクションベースモデルの前提となる企業価値は、その企業がもつ既存の資産の価値と成長オプションの価値（新規プロジェクトの持つオプション性）によって表わされるとする。すなわち、企業価値とは、現時点で保有している資産とこれから保有する資産の価値の総和として以下で表現される。

$$P(t) = \sum_{j=0}^t V_j(t) \chi_j(t) + V^*(t)$$

$P(t)$ はt期の企業価値、 $V_j(t)$ は既存の資産価値、 $V^*(t)$ は成長オプションの価値をそれぞれ表わしている。 $\chi_j(t)$ は、既存資産がt期において存続しているかどうかの変数であり、0か1の値をとる。この式の意味は、企業価値がt期までの既存資産価値の総和と成長オプションの価値の合計によって決まることを表している。ここで、既存資産価値は、

$$V_j(t) = E_t \left[\sum_{s=t+1}^{\infty} \frac{z(s)}{z(t)} C_j(s) \chi_j(s) \right]$$

で表現され、成長オプションの価値は、

$$V^*(t) = E_t \left[\sum_{s=t+1}^{\infty} \frac{z(s)}{z(t)} \max[V_s(s) - I, 0] \right]$$

で表される。ただし、 $z(t)$ はプライシングカーネル（確率的割引ファクター）、 $C_j(s)$ はキャッシュフロー、 I は投資額である。企業価値を解析的に求めるためには、既存資産価値と成長オプション価値について分けて求める必要がある。前提として、プライシングカーネルとキ

¹ Berk et al. [1999]の原文の解説に基づく。原文の Appendix ではより詳細な展開がなされている。

キャッシュフローには、標準ブラウン運動を仮定し、金利変動に Vasicek Model(Berk et al. [1999], Appendix B.)を用いると企業価値は、

$$P(t) = b(t)e^{\bar{C}-\beta(t)}D(r(t)) + Ie^{\bar{C}}J^*[r(t)]$$

と展開することができ解析的に解を求めることができる²。

期待リターンは、バリュエーション式(Berk et al. [1999],Appendix A.)から、

$$E_t[1 + R_{t+1}] = \frac{\pi n(t)(D_e(r(t))e^{-\beta t} + 1) + J_t^*(r(t))}{n(t)D_e(r(t))e^{-\beta t} + J^*(r(t))}$$

と求めることができる。 $n(t)$ は既存プロジェクト数、下の添え字 e は t 時点から $t+1$ 時点までの期待値をとったものである。この式から、既存プロジェクトがない新規ベンチャー企業などは、 $n(t) = 0$ となるので、

$$E_t[1 + R_{t+1}] = \frac{J_t^*(r(t))}{J^*(r(t))}$$

となり、ベータに依存しない期待リターンが求められる。また、十分に既存プロジェクトが存在する成熟企業などは、 $n(t) \rightarrow \infty$ であるので、

$$\lim_{n(t) \rightarrow \infty} E_t[1 + R_{t+1}] = \frac{\pi[e^{\beta(t)} + D_e(r(t))]}{D(r(t))}$$

となり、ベータの上昇に比例して期待リターンが大きくなることになる。ベータは時間の関数となっていることより時間の変動によって期待リターンとベータの関係が推移していくことがわかる。さらに、期待リターンの式と企業価値の解析解から

$$P(t) = b(t)e^{\bar{C}-\beta(t)}D(r(t)) + Ie^{\bar{C}}J^*[r(t)]$$

であるので、

$$b(t)e^{\bar{C}-\beta(t)} = \frac{P(t) - Ie^{\bar{C}}J^*[r(t)]}{D(r(t))}$$

となる。これを用いて、期待リターンを書き直すと

$$E_t[1 + R_{t+1}] = \frac{\pi D_e[r(t)]}{D[r(t)]} + \pi e^{\bar{C}} \left[\frac{b(t)}{P(t)} \right] + Ie^{\bar{C}} \left[J_e^*[r(t)] - J^*[r(t)] \frac{\pi D_e[r(t)]}{D[r(t)]} \right] \left[\frac{1}{P(t)} \right]$$

となる。なお、 $E_t[1 + R_{t+1}]$ は期待リターン、 $r(t)$ は金利、 $b(t)$ は t 時点までの既存資産の価値合計、 \bar{C} は平均キャッシュフロー、 I は投資額、 $J^*[r(t)]$ は成長オプションの条件付き期待値、

² 巻末補論にて詳細に展開している。

$D[r(t)]$ は割引関数であり、下の添え字 e は t 時点から $t + 1$ 時点の期待値をとったものである。なお、 π はコンソル債の利子の減価率³である。この式は、次の3つのパートに分けることができる。

期待リターン = 既存資産が生むキャッシュフローの価値変動
 + PBR の逆数に比例する部分
 + 成長オプションに関する部分

この式が示すように、企業価値のバリュエーション式から期待リターンを求めると、PBRの逆数に比例する項目がモデル式の中に含まれていることになる。すなわち、PBRの逆数が大きい（PBRが小さい）と、期待リターンが高いことを意味している。すなわちバリュー効果が、構造的な枠組みによって生じていることになる。

2.2 モデルに基づく仮説

プロダクションベースモデルは、従来のバリュエーションモデルでは表現できなかったキャッシュフロー変動の確率性や投資意思決定などの現実的な特徴を織り込んだ株価リターンの理論である。バリュー効果やサイズ効果という従来ではアノマリーとして捉えられていたものが、合理的な投資行動の結果として生み出されることも説明している。

本研究では、このプロダクションベースモデルに基づき、次の4つを分析対象とし検証を行う。まず、第一に B/M によるバリュープレミアムが存在するかどうかの検証である。B/M によって実際にどのくらいプレミアムが観測されるのか、またそれは市場によって異なるのかについて考察する。一般的にバリュー効果とは、低 PBR 株に重きをおいて投資することであるから、プロダクションベースモデルは通常のバリュー株モデルとも整合的である。B/M のプレミアムに関しては、実際に PBR の逆数をファクターとした時にプレミアムがどのくらいあるのかを検証することで知ることができる。第二は、高 PBR 株における市場を模倣することの検証である。バリュー効果を別の角度から見ると、高 PBR 株は市場の価格変動を模倣するのではないかと考えられる。B/M の構成項目を見ると、B (Book Value) は短期的にはあまり変動しない。一方 M (Market Value) は株価の変動を受けて変動しやすい。とするならば、Book Value の値が小さければ小さいほど、Market Value の変動に大きく依存すると考えられる。そうであるならば B/M の値が小さい高 PBR 株は、市場の変動を大きく受けることによって、投資収益率の動向がベンチマーク(市場)に似通ってくるだろう。第三は、キャッシュフローに関するファクターにもプレミアムが存在するかどうかである。キャ

³ $D[r(t)]$ はコンソル債の価値であり、 π を用いて以下のように定義される。

$$D[r(t)] = \sum_{s=t+1}^{\infty} \pi^{(s-t)} B[s-t, r(t)]$$

毎期、 $1 - \pi$ だけ支払われる利子が減価するときのコンソル債の価値を意味している。

キャッシュフローに関するファクターも PBR と同様にプレミアムを生むと期待できる。先に示した期待リターンの式の構成項目をみると、「既存資産が生むキャッシュフローの価値変動」と「成長オプションに係る部分」において、キャッシュフローが多いほど期待リターンが増加することがわかる。このことから、キャッシュフローに対して何らかのプレミアムが存在することが期待される。また、キャッシュフロー項目は利益項目との相関が強いことから、利益項目もプレミアムを生むと期待できる。第四は合理的な投資家によるバリュウ効果の減少についての検証である。PBR 効果が仮に効率的な市場の下で合理的な投資家の行動によってもたらされるのなら、モデルに基づけば PBR 効果は長期的には減少していくはずである。割安投資による行動から低 PBR 株は本来のファンダメンタルズに基づく価値を織り込んだ適正な価格に押し上げられるはずだからである。第一から第三まではアルファテストと呼ばれる分析手法を用いて検証する。第四についてはアルファテストによって求められた時系列データを用いて時系列分析及びトレンド分析を行うことで検証する。次節ではまず、アルファテストについて説明する。

3. 検証手法について

アルファテストとは、市場を上回る超過リターン（アルファ）があることを前提として、選択したファクターがどのくらいの超過リターンをもたらすことができるのかを評価する分析手法である。以下では一般的なリターン・モデルの説明と分析プロセスに基づいて説明する。

アルファとは、ベンチマークに対する超過リターンのことであり、アルファテストは超過リターンの源泉となるファクターを調べるテストである⁴。市場において、実際にどのくらいアルファがあるのかを実際のデータから求めるには、一般的には、次のようなマルチファクターモデルからパラメータを推定することになる。

$$R_i = \alpha + \beta_1 F_{i1} + \dots + \beta_m F_{im} + \varepsilon_i$$

R_i はある銘柄のある期間におけるリターン、 F_{ij} は当期首までに明らかになっているファクター値、 α 、 β_j はそれぞれパラメータである。

マルチファクターモデルから推定される β_j は、特定のファクターによってどの程度の株式リターンを説明できるのかを表しているので、一般的にファクター・リターンと呼ばれている。例えば、市場の全銘柄をNとすると、ある期間のリターン $\{R_1, \dots, R_N\}$ を、その期首までに観測されているm種類のファクターデータ $\{F_{1j}, \dots, F_{Nj}\}$ ($j = 1, \dots, m$)で重回帰することで、当該期間におけるパラメータ $\{\alpha, \beta_1, \beta_2, \dots, \beta_m\}$ が推定される。もしも、ファクター・リターンが推定した時点によらずに安定的に一定の傾向を示せば、このモデルによってある程度リターンを予測できていると考えられる。よって、優れたモデルを作成できるかどうかは、どのようなファクターを選択するかに依存することになる。アルファテストの

⁴ 乾・室町 [2000]、吉野 [2007]、吉野・斎藤 [2007]の説明に基づいている。

全体の分析プロセスは以下となる。

A) データの説明とファクター選択

全銘柄について、被説明変数を月末時点の月次リターンとし、説明変数として一般的に機関投資家に利用されているファクターをいくつか挙げ、回帰分析を用いて説明する。説明変数は、たとえばPBRの逆数、配当利回り、ROE等である。選択したファクターの値を対象となる市場の対象銘柄すべてについて計算する。このとき、ファクターのすべての値について基準化（平均0，分散1）と異常値処理を行う。

B) 一定期間におけるファクター・リターンの計算

対象とする全銘柄についてすべてのファクター値が求められたら、次はモデルの推定である。モデルの推定は、ある期のリターン・データとその期首までに観測されているファクターデータを用いてクロスセクションで回帰分析を行えばよい。この結果、推定されたモデルを用い、その説明変数に翌期首のファクターデータを代入することによって、翌期の期待リターンを求めることができる。

C) 分位ポートフォリオの作成

次に分位ポートフォリオを作成する。分位ポートフォリオとは、ファクター値（投資指標及び銘柄属性）順に銘柄数を均等に分けて作ったポートフォリオ⁵のことで、一般的には3分位、5分位、10分位に分けたポートフォリオが利用される。以下では、5分位ポートフォリオを前提に説明する。分析結果の評価については、仮にモデルの予測力が高いのであれば、每期、予測リターンと実績リターンは正の相関関係にあるので、予測リターンの大ききでソートして作った分位ポートフォリオのリターンは比例して高くなるはずである。分位ポートフォリオを構築するのは、システムティックリスク（市場全体の価格変動の影響による価格変動リスク）を消去することで、個別銘柄の持つ銘柄特性を抽出するためである。

D) ファクターの有効性評価

次に問題になってくるのはファクターの有効性である。どのファクターが最も優れているのかをファクター間の比較によって判断する必要がある。一般的に、ファクター効果の有効性を評価する方法としてはスプレッド・リターン、ファクター・リターン(回帰係数)、Information Coefficient(情報係数)の3つが使われる。

まず、スプレッド・リターンであるが、最上位の分位ポートフォリオの銘柄群の事後の平

⁵ 厳密には、業種によってファクターの値に特徴がある(平均が極端に高い)といった問題などがあり、単純に投資指標順にソートすることが望ましくない(ある業種がある分位に偏るなど)ことがある。また、均等に分けられない場合などではデータを補う必要があり、その方法にもいくつか考えられている。今回は、業種制約を考慮して分位ポートフォリオを作っているため、特定の業種にポートフォリオが偏るといった問題を排除している。また、足りないデータに関しては、直近のデータ前後の平均で補っている。

均リターンから、最低位の分位ポートフォリオの銘柄群の事後の平均リターンの差「(第1分位ポートフォリオの平均リターン) - (第5分位ポートフォリオの平均リターン)」のリターンを累積した累積リターンである。実務的には、第1分位のポートフォリオを購入し、第5分位ポートフォリオを売却する投資戦略によって獲得できるリターンを意味しているため実感として捉えやすい特徴がある。次に、ファクター・リターン(回帰係数)であるが、事後的に得られたリターンを、複数のファクター・エクスポージャーで回帰分析した時の回帰係数によって求めることができる。選択した複数のファクター値を用いてマルチファクター分析を行い、そのときのファクターリターン(回帰係数)を意味する。回帰係数が大きいほどファクター・リターンは高くなる。3つ目に **Information Coefficient**(情報係数)であるが、事前のファクター・エクスポージャーとリターンとの相関係数のことであり、ファクターによるリターン予測の精度を意味する。相関係数として、積率相関係数もしくは順位相関係数が一般的に用いられる⁶。回帰分析の傾向線(傾きの線)上にどれだけファクター値がプロットされているか、あるいは、どのくらい近い位置にあるのかを見るものであり、異常値を含むファクターに頑健な結果を返すことやマネジャー評価といった理論的な結びつきが強いことが知られている。

例えば、Clarke et al.[2002]及び袖山・矢野 [2003]は、ICに基づき次のように **Information Ratio**(情報比)を定義することで、銘柄とアルファ予測だけでなく、マネジャーのポートフォリオ組成力が運用能力に影響することを示している。

$$IR = TC \times IC \times \sqrt{N}$$

ただし、IRは**Information Ratio**(情報比)、TCは**Transfer Coefficient**(ポートフォリオにおける各銘柄のアクティブ・ウェイトとアルファとの相関)、Nは銘柄数である。

E) アルファの算出

ファクターの有効性を評価することができれば、あとはどのファクターを選択するかの問題である。ファクターの選択については必ずしも決まった形があるわけではない。アルファテストの結果、最も結果がよかったファクターをアルファとすることもあるがより高いリターンと安定性のあるアルファを得るために、いくつかの安定したファクターを組み合わせることも実務では行われている(合成ファクターを呼ぶ)。

4. アルファテストによる検証

ここでは、プロダクションベースモデルの観点から検証対象とした4つの分析対象のうち最初の3つの検証を行う。実際のデータを使って検証するため、次の分析方法を採用する。第一については、B/MがPBRの逆数の関係にあったことを踏まえて、PBRの逆数をP

⁶ ピアソンの積率相関係数は一般的に相関係数と呼ばれているものである。一方スピアマンの順位相関係数は先にデータに順位づけをおこない、その上で相関係数を求めたものである。

ファクターとしてそのファクタープレミアムを求める。このとき求められるリターンは、プロダクションベースモデルに織り込まれている B/M のプレミアムに相当するので、他のファクターと比較してプレミアムがどの程度あるのかを評価する。また、いくつかの市場のもとで同様の分析を行い市場間の比較も行う。第二については、高 PBR の分位ポートフォリオのパフォーマンスを市場のパフォーマンスと比較する。同様に、他のファクターと比較することで PBR 独自の効果であることを検証する。第三については、キャッシュフローに関連するファクター (Free Cashflow Yield 「フリーキャッシュフロー利回り」、Accruals 「アクルールズ」) のパフォーマンスを計算しプレミアムの存在を検証する。

今回分析するにあたり用いたデータについては次である。まずベンチマークとしては、MSCI⁷ US + Canada (North America)、MSCI Europe、MSCI Pacific ex japan (日本を除くアジア地域)、MSCI World ex japan (日本を除く世界)、TOPIX を用いている。また、ユニバースとしては各ベンチマークの指数採用銘柄である。また、分析期間は 2001 年 12 月から 2008 年 12 月末までの月次データ (月末値) である。ファクター値については、PBR の逆数、Free Cashflow Yield 「フリーキャッシュフロー利回り」、Accruals 「アクルールズ」である。

4.1 検証 1：バリュー効果の検証

図表 1-1 は、各市場における分位ポートフォリオ及びベンチマークのリターンと基本統計量をまとめたものである。併せてスプレッド・リターンと IC の t 値⁸を求めている。

まず、分位ポートフォリオを見ると、TOPIX と World は、第 1 分位ポートフォリオのリターンが最も高く、第 5 分位ポートフォリオに近づくほど低くなってきている。特に、日本でこの傾向が顕著である。ベンチマークの累積リターンであるが、TOPIX、North America が低く、Pacific が最も高い値となっている。日本はベンチマークのリターンが良くない。一方で、アジア諸国の市場は、ベンチマークのリターンが高く、その成長性の高さが見てとれる。TOPIX は、ベンチマークの水準に対して第 1 分位ポートフォリオのリターンが高い。

次に、分位ポートフォリオの有意性であるが、IC の t 値 (T-Stat) をみると、TOPIX が最も高く、Pacific が最も低い結果となった。一般的には IC の t 値による優位性があると評価するには 1.0 以上であることが望ましいことから Pacific はあまり当てはまりがよくない。World については 1.0 近傍であるので検討する余地がある。また、TOPIX に関しては 2.6 と当てはまりがよい。

図表 1-2 は、図表 1-1 のデータを対ベンチマーク比に直すことで、市場間の比較を可能にしたものである。ベンチマークのリターンに対してどのくらいアルファがあったのかを表している。Pacific、World の第 1 分位ポートフォリオの累積リターンはベンチマークの累積リターンの 1.2 倍程度のリターンを出している。Europe は 5 つの分位ポートフォリオ

⁷ MSCI はモルガン・スタンレー・キャピタル・インターナショナルのことで、同社の算出している MSCI インデックスは世界の株価動向を示す指数として実務では有名である。

⁸ IC-T 値は Information Coefficient の t 値である。

ともほぼ市場のリターンと同程度である。また、TOPIX の第 1 分位ポートフォリオは、ベンチマーク累積リターンの 2 倍弱のリターンを出しており、ほかの市場に比べてやはり高い水準である。

以上の検証結果をまとめると、低 PBR 株で構成されている第 1 分位ポートフォリオの累積リターンは、Europe と North America を除いて最も高い値であることがわかった。低 PBR 株はいわゆるバリュー株であるので、第 1 分位ポートフォリオが高いリターンを出しているということは、バリュープレミアムが存在していることを意味する。とくに、日本での効果が大きい結果となった。

4.2 検証 2：高 PBR 株の市場模倣

高 PBR 株は市場を模倣するのではないかという問題に対しては、PBR の逆数をファクターとするマルチファクター分析によって作った第 4 分位、第 5 分位ポートフォリオを検証すれば良い。高位分位は高 PBR 株によって作られたポートフォリオであるので、これらのポートフォリオが市場インデックスのリターンに似ているかどうかを調べればよい。

図表 1-2 によれば、第 4 分位ポートフォリオは、すべての市場においてベンチマークの累積リターンに近い水準の累積リターンを得ていた。世界的に、高 PBR によって作られたポートフォリオは、長期的な累積リターンに関して市場に近いことがわかる。また、第 5 分位ポートフォリオでは、とくに Pacific がベンチマークの累積リターンに近い水準であった。図表 1-3 は、Pacific における第 4 分位、第 5 分位ポートフォリオの時系列の推移を表示したものであるが、時系列の振舞いも類似している。

4.3 検証 3：キャッシュフロー・ファクターのプレミアム

キャッシュフローに関するファクターに対してもプレミアムの存在が期待できるかどうかを検証するため、Free Cash flow Yield と Accruals の 2 つのファクターに関してポートフォリオを作成し分析した。定義からキャッシュフロー項目が直接反映されるため使用した。

Free Cash flow Yield は、企業が本来の事業によって得られるキャッシュフローの利回りであり、1 株当たりのフリーキャッシュフローを株価で割ることで定義される。また、Accruals は、会社の利益の質をリーズナブルに評価することができる指標であり、営業利益から営業キャッシュフローを差し引くことで定義される。営業利益よりも営業キャッシュフローが多いほど、利益の質が高いことを意味している。つまり、Accruals 値がマイナスであるほど利益の質がいいという評価になる。また、キャッシュフローとは逆相関の関係があるから、「利益の質が良い企業＝キャッシュフローが潤沢な企業」ということになる。

図表 1-4 は分析結果をまとめたものである。最初に Free Cash flow Yield に基づいた分位ポートフォリオについては、「F1-FN Return Correlation PBR の逆数」で示されている数値のように、PBR の逆数のスプレッド・リターン（第 1 分位ポートフォリオのリターンから第 5 分位ポートフォリオのリターンを差し引いた値）との正の相関が強い。World においては完

全相関に近い水準にある。このことは PBR の逆数の分位ポートフォリオのリターン格差が大きくなるほど、Free Cash flow Yield による分位ポートフォリオのリターン格差が大きくなることを意味している。次に、各分位ポートフォリオ（対ベンチマークの値）では、第 1 分位ポートフォリオにはある程度プレミアムが観測されるが、第 1 分位から第 5 分位にかけてリターンが単調に減少していないため、持続的な予測力は見られない。PBR の逆数のスプレッド・リターンとの相関が強い結果であったことをふまえると Free Cash flow Yield による分位ポートフォリオのリターンも単調に減少すべきであるが、そうではないことから何らかのアノマリーがあると思われる。

次に Accruals に基づいた分位ポートフォリオについては、North America では、PBR の逆数のスプレッド・リターンの間には相関がみられない。一方で TOPIX や Pacific には強い正の相関がある。定義から Accruals とキャッシュフローとは逆相関であるはずなので、PBR の逆数のスプレッド・リターンの間には負の相関があるはずである。TOPIX や Pacific の市場においては特に強い正の相関がみられたのかについては詳細に分析してみなければわからないが、市場特有の営業利益に関するなんらかのアノマリーが存在する可能性がある。分位ポートフォリオについては、特に大きなプレミアムがあるとは言えない結果となった。

以上の検証結果から、当初想定していたキャッシュフローに関するファクターには、PBR の逆数ほどのプレミアムは期待できないことがわかった。

5. バリュエーション効果の循環性とトレンド

この節では、プロダクションベースモデルから立てた最後の分析対象について検証する。ここでは、合理的な投資家がバリュエーション効果に対してどのような影響を与えているのかを直接とらえることは難しいため、以下の 2 つのプロセスに分けて分析する。

① 合理的な投資家の行動がバリュエーション効果に織り込まれているかどうか。

② 織り込まれているとして、バリュエーション効果が減少している状況を捉えられるかどうか。

これら 2 つのことがわかれば、少なくともバリュエーション効果の減少の一つの理由として、合理的な投資家の投資戦略が挙げられることになる。

5.1 バリュエーション効果に内在する合理的投資家の投資行動

プロダクションベースモデルでは、モデルの中に PBR が織り込まれており、バリュエーション効果を説明することができた。その効果は、純粋に合理的な投資家が合理的な行動をする結果として生じるものであった。合理的な投資家は、1 単位あたりのリスクに対してより大きい期待リターンを望むことから、バリュエーション効果のような構造的に高い収益を得ることができるとアノマリーが存在するのであれば、バリュエーション効果を得るための投資戦略を積極的に行うはずである。具体的には、多くの合理的な投資家が低 PBR の銘柄をロングし、高 PBR の銘柄をショートする戦略を採用することになる。このような合理的な投資家が低 PBR 株を買う行動を行えば、株式の価格変動は投資家の需給に依存していることから、低 PBR 株は買

いが集中して株価が上昇する。一方、プロダクションベースモデルのもとでは、市場の相対的価値が上昇することによって株価の期待リターンを押し下げる効果⁹が働くため、価格の上昇効果は徐々に失われ、やがて価格が下落に転じることになる。つまり、合理的な投資家の投資行動は、株価の上昇と下落を引き起こす要因になる。もし、時系列推移の過程でバリュウ効果に明確な循環性が観測されるなら、その要因には合理的な投資家の投資行動の結果が含まれていると期待される。以下、これらのことを時系列分析によって検証する。

