

**人工知能（AI）が運用に与える影響
についての調査研究業務
報告書（要約版）**

株式会社ソニーコンピュータサイエンス研究所

2018年3月

要旨

本報告書は、2017 年秋に株式会社ソニーコンピュータサイエンス研究所（以下 CSL）が年金積立金管理運用独立行政法人（以下 GPIF）より受託した「人工知能が運用に与える影響」についての調査研究に関して報告を行うものである。その業務内容は、(1) 人工知能（AI）の年金積立金の長期運用への活用可能性についてと、(2) AI 技術が運用会社のビジネスモデルへ与える影響について、調査研究を行うことである。

GPIF の中核業務の一つは「マネジャー・ストラクチャー」と呼ばれるプロセスであり、これを通じて、運用資産をどのような種類の運用機関（＝マネジャー）に、どのように（再）配分するのかという構成（ストラクチャー）を組成および管理する。この際に、各々のマネジャーがどのような特性を持っているのか、様々な経済的背景の中でどのような運用行動を取るのか、その運用行動は GPIF に対して申告している内容と乖離せずに整合性が取れているのか、乖離している場合にはそれは妥当なものなのか警戒すべきものなのか、などを精度良く判断する必要がある。

そこで、今回、調査研究内容の一つ目の項目である「AI の年金積立金の長期運用への活用可能性」については、GPIF が運用機関から日次で収集している運用行動履歴のデータ（どの銘柄をどれだけ取引して、その結果各々の銘柄をどれだけ保有していて、評価損益がどの程度あるのか、etc…）から、深層学習によって該当するマネジャーの運用スタイルを推定する Style Detector Array システムの原理試作を行った。具体的には、あらかじめ定義した典型的ないくつかの運用スタイルを忠実に実行する仮想マネジャーの取引行動を訓練データとして Style Detector Array を訓練し、これに実在のマネジャーのデータを入力として与えることで、各々の運用スタイルの強度を成分とした属性ベクトルを出力として得る。その時間的な推移を見ることによって、背景となる経済状況やファンドの運用方針の転換などにより、属性ベクトルが時事刻々と変化していく様が見られるようになった。従来から GPIF では各々のマネジャーの運用スタイルの分析を行ってきたが、マネジャーに対するヒアリングに依拠する定性的なものであったり、定量的なものであっても行動の