以下の分析に使用するデータについては、アルファテストで計算された PBR の逆数をファクターとした時の IC 値の月次時系列データを用いる。分析期間は、2001 年 12 月 1 日から 2008 年 12 月 31 日までであり、分析対象としては MSCI North America、MSCI Europe、MSCI Pacific、MSCI World、TOPIX を用いている。なお、PBR の逆数をファクターとした時の IC 値の時系列データを用いるのは、第一に IC 値によってリターン・モデルの予測力評価が可能であること、第二に PBR の逆数は先の分析で予測リターンと実績リターンとの間に強い相関がみられるため (IC が高ければリターンが高い)、第三に分位ポートフォリオ分析において持続的に高い予測力を有していたためである。この IC 値の時系列データを分析することによって、予測力の変化がわかることに加えて、スプレッド・リターンと IC は強い相関を示しているため、高分位ポートフォリオと低分位ポートフォリオの差の変化(バリュウ効果)を同時に分析することができる。

5.2 バリュウ効果の循環性

PBR の逆数を使ってマルチファクター分析を行い、その時に計算された IC の時系列データに明確な循環性をとらえることができたなら、それはもともと合理的な前提のもとで生じるバリュウ効果に、合理的な投資家の投資行動が反応しているからだといえる。そこで、IC の時系列データに循環性があるかどうか、あるならばどのくらいの強さなのかを調べるために時系列分析を行う。時系列分析では時系列データに隠されている周期成分や各成分の強さを分析するが、今回、IC の時系列の周期成分を分析するためにスペクトル分析を行うことにする¹⁰。

⁹ Book to Market は次の式であるので、株価上昇は B/M を押し下げることになる。

$$\text{Book to Market} = \frac{\text{Book Value}}{\text{Market Value}} = \frac{\text{純資産}}{\text{株価} \times \text{発行済み株式数}}$$

¹⁰ スペクトル分析を行うまえに、IC の時系列データが定常過程なのかどうかを検証した。定常過程とは、時系列の性質として平均値や異時点間の共分散が時間の推移によって変化しない過程のことをいう。対象データが定常過程なのか非定常過程なのかを調べる方法として単位根検定がある。単位根検定は、次の仮説を検定するものである。

帰無仮説 H_0 : ブラウン運動である。(ランダムウォークである)

各市場の時系列データにスペクトル分析¹¹を行うことで、データに内在する周期性の有無や各成分の強さなどを分析することができる（松葉 [2007]）。この分析結果をまとめれば、次のようになる。それぞれの市場において大きな周期性が観測されるのは、日本を除く6か月の周期性と、日本だけ強く観測される12ヶ月の周期である。日本の12ヶ月周期は他の市場とは異なっており、日本のバリュー効果は12ヶ月周期で強く現れる傾向にある。市場間の比較においてわかることは、先進国の市場は比較的同じような周期性を持っていること及び Pacific については特に6ヶ月と4ヶ月の周期成分が強く観測されたことである。

North America	: 6 か月 & 3 ヶ月弱
Europe	: 6 か月 & 3 か月
Pacific	: 6 か月 & 4 か月弱
World	: 6 ヶ月 & 3 か月
TOPIX	: 12 ヶ月

以上をまとめると、IC の時系列データに明らかな周期性が見られる。しかも、それは世界的に観測される。また、特に日本の市場においては12ヶ月の強い周期性が存在する。

先に述べたように、PBR はプロダクションベース理論のもとでは構造的に組み込まれており、合理的な投資家の合理的な行動の結果としてバリュープレミアムを生じさせていた。合理的な投資家が行うロングショート戦略は合理的な行動の結果として株価を上昇・下降させ、バリュー効果に循環性をもたらすであろうと考えた。これらのことから、バリュー効果に明確な循環性が存在するのであれば、循環性を引き起こす要因として合理的な投資家

対立仮説 H_1 : ブラウン運動ではない。(ランダムウォークではない)

検定の結果としてでてくるP値を使って評価することが一般的である。検定の結果、帰無仮説が棄却されなければ、その時系列はブラウン運動となるので非定常過程であることがいえる。対象とする時系列データが定常過程であれば、そのまま用いればよい。検定の結果、どの市場も定常過程として扱えばいいことがわかった。

¹¹ 時系列における自己共分散 C_k のフーリエ変換が可能であるとき、周波数 $-\frac{1}{2} \leq f \leq \frac{1}{2}$ 上で定義される関数

$$P(f) = \sum_{-\infty}^{+\infty} C_k e^{-2\pi i k f} = C_0 + 2 \sum_{-\infty}^{+\infty} C_k \cos 2\pi k f$$

をパワースペクトル密度関数という。時系列の周期成分の相対的な強さを示すことから、時系列の周期特性をとらえるのに用いられる。先のパワースペクトル密度関数における自己共分散 C_k に代わって、標本データ y_1, y_2, \dots, y_n の自己共分散 \hat{C}_k を用いて定義したものをピリオドグラムと呼ぶ。

$$P_j = \hat{C}_0 + 2 \sum_{k=1}^{n-1} \hat{C}_k \cos 2\pi k f$$

ただし、周波数は $f_j = \frac{j}{n}$, $j = 0, 1, 2, \dots, \frac{n}{2}$ である。ピリオドグラムによってスペクトル密度を推定する。

の存在があるであろうと推測したのである。しかも、高いバリュー効果がみられる市場であれば、なおさらその循環性は強いはずである。これまでの分析は、まさにこれらの推測と合致した結果となった。

5.3 バリュー効果のトレンドとトレンドの減少

バリュー効果が低下しているかどうかについては、時系列データは周期的に変動する性質をもつものも少なくないことから、時系列データを季節性とトレンドに分解し、トレンドの傾向の有無を検証する。先のスペクトル分析では短期的な周期変動が観測された。トレンドは比較的なめらかな長期変動を示すものであり、次のように分けることができる。

$$\text{観測値} = \text{トレンド} + \text{周期変動} + \text{残差}$$

周期変動の中には季節による変動や短期的な変動要因が含まれている。通常、季節要素を推定することができれば、元のデータ(原系列)から季節変動を除去することでトレンドと循環変動の分析が可能になる。本章では、Robert et al. [1990]に基づき、季節変動とトレンドを抽出している¹²。

図表1-5は各市場の時系列IC値のトレンドのみをグラフ化したものである。個別市場については、まず、North Americaは全体のトレンドとしては減少傾向にあるが、2002年と2005年に上昇したあと、2006年の半ばより急激に落ち込んでいる。Europeはきれいな減少トレンドがみられ、2006年度半ば以降、特に強い減少がみられる。季節性としては5月・6月・9月に強く観測された。Pacificは2001年に急激な減少以降、低い水準で循環を繰り返している。直近は上昇トレンドが見られるが、過去の循環とは異なっているようだ。WorldはNorth Americaに近いトレンドであり全体としては減少傾向にあり、特に2006年以降に急激に減少している。ウェイトの50%をNorth Americaが占めていることが影響している可能性がある。TOPIXは2004年10月近辺までは、とくにトレンドの減少傾向は見られず循環が観測される。2005年には急激に減少し、それ以降循環性が見られない。次に、全体に共通する傾向としては、時間が経つにつれて、トレンドが低下している。長期的な分析であることを考えると、短期間で初期の水準に戻ることは考えにくく、今後もこの減少傾向(低水準傾向)は世界的に続く可能性がある。市場ごとの比較については、日本市場のバリュー効果は他の市場の影響をほとんど受けていないようである。2000年代前半のTOPIXとWorldを比較すると、TOPIXとWorldはNorth AmericaやPacific、Europeの動きとはあまり連動せず、互いに逆の動きを呈していたが、Worldは2006年あたりからNorth AmericaやPacific、Europeの動きに連動するようになってきている。一方でTOPIXは、2007年以降も独自の水準を継続している。また、水準としては当初に比べて低いのが、Europeを除きTOPIXを含めた世界全体には上昇トレンドの兆しが見られる。

以上から、PBRの逆数をファクターとしたプレミアム効果は、水準としては世界的に減

¹² 統計ソフト「R」を使っている。

少傾向にあることがわかる。IC の値とスプレッド・リターンとの間に強い相関があることを考えると、低 PBR 株をロングし、高 PBR 株をショートする戦略によって得られるリターン(バリューストック効果)も減少傾向にあるのだろう。さらに、直近におけるバリューストック効果の減少の程度からすると、短期間に元の水準に戻るとは考えられない。今後とも、バリューストック効果が減少する可能性がある。スペクトル分析においては、合理的な投資家の行動がバリューストック効果に織り込まれていることを、時系列データに明確な循環変動性が存在することによって検証した。特に、高いバリューストックプレミアムが観測された日本市場においては、他の市場との比較で、循環性が強く示された。市場全体を対象とした分析であることを考えれば、これらの結果は少なからず合理的な投資家の存在がバリューストック効果を生じさせていることを示している。このことはプロダクションベースモデルのなかで PBR に関連する項目が株価リターンを構成しているという結果と合致したものでもある。続いてのトレンド分析では、バリューストック効果が長期的に減少している状況が世界的に観測された。特に、最近の減少の速度は速い。また、バリューストック効果が強く観測された日本においても、やはり減少が見られる。循環変動性とトレンドには強い相関があることが一般的に知られているが、合理的な投資家の行動がバリューストック効果に多分に反映されており、効果が減少してきている状況とは、市場の効率性が高まることによってバリューストック効果が吸収されてきている状況だと考えるのが自然であろう。つまり、バリューストック効果が減少傾向にある一つの要因として、合理的な投資家の存在が考えられることになる。プロダクションベースモデルに基づくならば、合理的な投資家の合理的な投資行動によって PBR によるバリューストック効果もたらされる。そして、その効果は、市場の効率性によって徐々に吸収され、次第に弱まっていくであろう。

6. まとめ

今回、リアルオプションの手法をバリュエーションに応用したプロダクションベースモデルに基づき 4 つの仮説を立て分析を行った。これまでアノマリーとしてしか扱われてこなかったバリューストック効果が、プロダクションベースモデルの基では合理的な投資家の行動の結果として理論的に説明できる。モデルに基づいて立てた仮説を検証するために行ったグローバル市場を対象とした実証分析においてもバリューストック効果が観測された。特に日本市場における低 PBR による高いプレミアムが観測され、しかもその効果が安定的であったのは興味深い。しかしながら、トレンドを見ると、グローバル市場を共通して 2002 年から 2003 年ごろの水準に比べるとそれ以降は効果が低下している。このことは、Fama and French [2012]の分析結果とは異なるが、分析期間が違うという点に起因するかもしれない。仮説検証の中で、高 PBR 株で構成されたポートフォリオのリターンが市場のリターンに近似する結果は、バリューストック効果とプロダクションベースモデルを裏付けるものでもある。

ただし、プロダクションベースモデルですべてが説明できるということではない。キャッシュフローに関するファクターについては市場の効率性を PBR ほど反映しておらず、安定した結果は出なかった。キャッシュフロー以外の利益項目の変動要因や他のファクターと

の因果性など掘り下げた分析が必要であるだろう。

本章の研究では、バリュート投資の効果には循環性とトレンドが見られ、さらにトレンドの減少が観測された。特に日本市場においては、従来、バリュート投資をしていればそれなりのパフォーマンスを安定的に得ることができたため、バリュート投資が主要な投資戦略として位置づけられてきたが、今後についてはうまくいかないかもしれない。いち早くバリュート効果の減少が観測されている欧米などの機関投資家は、日本で扱っているファクターの何倍もの数のファクターを用意して様々な分析や検証を行っており、日本は少し遅れている感がある。ファクター効果以外のアルファの源泉の模索も始まっている。2014年の日本版スチュワードシップコード、2015年の日本版コーポレートガバナンスコードの導入により本格的に始まった投資家と企業とのエンゲージメント活動はその一環であろう。また、AIやビッグデータといった新技術を用いた資産運用の応用などもある。欧米で効果が見られるファクターは日本でも同様の効果が見られる傾向があるが、これは世界的に市場が類似してきていることを示すものかもしれない。今回の分析から見てバリュート効果の循環性やトレンドの減少など長期的な動向も似ている結果が得られたのは、国境を超えた事業の展開が行いやすくなってきたことやコンピュータの発達によって世界の市場がより密接になってきたことが大きな要因の一つではないだろうか。今回の分析においては、市場ごとに分析を行い比較検討したが、金融市場がグローバル化してきており、今後さらにその速度が速まることを考えるならば、世界を一つの市場として分析することも有効な手段となりえるであろう。

【補論】

ここでは、プロダクションベースモデルで想定される企業価値については、プライシングカーネルとキャッシュフローには、標準ブラウン運動を仮定し、金利変動に Vasicek Model(Berk et al. [1999], Appendix B.)を用いた場合の解析求める過程について展開している。既存資産価値は、

$$\sum_{j=0}^t V_j(t) \chi_j(t) = b(t) e^{\bar{c} - \beta(t)} D(r(t))$$

となる。b(t)はt時点で存続している既存資産合計、

$$b(t) \equiv I \sum_{j=0}^t \chi_j(t) \equiv I n(t)$$

$\beta(t)$ はプロジェクト毎のシステムティックリスク

$$\beta(t) \equiv -\ln \left[\sum_{j=0}^t \frac{\chi_j(t)}{n(t)} e^{-\beta_j} \right]$$

\bar{c} はキャッシュフローの平均である。また、

$$D(r(t)) = \sum_{s=t+1}^{\infty} \pi^{s-t} B(s-t, r(t))$$

$B(s-t, r(t))$ は額面が1で満期Sのリスクなしの割引債価格、 $1-\pi$ は資産償却率である。成長オプションの価値を考えると求めたいのは次式の解析解である。

$$V^*(t) = E_t \left[\sum_{s=t+1}^{\infty} \frac{z(s)}{z(t)} \max[V_s(s) - I, 0] \right]$$

この式は、将来の投資による累積純キャッシュと0の大きいほうが成長オプションの価値となることを意味している。ここで、sはs>tであり、t期以降の将来を意味している。

このとき、オプション価値は、

$$V_s(s) - I = I(\exp[\bar{c} - \beta_s] D[r(s)] - 1)$$

となる。 β_s が与えられるとき、

$$\exp[\bar{C} - \beta_s] \sum_{k=1}^{\infty} B[k, r_{\beta_s}^*] = 1$$

のもとで、 $r_{\beta_s}^*$ が決定されるので、 β_s が与えられるときの成長オプションの条件付き期待値は、

$$\begin{aligned} & E_t \left[\sum_{s=t+1}^{\infty} \frac{z(s)}{z(t)} \max[V_s(s) - I, 0] \mid \beta_s \right] \\ &= IE_t \left[\frac{z(s)}{z(t)} \max \left[\exp[\bar{C} - \beta_s] \sum_{k=1}^{\infty} B[k, r_{\beta_s}] - 1, 0 \right] \mid \beta_s \right] \\ &= IE_t \left[\frac{z(s)}{z(t)} \max \left[\exp[\bar{C} - \beta_s] \sum_{k=1}^{\infty} B[k, r_{\beta_s}] - B[k, r_{\beta_s}^*], 0 \right] \mid \beta_s \right] \end{aligned}$$

と展開することができる。先の $r_{\beta_s}^*$ が定義されることによって、

$$\exp[\bar{C} - \beta_s] \sum_{k=1}^{\infty} B[k, r_{\beta_s}] - B[k, r_{\beta_s}^*] \geq 0$$

であることが知られているので、

$$\begin{aligned} & \max \left[\exp[\bar{C} - \beta_s] \sum_{k=1}^{\infty} B[k, r_{\beta_s}] - B[k, r_{\beta_s}^*], 0 \right] \\ &= \exp[\bar{C} - \beta_s] \sum_{k=1}^{\infty} \max [B[k, r_{\beta_s}] - B[k, r_{\beta_s}^*], 0] \end{aligned}$$

よって、

$$\begin{aligned} & E_t \left[\frac{z(s)}{z(t)} \max[V_s(s) - I, 0] \mid \beta_s \right] \\ &= IE_t \left[\frac{z(s)}{z(t)} e^{\bar{C} - \beta_s} \sum_{k=1}^{\infty} \max [B(k, r(s)) - B(k, r^*(\beta_s)), 0] \mid \beta_s \right] \end{aligned}$$

である。

$$J[r(t), s - t, r^*(\beta_s)] \equiv E_t \left[\frac{z(s)}{z(t)} \max [B(k, r(s)) - B(k, r^*(\beta_s)), 0] \mid \beta_s \right]$$

とする関数 J を定義すると、Vasicek model を前提とすることで求めることができる。この関数を使えば、条件なしの成長オプションの価値は、

$$V^*(t) = I e^{\bar{C}} \sum_{s=t+1}^{\infty} \sum_{k=1}^{\infty} \int_{\beta} J[r(t), s - t, r^*(\beta_s)] e^{-\beta_s} dF_{\beta}(\beta_s)$$

$$s \equiv Ie^{\bar{c}}J^*[r(t)]$$

となる。

以上より、すべてをまとめると求めたい企業価値は、

$$P(t) = b(t)e^{\bar{c}-\beta(t)}D(r(t)) + Ie^{\bar{c}}J^*[r(t)]$$

となりこれは解析的に求めることができる。

【引用文献】

- Berk, J., Green, R.C. and Naik, V. [1999] “Optimal investment, growth options, and security returns,” *Journal of Finance*, 54, 1553-1607.
- Fama, E. F. and French, K. R. [1996] “Multifactor explanations of asset pricing anomalies,” *Journal of Finance*, 51, 55-84.
- Fama, E. F. and French, K. R. [2012] “Size, value, and momentum in international stock returns,” *Journal of Financial Economics*, 105, 457-472.
- Lakonishok, J., Shleifer, A. and Vishny, R.W. [1994] “Contrarian investment, extrapolation, and risk,” *Journal of Finance*, 49, 1541-1578.
- 乾孝治・室町幸雄 [2000] 『金融モデルにおける推定と最適化』朝倉書店.
- 大庭昭彦編 [2008] 『最新金融工学に学ぶ資産運用戦略』東洋経新報社.
- 袖山則宏・矢野学 [2003] 「アクティブ能力と運用制約」『証券アナリストジャーナル』 2003年11月号, 102-116頁.
- 西岡平太 [2008] 「日本株式市場におけるバリュー株効果要因分析」『証券アナリストジャーナル』 2008年3月号, 108-119頁.
- 松葉育雄 [2007] 『長期記憶過程の統計』共立出版株式会社.
- 南正太郎 [2010] 「プロダクションベースモデルに基づく株価の実証分析」川北英隆・白須洋子・山本信一編『総合分析 株式の長期投資』第9章, 中央経済社.
- 吉野貴晶 [2007] 「一時的なショックを超えバリュー効果は長期的に持続するだろう」大和総研.
- 吉野貴晶・斉藤哲郎 [2007] 「効率的なファンドマネジメント手法の考察 37: 効率性、収益性ファクターの効果」大和総研.

図表 1 - 1 : PBR の逆数をファクターとした各国のポートフォリオの結果と基本統計量

	分位ポートフォリオ					Benchmark Return	F1-Fn Return
	1	2	3	4	5		
NorthAmerica	84.29	113.93	114.88	105.69	85.59	101.34	-1.30
Europe	125.87	139.49	140.20	154.38	118.20	136.48	7.67
TOPIX	211.46	150.26	134.56	91.79	61.72	117.75	149.74
Pacific	228.01	218.09	152.29	201.02	180.66	195.62	47.35
World	156.27	142.23	127.34	122.83	106.36	130.67	49.91

	IC	IC T-Stat	Factor Average	Factor Std.Dev	Factor Skewness	Factor Kurtosis
NorthAmerica	0.01	0.20	-0.07	0.05	3.53	80.94
Europe	0.01	0.25	-0.02	0.06	-0.98	82.31
TOPIX	0.06	2.60	-0.25	0.17	5.77	70.69
Pacific	0.01	0.11	-0.07	0.06	3.22	21.01
World	0.02	0.61	-0.05	0.06	1.96	129.21

(注)

PBR の逆数をファクターとした各国の分位ポートフォリオの累積リターンの結果と基本統計量を示したものである。情報係数(IC)及びそのt値も併せて掲載している。North America、Europe、TOPIX、Pacific、World の各市場を対象とし、ユニバースおよびユニバース構成銘柄は MSCI を用いている。


図表 1 - 2 : ベンチマーク対比の分位ポートフォリオのパフォーマンス

	分位ポートフォリオ(ベンチマーク比)					Benchmark Return	F1-Fn Return
	1	2	3	4	5		
North America	0.83	1.12	1.13	1.04	0.84	101.34	-0.01
Europe	0.92	1.02	1.03	1.13	0.87	136.48	0.06
TOPIX	1.80	1.28	1.14	0.78	0.52	117.75	1.27
Pacific	1.17	1.11	0.78	1.03	0.92	195.62	0.24
World	1.20	1.09	0.97	0.94	0.81	130.67	0.38

(注)

North America、Europe、TOPIX、Pacific、World の各市場を対象とし、それぞれの分位ポートフォリオのリターンを計算。分位ポートフォリオのリターンから各国のベンチマークのリターンを差し引いて求めた超過リターンを集計したものである。

図表 1 - 3 : Pacific (アジア) 対第 4 分位、第 5 分位ポートフォリオ



(注)

Pacific (アジア) における第 4 分位、第 5 分位ポートフォリオの累積リターンの時系列推移を示したグラフである。第 4 分位ポートフォリオは、すべての市場においてベンチマークの累積リターンに近い水準の累積リターンを得ていた。世界的に、高 PBR によって作られたポートフォリオは、長期的な累積リターンに関して市場の累積リターンに近いことがわかる。また、第 5 分位ポートフォリオでは、とくに Pacific がベンチマークの累積リターンに近い水準であった。

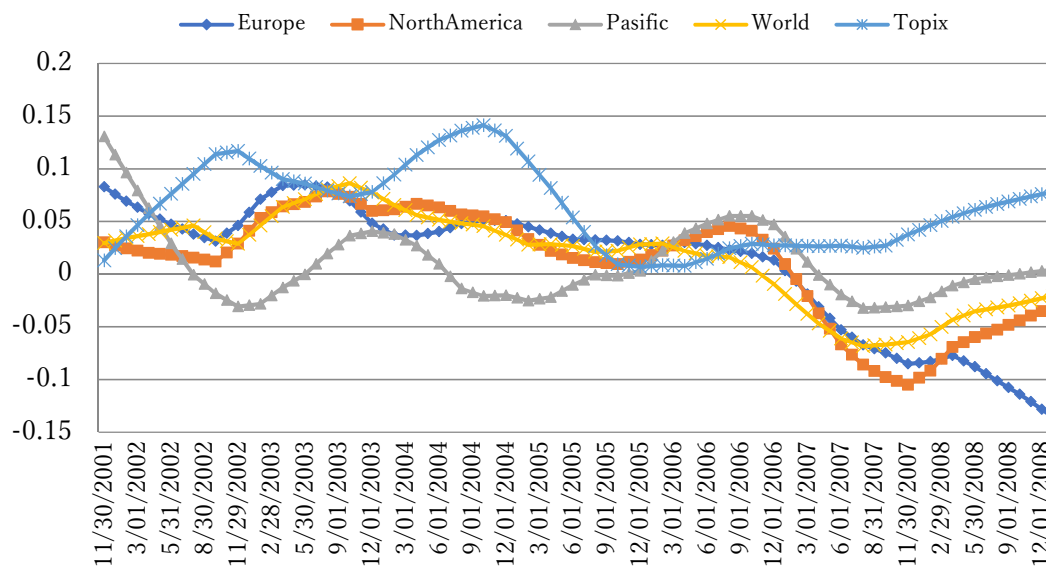
図表1-4：キャッシュフローに関するファクターのパフォーマンスと基本統計量

対象	Factor	F1-FN Return Correlation		分位ポートフォリオ (対ベンチマークの値)					Benchmark Return	IC	IC T-Stat	Factor Std. Dev.	Factor Average
		F1-Fn	PBRの逆数	1	2	3	4	5					
NorthAmerica	Free Cashflow	23.77	0.87	111.32	117.13	105.10	125.73	87.55	101.34	0.00	0.08	0.01	0.04
	Yield			1.10	1.16	1.04	1.24	0.86					
Europe	Free Cashflow	46.27	0.89	168.19	216.99	137.52	116.39	121.92	136.48	0.02	0.49	0.04	-0.06
	Yield			1.23	1.59	1.01	0.85	0.89					
TOPIX	Free Cashflow	68.77	0.88	184.37	141.25	109.99	97.61	115.60	117.75	0.03	1.05	0.06	-0.05
	Yield			1.57	1.20	0.93	0.83	0.98					
Pacific	Free Cashflow	154.40	0.76	318.96	203.67	231.18	167.91	164.56	195.62	0.02	0.31	0.05	0.05
	Yield			1.63	1.04	1.18	0.86	0.84					
World	Free Cashflow	36.52	0.94	165.05	162.22	132.14	122.02	128.53	130.67	0.01	0.52	-0.03	0.03
	Yield			1.26	1.24	1.01	0.93	0.98					
NorthAmerica	Accruals	-7.45	0.02	98.52	106.24	119.28	118.16	105.97	101.34	0.00	-0.07	0.05	-0.04
				0.97	1.05	1.18	1.17	1.05					
Europe	Accruals	35.04	0.68	162.04	172.75	179.83	151.98	127.00	136.48	0.00	0.10	0.04	-0.04
				1.19	1.27	1.32	1.11	0.93					
TOPIX	Accruals	73.96	0.92	150.85	154.97	138.45	134.73	76.90	117.75	0.02	0.98	0.03	0.18
				1.28	1.32	1.18	1.14	0.65					
Pacific	Accruals	105.98	0.90	258.69	296.70	188.36	157.34	152.72	195.62	0.02	0.28	0.11	0.03
				1.32	1.52	0.96	0.80	0.78					
World	Accruals	22.88	0.65	144.27	168.59	149.18	134.36	121.38	130.67	0.01	0.34	0.00	0.03
				1.10	1.29	1.14	1.03	0.93					

(注)

キャッシュフローに関するファクター（Free Cashflow Yield「キャッシュフロー利回り」及びアクルーアルズ「Accruals」）を用いて North America、Europe、TOPIX、Pacific、World の各市場を対象とし、対ベンチマーク比の分位ポートフォリオの比率を集計したものである。t 値、ファクター標準偏差、ファクター平均の基本統計量も併せて表示している。

図表 1 - 5 : トレンドの市場間の比較



(注)

アルファテスティングで算出された PBR の逆数をファクターとしたときの IC 値の月次時系列データを用いてトレンド分析を行った結果を示している。分析期間は 2001 年 12 月から 2008 年 12 月であり、ユニバースおよびユニバース構成銘柄として、MSCI North America、MSCI Europe、TOPIX、MSCI Pacific、MSCI World を用いている。観測された IC 値の時系列データをトレンド、周期変動および残差に分解し、トレンドのみを抽出した。

第2章 日銀のETF買入が現物株市場に及ぼす影響の一考察

1. はじめに

2013年4月4日午後、日本銀行（以下「日銀」）が大規模な金融緩和の実施を決めると、株式市場は大幅上昇という形でこれを歓迎した。その後、2014年10月には、追加金融緩和として国債とETF（指数連動型上場投資信託）及びJ-REIT（不動産投資信託）の保有額の増加ペースの拡大を決定した。国債の買入れは中長期的な持続可能性が日銀内でも議論される等、将来的に困難になることが指摘されている（野口 [2015]）が、市場規模からみて購入余力があるETFの買入れ強化がさらなる追加緩和策として期待された。一方で、ETFの買入れはETF市場の拡大に寄与する一方で、潜在的には需給を歪め適正な価格形成を妨げるリスクがあるとの指摘もある（大塚 [2015]）。本章では、日銀の緩和策（ETF買入れ）が株式市場を歪めるとされるメカニズムに着目したうえで、実際に歪みが生じているのかについて検証する。日銀のETF買入れについての先行研究として今井 [2017]が挙げられる。今井 [2017]では、日銀が浮動株の多くの部分を保有することによって株価形成に歪みをもたらしているのではないかという点について分析している。浮動株修正後時価総額に対する保有比率に着目するとTOPIXやJPX日経400の構成銘柄に対する影響度合いは限定的であるものの、日経平均の構成銘柄の一部に関しては値嵩株への配分の集中から極めて高い比率になっていること示している。特に集中度が高い上位3銘柄の指数化したPBRの推移を分析したところ、株価形成を歪ませる状況が見られなかったとの結論を述べている。本章の分析では、まず第2節でETF買入れと株価上昇との関係についてETFの仕組みについて説明する。第3節では、ETF市場への影響について、買入のタイミング及び売買高とリターンに着目して分析している。第4節では、個別株式への影響について225銘柄の平均的な売買高増加率と比べて個別銘柄の売買高が増えた分を“異常売買高増加率”と定義し、銘柄属性指標及びリターンとの関係を検証した。併せて値嵩株とリターンとの関係についても分析している。本章のようにETF買入れによる個別銘柄への影響について銘柄属性とリターンとの関係から直接検証した研究はない、この点は先行研究とは異なるものである。本章の結論としては、市場でよく言われている批判は当たらないことや日銀のETF¹買入をきっかけに市場が自ら歪みを是正する方向に行動している可能性が示唆された。

2. 日銀のETF買入と株価上昇との関係

日銀の緩和策の1つは「2年間で約2兆円分のETFを買い入れる」というものであった。日銀の買入対象となるのは日経平均連動型ETFと東証株価指数（TOPIX）連動型ETFで、これらの時価総額は合計4.8兆円²である。その4割以上に相当することを考えれば、2兆円

¹ 上場投資信託（Exchange Traded Fund）のこと。

² 2013年3月末時点。

という買入規模がいかに大きいか分かる。時価総額に対する買入規模が大きければ ETF の価格を押し上げるインパクトも大きいことは容易に想像できる。しかし、ETF はあくまで投資信託であり、日銀は個別企業の株式を直接買う訳ではない。なぜ日銀による ETF 買入が個別銘柄の株価値上がりに繋がるのか、まずその仕組みについて説明する。

図表 2-1 は、ETF 市場及び設定・交換についての解説図である。通常の投資信託では投資家は金銭を拠出して受益証券を受け取るが、ETF では金銭の拠出は認められておらず、現物株式のバスケットを拠出した場合に限って ETF の受益証券を受け取ることができる³。これを「設定」と呼ぶ。反対に投資家が ETF の受益証券を管理会社（運用会社）に持ち込み、これと引き換えに現物株式バスケットを受け取る「交換」という仕組みもあり、いずれも指定参加者（証券会社）を介して行われる。

設定や交換は数億円単位で行われるため機関投資家が中心となる。機関投資家が設定により得た ETF の受益証券を証券取引所で売却すると、ETF は株式市場に流通する。取引所では数千円～数万円単位で売買できるので、個人投資家にも身近となる。仮に流通市場で ETF と現物株式の価格にギャップがあれば、（機関）投資家は設定や交換制度を利用して差益を得ることができる。例えば現物株式よりも ETF の市場価格が高ければ、割安な現物株を買って ETF を「設定」し、割高な ETF を市場価格で売却すれば差額が利益となる。逆に ETF の方が安ければ、ETF を買って管理会社に持ち込むと割高な現物株と「交換」できる。この現物株を市場で売却すれば無リスクで利益を得ることができる。

つまり、ETF と現物株の間に裁定が働くため、日銀の買入によって ETF が値上がりすれば、その ETF を構成する現物株も値上がりするというのが基本的な考え方である。

3. ETF 市場への影響

図表 2-2 は 2013 年 1 月 4 日から 5 月 17 日までの 100 営業日について、日経平均連動型 ETF の日々の売買高（5 種類の ETF の合計）の推移を示したもののだが、日銀が買入を実施した日は ETF の売買高が大きい傾向がある。もっとも日銀が ETF を流通市場（取引所）で買い付けているかどうかは公表されておらず、全額を ETF の「設定」で買い入れている可能性も完全に否定できるものではない。しかし、図表 2-2 を見る限り、少なくとも日銀が買い入れた日は売買高が膨らんでいることから、通常よりも買い需要が多く、売買の主体が日銀である可能性は高い。

では ETF 価格への影響はどうだろうか。日銀が ETF を買い入れるタイミングとしては、「午前の TOPIX が前日終値と比べて 1%以上下がると、その日の午後に ETF の買入を実施する」とされている⁴。そこで図表 2-3 に日銀が買入を実施した日の午前と午後に分けて、日経平均連動型 ETF のリターンを示した。

図表 2-3 から、買入実施日の午前は ETF 価格が概ね 1%以上下落したケースが多いこ

³ リンク債 ETF では金銭を拠出する。

⁴ 最近手法を変更したと見られているが具体的には明らかにされていない。

と分かる。一方、同じ日の午後のリターンは、大胆緩和を決定した4月4日こそ大幅なプラスとなったものの、9回のうち5回はマイナスであった。つまり、この5回は日銀が買入を実施してもETF価格が午前の終値よりも更に下落したことになる。

買入効果があったのかどうかを検証するために、午前のリターンがマイナスであった34日間を日銀の買入が実施された日（うち9日）と実施されなかった日（うち25日）に分けて、同じ日の午後のリターン別に集計すると、買入を実施しなかった日は午前よりも更に大きなマイナスとなった日が7回（28%）あったのに対して、買入を実施した日はそのようなケースが1回もなかった（図表2-4）。更に、午後のリターンがプラスになった（午前中のマイナスから値を戻した）ケースの割合が、買入せずでは24%であり、買入実施では44%となった。株価には企業の決算発表、外国為替市場や海外株式市場の動向など様々な内外要因が影響するので一概には言えないが、日銀による買入がETF価格（≒株価指数）の下落を抑制するだけでなく、値上がりにも繋がっている可能性がある。

4. 現物株市場への影響

第2節で述べたようにETFと現物株には裁定が働く。したがって、日銀がETF買入を実施すると、そのETFを構成する現物株の売買高や価格に影響を及ぼすことが想定される。また、詳細は明らかにされていないが、日銀は株価指数の午前の終値に応じて、その日の午後にETFを買い入れるとされる。そこで本節では「日銀がETF買入を実施した日の午後」に焦点を当て、日経平均構成銘柄を対象に個別銘柄への影響を検証する。

日銀がETF買入を実施した日の午後はETFと現物株の裁定機会が増えるためETF構成銘柄の売買高が増加すると考えられる。ただし、売買高が増える割合は225銘柄に共通とは限らない。そこで、225銘柄の平均的な売買高増加率と比べて個別銘柄の売買高が増えた分を“異常売買高増加率”とし、次のように定義する。

$$\text{銘柄 A の売買高増加率} = \frac{\text{銘柄 A の半日の売買高} \times 2}{\text{銘柄 A の過去 20 営業日の平均売買高}} \quad (1)$$

$$\text{225 銘柄全体の平均的な売買高増加率} = \frac{\text{225 銘柄の半日の売買高合計} \times 2}{\text{225 銘柄の過去 20 営業日の平均売買高}} \quad (2)$$

$$\text{銘柄 A の異常売買高増加率} = \frac{\text{銘柄 A の売買高増加率}}{\text{225 銘柄全体の平均的な売買高増加率}} \quad (3)$$

式(1)は、ある半日における銘柄Aの売買高が、当該銘柄の過去20営業日の平均的な売買高の何倍かを表す。いわば「普段と比べた売買高の増加率」を意味する。ここで分子に2を乗じているのは半日あたりの売買高を1日換算して分母とベースを合わせるためである。式(2)は半日における225全銘柄の合計売買高を過去20営業日の平均で割ったもので、225銘柄全体の平均では当該半日の売買高が普段の何倍かを表している。そして、225

銘柄全体の平均と比べて銘柄 A の売買高がどのくらい増えたかを求めるため、式 (3) にて式 (1) を式 (2) で除したものを異常売買高増加率としている。普段と比べて売買高が大きく増えた銘柄ほど異常売買高増加率の値が大きくなる。

異常売買高増加率が高い銘柄はどのような特性を持つのかを調べるため次の方法で分析を行った。まず、2013 年 1 月 4 日から 2013 年 5 月 17 日までの 100 営業日を午前と午後に分けた 200 個の半日データを用いて、日経 225 銘柄を各半日の異常売買高増加率の大きい順に並べ、銘柄数の等しい 5 つのグループに分けたポートフォリオを作成する (1 グループあたり 45 銘柄となる)。次に、グループごとに各時点の銘柄属性指標の単純平均値を求める。こうして求めた各グループの 200 個の半日データを「ETF 買入実施日の午後 (10 個の半日データ)」と「それ以外 (190 個の半日データ)」に分け、各々の平均を求めた。

図表 2-5、図表 2-6、図表 2-7 は異常売買高増加率が最も大きい第 1 グループから最も小さい第 5 グループについて、銘柄属性指標である市場ベータ (過去 60 ヶ月 TOPIX 感応度)、売買代金回転率 (過去 20 営業日平均)、日経平均株価指数に占める構成比をプロットしたものである。

異常売買高増加率が高い 1G や 2G を見ると、「日銀が ETF 買入を実施した日の午後」は、「その他の半日」と比べて、ベータや売買代金回転率が低い傾向が見られる。また、買入実施日の午後に限らず 1G は日経平均構成比が小さい (値高株ではない) という点も特徴として見られた、これらの理由は次のように解釈できる。まず、分析対象期間 (2013 年 1 月 4 日～5 月 17 日) は株価が大きく上昇する局面であったため日々の市場では更なる値上がり期待から、ベータや人気 (売買代金回転率) の高い銘柄が積極的に買われたとみられる。また、株価指数先物との裁定取引などにより指数構成比が大きい値高株がほぼ一貫して活発に取引され一方で、銘柄物色の対象が短期間で入れ替わった結果として、値高株は異常売買高増加率が大きくならず (分母の過去 20 営業日の平均売買高が大きいため)、1G には分類されにくかったのだろう。一方で、日銀が ETF を買い入れた日の午後は ETF と現物株の裁定機会が増えたことから相対的にベータが低く上昇過程で放置されていた不人気銘柄 (出遅れていたため裁定機会がより大きい) の売買が活発化したことに加えて、午前中に株価指数が比較的大きく値下がりしたことから、調整局面入りを警戒する向きもあって高ベータ銘柄は手控えられたようだ。総じて、1G に属する銘柄の顔ぶれは「その他の半日」と「買入実施日の午後」で異なるものの、どちらも指数構成比は高くない (値高株ではない) 結果となった。

次に株価への影響について検証する。先ほどの分析と同じように 225 銘柄を異常売買高増加率の大ききで 5 つのグループに分け、超過リターン (225 全銘柄の単純平均リターンに対する超過リターン) を集計したものが図表 2-8 である。

ETF 買入実施日の午後以外 (グラフの「その他の半日」) では、異常売買高増加率が高い銘柄ほど超過リターンも大きくなっている。短期間に物色の矛先が次々と交代しながら株式市場全体が値上がりする中で、突如動意づいた銘柄ほどリターンが高かったと解釈され

る。しかし、買入実施日の午後は 1G~5G のいずれも超過リターンがゼロ%近傍であり、異常売買高増加率と超過リターンに明確な関係が認められない。つまり、日銀が ETF 買付を実施した日の午後に普段と比べて売買高が増えた銘柄は他の銘柄よりもリターンが高かった訳ではないことになる。

別の視点から ETF 買入と現物株リターンの関係を検証する。図表 2-9 は日経平均構成比でグループ分けした超過リターンを見たものである。日経平均構成比が大きい銘柄（値嵩株）である 1G~3G は、「その他の半日」において超過リターンがプラスとなっている。このことは、値嵩株が更に値上がりした様子を示している。一方、「買入実施日の午後」では 3G~5G のリターンが高く、全く逆のことが起きている。つまり、値嵩株が更に値上がりするのは日銀が“出動”していないときである。値嵩株に配分が集中することになる日経平均連動型 ETF の場合、値嵩株であるゆえに値上がりすることは、実力よりも株価が過大評価されている銘柄により多くの資金が投入されてしまうことを意味するが、現物株市場では ETF 価格との裁定機会がより大きな“出遅れ銘柄”の取引が活発化し、過小評価されている銘柄のリターンが高くなった可能性がある。そうだとすれば、日銀の ETF 買入をきっかけとして、結果的には市場自身が過大評価や過小評価を是正する方向に行動しているのであろう。

5. まとめ

本研究では、はじめに日銀による ETF 買入が ETF の価格変化や「設定・交換」という ETF の仕組みを通じて現物株に影響しうることを述べた上で、日銀の買入行動に関して仮定を置き日経平均連動型 ETF の価格変化を検証した。その結果、日銀が ETF 買入を実施した日の午後は、買入を行わなかった日の午後よりも ETF の価格が下支えされている可能性が示唆された。

次に ETF 買入が現物株に及ぼす影響を調べたところ、買入実施日の午後取引が活発化した銘柄は、それ以外の半日と比べて相対的にベータが低く、流動性も低い（不人気な）銘柄である傾向が見られた。また、株価リターンとの関係では、普段は日経平均構成比が大きな値嵩株のリターンが高い一方で、買入実施日の午後はむしろ低位株のリターンが高い様子が観察された。

市場では「日銀の ETF 買入で日経平均構成比が大きい値嵩株のウェイトが更に増大し、市場を歪めているのでは」といった問題意識が聞かれるが(今井 [2017])。本研究の分析結果からは、値嵩株が更に値上がりするのは日銀が“出動”していないときあることが示された。また、値嵩株に配分が集中することになる日経平均連動型 ETF に於いては実力よりも株価が過大評価されている銘柄により多くの資金が投入されてしまうが、現物株市場では過小評価されている銘柄のリターンの方が高い様子が見られた。これらは、日銀の ETF 買入によって結果的には市場自身が過大評価や過小評価を是正する方向に働きかけている可能性が示すものであり、これらは、「市場が自ら起こした現象」と言えるかもしれない。

【引用文献】

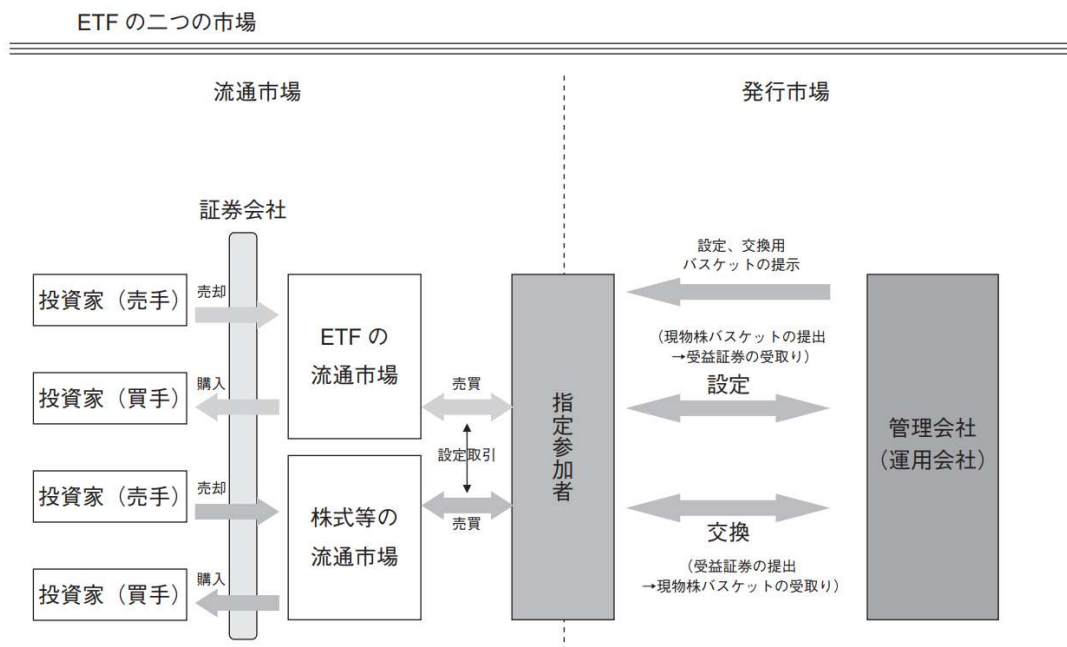
今井幸英 [2017] 「日本銀行のETF買入の現状と課題」『証券アナリストジャーナル』2017年1月号, 24-34頁.

井出真吾・南正太郎 [2013] 「日銀のETF買入が市場を歪めているは本当か-現物株市場に及ぼす影響の一考察-」『月刊資本市場』2013年7月号, 18-25頁.

大塚理恵子 [2015] 「日銀のETF購入と株式市場—日本株の下支え効果の検証と内包するリスク」『みずほインサイト』みずほ総合研究所 2015年4月23日, 1-4頁.

野口雄裕 [2015] 「国債市場の不安定化と金融政策」『みずほインサイト』みずほ総合研究所 2015年3月31日, 1-6頁.

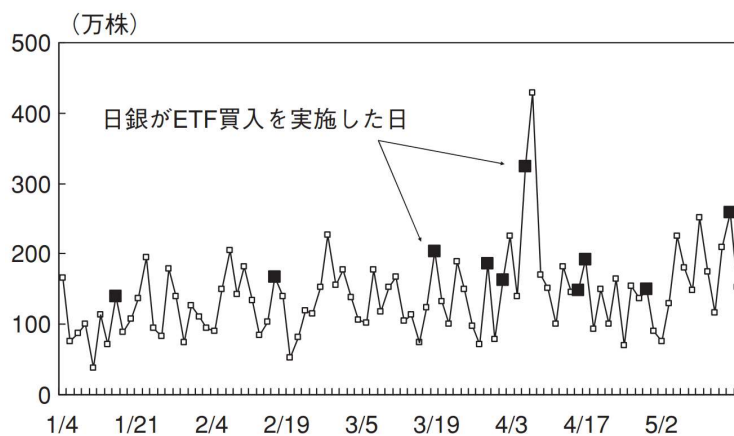
図表 2 - 1 : ETF 市場の仕組み



(注)

東京証券取引所のホームページより抜粋。ETF 市場および設定と交換についての解説図である。

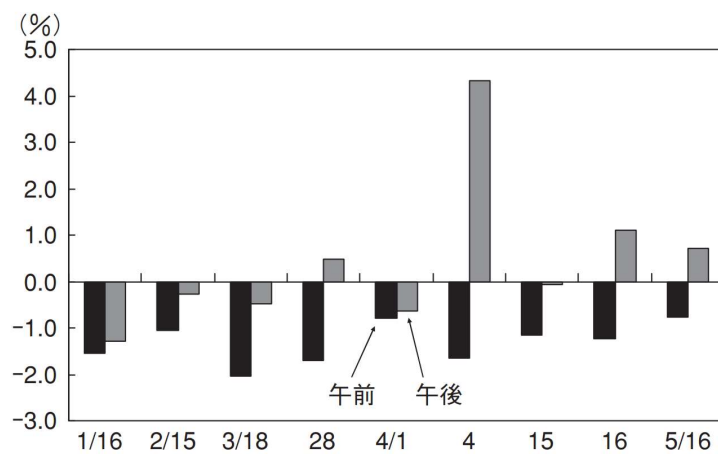
図表 2-2 : 日銀による ETF 買入実施日の日経平均連動型 ETF の売買高



(注)

データは Bloomberg より取得、筆者作成。日銀が ETF 買入を実施した日についてポイントを強調して表示している。2013 年 1 月 4 日から 5 月 17 日までの 100 営業日について、日経平均連動型 ETF の日々の売買高 (5 種類の ETF の合計) の推移を示したものである。

図表 2-3 : 日銀の ETF 買入実施日における午前と午後の ETF のリターン



(注)

データは Bloomberg より取得、筆者作成。対象は日経 225 連動型上場投資信託（銘柄コード 1321）である。日銀が買入を実施した日の午前と午後に分けて、日経平均連動型 ETF のリターンを示したものである。ただし、4 月 26 日も日銀の ETF 買入が実施されたが、午前中のリターンがプラスのため除外した。


図表 2-4 : ETF 買入実施日と買入しなかった日のうち午前のリターンがマイナスの日の
午後のリターン

	(回)			
	買入実施		買入せず	
午前より大きなマイナス	0	0%	7	28%
午前より小さなマイナス	5	56%	12	48%
プラス	4	44%	6	24%
計	9	100%	25	100%

(注)

データは Bloomberg より取得、筆者作成。午前のリターンがマイナスであった 34 日を日銀の買入が実施された日（うち 9 日）と実施されなかった日（うち 25 日）に分けて、同じ日の午後のリターン別に集計したものである。


図表 2-5 : 異常売買高増加率でグルーピングしたポートフォリオとその市場ベータ



(注)

2013年1月4日から2013年5月17日までの100営業日を午前と午後に分けた200半日について、日経225銘柄を各半日の異常売買高増加率の大きい順に並べ、銘柄数の等しい5つのグループに分ける(1グループあたり45銘柄)。その後、グループごとに各時点の市場ベータ(過去60ヶ月TOPIX感応度)の単純平均値を求める。こうして求めた各グループの200半日分のデータを「ETF買入実施日の午後(10半日)」と「それ以外(190半日)」に分け、各々の平均を計算している。


図表 2-6 : 異常売買高増加率でグルーピングしたポートフォリオと流動性



(注)

2013年1月4日から2013年5月17日までの100営業日を午前と午後に分けた200半日について、日経225銘柄を各半日の異常売買高増加率の大きい順に並べ、銘柄数の等しい5つのグループに分ける(1グループあたり45銘柄)。その後、グループごとに各時点の流動性(過去20営業日平均)の単純平均値を求める。こうして求めた各グループの200半日分のデータを「ETF買入実施日の午後(10半日)」と「それ以外(190半日)」に分け、各々の平均を計算している。


図表 2-7：異常売買高増加率でグルーピングしたポートフォリオと日経平均構成比



(注)

2013年1月4日から2013年5月17日までの100営業日を午前と午後に分けた200半日について、日経225銘柄を各半日の異常売買高増加率の大きい順に並べ、銘柄数の等しい5つのグループに分ける(1グループあたり45銘柄)。その後、グループごとに各時点の日経平均構成比(日経平均株価指数に占める構成比)の単純平均値を求める。こうして求めた各グループの200半日分のデータを「ETF買入実施日の午後(10半日)」と「それ以外(190半日)」に分け、各々の平均を計算している。


図表 2-8 : 異常売買高増加率でグルーピングしたポートフォリオと超過リターン



(注)

2013年1月4日から2013年5月17日までの100営業日を午前と午後に分けた200半日について、日経225銘柄を各半日の異常売買高増加率の大きい順に並べ、銘柄数の等しい5つのグループに分ける(1グループあたり45銘柄)。その後、グループごとに各時点の超過リターン(225全銘柄の単純平均リターンに対する超過リターン)の単純平均値を求める。こうして求めた各グループの200半日分のデータを「ETF買入実施日の午後(10半日)」と「それ以外(190半日)」に分け、各々の平均を計算している。

図表 2-9 : 日経平均構成比でグルーピングしたポートフォリオと超過リターン



(注)

2013年1月4日から2013年5月17日までの100営業日を午前と午後に分けた200半日について、日経225銘柄を各半日の日経平均構成比（日経平均株価指数に占める構成比）の高い順に並べ、銘柄数の等しい5つのグループに分ける（1グループあたり45銘柄）。その後、グループごとに各時点の超過リターン（225全銘柄の単純平均リターンに対する超過リターン）の単純平均値を求める。こうして求めた各グループの200半日分のデータを「ETF買入実施日の午後（10半日）」と「それ以外（190半日）」に分け、各々の平均を計算している。

第3章 エンゲージメント効果の測定—投資ファンドのパフォーマンス評価とエンゲージメントの事例研究—

1. はじめに

エンゲージメントは、近年の我が国のコーポレートガバナンス改革における重要なテーマであるが、導入から日が浅いこともあり、その評価を測定した研究はほとんどない。本研究では、エンゲージメントに注力している投資ファンドのパフォーマンスに注目して、日本におけるエンゲージメント効果を測定し、具体的なエンゲージメント活動についての事例研究を行った。具体的には、比較的長期に渡って運用実績があるあすかバリューアップファンドを取り挙げた。ファンドの特徴およびリターンを概観し、エンゲージメント活動がどの程度リターンに寄与しているのかについて、Sharpe [1992]のスタイル分析の手法を用いて検証した。エンゲージメント活動は個別企業に対して行うものであり、個別銘柄に関連した効果を検証するために、Daniel et al. [1999]の3ファクターモデルを用いた分析を行っている。エンゲージメント活動の事例として育児用品会社と在宅介護関連企業の2社を取り上げ、エンゲージメント活動及びリターンへの影響についても検証を行った。明確にエンゲージメント効果を測定することは困難であるとしても、エンゲージメントにより株式市場の評価の向上につながる可能性を示すことができた。

本章の構成は以下である。第2節では、ファンドのパフォーマンスの測定方法及び背景にある投資スタイルの考え方、応用に関する先行研究について説明している。また、エンゲージメント効果に関連する先行研究を取り上げてはいるが、ESG投資(Environmental and Social Governance Investing、環境・社会・ガバナンス投資)やSRI(社会的責任投資)の側面からの研究が大部分である。Sharpe [1992]のスタイル分析についての定式化もしている。第3節では、あすかバリューアップファンドの特徴及び過去のファンドパフォーマンス、その時々市場環境等について振り返っている。また、ファンドのリターンに対してスタイル分析を行うことで、市場および投資スタイルでは説明できないアルファの存在とアルファがユニークであることを分析した結果をまとめている。第4節では、育児用品会社と在宅介護関連企業の具体的なエンゲージメント活動内容について解説し3ファクター・モデルで観測されるアルファとエンゲージメント活動との関係について検証している。第5節は、本章のまとめである。

2. リサーチデザインと先行研究

本節では、エンゲージメント・ファンドのパフォーマンスを測定することで、エンゲージメント効果を検証する。ファンドのパフォーマンス測定の方法としては、例えば、ベンチマークに対する超過リターンと超過リターンの標準偏差(=トラッキングエラー)の比率であるインフォメーション・レシオや、CAPMに基づくアルファ(ジェンセンのアルファ)、投

資スタイルに注目した Sharpe [1992]のスタイル分析などがある。本研究では、Sharpe [1992]のスタイル分析を用いている。インフォメーション・レシオや CAPM に基づくアルファを選択しない理由は、ベンチマークに依存する評価方法であるからである。本研究の対象とするエンゲージメント・ファンドは絶対値運用であるため、ベンチマークを設定していない。そのため、ベンチマークに依存する評価方法は適切ではない。加えて、本来、長期にわたって企業価値を高めるために対話を必要とするファンドとしてはベンチマークによる短期の相対評価ではなく、長期にわたる絶対値評価が望ましい。スタイル分析手法を用いる積極的な理由は、投資スタイル効果と投資スタイルでは説明できない効果（エンゲージメント効果を含む）を分けることができるためである。

投資スタイルという考え方が登場したのは 1970 年代と言われている。日本では、1990 年頃から運用パフォーマンスを説明する概念として投資スタイルが導入され始めた。今日では企業・公的年金基金をはじめとして多くの機関投資家の運用現場においてリスク管理やアルファ獲得の手段として投資スタイルが用いられている。本研究では投資スタイルが存在することを前提としているが、効率的市場仮説のように市場が効率的であるならば、すべての銘柄は情報に基づき常に正しく価格付けされることになり、個別銘柄の特性はリターンとは無関係となる。そうであるならば、エンゲージメント運用の源泉である情報のギャップの差を埋めることによるアルファの獲得や長期的な株価リターンの ROE への収束などは存在し得ないことになる。先行研究において効率的市場仮説の反証としては Lakonishok et al. [1991]や Haugen and Baker [1996]が代表的な研究として挙げられる。前者はバリュー株効果を検証したものであり、バリュー効果をもたらしている低 PBR 銘柄が相対的に高いリターンをもたらしているのは、投資家が企業の過去のパフォーマンスに対して過剰な反応を示した結果であると述べている。後者はファクターと株式の期待リターンとの関係をクロスセクションにおける回帰分析を行い、ファクター効果を示した上で、そこから 2 つの反証を得ている。一つは、期待収益率が高い銘柄は実際に収益率が低い銘柄よりもリスクが明らかに低いというもので、リターンが高いのであればリスクも低いはずであるということ。もう一つは、期待リターンを決める重要な要因は、グローバルな主要市場において同様であるということである。効率的市場仮説が成り立つならば、期間や国ごとの要因によって株式リターンは変わらないと述べている。

スタイル分析は投資信託やヘッジファンドのマネジャー評価を行うために開発されたものであるが、通常の使い方としては対象とするファンドのリターンがどのようなスタイル属性を持っているのかを算出し比較するために用いられる。例えば、分析の結果、あるファンドは大型株の属性をもっており、別のファンドは小型株の属性を持っているならばその二つを保有することは相場付きが大型株優位なときであって小型株優位なときであって互いに分散効果が働くことになる。また、リスク管理を行う際にも保有しているファンドがどのような相場付きに優位でそうではないのかを測定することができる。このようなスタイル分析を応用した研究としては、まず Frank and Travers [2004]のスタイル分析の拡張が

挙げられる。スタイル分析を行った結果を用いてスタイル・インデックスに起因するリターン (Style Contribution) とスタイル・インデックスに寄与しないリターン (Selection Contribution) に分けるものであるが、この拡張によりファンドの投資スタイルによる分類に加えてスタイル・インデックスがどの程度ファンドのリターンに寄与するのかが分かるようになった。また、スタイル・インデックスの説明力が高いほど、ファンドのリターンの振る舞いがスタイル・インデックスによって表現できることも示した。本研究ではこのスタイル分析の拡張を応用している。他の応用研究としてはヘッジファンドのリスク管理や複製の研究が挙げられる。例えば Michel et al. [2004] はスタイル分析を時系列モデル DSA (Dynamic Style Analysis) に拡張し、通常アセットクラスがブラックボックスであるヘッジファンドの隠れたリスクを限定的に複製することでコントロール可能な新しいフレームワークになるものとして提唱している。また、Alexandre and Megan [2014] は DSA を用いて最大のヘッジファンドのベータエクスポージャーを決定係数で 67% も説明できたことを示している。

エンゲージメント効果を研究したものとしては、例えば、伊藤他 [2017] は、ガバナンス・スコアが高い銘柄群は低い銘柄群と比べてリターンが優位に高いことを示している。また、Norsinger and Varma [2014] では、社会的責任投資を実践しているファンドは金融危機時にリスクが低いことを実証しており、特にガバナンスのリターンが金融危機時に有意であることを示した。ESG 投資や SRI (社会的責任投資) といった側面からの検証は行われつつあるものの、エンゲージメント効果をスタイル分析を用いて検証している研究は未だない。特に日本においては日本版ガバナンス・コードが導入されてまだ日が浅いためか、投資家のエンゲージメント活動や投資家と企業との対話の事例の紹介が中心のように思われることから、本研究の最大の貢献はここにある。

以下では定式化と解法について説明する。スタイル・ベンチマークに対するファンドの相対的な運用成果は、以下で定式化できる。ポートフォリオ・リターンを $R(t)$ 、スタイル・インデックス・リターンを $f_j(t)$ とすると、

$$R(t) = \sum w_j f_j(t) + \epsilon(t)$$

w_j はポートフォリオにおけるスタイル j のウェイト、 $\epsilon(t)$ は超過リターンとなる。 w_j と $\epsilon(t)$ を推定することで、ポートフォリオ・リターンのうちスタイル・インデックス・リターンで説明できる部分とそれ以外のアルファに該当する部分を分けて求めることができる。各ウェイトである w_j は正値であり、その合計は 1 となるような制約条件下において、 $\epsilon(t)$ の分散を最小化する 2 次計画法によって解を求めることができる。

上述のように、定式化によって求めるモデルリターンと実際に観測されるリターンとの間の分散を最小化することは、 $R(t)$ をポートフォリオ・リターン、 w_j をスタイル・インデックス・ウェイト、 $f_j(t)$ をスタイル・インデックス・リターンとすると、

$$\min \text{VAR}(R(t) - \sum [w_j f_j(t)])$$

となる。ところで、

$$\text{VAR}(aX + bY) = a^2 \text{VAR}(X) + b^2 \text{VAR}(Y) + 2abC(X, Y)$$

であるので、上式で定式化した分散の最小化は、

$$= \text{VAR}(R(t)) + w'Vw - 2w'C(R(t), f_j(t))$$

となる。ここで、 V はスタイル・インデックス・リターンの分散共分散行列、 C はポートフォリオ・リターンとスタイル・インデックス・リターンとの共分散行列である。この式は制約条件付き 2 次計画問題なので、

$$\begin{aligned} \min & \frac{1}{2} w'Vw - C'w \\ \text{s.t.} & w'e = 1 \\ & w_i > 0 \end{aligned}$$

となり、この問題を解析的に説くことができ、最適なスタイル・ウェイトを算出することができる。ただし、 C は 0-1 ベクトルである。

スタイル・ウェイトは、スタイル・インデックスの加重平均ウェイトであることから、ポートフォリオ・リターンを説明する最適な組み合わせである。また、超過リターンは、スタイル・インデックスでは説明できない残りのアルファである。リターンのみを用いるこの手法は、ポートフォリオの運用成果の比較を行う場合には、市場に対する感応度をコントロールするジェンセンのアルファの考え方と同様のものであり、実際の運用においても理解を得やすい利点がある。また、ベンチマークを設定していないヘッジファンドなどのオルタナティブ運用にも適用が可能である。ベンチマークを設定しているかどうかに関わらず、横並びの比較ができるメリットもある。

3. エンゲージメント・ファンドのパフォーマンス評価

あすかバリューアップファンドは、2005 年に設立して以来、企業価値向上のためのエンゲージメント活動に従事してきている。主として、日本の上場中小型時価総額企業に対して、15-20 社への集中投資かつマイノリティ投資を行い、投資後の有効的な価値創造活動（バリューアップ活動と呼んでいる）を実践している。こうしたバリューアップ活動は、原則として、公知情報を基にした外部からの企業価値向上のための仮説・提案活動である。主な特徴の一つは、仮説提案型であることである。投資先企業との信頼関係を構築しながら、企業のステークホルダーとして企業価値向上のための仮説を様々な角度から議論し、お互いの認

識レベルを共有、企業価値向上の提案を行う。もう一つは、目的が企業価値向上にあるという点である。エンゲージメント活動にはコストが発生するが、それが企業価値の上昇（ひいては株価の上昇）という形で報われなければ、コスト負担の問題が生じ、活動の持続性が確保できない。これら 2 つの特徴が他のエンゲージメント・ファンドとの大きな違いである（日本アナリスト協会編 [2017]）。以上が、あすかバリューアップファンドにおけるエンゲージメント活動の概要である。IR 活動やミーティングだけの他のエンゲージメント・ファンドは活動の効果と株価との関係がわからない。企業価値を高めるような活動まで行うエンゲージメント活動を行うファンドのリターンであれば、本研究が目的とするエンゲージメント活動の効果の測定により適していると思われるため、以下ではあすかバリューアップファンドに着目して分析を行っている。

以下、分析に際しての条件を述べる。分析の対象は、あすかバリューアップファンドであり、手数料考慮後のネットリターンを用いている。外部に公表されリターンの比較対象となるのは、グロスリターンではなく、ネットリターンであるために用いている。スタイル・インデックスとしては、Russell/Nomura 日本株インデックスのうち、Russell/Nomura Large Cap Value インデックス、Russell/Nomura Large Cap Growth インデックス、Russell/Nomura Small Cap Value インデックス、Russell/Nomura Small Cap Growth インデックスをそれぞれ大型バリュー指数、大型グロース指数、小型バリュー指数、小型グロース指数として用いた。データの頻度は月次であり、ファンド設定来の 2005 年 4 月から 2016 年 10 月末までの期間を用いて検証を行っている。なお、Fama and French [1992]や久保田・竹原 [2007]では、スタイルの分類をファクターから計算し分析を行っているが、研究によってファクターの定義が一律に定まらないなどの問題点もあることから、実務上、証券会社が公表しているスタイル・インデックスを用いるケースが多い。そのため、今回は Russell/Nomura 日本株インデックスを用いている。

まず、あすかバリューアップファンドおよびスタイル・インデックスの推移についてマーケット環境とともに振り返る。図表 3-1 はあすかバリューアップファンド（以下、ValueUP）とスタイル・インデックスのリターン・リスクを比較したものである。過去最大の累積騰落率（MaxDD）をみると、小型グロース株が-69.50%と最も大きいのが、VaR では大型バリュー株が-9.60%と最も悪いことを見ると、小型グロース株は持続的な売りが強かった一方で、大型バリュー株では短期的に強い売りが過去に起こったことがわかる。パフォーマンス比較という点では、ValueUP は最大累積騰落率や VaR を抑えつつ最も高いシャープレシオであった。ファンドのリターンが、スタイル効果や TOPIX による効果ですべて説明がつくのであれば、ValueUP と他のインデックスとの最大騰落率および VaR との差は生じない。

図表 3-2 は ValueUP とスタイル・インデックスの累積収益率のグラフである。グラフから 2006 年をピークに 2009 年初頭まで、市場全体としては大きく株価を下げる局面であった。この時期に最大累積騰落率が生じたものと思われる。2006 年は、当時の小泉総理が郵政改革を掲げた衆院選挙で自民党が圧勝、先の日本の構造改革が進むと期待した外人投

資家が日本市場を買うとの流れからピークを付けた。その後、ライブドア事件や日銀の量的緩和政策・ゼロ金利政策の解除とならざるを得ないほどの経済の停滞などから低迷が始まり、2008年の10月にはリーマン・ショック、2009年には米国のクライスラーやゼネラルモーターズの破綻、ギリシャ・ショックなどから世界同時株安になる。米国はすぐに上昇局面に入るものの、日本は2013年のアベノミクス相場に入るまではほぼ横ばいで株価は推移した。2013年以降はアベノミクス上昇相場に入ったものの2015年にピークとなり、今日まで下げ基調になっている。小型株に関しては、2015年のピーク以降大きな上昇・下降はあったものの概ね横ばいの水準にある。ValueUP と他のインデックスとの比較において2006年から2009年は下げ幅が小さく、2010年の4月は市場全体の下げを受けていない。また、2014年から2015年の期間においては市場とは逆の動き方をしているように見える。

それではスタイル分析を行った結果はどうであろうか。図表3-3は、上段はスタイル分析による結果、下段は重回帰分析を行った結果を示している。比較対象ごとにスタイル・ウェイト、重回帰・ウェイトを計算したものであるが併せて設定来の期間のアルファの平均とモデルの説明力として自由度修正済決定係数を記載している。上段のスタイル分析では、例えばTPXを見ると大型バリューインデックス(RN_LV)が40.56%を占める。修正決定係数が99.95%であることから、各スタイル・ウェイトの比率でスタイル・インデックスをもし設定来に保有していれば、TOPIXのリターンはほとんどスタイル・インデックスで説明できたことになる。過去平均のアルファのずれは、-1.89%という見方である。TPX_Smallは、RN_SVが72.05%、RN_SGが27.95%、修正決定係数が98.18であるが、ラッセル野村の小型株指数インデックスと構成銘柄の差はあまりないことから、当然の結果といえる。一方で、ValueUPは、RN_SVが33.37%、RN_SGが66.63%の比率ではあるが、説明力はなく、過去平均のアルファのずれは10.15%と大きい。これはスタイル・インデックスのリターンでは説明できないアルファがあるということを示している。リターンを説明する適切なモデルを記述することが目的ではないので、説明力が高いかどうかは重要ではない。むしろ、説明力が小さいほど、モデルでは説明できないアルファがあるということを示している。また、そもそもファンドの組成の仕方からボトムアップの集中投資であることから、市場に関連するインデックスでは説明するのは難しいはずである。重回帰分析の結果と比較すると傾向としては概ねスタイル分析の結果と同様を示しているが、例えばTPX_SmallやValueUPは、マイナスのウェイトになっている。重回帰分析はウェイトの制約条件はないので、仮にスタイル・インデックスをショートポジションで保有することができるならば実現可能ではある。分析の対象によっては±100%のウェイトになることもあり、その場合の解釈は難しい。

図表3-4は、ValueUPとスタイル・インデックスで説明できないアルファと説明できるリターンを時系列に表記したものである。ファンド設定時から2008年の初頭、2008年初頭から2013年の初頭、それ以降の3つの期間に大きく分かれるようだ。ファンド設定時から2008年の初頭の期間は、概ねスタイル・インデックスと同じ動き方をしており水準も同程

度である。先のスタイル・ウェイトから見ると、ウェイトの大部分をラッセル野村の小型バリュー・グロス指数が占めていることから、小型株効果が多分に含まれていたと言えよう。2008年初頭から2013年の初頭は、スタイルでは説明できないアルファが大きく積み上がり、その後も少しずつ右肩あがりに上昇している。累積リターンのグラフであるので、右肩上がりほど、ユニークなアルファが取れていることを意味する。2011年7月をピークに、スタイル・インデックスの寄与度が高まって来ている。2015年6月以降は、またスタイル・インデックスでは説明できないアルファが積み重なりつつある。大きくアルファの性質が変わっているのにはファンド特有の理由がある。2008年初頭の上昇については、エンゲージメント効果が大きく発現する期待から、のちのケースの説明で取り上げる育児用品会社の保有比率を高めていたことがある。育児用品会社の投資を始めて以降大きく株価が上昇したため、ValueUP全体に対して大きく寄与した。市場インデックスが下がる中、ValueUPが下がらなかったのはそのためである。また、2013年は組織体制が大きく変わった時期であり、ポートフォリオの見直しがあったため大きな変化が見られた。

先の分析では、スタイル分析の結果をまとめた。結果を受けて、スタイル・インデックスでは説明できないアルファの推移が定常過程であるかどうかについて単位根検定¹を行う。アルファが定常過程であることには2つの意義がある。一つは、アルファがユニークであるということである。モデルから算出されたアルファの時系列推移が過去データとの相関、トレンドなどなんらかの要因をもっており定常過程ではない場合、アルファが固有の要因によって生じたものではない可能性がある。例えば、季節性によってアルファの大部分を説明できたり、意図的に株価を釣り上げたりした場合などが考えられるのではないだろうか。もう一つは、アルファが平均回帰する時系列データなのかどうかということである。図表3-5は、ValueUPとTPXについて単位根検定を行った結果である。ValueUPのP値は0.01以下であるので定常過程である。TPXについても0.03であることから定常過程である。

4. エンゲージメント効果の事例分析

ファンドのケースにおいて、図表3-4では、2008年4月ごろから2009年の前半にかけて、スタイルでは説明できないアルファが極端に上昇していた。この時期において、もっともファンドに対する寄与が大きかった銘柄として育児用品会社がある。図表3-6は、ファンドと育児用品会社のNAVに対するウェイトを示したものである。ファンドの保有ウェイトの20%程度を占めていることから、ファンドのリターンに対する寄与が大きかったことがわかる。以下では、寄与が大きかった育児用品会社のケースを取り上げるとともに、育児用品会社と同様に中期経営計画に対するエンゲージメント活動を行った在宅介護関連企業についても取り上げる。

¹ 単位根検定は対象時系列データが単位根を持つか否かを判断するものである。時系列データの回帰分析を行う際に、単位根を含む系列で回帰を行うと見せかけの回帰が発生することが知られている。そのため、一般的には時系列回帰を行う対象に対して検定を行う。ここでは算出したアルファがランダムウォーク（単位根を持つ和分過程）なのか自己相関のない定常過程なのかを調べるために検定を用いている。

4.1 個別銘柄のアルファの算出方法について

スタイル・ウェイトはポートフォリオを前提としているため、個別銘柄のアルファを測定するためには用いることができない。そこで、個別銘柄のアルファを算出するために、Daniel et al. [1999]に基づき²スタイル・ベータと残差リターンであるアルファを求める。 R_{stock} を個別銘柄のリターン、 α を個別銘柄の残差リターン、 β_{market} を個別銘柄の市場全体に対する感応度、 R_{market} を市場の月次リターン、 $\beta_{growth-value}$ をグロース・インデックスとバリュース・インデックスのリターンの差に対する感応度、 $R_{growth-value}$ をグロース・インデックスとバリュース・インデックスのリターンの差、 $\beta_{large-small}$ を大型株・インデックスと小型株・インデックスのリターンの差に対する感応度、 $R_{large-small}$ を大型株・インデックスと小型株・インデックスのリターン差とすると、3ファクター・モデルは、

$$R_{stock} = \alpha + \beta_{market}(R_{market}) + \beta_{growth-value}(R_{growth-value}) + \beta_{large-small}(R_{large-small})$$

と定義される。これは個別銘柄の60カ月リターンを同時期の市場インデックスとスタイル・インデックスのリターンと回帰するモデルであり、回帰式から求められるベータは、市場インデックス要因によるシステムティックな感応度と、グロース/バリュースに対する感応度および大型/小型に対する感応度を意味する。なお、グロースとバリュース、大型と小型のリターンの差（以下リターン・スプレッド）を用いているのは、説明変数同士の相関が高い場合、多重共線性を生じ、回帰結果が不安定になるためである。

以下では、過去60カ月のリターンを使い、3ファクター・モデルに基づいてスタイル・ベータとアルファを求める。そのうえで算出したアルファの時系列推移とエンゲージメント活動を照らし合わせて考察する。図表3-7は分析に使用した全期間（育児用品会社は2005年3月～2009年12月、在宅介護関連企業は2014年1月～2016年12月）を3ファクター・モデルで分析した結果をまとめている。Market、Growth-Value Spread、Large-Small Spreadはそれぞれのベータ値ある。分析対象全期間においては、両企業ともGrowth-Value Spreadはプラスであり、Large-Small Spreadがマイナスとグロースおよび小型株の特性を持っている事が分かる。

4.2 育児用品会社の事例

育児用品市場において国内ではリーダー的な企業である当社は、高品質を強みに成長市場である海外市場の開拓を積極的に進め、グローバルブランドを確立することで長期的な企業価値向上につながるものと見込んでいた。株価との関係においてより具体的には、自己資本利益率（ROE）の向上や配当性向の向上を通じて、資本市場を意識した経営を進めることで株式市場からの適切な評価が得られることを期待したことから、10カ月にわたる中期経営計画の作成をサポートするエンゲージメント活動を行うことにした。

² Fama and French [2002]ではマーケット・ベータを算出する際にはベンチマークから安全資産の金利を差し引いた値を用いているが、Daniel et al. [1999]では用いていない。

2005年から投資を実施。2007年には中期経営計画を策定するプロジェクトを立ち上げ、2008年の新中期経営計画の発表に至るまでにIR改善やコスト削減にかかわる具体的な策及び海外の協業分析のリーサーチ結果を共有したりと継続的なエンゲージメント活動と議論を進めてきた。中期経営計画策定プロジェクトでは、海外市場の成長ポテンシャルや海外競合企業の調査などを行い情報提供したことに加えて、資本効率や財務分析を用いて中期経営計画として望ましい資料の在り方などさまざまな対話を重ねている。もちろんすべて公表されている情報に基づいて議論のための資料等は作成している。

図表3-8は、エンゲージメント活動の状況を示したものの、図表3-9は3ファクター・モデルで算出したスタイル・ベータとアルファの各年毎に集計した結果である。図表4-9を活動内容と照らし合わせてみると、2005年に投資を始めてから、経年でアルファの平均値の水準が高くなっている。とくにエンゲージメント活動が本格化した2007年、2008年は1.02%、1.12%でかつ、時系列アルファの分散も相対的に低い水準にある（2007年0.17%、2008年0.23%）。安定的にアルファが高まったことを意味している。2009年の年平均アルファが最も高いが、エンゲージメント活動の効果が表れている部分と育児用品会社が立て続けに公表したイベントが好感された部分（米母乳関連商品ブランド営業権獲得、増配、中国新工場建設、インド子会社設立、英国アパレル国内独占販売権取得）が含まれるとみられる。このことは分散（0.34%）がやや大きいことから推測される。なお、ベータについても考察すると、ベータ（Market）は2005年から2009年にかけて0.76から0.26へと市場への依存度が低くなっている。また、ベータ（G-V）は2005年、2006年はプラス（グロース）であったが2007年以降はマイナス（バリュー）の特性を示している。ベータ（L-S）では2005年は-2.06と小型が強かったが特に2007年、2008年は小型の傾向が弱い。スタイル・ベータが大きく変わったのは、中期経営計画発表等によりこれまで育児用品会社を見ていなかった投資家が参加してきたためと考えられる。特にグロースの特性からバリューの特性に変化したのはバリュー投資家が、小型株の特性が小さくなったのは大型株を選好する投資家が参入してきたことによるものであると考えられる。このように市場に評価されるようなあるべき中期経営計画を発表できたことには、投資家でありかつ資本市場について一定の経験と知恵を持ってエンゲージメント活動を行ってきたことによる貢献があったためであろう。なお、エンゲージメント活動後に、社長からは以下のコメントをいただいている。「あすかさんは、当社の事業のみならず創業の精神や歴史も理解したうえで、本当に会社のためになるであろうことを考えて提案をしてくれる。こうした姿勢で、長期投資しようとしてくれる姿には胸が打たれる。目先のことだけでなく、将来の展望や長い目で見た経営の方向性について、時には真摯に苦言も呈してくれる。あすかさんのような株主の存在は貴重だ。経営をやっていると、つい損益計算書に没頭しがちで普段じっくり考えることの無い資本政策や資本効率についても、側面からよきアドバイザーになってくれている。」

4.3 在宅介護関連企業の事例

中期経営計画のエンゲージメント活動を行った同様のケースとして在宅介護関連企業についても取り上げる。なお、在宅介護関連企業についてはファンドに対するウェイトは大きくなくリターン寄与は小さい。

在宅介護大手であるこの会社は2004年の上場以来、業界の成長期待を背景に高い成長率とROEを維持してきたが、施設介護事業及び非介護保険対象事業への拡大のための戦略を模索していた。業界の拡大と業界内での圧倒的な競争力を持つにもかかわらず、株価水準的には低位安定な水準であったことから、2010年ごろからエンゲージメント活動を始めることにした。介護保険業界の行政が目まぐるしく変わる状況の中、エンゲージメント活動を通じて当社の投資家や資本市場に対する姿勢などをみつつ、しばらくは投資タイミングを計っていた。2015年に入り、介護報酬改定を織り込んだ会社側の中期経営計画策定に関する公式発表をうけ投資をスタート、より掘り下げたエンゲージメント活動を行うこととした。2015年秋ごろの中期経営計画を発表するタイミングに合わせて、中期経営計画プロジェクトを会社側と共同で実施。最終的には計6回にわたって資本市場や投資家から見た会社側に対して期待されるもしくはあるべき中期経営計画について対話を行っている。それまでも新社長に就任した2代目社長との面談や中期経営計画について勉強会などをマネジメントに対して行ったりした。

図表3-10は、在宅介護関連企業に対するエンゲージメント活動状況と株価推移を示したものである。中期経営計画プロジェクトでは、市場分析や競争力分析など「長期ビジョン」策定のための調査と提案を行うことから始めた。プロジェクト4回目に至るまでに、EVAの経営企画取り込み提案や事業セグメントごとのEVA創出能力の評価、価値破壊事業の収益力改善のための仮説提案など、外部から手に入れることができる情報のみを使って議論を深めた。2015年11月に中期経営計画を発表して以降、株価は上昇傾向にある。

図表3-11は、在宅介護関連企業のスタイル・ベータとアルファをまとめた結果である。中期経営計画プロジェクトのために特に2015年に活動が集中していたことから、2015年のアルファが1.79%と高い。2016年にアルファが低くなったのは、60カ月間のリターンを使用していることから、過去の介護保険改定で大きく株価が下がったことによる影響などが含まれるためと思われる。ただし、株価は上昇している。ベータについては、特にベータ(G-V)のプラスが高まっていることからグロース色が強くなっており、ベータ(L-S)はマイナスが高まっていることから小型株色が強くなっている。育児用品会社とは異なり、投資家の特性に変化は見られないが、ベータは緩やかな変化の中、エンゲージメント活動を積極的に行った2015年だけアルファの水準が高まったことは、活動の効果を意味しているのではないだろうか。なお、エンゲージメント活動後、在宅介護関連企業の社長はあすかの投資家総会での登壇を快く引き受けてくださり、エンゲージメント活動に対する好意的な評価を講演していただいた。

4.4 2社の事例より

市場からの評価が変わるためには、業績だけではなく、市場への情報発信の仕方などのIRの改善、組織が考える将来への期待が信じられるかどうかなど様々な要因が必要である。中期経営計画は長期経営ビジョンを達成するための中期に行うべき利益目標や修正すべきことなどを明確にしたものであり、具体的かつ分かりやすいものであるほうが望ましい。あるべき中期経営計画を発表することで株式市場が適切に会社を評価する大変いい機会でもある。

例に取り挙げた育児用品会社や在宅介護関連企業は、中期経営計画を出すタイミングで、市場が求めるあるべき中期経営計画の姿や投資家が会社に対して期待していることなどを徹底的に分析し、数回にわたり、社長やマネジメントに対して議論と提案を重ねてきた。事業会社としては中期経営計画を徹底的に分析し改善等を重ねることは経営課題や修正すべき点、新しい気づきがあるなど組織を見直す上でも有効な手段である。市場からの評価が変わることは会社の経営努力が一番の理由ではあるが、エンゲージメント活動が集中した時期にアルファの水準が高まったことは、エンゲージメント活動が会社の変革を促すうえで一定の効果があったのではないだろうか。なお、中期経営計画を公表して以降、セルサイド・アナリスト等へのヒアリングを行ったところ、会社の強みや将来ビジョンに対する期待が信じられるようになり見方が大きく変わったとの評価が聞かれた。

5. まとめ

本章では、投資スタイルを用いてエンゲージメント効果の測定を試みた。ファンドについてはSharpe [1992]のスタイル分析を応用して、個別銘柄については3ファクター・モデルに基づくスタイル・ベータ、アルファを応用した。

ファンドのケースにおいては投資スタイルを用いることで、スタイル・インデックスで説明できるリターンと説明できない固有のリターン(アルファ)に分けることができたが、これはファンドにはアルファが存在することとともに、アルファの時系列推移や説明力の変化を見ると持続的に安定したアルファを取得する難しさも示している。なお、Sharpe [1992]のスタイル分析法で注意すべきは、説明力の高さが重要なのではなく、説明できないことこそがアルファのユニークさにつながるということである。スタイル・インデックスで大部分を説明できるのであれば、スタイル・ウェイトの比率でスタイル・インデックスを保有することで対象のファンドは複製できることになり、高いマネジメント・フィーを払うことの合理的な理由にならない。スタイル・インデックスで説明できないアルファの推移について定常過程であるかどうかの単位根検定も行った。検定の結果、ValueUPのアルファは定常過程でありユニークであることが分かった。

個別ケースにおいては中期経営計画に対するエンゲージメント活動を重点的に行った育児用品会社と在宅介護関連企業を取り挙げた。両社ともエンゲージメント活動が本格化した年はアルファが高くなった。ベータに目を向けると、育児用品会社はバリューからグロー

スへ、小型株の強い傾向がやや大型株寄りへと変化が見られた。在宅介護関連企業は、グロース及び小型株への特性が強まる結果となった。市場からの評価が変わるためには、業績だけでなく、市場への情報発信の仕方、組織が考える将来への期待が信じられるかどうかなど様々な要因が必要であり、中期経営計画は市場から再評価される大変いい機会であるが、エンゲージメント活動が集中した時期にアルファの水準の高まりやベータ変化による投資スタイルの変化が見られたのは、活動による貢献があったためと言える。

ファンドとエンゲージメント活動との関係で見ると、ファンドのリターンにおいてスタイルでは説明できないアルファが極端に上昇した 2008 年 4 月ごろから 2009 年の前半にファンド内に占めるウェイトが高くリターン寄与度が高かった育児用品会社は、エンゲージメント活動によって高まったアルファがファンドリターンに貢献したよい事例である。ただし、エンゲージメント効果がどの程度ファンドに寄与していたかを定量化するためにはさらなる研究の余地があるだろう。

本研究において、投資スタイルを用いることでエンゲージメント効果を測定化できる可能性を示すことができた。複数の要因が絡み合うエンゲージメント効果を要因ごとにかつ定量的に表現することは簡単ではないものの、今後の研究によってはより精緻な表現は可能かもしれない。例えば、本研究の結果であるファンドのアルファには、エンゲージメント効果以外の効果が含まれる。個別銘柄のウェイトの決定やトレーディングタイミング、キャッシュコントロール、株以外のアセットクラスの効果、非保有銘柄の効果、リターンリバーサルや流動性などの他のファクターの効果などである。このような効果を分け取除くことができるならポートフォリオ管理や運用実務への応用も期待できるであろう。また、エンゲージメント効果の一部はスタイル・インデックスにも含まれる。例えば、EPS を向上させるためのエンゲージメント活動が実を結んだ結果として好業績になり、株価が上昇した場合、上場会社のほとんどはインデックスに含まれることから、インデックスの組入れ比率だけインデックスそのものを押し上げることになる。今回の分析にはこのエンゲージメント効果は考慮していない。エンゲージメント活動によるアルファがファンド特有というのであれば、類似企業のファンドを同じ指数で分析する必要もある。共通のスタイル・インデックスで評価することでファンドのユニークさを横比較することが可能となるからである。エンゲージメント活動の定量化に関する研究は始まったばかりであり、今後の研究が期待される。日本版コーポレートガバナンスコードとも関連することであり、実務においては今後求められるであろう。

【引用文献】

- Coggin, T. D., Fabozzi, F. J. and Arnott, R. D. [1999] *The handbook of equity style management*, Wiley Finance.
- Dussaucy, A. and Woods, M. [2012] “Bridgewater pure alpha: how much is explained by dynamic beta?,” Working Paper, Markov Processes International, 1-9.
- Fama, E. F. and French, K. R. [1992] “The cross-section of expected stock returns,” *Journal of Finance*, 47, 427-465.
- Haugen, R. A. and Baker, N. L. [1996] “Commonality in the determinants of expected stock returns,” *Journal of Financial Economics*, 41, 401-439.
- Lakonishok, J., Shleifer, A. and Vishny, R.W. [1994] “Contrarian investment, extrapolation, and risk,” *Journal of Finance*, 49, 141-157.
- Markov, M., Mottl, V. and Muchnik, I. [2004] “Dynamic style analysis and applications,” Working Paper, SSRN Electronic Journal, 1-32.
- Nofsinger, J. and Varma, A. [2014] “Socially responsible funds and market crises,” *Journal of Banking and Finance*, 48, 180-193.
- Sharpe, W. F. [1992] “Asset allocation: Management style and performance measurement,” *Journal of Portfolio Management*, 18, 7-19.
- Travers, F. J. [2004] *Investment manager analysis*, Wiley Finance.
- 伊藤桂一・佐藤史仁・太田佳代子・藤川隆宗 [2017] 「市場が評価するガバナンスのクオリティ」『日本価値創造 ERM 学会研究発表大会資料』 2017 年 9 月 8 日.
- 久保田敬一・竹原均 [2007] 「Fama-French ファクター・モデルの有効性の再検証」『現代ファイナンス』 2007 年 9 月号, 3-23 頁.
- 日本証券アナリスト協会編 [2017] 『企業・投資家・証券アナリスト 価値向上のための対話』 日本経済新聞出版社.


図表 3-1 : ファンドと各インデックスのリターン及びリスクの比較

						(%)
NAME	MTD	YTD	FYTD	SR (rf=0)	Max DD	VaR (.95)
TPX	5.31	-8.10	4.48	0.26	-56.20	-9.00
ValueUP	3.68	-0.42	2.87	0.49	-34.00	-5.50
Large_Value	6.98	-11.21	5.75	0.26	-56.10	-9.60
Large_Growth	3.90	-6.63	3.18	0.25	-60.00	-9.10
Small_Value	7.20	-3.12	9.33	0.40	-51.30	-8.20
Small_Growth	3.88	-3.05	0.29	0.20	-69.50	-8.90

(注)

あすかバリューアップ戦略 (ValueUP)、TOPIX(TPX)、各スタイル・インデックスのリターン及びリスクをまとめたものである。MTD は 2016 年 10 月、YTD は 2016 年 1 月～2016 年 10 月、FYTD は 2016 年 4 月～2016 年 10 月の期間である。SR はシャープレシオ (ただし、リスクフリーレートは 0 としている)、MaxDD は最大騰落率、VaR は Value At Risk である。Large_Value は、Russell/Nomura Large Cap Value インデックス、Large_Growth は、Russell/Nomura Large Cap Growth インデックス、Small_Value は、Russell/Nomura Small Cap Value インデックス、Small_Growth は、Russell/Nomura Small Cap Growth インデックスである。

図表3-2：ファンドとスタイル・インデックスの累積収益率の比較



(注)

ファンドの設定が2005年3月であることから、2005年3月を基準0とし、2005年3月から2016年10月までのファンドおよび各インデックスの累積収益率を表示している。


図表 3-3 : スタイル・ウェイト、重回帰ウェイトの算出結果のまとめ

							(%)
Weight Calc	Name	RN_LV	RN_LG	RN_SV	RN_SG	Hst_Alph	Adj R-sq
Style Weight	TPX	40.56	43.56	11.67	4.21	-1.89	99.95
	TPX_Small	0.00	0.00	72.05	27.95	0.42	98.18
	ValueUP	0.00	0.00	33.37	66.63	10.15	-13.47
Reg Weight	TPX	40.63	43.55	11.48	4.34	-1.85	99.95
	TPX_Small	-15.32	2.83	88.29	24.06	-2.22	98.66
	ValueUP	-26.44	-19.18	36.10	56.62	31.42	56.47

(注)

TOPIX(TPX)、TOPIX SMALL INDEX(TPX_Small)、ファンド(ValueUP)ごとに、リターンを説明変数、スタイル・インデックスのリターンを被説明変数としスタイル分析及び重回帰分析を行った結果算出されたウェイト(寄与度)をまとめている。上段はスタイル分析による結果、下段は重回帰分析による結果である。また、”Hst_Alpha”は全分析期間(設定来)において観測されたアルファ(モデルと実績値の誤差)の平均値であり、モデルの説明力として自由度修正済決定係数(Adj R-sq)も併せて記載している。なお、RN_LV は、Russell/Nomura Large Cap Value インデックス、RN_LG は、Russell/Nomura Large Cap Growth インデックス、RN_SV は、Russell/Nomura Small Cap Value インデックス、RN_L は、Russell/Nomura Small Cap Growth インデックスである。

図表3-4：ファンドリターン、スタイル効果、スタイル効果除きのアルファの累積グラフ



(注)

2005年3月から2016年10月までのファンドの累積リターン(ValueUP)及びスタイル効果、スタイルでは説明できないアルファ(残差)の累積値を表示している。スタイルで説明できないアルファ(残差)は、ファンドのリターンを説明変数、スタイル・インデックスのリターンを被説明変数としスタイル分析を行った結果、残差として出力された値である。


図表 3 - 5 : アルファの推移が定常過程であるかどうかの単位根検定の結果

	Dickey-Fuller	Lag order	p.value
ValueUP	-5.28	5.00	0.01
TPX	-3.67	5.00	0.03

(注)

スタイル・インデックスでは説明できないアルファの時系列推移が定常過程であるかどうかについて **Dickey-Fuller** の単位根検定を行った結果をまとめている。ValueUP の P 値は 0.01 以下であるので単位根はない、すなわち定常過程である。また TPX についても 0.03 であることから定常過程である。

図表 3-6 : 最大保有銘柄 NAV に対するウェイトの比率とスタイル効果及びアルファ



(注)

ファンドの累積リターン、スタイル効果、スタイルでは説明できないアルファの累積値に、ファンドに組み入れられている最大保有銘柄である育児用品会社のファンドNAVに対するウェイトを併せて記載している。期間は、育児用品会社を保有していた2005年3月から2010年12月までである。なお、平常時の保有最大比率は10%~15%を想定している。

図表 3-7 : 全期間のスタイル・ベータとアルファの測定


	育児用品会社	在宅介護関連企業
Market	0.828*** (0.130)	0.512*** (0.189)
Growth-Value Spread	0.600** (0.245)	1.145** (0.487)
Large-Small Spread	-1.552*** (0.279)	-1.664*** (0.460)
Alpha	0.014** (0.007)	0.011 (0.010)
Observations	225	152
R ²	0.217	0.128
Adjusted R ²	0.207	0.110

Note: *p<0.1; **p<0.05; ***p<0.01

(注)

分析に使用した全期間（育児用品会社は 2005 年 3 月～2009 年 12 月、在宅介護関連企業は 2014 年 1 月～2016 年 12 月）を 3 ファクター・モデルで分析した結果をまとめている。Market は個別銘柄の市場全体に対する感応度、Growth-Value Spread は、グロース・インデックスとバリュー・インデックスのリターンの差（リターン・スプレッド）に対する感応度、Large-Small Spread は、大型株・インデックスから小型株・インデックスのリターンの差に対する感応度、Alpha は、3 ファクター・モデルの算出された残差である。Observations は使用したデータ数（ここでは、銘柄を保有していた月数）、R²は決定係数、Adjusted R²は、自由度調整済み決定係数である。なお、p 値による説明力が高いものには、説明力の高さに応じて*を表示している。

図表 3-8 : 育児用品会社に対するエンゲージメント活動



(注)

育児用品会社に対するエンゲージメント活動記録と株価を示したものである。2005年10月に投資を開始、2008年の新中期経営計画の発表に至るまでにIR改善やコスト削減にかかわる具体的な策、海外の協業分析の研究成果を共有したりと継続的なエンゲージメント活動と議論を進めてきた。その間、株価についても市場インデックスを大きく超過している。

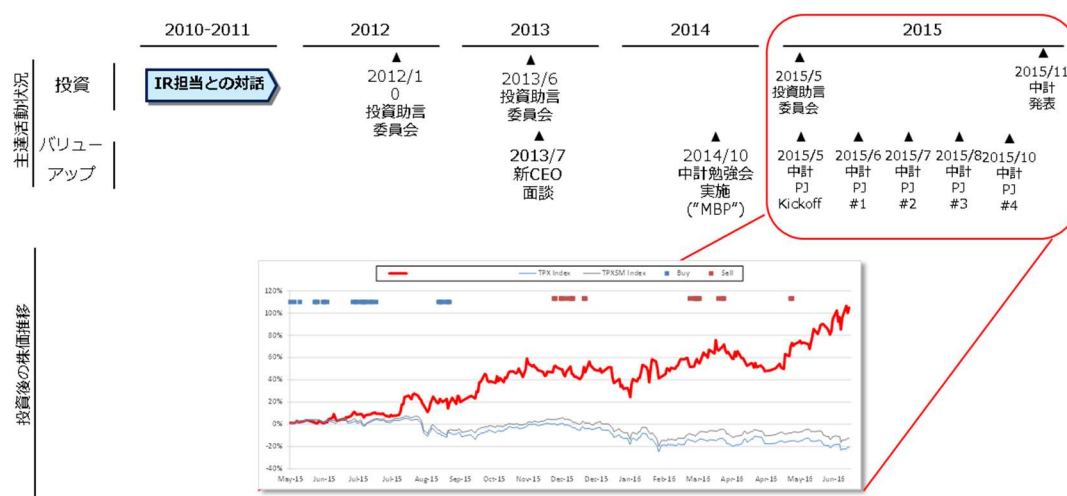
図表 3-9：育児用品会社のスタイル・ベータとアルファの測定

	アルファ		ベータ (Market)		ベータ (G-V)		ベータ (L-S)	
	平均	分散	平均	分散	平均	分散	平均	分散
2005 年	0.61%	0.18%	0.76	0.05	0.99	0.16	-2.06	0.11
2006 年	0.87%	0.33%	0.52	0.09	0.46	0.43	-1.36	0.26
2007 年	1.02%	0.17%	0.36	0.04	-0.47	0.10	-0.80	0.03
2008 年	1.12%	0.23%	0.20	0.09	-0.65	0.26	-0.89	0.04
2009 年	1.26%	0.34%	0.26	0.05	-0.46	0.15	-1.15	0.13

(注)

過去 60 カ月の育児用品会社のリターンと市場インデックス及びスタイル・インデックスのリターンを用いて 3 ファクター・モデルに基づきベータとアルファを算出。毎月ごとに値を計算し、年毎に平均と分散を集計している。アルファは%、ベータは回帰係数であるため、単位はポイントである。なお、ベータ(G-V)はグロース・インデックスとバリュー・インデックスのリターンの差 (リターン・スプレッド) に対する感応度、ベータ(L-S)は、大型株・インデックスから小型株・インデックスのリターンの差に対する感応度である。

図表 3-10：在宅介護関連企業に対するエンゲージメント活動



(注)

在宅介護関連企業に対するエンゲージメント活動記録と株価との関係をまとめた。2010年からエンゲージメント活動を実施、2015年に入り、介護報酬改定を織り込んだ会社側の中期経営計画策定に関する公式発表をうけ投資を開始した。2015年秋ごろの中期経営計画を発表するタイミングに合わせて、中期経営計画プロジェクトを会社側と共同で実施。最終的には計6回にわたって資本市場や投資家から見た会社側に対して期待されるもしくはあるべき中期経営計画について対話を実施した。

図表 3-11：在宅介護関連企業にスタイル・ベータとアルファの測定

	アルファ		ベータ (Market)		ベータ (G-V)		ベータ (L-S)	
	平均	分散	平均	分散	平均	分散	平均	分散
2014 年	1.44%	0.17%	0.74	0.043	1.25	0.125	-2.03	0.197
2015 年	1.79%	0.31%	0.70	0.043	1.49	0.194	-2.27	0.121
2016 年	1.28%	0.48%	0.73	0.051	1.68	0.178	-2.55	0.121

(注)

過去 60 カ月の在宅介護関連企業のリターンと市場インデックス及びスタイル・インデックスのリターンを用いて 3 ファクター・モデルに基づきベータとアルファを算出。毎月ごとに値を計算しているが、年毎に平均と分散を集計したもの。アルファは%、ベータは回帰係数であるため、単位はポイントである。なお、ベータ(G-V)はグロース・インデックスとバリュー・インデックスのリターンの差 (リターン・スプレッド) に対する感応度、ベータ(L-S)は、大型株・インデックスから小型株・インデックスのリターンの差に対する感応度である。

第4章 AIの資産運用への応用可能性と限界

1. はじめに

本章では、南・光定 [2017]や Sugitomo and Minami [2018]、Minami [2018]に基づき、アベノミクス第二ステージの重点政策「日本再興戦略 2017」及び「未来投資戦略 2017」の主要政策テーマに取り上げられている“第4次産業革命”及び“FinTech”にて中心技術として取り上げられたAIがどのように資産運用業に応用できるのかについて議論する。投資理論に基づき発展してきた背景もあり資産運用業においては投資理論及び計量分析といった従来の考え方に最先端のAI技術をどのように応用することができるのかは重要な関心事の一つである。今後必要とされる分野であることは間違いないであろう。まず、第1節では、AIは機械学習であるということを再確認したうえで、代表的なAI技術の基本的な考え方及び資産運用業への応用の仕方について事例を交えて論じている。AIが機械学習であることで生じる限界についても考察し、今後の証券アナリストやファンドマネジャーに求められる能力について論じている。第2節以降では、AIの具体的な応用について研究した結果をまとめている。第2節では、計量アクティブ運用において株式の超過リターン（アルファ）があるかどうかを検証する際に用いられる分析手法アルファテストにAI技術を応用している。非線形のモデルが取り扱いやすくなったことで、線形モデルよりも良い結果をもたらす可能性を示している。第3節では、ディープラーニングと呼ばれる手法のうち時系列データに対して適用するために登場してきた Long-Short Term Memory Recurrent Neural Network (LSTM-RNN) を用いて、企業のコーポレートアクション、プレスリリース、マクロ指標を織り込んだ株価予想を試みている。AIの手法の資産運用への応用は始まったばかりであり、今後様々な研究がなされることが期待される。

2. AIの基本的手法とその応用

2.1 機械学習としてのAI

コンピュータが学習し、自動的に結論を導き出す様があたかも知性をもって考えているようであることから汎用人工知能 (AGI, Artificial General Intelligence)のことをいわゆるAI (人工知能)と呼んでいる場合があるが、AIが意思をもって、意思決定をするということは現在の技術や技術の発展によってもたらされるものとは程遠いと思われる。なぜならば、現在のAIはそのほとんどが機械学習のことを指しており、統計的手法の応用やデータマイニングと大きく変わらないからである(植野[2017])。機械学習とは、ビッグデータと呼ばれる大量のデータを活用し、様々なデータから法則性を導き出す手法である。この機械学習は様々な課題をこなせる汎用AI (AGI, Artificial General Intelligence)とは大きく異なるが、一部には人工知能という日本語の語感から、汎用AI (AGI)であると誤解している可能性があるため、強調しておきたい。一方で、特定の用途によっては、コンピュータが自ら学習するこ

とで、これまで難しかった問題が解けるようになったり、人間が処理するには現実的ではない情報の処理が可能になったりするという点で、今後の応用可能性は飛躍的に広がったのは事実である。

機械学習を行う手法は従来からあったものもあれば、最近登場してきたものもある。こうした過去の手法も含め再度脚光を浴びている背景には、

- ① コンピュータの処理速度が高速になったこと
- ② インターネットなどの普及により大量の過去のデータ蓄積がなされつつあること
- ③ 従来の機械学習手法やディープラーニング（深層学習）という手法に、強化学習というもう一つのプロセス（アルゴリズム）が結合したこと

などがある。

以下ではAI(以下、機械学習を指す)を正しく理解するために、AIで用いられる手法について考え方を整理する。各手法の考え方の概説の後に、それぞれの手法がどのような形で資産運用へ応用できるかについて、いくつかの実例やアイデアを紹介する。実際にこれらの手法を使って詳細な分析もしくは資産運用へ応用するためには、数学的な解釈とビッグデータの適切な扱い、統計分析などのスキルが必要となるので、ここで述べるアイデアは簡単に実現するものではないが、機械学習でどのようなことが可能なのか、多少単純化した例も含めて紹介している。

2.2 AI手法の事例と応用の仕方

2.2.1 アソシエーションルール

A社の株価とB社の株価の値動きの連動性を見る指標の一つに相関係数がある。1から-1までの値をとり、相関係数が1に近いほど、一方が上昇した時もう一方も上昇する傾向が強いといった評価をする。相関係数は、株価などの分析対象そのものが計算可能な数値であることが前提となっているが、例えば「個人投資家グループは株主優待が充実している銘柄を好む」や「トヨタを買う人はソフトバンクも買う傾向がある」というような、なんらかの組み合わせに関連性と規則性を持つ場合はどのように評価すればよいだろうか。値動き以外の様々なデータから規則、あるいは組み合わせのようなパターンを検出する機械学習手法にアソシエーションルールというものがある。アソシエーションルールは大量の組み合わせデータを集計し、その中からアルゴリズムによって様々なパターンのルールを抽出する。ルールを抽出する際にはどの程度確かさがあるかを評価するために「支持度」、「確信度」、「リフト」の指標を用いる。「支持度」はどの程度そのルールが現れるかの割合を示しており、「確信度」は、そのルールの関連性の強さ、「リフト」は偶然かどうかを意味する。これら3項目の指標は高いほど良く、総合的に考慮することでアソシエーションルールの精度を評価することができる。

図表4-1は筆者が便宜的に準備したデータに基づいてルールを求めた結果である。支持度を基準として降順に示している。例えば、1行目は「NISSAN」を購入する人は

「SOFTBANK」を購入する傾向があり、支持度が最も高いルールであることを意味する。また、確信度も高く、偶然である可能性が低い。これに対して、20行目にあるように「TOYOTAとケーヒン」を共に購入する人が「SOFTBANK」を購入する傾向は低いことが読み取れる。例えば、アソシエーションルールを用いると先に挙げた「個人投資家グループは株主優待が充実している銘柄を好む」のような投資家別の売買パターンや特性といったものを評価したりすることができる可能性がある。このようなルールが一度定まれば、新しい株主優待が出てきたときにどのような特性の個人投資家グループがそれを選好するのかを予測することができる。また、投資信託の保有銘柄は一般に公開されているが、このような投資信託が保有しているデータを時系列で分析することで、投資信託ごとのポートフォリオや銘柄選定の傾向を分析できる可能性がある。

2.2.2 決定木と集団学習

取り得る選択枝や起こり得るシナリオを樹形図の形で洗い出し、それぞれの選択枝の期待値を比較した上で意思決定を行う手法に決定木がある。これは、金融業界やコンサルタント業界ではよく使われる手法である。例えば、金融業界ではプロジェクト評価を行う際に用いるシナリオ分析という考え方があり、コンサルタント業界では経営戦略策定や買収提案などで使われることがある。これまでは担当者が考え得るすべての樹形図を手作業で作成していた。しかしながら、AIによる決定木学習はデータに基づいて樹形図を自動的につくることができる手法である。AIによる決定木学習では、まず、人間が説明変数を決める。例えば、図表4—2は日本株の上昇・下落の予測モデルであり、日本株の予測の説明変数(決定木の枝)として、米国株式と国内金利を用いている。AIを用いた決定木学習においては、枝を分割させるための分割基準(高い水準がどの程度かなど)や説明変数(枝)の選定方法などについて様々な手法が研究されているが、説明変数と分割基準を決めると、あとは過去のデータのみに基づいてコンピュータが樹形図を作成してくれる。

集団学習では、説明変数を変えたモデルを複数用意する。例えば、図表4—2の日本株の予測モデルの説明変数に、為替を追加したモデルを使う場合もある。または、分割基準(高い、低い)を他の方法に変更する場合もある。一つの決定木学習のモデルからは、当然一つの分析結果しか得られない。その分析結果の正解率が低い場合には、モデルを複数用意し、それらの中から最も正解率が高いモデルを選ぶこともある(多数決という)。または、多数決ではなく、それらのモデルの結果を何らかの方法で統合する(例えば平均値など)ことで、よりよいモデルや分析結果を得る場合もある。コンピュータの機能が高度化したため、変数やパラメータを変えた同様な分析を幾つも行いうることが可能になっている。このように、複数のモデルを使い、そこから出てきた結果を統合して、より良いモデルを導き出す手法を集団学習(アンサンブル学習ともいう)と呼ぶ。その中でも、本節で説明した決定木学習を用いて集団学習を行うことをランダムフォレストと呼んでいる。例えば、図表4—2のように決定木学習を用いて日本株式の上昇・下落を予測することを考える。1番目の変数に「米国株

式の上昇・下落」、2番目の変数に「国内金利の上昇・低下」とした場合、「もし、米国株式が下落し、国内金利が上昇した場合、日本株はほとんどのケースで下落する」といったようなイメージである。図表4—2の例では、一番上は7/12となっているが、これは、これまでの全ケース12回中、7回日本株が上昇していることを意味する。その中で米国株式が下落した場合は、12回中6回あり、そのうち3回は日本株が下落していることを意味している。変数に米国株式及び国内金利を用いたが、失業率や前日の日本株の上昇・下落といった別の変数を用いた方が説明力は高いかもしれない。ランダムフォレストの場合は、このように様々な変数を用いて決定木学習を行い、最適な組み合わせや合算結果を求めるものである。

瀬之口 [2013]では、過去に銀行株のレジーム（株価水準）が急激に変化する直前に、94種類の金融経済指標の中でどのような共通の変化要因があったかを抽出している。抽出方法としては複数の手法を用い、その結果を比較検討することで、ランダムフォレストが最も判別精度が高かったという結論を示している。

2.2.3 クラスタリング

特徴のないデータもしくはあらかじめ特徴があるかどうか分からないデータを分類するには、何らかの、データのみから導き出される特徴を与えることが考えられる。例えば、個別企業の株価の値動きのデータであれば、その値動きに従って、何らかの同じような小グループに分けることができるかもしれない。値動きの分類の基準には、単純な上昇・下落というものだけでなく、A社と同じような値動きをするグループ（類似度）や、A社とB社の合成した値動きと関連が高いグループ（群平均法）、データサンプルの平均値からのかい離度の高低（距離）によるグループなど、複雑な計算からデータを特徴付けることが可能になっている。こうした特徴付けはコンピュータ処理速度の発達のおかげで、人間が手を加えずに機械が特徴付けをすることが可能になっている。このようにデータのみを使って特徴付けをし、分類する機械学習の手法をクラスタリングと呼ぶ。ただし、人間があらかじめ決めた分類とは異なり、データから求めたものであるため、分類分けされた各グループにどのような特徴があるのかは人間が解釈を与えなければならない。

図表4—3は主要インデックスと33業種インデックス指数の2008年から2016年までの年間収益率を用いてクラスタリングした結果を示している。縦軸と横軸は、コンピュータが特徴付けのために与えたクラスター中心（seeds）の点から各要素までの距離を示したものである。縦軸はクラスター中心1から各要素までの距離、横軸はクラスター中心2から各要素までの距離を意味する。解釈の仕方は様々あるが、例えば、右上のグループに分類された業種群は基幹産業を中心としたグループとの見方ができる。他の応用例としては、様々なデータに加えて、複数の株価の値動きのデータを用いてクラスタリングを行うことで従来からある業種別や規模別といったグループ分けとは異なる分類ができる可能性がある。その場合、例えば、為替による感応度が高いグループ分けかもしれないし、当該株式群を保有し

ている投資家の属性を反映したグループ分けになっているかもしれない。もしそのような解釈が与えられるような分類を見つければポートフォリオ管理やリスク分析にも応用することができる。

杉本他 [2016]では、クラスタリングの手法を用いて、自動車関連企業が保有する特許をエンジン駆動系、ICT 制御系、電池素材系、車体・内装系に大分類し、各企業がどのような技術領域に強い特許を保有しているか、特許俯瞰図を作成している。これらは、特許情報を用いた自動車関連技術マップともいえ、業界全体の動きや、企業や特定技術分野の強みや弱みを概観することができる。

2.2.4 ニューラルネットワーク

ニューラルネットワークには、階層型ニューラルネットワークと非階層型と呼ばれるものがあるが、ここでは、現在最も多く使われている階層型ニューラルネットワークについて説明する。まず、理解しやすくするために重回帰分析について考える。重回帰分析は複数の説明変数と重みづけ（ウェイト）の積の和によって目的変数を説明する。これらは説明変数と目的変数との間に線で描ける関係があることが前提となっている。一方、階層型ニューラルネットワークの場合、最初の段階で、あらかじめ指定した利用可能なすべての説明変数を使い、それらの説明変数に対してランダムに重みづけ（ウェイト）を与え、その結果が目的変数に近づくよう計算する。次の段階では、重要度の低い説明変数を減らした上で、重みづけを変える計算を行う。また、その次の段階では、更に重要度の低い説明変数を減らした上で新しい重みづけを計算し直し、可能な限り目的変数に近づくようにする。目的変数と説明変数との間に複雑な関係を持つモデルであっても同様のプロセスを経ることによって計算が可能となる。重みの付け方、変数の絞り込み方、得られた結果の評価方法、繰り返し計算の方法などについて様々な手法が研究されている。これは、あたかも人間の脳の中の神経細胞（ニューロン）が多数の他の神経細胞から信号を受け取り、意思決定を行っていることと類似していることからニューラルネットワークと呼ばれている。

図表 4—4 は個人のクレジットスコアをニューラルネットワークで求めるプロセスを示したものである。収入 (Income) やローン (Loan) の有無、家族数 (Family Number)、税金 (Tax)、残存期間 (Remaining Period)、年齢 (Age) などの説明変数から、10 年後デフォルト (Default10yr) するかどうかについて、最終結果に至るまでに 1 つの隠れたプロセス（層）を経ることで、最適な変数の数と影響度合いを計算している。過去のデータを用いていったんモデルが作成されると新しいインプットがあった場合に、デフォルトするかどうか（アウトプット）を求めることができる。他の応用例として、例えば、財務指標を説明変数とする企業の格付け評価や倒産確率推定などへの応用が可能であろう。従来からある一般化線形モデル（ロジスティック回帰モデル・プロビット回帰モデル）とは異なり、変数間の影響やより複雑な関数をモデル化することもできる。

2.2.5 グラフ

様々なデータ間の関係性を点（ノード）と線（エッジ）を用いて可視化されたネットワーク構造をグラフと呼ぶ。例えば、図表4-5は仕入れ先や販売先の間接関係を図示したものである。円（点・ノード）の大きさは影響力の大きさを示している。矢印の向きは仕入れ⇒販売の方向を示している。この他にもグラフ化できる（ネットワーク構造を持つ）事例としては、ソーシャルネットワークにおける人間間の繋がり、文章分類、構文解析、ウェブ構造など様々なものがある。点（ノード）同士の何らかの関連性や関連度合いの強さなどを分析するわけだが、関係といっても一方的に関係を持つ場合と相互に関係を持つ場合があるし、直接的な関係だけでなく、他の点（ノード）を経由して間接的に関係している場合もある。グラフを用いることで、バラバラになっている関係性を分かりやすい形で可視化することができる特徴がある。資産運用への応用を考える際には、ネットワーク構造で表現できるかが重要なポイントである。例えば、株式持合いや企業間のサプライチェーンといったものはネットワーク構造で表現できるであろう。他にも、株式収益率を検証する場合、単なる企業間の相関による分類や所属する業種による分類でみるよりも、サプライチェーンによるネットワーク構造の中での株式収益率の関係を分析することは新しい発見につながる可能性がある。

2.2.6 テキストマイニング

テキストマイニングはテキストデータを分析することで単語の頻度や相関、傾向、時系列特性などを調べる手法である。膨大なテキストデータに機械学習を適用することで、高度な分析ができるようになる。これまで取り上げてきた機械学習の目的は、分類や予測をすることであったが、テキストデータにおいても同じように機械学習を適用することで言葉や文脈の分類や予測をすることができるようになる。ただし、テキストデータは言語特有の性質があるために複雑な処理が必要となる。

例えば、「来期は増収増益を想定しておりますが、今期は新規設備投資のために先行投資を計画しており、昨年対比では減益になる見込みです」という文章があった場合、この文章がポジティブな意味であるかネガティブな意味であるかの区別がつかない。増収増益の単語はポジティブではあるが、昨年対比や先行投資によるコストから減益になるのであればネガティブとも取れるからである。文を書く人の表現やそれを解釈する人によっても異なる意味になる。また、極端な事例ではあるが、「担当者が現在走っている期の売り上げを分析したところ」といった文章の場合は、コンピュータにとっては、担当者が分析しているのか、担当者が走っているのかの区別はつかない。

テキストデータを解析する事例として、成蹊大学言語情報研究室が公開している決算短信PDF検索システム「CEES」¹がある。このシステムでは、企業が公表している決算短信をテキストマイニングすることで、決算短信に含まれる業績要因文を抽出し、入力したキー

¹ <http://www.ci.seikei.ac.jp/sakai/>

ワードに関連する業績要因文とそれを含む決算短信、及び企業を検索することができる。同システムでは、単なる関連銘柄を抽出するだけでなく、その業績要因文が当該企業にとって重要性が高いかどうかも判断して抽出結果を表示している。また、業績要因文の文脈を読み取り、その業績要因文が当該企業の業績にポジティブかネガティブかを自動的に判断している。他の応用事例として、例えば、企業が公表する有価証券報告書や決算短信、証券アナリストの企業レポート、経済動向や企業のニュース記事などは、株価や景気の先行きを予測する上では欠かせない情報であるが、これらのテキスト情報をテキストマイニングすることで、新しい決算書類が公表された時にポジティブな記事なのかどうかや、判断に必要な情報だけを即座に抽出するといったことが可能になるかもしれない。事実、膨大なニュースを分析して機械的に投資判断するようなファンドも既に出てきている。

2.2.7 ディープラーニング（深層学習）

ニューラルネットワークを拡張した概念としてディープラーニングと呼ばれる手法がある。従来のニューラルネットワークはどんな変数（特徴量と呼ぶ）が問題を解決するために必要なのかについて、人間が指定しなければならなかったのに対して、ディープラーニングではどんな変数に着目すればよいのかもコンピュータが学習し自動的に性能を高めることができる。ディープラーニングにおいては、コンピュータ自身が変数を抽出し、自らその変数に重みづけを行い、最適な結果となるように、変数の取捨選択や重みづけの変更を繰り返し行い、最終的に絞り込まれた変数を特定する。

例えば、株価は、企業の売上や利益水準だけでなく、日本経済の動向や事業環境、投資家の属性、トレンドなど、数え上げればきりがないうどんさんの要因によって形成されており、その中でどれが特に重要な変数なのかを判断するのは困難である。ディープラーニングではこれらの変数を取捨選択し、それらの変数が株価にどう影響しているかを繰り返し推論し、最終的に株価に最も影響を与えている変数を導き出す。ここで、最終的な変数は、いくつかの変数を複合した新しい変数になることもある。こうして導出された株価に影響を与える変数を特徴量と呼んでいる。ただ、これはあくまでも過去の株価の動きを説明している特徴量に過ぎず、必ずしも、将来を示しているわけではないことには注意を要する。

ディープラーニングは、応用可能性が広いことからパターン認識、レコメンドや異常値検出などの分野で用いられている。例えば、過去に売買した株価の属性データからファンドマネジャーの好みに合うような銘柄の推奨に応用できたりする可能性がある。また、異常値検知を応用すれば株価の暴落の兆候をあらかじめ予測することができるようになるかもしれない。暴落のような圧倒的に取得できるデータが少ない場合であっても正常時のデータを学習することで、正常値からかい離れた場合を異常と判断できる可能性があるからである

2.2.8 強化学習

最後に強化学習についても論じる。強化学習はこれまで説明してきた“手法”ではなく²、データの入出力の関係に着目した機械学習の“プロセス (アルゴリズム)”についての枠組みの一つである。ニューラルネットワークは、データと正解の組み合わせが事前に与えられ、それを基に学習する手法である。データと正解の組み合わせという例題を与えることで学習するさまから教師あり学習と呼ばれる。一方、クラスタリングやランダムフォレストは、正解があらかじめ決まっておらず、データが持つ背景にある構造的な特徴を抽出することから教師なし学習と呼ぶ。強化学習は、教師あり学習のように正解は与えないが、その代わりに行動の選択肢と報酬 (ポイント) という概念を与える。ある行動をした結果、より高い報酬 (ポイント) を得ることができればそれが正しい行動だったというように学習する。一度の行動だけでなく連続した行動を評価し累積した報酬 (ポイント) が最大になるような結果を出力する。正解を与えないことから何度も何度も行動を評価し直すことで精度を高めていく様子から試行錯誤する学習ともいえる。

例えば、一時的なネガティブな決算が発表され、暴落した株式を売却するかどうかについて考えてみよう。教師あり学習のような手法ではロジックの組み立て上、その瞬間にすべて売却の方が良いという結論になりやすい。ネガティブな情報というインプットに対して株価売却というアウトプットが対応関係にあるからだ。一方で、強化学習のロジックを使えば、全てを売却せず、保有し続ける選択をする可能性がある。一時的な情報で株価が低下しても保有し続けるという選択をすることで、株価が元の水準以上に上がり報酬 (ポイント) が最大になる可能性があるからである。

3. 応用事例 1 : マルチファクターモデルへの応用

3.1 はじめに

株式のファクター・モデルは、計量的アクティブ運用 (クオンツ) の分野で最も用いられている手法の一つである。最も単純なファクター・モデルは CAPM (Capital Asset Pricing Model) であり、市場感応度 (ベータ) と知られている単一のファクターを用いて株式のリターンを説明するモデルである。市場感応度以外でも企業の売上高や為替など様々なファクターが株式のリターンに影響を与えるのではないかと予想できるが、特に複数のファクターにより株式のリターンを説明するモデルをマルチファクターモデルと呼ぶ。ファイナンス分野における一般的なマルチファクターモデルは、Ross [1976] により提唱された裁定価格理論 (APT : Arbitrage Pricing Theory) と同義に用いられることがあるが、運用実務においては、CAPM をベースとした Barra 型アプローチや Fama-French 型アプローチのマルチファクターモデルも広く用いられている。マクロ経済変数を先験的に与えて、個別企業の株式収益率を求める方法や、過去の株式収益率から因子分析によって因子を引き出す方法などは、APT 型のマルチファクターモデルに分類される。一方、PER や PBR に代表される投資指標

² 代表的な手法としては、Q 学習 (Q-Learning) や TD 学習 (Temporal Difference Learning) がある。

のような個別企業の株式が持つ銘柄属性を用いて個別企業の株式収益率を求める方法は、Barra 型または Fama-French 型のマルチファクターモデルに分類される。Barra 型アプローチは Rosenberg and Rudd [1982]により初めて紹介された。その後、Grinold and Kahn [2000]、Conner et al [2010]により拡張されたものである。ある一時点における株式銘柄群の株式収益率は共通のファクターによって説明されるとすることから、クロスセクション回帰分析によって計算される。また Fama-French 型は、Fama and French [1992]によって初めて紹介された。ある一時点における株式収益率とファクターの関係を示すのは Barra 型と同じであるが、ファクターは時系列回帰分析によって求められる点が異なる。本研究は時系列回帰分析によって株式収益率とファクターとの関係を検証するという点で Fama-French 型のマルチファクターモデルに分類されるものである。

もう一つ、マルチファクターモデルを用いるに当たって明確にしておかなければならない事項がある。個別企業の株式収益率を銘柄属性で説明するマルチファクターモデルの利用方法として通常2種類考えられる。1つは、銘柄属性の寄与度から相場の傾向を判断して、将来の株式収益率を計算するために利用する方法（リターンモデル）。もう1つは、銘柄属性の寄与度をマーケット・リターンで時系列回帰してファンダメンタル・ベータを求め、ポートフォリオの属性を分解する方法（リスクモデル）である。本研究においては、リターン・モデルを想定している。

本節の目的は、計量的アクティブ運用における機械学習手法の応用可能性を探ることであり、今後の計量アクティブ運用の分野への発展に寄与することであることから前提を明確にしておく。まず、本研究におけるマルチファクターモデルを以下で定義する。

$$R_{it} = \sum_{j=1}^k X_{ijt} f_{jt} + \epsilon_{it}$$

ただし、 R_{it} はt期における企業iの株式収益率、 X_{ijt} はt期における企業iの第jファクターのファクター・エクスポージャー、 f_{jt} はt期における第jファクターのファクター・リターン、 ϵ_{it} はファクターでは説明できない誤差である。

個別企業の将来の株式収益率を複数の銘柄属性（ファクター）による重回帰分析により算出するモデルである。このモデルの下では株式収益率とファクターの間における関係は線形であるが、金融市場の複雑性を考えると非線形を仮定するほうがより適切に関係性を表現できる可能性がある。そこで、本研究では、非線形の関係性を表現できる機械学習の代表的な手法（サポートベクターマシン、勾配ブースティング、ニューラルネットワーク）を用いて、従来の線形モデルと比較し、非線形手法の実務運用における有効性と応用可能性を検証する。機械学習の手法のうち上記3つを比較対象とした共通の理由として、回帰問題への応用ができる手法であることがあげられる。個別の理由については以下で説明する。

3.2 関連研究と手法の基本的概念

Joseph [2014]は、PBR のファクター・リターンを予測するために、VIX、VIX の 1 カ月変化率、PBR の分布、PBR の分布の変化率、1 カ月前の PBR のファクター・リターンを変数とし、パラメータの推定に縮小推定法 (Shrinkage Method)を用いたロジスティック回帰分析を用いた検証を行っている。また、プライスモメンタムについても同様の分析を行っている。ともに、翌期の予測精度が大幅に高くなっている結果を得ている。他の機械学習手法として、CART (Classification and Regression tree)を使った検証もしており、時期によってはロジスティック回帰分析よりも有効性が見られることを示した。上記の分析は、ファクター・リターンの時系列予測に他の変数を用いて非線形の機械学習手法の適用を試みたものであるが、リターン・モデルについて適用したものではない。リターン・モデルでは、ファクター・リターンの予測値 (ファクター・ウェイトと呼ぶ) と直近のファクター・エクスポージャーから、将来の予測リターンが計算され、これを予測アルファと呼ぶが、上記の研究は予測モデルのマルチファクターに言及したものではない点で我々の研究とは異なる。

以下では、分析に用いた機械学習分析手法の基礎的概念について整理する。

3.2.1 サポートベクターマシン

非線形のサポートベクターモデルは、未学習のデータに対して高い識別性能があり、現在知られている手法の中で最も分類性能が優れた学習モデルの一つとして知られている。将来の市場で起こる出来事は不確実であり、ファクターとリターンとの関係も常に一定ではないことを前提とすると、未学習のデータに対する高い識別性能があるサポートベクター回帰は適合しやすい可能性がある。本節で用いる ϵ -SVR は、線形回帰の時、 ϵ -insentive 損失関数 $L^\epsilon(x, y, f)$ を使って線形関数 $y = f(x) = \langle w \cdot x \rangle + b$ を推定するものであり、

$$L^\epsilon(x, y, f) = \max(0, |y - f(x)| - \epsilon)$$

となる。なお予測値が実測値を上回る場合は $L^\epsilon(x, y, f) = \xi$ とし、予測値が実測値を下回っている場合は $L^\epsilon(x, y, f) = \hat{\xi}$ で表現する。最終的には以下の主問題を解くことになる。

$$\begin{aligned} \min_{w, L^\epsilon, b} & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l L^\epsilon(x_i, y_i, f), \\ \text{s.t.} & (\langle w \cdot x_i \rangle + b) - y_i \leq \epsilon + \xi_i \\ & y_i - (\langle w \cdot x_i \rangle + b) \leq \epsilon + \hat{\xi}_i \\ & \xi_i, \hat{\xi}_i \geq 0, i = 1, 2, \dots, l \end{aligned}$$

ここで、上記の式における元データ x を非線形関数 $\phi(x)$ によって高次元空間に写像すること

により非線形回帰へと拡張できる。上記の主問題は実際には双対定理を使い双対問題として解くことができる。この時双対問題中に $\langle \phi(x_i) \cdot \phi(x_j) \rangle$ と内積計算が現れる。一般的に高次元空間で内積計算を直接行うことはとても煩雑であり、この内積計算を行うことができるカーネル関数 $K(x_i, x_j)$ を適用する。カーネル関数としては、ガウシアンカーネル

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right)$$

を用いている。

3.2.2 決定木・勾配ブースティング

取り得る選択枝や起こり得るシナリオを樹形図の形で洗い出し、それぞれの選択枝の期待値を比較した上で意思決定を行う手法として決定木というものがある。金融業界やコンサルティング業界においてよく用いられる手法である。本節ではより精緻なモデルを構築するため、アンサンブル学習の一つである勾配ブースティングという手法と決定木を組み合わせる。勾配ブースティングとは、学習データから復元抽出を繰り返し複数のデータセットを作成し、それぞれに対して弱学習器を作り、全ての弱学習器の解で多数決を取り最終解を求める方法である。弱学習器を作成する際に、前回作成した弱学習器の結果を利用して、誤分類された値の重みを大きくするように更新する。この重みづけの際に勾配降下法を用いるのが、勾配ブースティングである。本節では、GBDT (Gradient Boosting Decision Tree)をモデルとして用いている。まず、決定木をつくり、うまくモデルが説明できなかった観測値に対して重みを付け、重みのついた状態で次の決定木を作成するというプロセスを指定した回数繰り返す。実際に観測された値との誤差に対して学習を行うため、より優れた決定木が残ることになる。ファクターとリターンとの関係が変化した場合、組み合わせで優れた決定木を学習することから、市場変化に適応する非線形モデルとして予測精度が高まる可能性がある。

3.2.3 ニューラルネットワーク

ニューラルネットワークには、階層型ニューラルネットワークと非階層型と呼ばれるものがあるが、今回、階層型ニューラルネットワークを用いる。階層型ニューラルネットワークとは、入力層、中間層、出力層をもつネットワークであり、入力層に説明変数を取り、中間層でそれらの説明変数に対してランダムに重みづけを与え、その結果が出力層である目的変数に近づくように、最適な重みを計算していく。ファクター間の相互相関を考慮し、必要な変数に集約するプロセスは、変数の組み合わせ方法に基づく先に挙げた2つの機械学習の手法とは異なる。ファクター間の関係や説明に必要な変数を集約する非線形モデルとしてこれも予測精度が高まる可能性がある。

3.3 リターン・モデルへの応用

3.3.1 応用における考え方

通常、ファンダメンタル・ファクターモデルにて算出した将来の株式収益率が実際の運用で活用できるかどうかについては、ファクター・リターンの有効性と安定性を検証しなければならない。しかしながら、機械学習手法(サポートベクターマシン、勾配ブースティング、ニューラルネットワーク)についてはファクター・リターンに該当する係数を特定するのは困難である。そのため次のような検証を行う。まず、ユニバース構成銘柄を対象とし、以下で説明するファクターと機械学習手法から得られた結果として求められる将来の株式収益率を個別銘柄対比で大きい順にソートし、将来の株式収益率が大きい順に5分位のグループに分ける。最も大きいグループをロングポートフォリオ、最も小さいグループをショートポートフォリオとし、それぞれ翌期まで保有した場合のポートフォリオ・リターンを計測する。その後、ロングポートフォリオとショートポートフォリオの差分(スプレッド・リターン)を計算。分析期間にわたって繰り返し計算を行い、毎月毎のスプレッド・リターンの累積値を求め、従来の線形モデルと機械学習手法の結果を比較する。将来の収益率の予測力が高いほど、実現した将来の株式収益率と予測した収益率の差は小さくなり、ロング・ショートポートフォリオの累積リターンは大きくなるはずである。なお、実証するにあたり、実現値と予測値を用いて RMSE および MAE を計算している。

3.3.2 検証手順

ユニバースは、TOPIX 構成銘柄のうち、時価総額が大きく流動性が高い TOPIX500 構成銘柄とした。時価総額が小さく、流動性が小さい銘柄については、株式のリターンに対してファクター以外のイベント(例えば決算情報やニュース)が与える影響が大きい可能性がある。使用するファクターについては一般的によく使われる投資指標である PER、PBR、ROE、対数時価総額、3 ヶ月 β の 5 つとする。PER、PBR についてはバリュースコア指標、ROE はグロース指標、対数時価総額は規模指標、 β は市場感応度の表す代表的な指標である。本節においては、ファクターの効果を調べることではないため、代表的なファクターを取り上げており、比較するモデル上は同様のファクターを用いて検証している。なお、PER と PBR については逆数に変換している。これは、値が小さいほど割安になるよう、ファクターの値の属性の方向と数値の高さをそろえた方が、他のファクターとの関係で分析しやすいためである。分析期間については、2000 年 1 月末から 2017 年 6 月までの月次データに基づく。機械学習を応用する意味では長期であるほど望ましいが、データ数が多いほど計算負荷が極端に大きくなってしまふ。ユニバース 500 銘柄に対して株価とファクターおよび計算の負荷を考慮して 2000 年以降の月次データにしている。ポートフォリオについては月次リバランスにてリターンを計算している。なお、個別銘柄の所属する業種によるファクター値の水準の違いによる影響を除くため、まず東証 33 業種内で基準化(z-score)し、その後、再度 TOPIX500 全体で基準化した。

比較基準となる重回帰モデルについては、過去1年間（t期よりも前）の各銘柄の月末ファクター値を説明変数、翌月末(t期)リターンを目的変数として回帰係数（ファクター・リターン）を算出。得られた回帰係数（ファクター・リターン）をテスト期間における月末の各銘柄のファクター値（ファクター・ウェイト）にかけることで、各銘柄の将来の株式収益率（期待リターン）を算出している。先の検証についての考え方に従って、得られた期待リターンを基に作った5分位ポートフォリオの1分位をロング、5分位をショートし、翌月まで保有した時のロングポートフォリオとショートポートフォリオのリターン差（スプレッド・リターン）を求めている。これを月次でローリングし得られたリターンを累積した。比較対象である機械学習手法（サポートベクターマシン、勾配ブースティング、ニューラルネットワーク）についても同様のプロセスにて計算している。ファクターを用いて期待リターンを計算する際に、重回帰モデルではなく機械学習手法を用いている。

有効性を検証するために、ポートフォリオのパフォーマンスの比較および予測精度の2つのパターンを示す。なお、ポートフォリオのパフォーマンスについては、月次平均リターン、月次標準偏差、およびシャープレシオ。予測精度として、計算期間に渡り累積した RMSE と MAE を用いている³。

3.3.3 分析結果

図表4-6は検証結果をまとめたものである。ポートフォリオのパフォーマンスの比較では、月次平均リターンはニューラルネットワークによるモデルが最も高い結果となった。ボラティリティを考慮したシャープレシオについても同様の結果である。予測精度の比較では、実績値と予測値から求めた RMSE と MAE の累積値はともに SVM が最も良い結果となった。GBDT についてはポートフォリオのパフォーマンスについては重回帰分析に劣るものの、累積 RMSE、累積 MAE については精度が高い結果となった。

3.4 考察

本節では、ファンダメンタル・ファクターモデルに着目しリターン予測の精度について、従来の重回帰分析に加え、GBDT、SVM、ニューラルネットワークを適用し比較した。結果として、当てはまりの精度である累積 RMSE、累積 MAE は全ての非線形モデルで改善が見られ、月次平均リターンや月次シャープレシオにおいても、一部のモデルで改善が見られた。このことは、金融市場における銘柄のリターンとファクター値間の関係は従来の線形関係ではなく、非線形関係が存在すると考えられ、そのような非線形関係を捉えられるモデルが、従来のモデルに対し優位性を持つ可能性がある。

³ 実装について：筆者らが構築した株式分析システムに基づいている。データは FACTSET より取得、基本となるデータベース・計算システムおよびファンダメンタル・ファクターモデルについては Python、機械学習の計算については R と機械学習パッケージである 'nnet' を用いた。

今後の展望として、非線形の分析は実際の運用においても重要な意味がある。例えば、ファクターにベットしている大規模ファンドやスマートベータと呼ばれるファンドは、ティルトしているファクターの有効性は見られるもののファンドパフォーマンスがそぐわないことがある。これは、従来のマルチファクターモデルは線形モデルであるために、本来非線形で評価すべきものを線形評価することによるズレが起因している可能性がある。また、クロスセクション回帰分析への応用も期待されるだろう。もしくはクロスセクションと時系列回帰分析の両方を考慮した多変量回帰分析への応用も興味深い結果が得られるかもしれない。計量アクティブ運用の分野はそれだけでも奥深い研究対象であることから、基本的な分析手法や考え方を踏襲した上で、機械学習手法を応用するのは簡単ではない。しかしながら、実際の運用において広く使われる考え方であることに加え、計量アクティブ運用と機械学習手法の相性はよい側面もあることを考えれば、今後あらゆる角度からの応用が求められる。

4. 応用事例2：ディープラーニングを用いたイベント考慮後の株価予測

4.1 背景

株式資産運用の実務においては、株価を予測することは重要な仕事の一つである。最終的には株価は需給によって決定するものの、企業の将来の業績を調べることで売買を判断する投資家もいれば、株価の動きだけを見て判断する投資家もいる。また、PER や PBR といった株式指標を参考に割安・割高を判断する投資家もいるだろう。好きな企業だから買うという投資家もいるかもしれない。このように様々な見通しや考え方を持った市場参加者によって株価は決まるため、将来の株価を予測するのは簡単ではない。

企業の将来の業績から株価を予測する手法には、例えば将来の株式配当を現在価値に割り引くことで求める配当割引モデルや企業が事業を行った結果生み出される将来キャッシュフローの現在価値を求める割引キャッシュフローモデルなどがある。また、株価は EPS （一株当たり純利益） \times PER（株価収益率）によって構成されていると考える倍率法では、PER は一定であると想定した場合、将来の業績が好調のため EPS が倍になるのであれば、株価も単純に倍になると考えられる。少なくともその株価水準に長期的には収斂されていくだろうと期待される。

個別企業を分析する人が、多くの企業で四半期ごとに公表される企業の決算発表や日々のプレスリリースに着目するのは、業績の進捗を知ること、これまでの見通しが正しかったかどうかを判断したり、今後の企業の成長がどの程度期待できるのかを見極めたりする意味がある。将来にわたり企業価値を高めるであろうと投資家の多くが考える情報があれば株価は上昇するからである。

このように、将来の株価を予測する上では、企業の決算発表やプレスリリースといった情報はとても重要な意味を持つ。また、過去の株価はこのような情報に基づいて判断してきた投資家の思惑が含まれているといえるだろう。

本節で提案する LSTM-RNN (Long Short Term Memory Recurrent Neural Network)は、再帰的ニューラルネットワーク (Recurrent Neural Network)の一種であり、通常の RNN において長期の系列データを学習する際に発生する勾配問題を回避することから、長期の時間依存も短期の時間依存も学習できる特性がある(Hochreiter and Schmidhuber [1997]⁴)。従来の RNN では考慮できない過去の情報をネットワーク内に保持し、必要なタイミングでのみ取得・置換したいとの課題から登場してきた背景がある。

発表された情報がどの時点の株価に影響しているのかは知ることは難しいものの、そのような状況を織り込んだ株価予測を行う上では、LSTM-RNN は有効な手段になるものと思われる。

4.2 先行・関連研究

LSTM-RNN を用いた株価予測を行った関連研究について説明する。株価だけに応用した研究としては、Murtaza [2015]らは、インドの取引所の NIFTY50 銘柄の株価について、Open、Close、High、Low それぞれのデータを組み合わせたときの LSTM-RNN による株価の予測精度について比較検証している。結果としては 4 つのデータを用いて予測を行った場合が最も望ましいことを示した。また、Qun [2015]らは、個別銘柄の寄付きの株価について、上海総合指数とフォーラム内の情報から取得した感情データを変数にして予測することを行っている。結論としては従来型の RNN を適用するよりも良好な結果が得られたようだ。また、宮崎・松尾 [2017]らは、日経平均の値を TOPIX core30 主要構成銘柄を入力データとして騰落を予測することをさまざまな機械学習手法を用いて予測精度を比較検討している。結果によると LSTM が群を抜いて正確さが高く、長期的なトレンドの予測ができている可能性を示した。このように、LSTM-RNN は時系列データ分析において適用する場合、効果が高いことが知られているが、株価を予測するという点においてモデルの設定の仕方によっては先の論文のように有効な予測モデルの手段になりえる可能性がある。

そこで本研究では、LSTM-RNN を用いることで企業のイベントを織り込んだ株式予測の手法を提案する。具体的には、特定の企業を取り上げ、決算発表日、コーポレートアクションのプレスリリース、企業が投資家向けに公表している受注残高を変数に用いて、将来株価を予測する。

4.3 分析

4.3.1 モデル

x_t は t 時点の入力値 (ベクトル)、 h_t は出力値とするとき、LSTM-RNNは以下に定式化される。

⁴ 既存の RNN (RTRL (Real-Time Recurrent Learning)、BPTT (Back-Propagation Through Time) 法を用いた学習) と LSTM を用いて 100 ステップのラグ付きデータを学習させた場合、既存の RNN は全く学習できていない一方で、LSTM は短期の学習時間で学習できることを示している。

$$\begin{aligned}
f_t &= \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \\
i_t &= \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \\
o_t &= \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \\
c_t &= f_t \odot c_{t-1} + i_t \odot \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \\
h_t &= o_t \odot \sigma_h(c_t)
\end{aligned}$$

c_t はメモリセルの状態ベクトル、 W 、 U 、 b はパラメータ行列とベクトルである。また、 f_t は古い情報を記憶する重みベクトルである忘却ゲート、 i_t は新しい情報を得るための重みベクトルである入力ゲート、 o_t は出力候補のベクトルを出す出力ゲートを表す。活性化関数のうち、 σ_g はシグモイド関数、 $\sigma_{c,h}$ は双曲線正接関数である。

4.3.2 データ

分析対象として、株式会社ツガミ（証券コード：6101）の株価を取り上げ分析を行った。工作機械メーカーであるツガミは、自動旋盤機を作っている世界的ニッチ企業である。生産と売上げの大半は中国であることから、企業業績は国内の受注だけでなく海外の受注に大きく依存している。また、国内市場が縮小する中、海外へ事業の基盤を移す政策を進めており、また同時に明確な資本政策も発表していることから、生産工場の移管や自己株式の取得、ストックオプションなど積極的なコーポレートアクションを公表している。シクリカル銘柄にも分類されることがあるツガミは、中・小型株であることに加えて、マクロ指標（工作機械受注高）や企業が月中に発表する前月の国内と海外の受注高推移、コーポレートアクションのプレスリリースに株価が反応しやすい特徴がみられる。今回の分析にツガミを取り挙げたのは、企業にまつわるプレスリリース及びマクロ指標のインパクトが株価へ与える影響が大きい企業であると推測されるためである。本節で用いる分析手法は、モデルの性質上、イベントが頻出し、そのイベントの特性も様々なパターンとして表れる方が望ましい。

今回分析に用いる変数は、株価に加えて、企業がHP上に公表するイベント情報（プレスリリース）と企業の国内および海外の受注残高、内閣府が提供している工作機械受注高である。これらのイベントは、セルサイド含めアナリストであれば通常みるべき指標やイベントであり、特別なものではない。なお、イベント情報は、決算発表日などの法定開示に関するものと、自己株式取得、ストックオプションの発行などコーポレートアクションに関するものを分けて変数にしている。

なお、日次で分析するために月次および四半期のマクロ指標については、多項式スプライン補完を行った。スプラインを行った理由としては、日次で機械学習の分析を行う上で、情報量を増やす意味もあるが、受注などのデータは日々の企業活動によって徐々に蓄積され、結果として4半期の数値になることを考えればスプライン補完することに一定の合理性があると思われるからである。使用したデータの期間はイベントデータ及びマクロデータで共通に取得できた2013年4月15日から9月11日までである。イベント情報については、

データクリーニングの過程で ID として数値にエンコーディングしている。データが公表された翌日から予測に使えるようにラグ（イベント公表の翌日に予測が利用できるようにしている）を考慮している。全期間 1082 日のうち 700 日をトレーニング期間、3 割にあたる残りの期間をテスト期間とした。

4.3.3 検証手法

実際の運用を想定するならば実績値と乖離がないほうが望ましい。そこで、RMSE(Root Mean Squared Error) を使ってモデルの評価をすることにした。この検証手法は機械学習の精度を評価する上で、一般的な評価手法である。

$$RMSE = \sqrt{\frac{1}{N} \sum (\hat{y}_t - y_t)^2}$$

\hat{y}_t は予測値、 y_t は実績値である。

4.3.4 実装について

Hochreiter [1999]らによって提唱された LSTM-RNN に基づいている。計算するにあたって、学習時には、Epoch 数を 50、100、500 の 3 つのパターンで計算。隠れ層のユニット数は 50、LSTM 層は 1 とした。学習のフレームワークとしては、フロントエンドに Keras、バックエンドには Tensorflow を使用して実装している。確率的勾配降下法の最適化を行う上で、Adam(Adaptive Moment Estimation)により学習率の設定を行っている。また、GPU は GeForce GTX 1060 3GB を使用した。

4.3.5 検証結果

図表 4-7 は、説明する変数に株価のみを用いた場合、イベントのみを用いた場合、企業が公表する受注残高とマクロ指標を用いた場合、イベント及び受注残高を用いた場合、マクロ指標のすべてを用いた場合について、それぞれの RMSE につき Epoch 数別にまとめたものである。イベントを考慮した場合は、株価のみを用いた予測よりも総じて予測誤差が小さい。マクロ指標を用いた場合は、Epoch 数が 500 の時のみ予測誤差が小さくなっている。すべてを変数にした場合は、むしろ精度が低くなってしまいう結果となった。運用実務においては、実績値の上昇・下降をどのくらい予測できているかが重要になることから、一致率も図表 4-8 に掲載している。どの分析においても 50%に満たないことから本研究においてはあまり実用的ではない。ただし、株価のみを使用した結果よりも一致率が高くなる場合もあるようだ。

4.4 考察

本節では、LSTM-RNN を用いて特定の企業が出すイベント情報や受注残高を織り込んだ

上での将来の株価を予測するということを試みた。説明する変数に株価のみを用いた場合、イベントのみを用いた場合、企業が公表する受注残高とマクロ指標である工作機械受注高を用いた場合、イベント及び受注残高を用いた場合、マクロ指標のすべてを用いた場合を比較して株価の予測値と実績値の差がどの程度異なるのかについて比較検討した。結果としてはイベントのみを用いた予測が最も実績値との誤差が小さいことが分かった。Epoch 数を変えて計算してもその傾向は変わらないことから、当該企業についてはイベント情報が将来株価を予測する上で有効かもしれない。ただし、本研究は、このようなイベントを考慮する時系列予測の提案が目的であり、分析の精度を高めるためにはより長期にわたる分析を行うことが望ましいだろう。

本節で提案したモデルは容易に拡張できる。株価に影響を与える変数は企業によって異なるであろうことから、TOPIX 構成銘柄など個別銘柄ごとに分析することができる。また、上場企業は法定開示資料や決算報告資料など定期的な情報の開示が必須であることは欧米でも同様であることからグローバル銘柄においても本提案手法と同様の分析を行うことができる。本研究においては単にイベントがあったという情報だけであるが、その情報にポジティブ・ネガティブの属性を持たせる応用も可能である。むしろそのほうが株価を説明する情報としては適切であるかもしれない。今回の予測対象は株価であるが、企業の業績予想をイベントやマクロ指標に基づいて行うことで株価予測を本研究とは異なるアプローチで行うことができるだろう。また、最適な自己株式の取得のタイミングを評価することに応用できれば企業にとっても役に立つ可能性もある。

5. まとめ

本章の研究では AI（機械学習）がどのように資産運用に応用できるのかについて論じてきた。まず、第 1 節では、そもそも AI がどのようなものであるのかということについて、代表的な手法を取り上げ、考え方およびその応用の仕方について説明した。決定木学習やクラスタリングのように既に使われてきた考え方をコンピュータで効率よく計算できるように発展させたものや、アソシエーションルール、ニューラルネットワークなどの従来の統計分析にはなかった手法、また、グラフ、テキストマイニング、ディープラーニングのように機械学習特有の考え方に基づく手法など AI と言っても様々な考え方があり、応用可能な分野が異なるとともに各手法の特性を示すことができた。グラフ（ネットワーク構造）という特殊なデータ構造に対して機械学習を適用することで、株式持合いや企業間サプライチェーンのような新しい切り口の分析が可能になるかもしれない。テキストマイニングは、言語を扱うあらゆる分野への応用可能性を秘めている。ディープラーニングは分析のための勘所ともいえる変数の選択さえも自己学習できるという点で従来の分析から大きく前進している。昨今の AI ブームの発端となったのは、これまで述べた“統計手法”に、新しい強化学習という“プロセス（アルゴリズム）”が加わったことが一つの要因となっている。このように、AI の応用可能性は飛躍的に広がったのではないだろうか。第 3 節・第 4 節で取り挙げ

た事例は、資産運用への具体的な応用方法について研究したものである。第3節では、計量アクティブ運用で主に使われるマルチファクターモデルにAIを応用した事例であるが、AIがもつ非線形性の特徴を従来の線形モデルの拡張として応用できないかという試みである。第4節は、過去の情報を蓄積し、必要な時に必要な分だけ情報として利用できるという特性を持つAI手法をイベント情報を織り込む形で株価を予測することに応用したものである。AI手法がもつ非線形性や情報利用のコントロール、学習といった特性は従来の分析手法にないものであり、資産運用の分野においてのあらゆる角度からの研究が可能であり、今後必要となるだろう。ただし、資産運用業界への応用については、幾つかの押さえるべきポイントがある。一つはアナリストやファンドマネジャーは、AIが何をできるかについて正しく理解し、それを使いこなさなければならないことである。あらかじめ決まった条件下ではAI（機械学習）の方が処理できる情報量や速さにおいては人間より優れている側面があるからだ。AIができることを理解した上で、業務のプロセスを見直し、どの部分がAIに代替可能か、どの部分は代替不可能なのかを見極める必要がある。もう一つは、AIは入力する過去のデータが学習の基になっていることから、今後、運用業界に携わる人間は、どのような情報をデータとして取得し、保存していくかを選択すべきであるということである。一方で、どんなに大量のデータを分析対象としても、これまで起こったことのない事象については学習することができないため予測不可能だということも忘れてはいけない。過去にないような事象が起こる可能性が常にある資産運用業界においては、AI（機械学習）ができることは限定的ではないだろうか。また、これまで説明してきた分析手法の多くでは、前提となる変数（変数の収集も含めて）を人間が与えている。人間が変数の選択という判断をすることは、その時点で人間が間違いを犯している可能性を排除することはできないことを意味する。一方で、ディープラーニングのように変数でさえも、コンピュータが学習してしまう手法の場合は、人間が予想もしない学習（変数の選択）をすることで、とても説明がつかない結果を返す可能性がある。資産運用業務は、上述のようにこれまで起こったことがないことが起こり得る世界であり、分析結果に対して、結果の解釈（説明）を与えられないものを盲目的に信じて意思決定を行うことは難しい。（これが囲碁や将棋のように、一定のルールの枠組みの範囲でしか物事が動かない世界とは異なる点である。）したがって、AI（機械学習）は技術的には高度化しても、人に取って代わることが出来ない部分は残るはずであり、人間はAI（機械学習）というツールをよく理解し、いかに使いこなすかが重要であり、今後もその関係は、暫くは変わらないであろう。

【引用文献】

- Brownlee, J. [2017] *Long short-term memory networks with python develop sequence prediction models with deep learning*, Machine Learning Mastery, ebook.
- Fama, E. F. and French, K. R. [1992] “The cross-section of expected stock returns,” *Journal of Finance*, 47, 427-465.
- Fritsch, S., Guenther, F., Suling, M. and Mueller, S. M. [2016] “Package ‘neuralnet’,” r-project.org.
<https://cran.r-project.org/web/packages/neuralnet/neuralnet.pdf>
- Hochreiter, S. and Schmidhuber, J. [1997] “Long short-term memory,” *Neural Computation*, 9, 1735-1780.
- Kassambara, A. and Mundt, F. [2017] “Package ‘factoextra’,” r-project.org.
<https://cran.r-project.org/web/packages/factoextra/factoextra.pdf>
- Meyer, D., Dimitriadou, E., Hornik, K., Weingessel, A., Leisch, F., Chang, C. C. and Lin, C. C. [2017] “Package ‘e1071’,” r-project.org.
<https://cran.r-project.org/web/packages/e1071/e1071.pdf>
- Mezrich, J. [2014] “Factor forecasting with machine learning,” Working Paper, Nomura equity Research Report, 1-22.
- Minami, S. [2018] “Prediction equity price with corporate action events using lstm-rnn,” *Journal of Mathematical Finance*, 8, 58-63.
- Roondiwala, M., Patel, H. and Varma, S. [2015] “Predicting stock prices using lstm,” *International Journal of Science and Research*, 6, 2319-7064.
- Rosenberg, B. and Rudd, A. [1982] “Factor related and specific returns of common stocks: Serial correlation and market efficiency,” *Journal of Finance*, 37, 543-554.
- Ross, S. A. [1976] “The arbitrage theory of capital asset pricing,” *Journal of Economic Theory*, 13, 341-360.
- Sugitomo, S. and Minami, S. [2018] “Fundamental factor models using machine learning,” *Journal of Mathematical Finance*, 8, 111-118.
- Zhuge, Q., Xu, L.Y. and Zhang, G.W. [2015] “Lstm neural network with emotional analysis for prediction of stock price,” *Engineering Letters*, 25, 167-175.
- 植野剛 [2017] 「機械学習とは何か？」『証券アナリストジャーナル』2017年8月号, 6-15頁.
- 河田剛 [2017] 「AI時代とアナリスト」『証券アナリストジャーナル』2017年5月号, 46-5頁.
- 金明哲 [2009] 『Rによるデータサイエンス』森北出版.
- 金明哲 [2016] 『定性的データ分析』共立出版.
- 酒井浩之・西沢裕子・松並祥吾・坂地泰紀 [2015] 「企業の決算短信 PDF からの業績要因の抽出」『人工知能学会論文誌』2015年30巻1号, 172-182頁.
- 杉本浩一・岩井徹・松島憲之・原口右京・安岡勇亮・八木亮 [2016] 「非連続イノベーションが自動車産業に迫る 100年ぶりの大改革【総論編】」三菱 UFJ モルガンスタンレー証券

2016年10月26日, 1-71頁.

瀬之口潤輔 [2013]「株価の局面変化に対する要因抽出」『人工知能学会研究会資料』2014年10月11日.

南正太郎・光定洋介 [2017]「AIの資産運用への応用の可能性と限界」『証券アナリストジャーナル』2017年8月号, 16-26頁.

宮崎邦洋・松尾豊 [2017]「深層学習を用いた株価予測の分析」『人工知能学会第31回全国大会資料』2017年5月24日, 1-3頁.

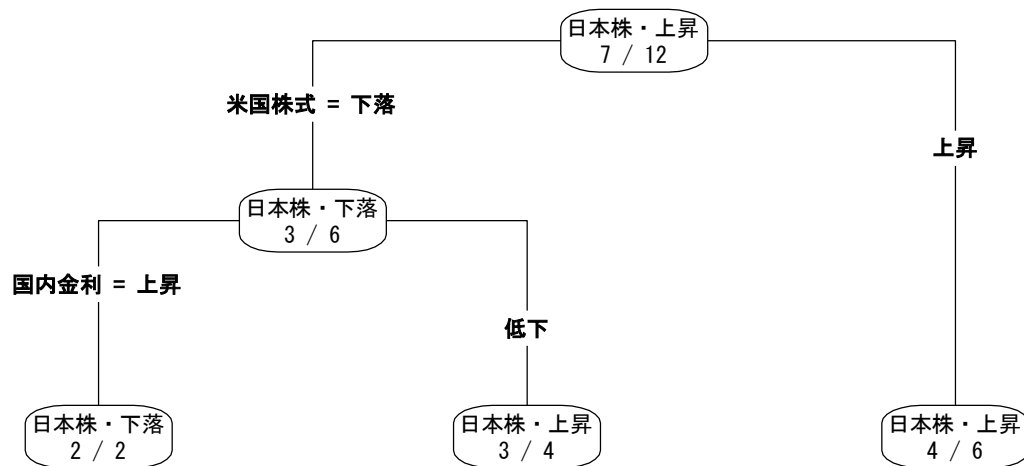
図表 4-1 : アソシエーションルール

ルール	支持度	確信度	リフト
[1] {NISSAN} => {SOFTBANK}	0.67	1.00	1.13
[2] {TOYOTA} => {SOFTBANK}	0.56	0.83	0.94
[3] {NTT} => {NISSAN}	0.44	0.80	1.20
⋮	⋮	⋮	⋮
[19] {SOFTBANK, ケーヒン} => {DENSO}	0.22	0.42	0.53
[20] {TOYOTA, ケーヒン} => {SOFTBANK}	0.20	0.41	0.60

(注)

データは筆者が作成した架空のものである。金 [2016]のプログラムコードを参考に筆者が作成。株式の売買記録のうち、どのユーザーがどのような株式を購入したかの情報をリスト上に保有したデータを作成。購買アイテムの履歴のみのデータに対して、アソシエーションルールを計算するプログラムを実行し結果の一部抜粋を表記している。

図表 4 - 2 : 決定木



(注)

データは筆者が作成した架空のものである。金 [2009]のプログラムコードを参考に筆者が作成。データについては、日本株式が上昇・下落、米国株式が上昇・下落、国内金利が低下・上昇の様々な組み合わせをリスト形式にしたものを準備した。なお、わかりやすい図を描くために枝を3つに設定している。

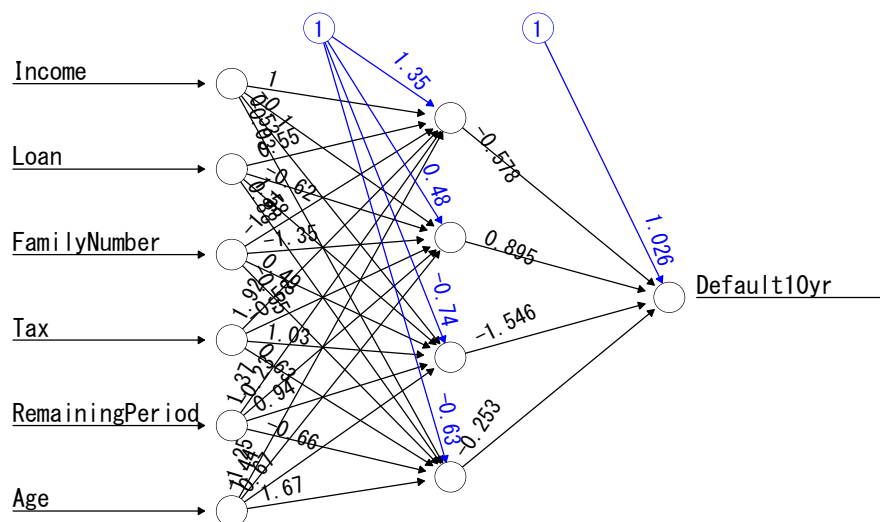
図表 4-3 : 主要インデックスと 33 業種指数の年間収益率をクラスター分けした図



(注)

データは Bloomberg より取得。Kassambara and Mundt [2017]のプログラミングコードを参考に筆者作成。主要インデックスと東京証券取引所が公表している 33 業種インデックス指数の 2008 年から 2016 年までの年間収益率のデータに対してクラスタリングを行った結果を図示している。縦軸と横軸はクラスター中心の点から計算された各要素までの距離を示したものである。k平均法に基づき、クラスター数は 3 つを設定し計算している。

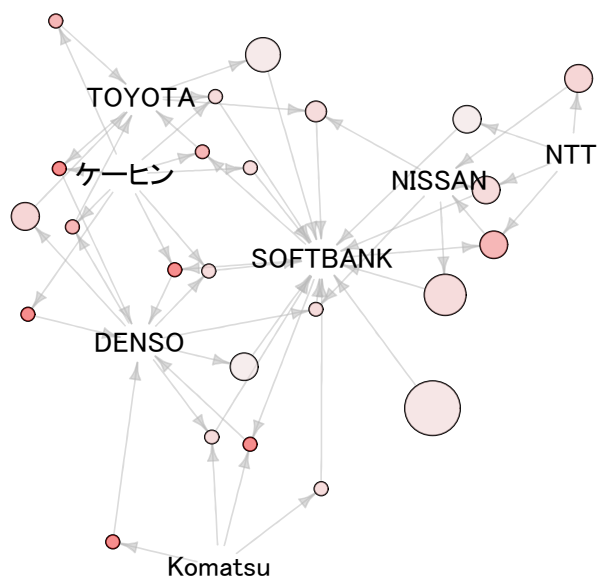
図表4-4：個人のクレジットスコアをニューラルネットワークで求めるプロセス



(注)

データは架空のものである。多層パーセプトロンと呼ばれる考え方をを用いて計算。図中の①は、切片を表すための定数項である。Fritsch et al. [2016]のプログラムコードを参考に筆者作成。収入 (Income)やローン (Loan)の有無、家族数 (Family Number)、税金 (Tax)、残存期間 (Remaining Period)、年齢 (Age)などの説明変数から、10年後デフォルト (Default10yr)するかどうかについて、最終結果に至るまでに1つの隠れたプロセス (層)を経ることで、最適な変数の数と影響度合いを計算している。

図表 4-5 : 企業間サプライチェーンのネットワーク図



(注)

データは架空のものである。金 [2016]のプログラムコードを参考に筆者作成。企業名のみで構成される仕入れ先、販売先の関係の組み合わせのデータをリスト形式で作成し、データの中での頻出度の高いものほど影響度の大きいものとしてネットワークグラフで表示している。矢印は販売先を示している。

図表 4－6：検証結果

	重回帰分析	GBDT	SVM	NN
平均リターン	0.10	0.09	0.12	0.18
標準偏差	2.83	2.86	2.89	2.72
シャープレシオ	0.037	0.034	0.042	0.068
累積 RMSE	1832.17	1831.61	1823.53	1832.92
累積 MAE	1428.71	1428.14	1418.28	1428.39

(注)

データは Quick-FactSet より取得。ユニバースは TOPIX500 構成銘柄であり、使用ファクターは PER、PBR、ROE、対数時価総額、3 ヶ月 β の 5 つを用いた。分析期間は 2000 年 1 月末から 2017 年 6 月であり、毎月リバランスによりポートフォリオの平均リターンを計測している。重回帰分析、GBDT (勾配ブースティング)、SVM (サポートベクターマシン)、NN (ニューラルネットワーク) を用いた場合のポートフォリオ・リターンの基本統計量及び当てはまりの指標である RMSE、MAE を比較した結果をまとめている。

図表 4-7：学習回数および使用した情報毎の RMSE

RMSE	株価のみ	イベント	マクロ指標	すべて
Epoch = 50	19.5	18.9	19.9	20.4
Epoch = 100	17.1	16.9	17.6	18.1
Epoch = 500	15.0	14.9	14.8	15.3

(注)

列に学習の回数、行には予測に用いた情報ごとに予測と実績値の誤差を示す RMSE をまとめたものである。Epoch の数値が大きいほど、学習の回数が多いことを示している。“イベント”は株価及びコーポレートアクションのイベント情報を用いて予測した結果である。“マクロ指標”は、株価及び企業が公表する受注残高と工作機械受注高を用いて予測した結果である。“すべて”は、株価、イベント情報、企業が公表する受注残高、工作機械受注高を用いて予測した結果を示している。

図表 4 - 8 : 一致率

一致率	株価のみ	イベント	マクロ指標	すべて
Epoch = 50	0.4842	0.4868	0.4711	0.4737
Epoch = 100	0.4895	0.4789	0.4921	0.4947
Epoch = 500	0.4579	0.4526	0.4553	0.4711

(注)

LSTM-RNN のアルゴリズムに基づいて計算出力された予測値と実績値を用いて、全期間における上昇・下降が同じであった回数の比率を算出（一致率と定義）。それぞれの一致率を Epoch 数別にまとめた。

結語

本論文では、日本の株式市場における資産運用の新潮流に焦点をおき、実務の中で生じた課題や問題意識に対して実証研究と事例研究を行った。第1章では、バリュエーション効果の循環性及びトレンドを検証した上で、その効果が低下傾向にあるということを分析した。第2章では、日銀の金融政策の一環であるETF買入が現物株市場に対して与える影響についての考察を行った。第3章は、日本版スチュワードシップコード・コーポレートガバナンスコードに関連して企業と投資家との対話（エンゲージメント）の効果を計量的に測定することを試みた。第4章は、資産運用実務にAIという新しい技術をどのように応用できるのかについて研究した。AIの基本的な手法と考え方と応用可能性と限界について論じた上で、具体的な応用事例としてマルチファクターモデルへのAI手法の応用とディープラーニングを用いてイベントを考慮した株価予測を取り挙げた。

第1章では、リアルオプションを用いた企業価値評価モデルであるプロダクションベースモデルにおいてはバリュエーション効果がモデルの構造上説明できる。そのため、モデルに基づき企業価値と株価との関係を示す仮説を立てその仮説の検証を行った。検証方法としては、実務で用いられるアルファテストという分析手法とアルファテストから計算される説明力を示す時系列データに対してスペクトル分析及びトレンド分析を用いた。その結果、バリュエーション効果には循環性とトレンドがあり、トレンドが低下していることが示された。低下の要因は、モデルに基づけば合理的投資家が存在することで、合理的な投資家の投資行動の結果、引き起こされている可能性が示唆される。諸外国との比較においても同様の結果が観測されており、日本の株式市場特有のことではない。いち早くバリュエーション効果が低下している海外では、バリュエーション以外のアルファの模索が盛んに研究されており、日本はやや遅れている感がある。ファクター効果以外のアルファの源泉の模索も始まっている。2014年の日本版スチュワードシップコード、2015年の日本版コーポレートガバナンスコードの導入により本格的に始まった投資家と企業とのエンゲージメント活動はその一環であろう。また、AIといったビッグデータといった新技術を用いた資産運用の応用などもある。グローバル市場を一つの市場としてみなした研究やエンゲージメント、AIなどの新しい潮流に関する研究は今後求められてくるであろう。

第2章は、日本銀行が金融政策の一環で行っているETF買入が現物市場に及ぼす影響について考察した。はじめにETF買入がETFの価格変化及び「設定・交換」というETFの仕組みを通じて現物株に影響しうることを説明した。そのうえで、日経平均連動型ETFの価格変化をファクターを用いて検証した。その結果、日銀がETF買入を実施した日の午後は、買入を行わなかった日の午後よりもETF価格が下支えされている可能性が示唆された。次に、現物株への影響を調べたところ、買入実施日の午後取引が活発化した銘柄は、それ以外の半日と比べて相対的にベータが低く、流動性も低い（不人気）銘柄である傾向が見られた。株価リターンとの関係では、普段、日経平均構成比が大きな値高株のリターンが高い一

方で、買入実施日の午後は低位株のリターンの方が高い様子が観察された。アベノミクス以降、市場でしばしば言われる「ETF 買入で日経平均構成比が大きい値高株のウェイトが更に増大し、市場を歪めている」との指摘とは異なる結果である。また、「実力よりも株価が過大評価されている銘柄により多くの資金を投入することになる」との指摘については、指摘そのものは外れていないものの、現物市場では過小評価されている銘柄のリターンの方が高い様子が観測されたことは非常に興味深いものである。本章の分析期間が 2013 年 5 月 17 日までであり、この間に渡り株価が一本調子で上昇しているため、分析結果に影響している可能性がある。様々な市場環境における分析を行うことが今後の課題である。株式運用実務においては当局の行動は必要なイベントの一つである、特に第 2 章の分析はアベノミクスの金融政策の目玉であり、ファクターによるアプローチによって影響を分析することで具体的な結論を得ることができたのは一定の成果である。

第 3 章では企業と投資家の対話（エンゲージメント）効果の測定について投資スタイルを用いて測定を試みた。まず、ファンド全体について Sharpe が提唱したスタイル分析により投資スタイルの影響を取り除いたアルファについて計測した。その後、ファンドを構成する銘柄 2 つを取り挙げたうえで、3 ファクター・モデルによる検証を行った。ファンドの分析においてはアルファの存在とともに、その時系列推移は定常過程（ユニーク）であることが分かった。個別銘柄の事例では、実際のエンゲージメント活動の詳細とアルファとの関係について考察している。結果としては、エンゲージメント効果を定量化するには今後研究の余地があるものの、定量化できる可能性を示すことができた。エンゲージメント活動の詳細は公に情報として出にくい側面があるため広く分析することは容易ではない。しかし、エンゲージメント活動を謳っているファンドが多く設定され、事例として現実の世界において情報が蓄積されているのは容易に想像される。エンゲージメント効果の測定はまだ始まったばかりであり、さまざまな切り口やアプローチからの研究が求められる。

第 4 章は、AI（機械学習）がどのように資産運用に応用できるのかについて論じてきた。まず、そもそも AI がどのようなものであるのかということについて、代表的な手法を取り上げ、考え方およびその応用の仕方について説明した。AI には様々な考え方があり、応用可能な分野が異なるとともに各手法の特性を示すことができた。具体的な応用事例として計量アクティブ運用で主に使われるマルチファクターモデルに AI を応用したものや過去の情報を蓄積し、必要な時に必要な分だけ情報として利用できるという特性を持つ AI 手法をイベント情報を織り込む形で株価を予測することに応用したものなどを取り挙げた。AI 手法がもつ非線形性や情報利用のコントロール、学習といった特性は従来の分析手法にないものであり、資産運用の分野におけるあらゆる角度からの研究が今後求められる。ただし、資産運用業界への応用については、幾つかの押さえるべきポイントとして、一つはアナリストやファンドマネジャーは、AI が何をできるのかについて正しく理解し、それを使いこなさなければならないことである。それは、あらかじめ決まった条件下では AI（機械学習）の方が処理できる情報量や速さにおいては人間より優れている側面があるからだ。もう一つ

は、AI は入力する過去のデータが学習の基になっていることから、どのような情報をデータとして取得し、保存していくかを選択すべきであるということである。一方で、どんなに大量のデータを分析対象としても、これまで起こったことのない事象については学習することができないため予測不可能だということも忘れてはいけない。資産運用業務は、これまで起こったことがないことが起こり得る世界であり、分析結果に対して、結果の解釈（説明）を与えられないものを盲目的に信じて意思決定を行うことは難しい。そのため、AI（機械学習）は技術的には高度化しても、人にとって代わることが出来ない部分は残るはずであり、人間はAI(機械学習)というツールをよく理解し、いかに使いこなすかが重要であり、今後もその関係は暫く変わらないであろう。

本論文は資産運用業界における新潮流に焦点を当て資産運用実務において生じた課題に関して実証分析と事例分析を行った。時代によって求められるものは変わり、検証の仕方によっては異なる解釈ができる可能性はあるが、内容の新規性に加えて、いち早く課題に対する検証を行ったことは意義がある。また、エンゲージメント効果の測定など新しいアプローチや AI のように他の分野の技術や理論を取り入れるには、単純に応用するだけでなく、従来の金融経済学の考え方をしっかりと踏襲したうえでの検証が十分に求められる。理論モデルの構築もしかり、様々な切り口による分析及びアプローチが今後さらに必要となってくるであろう。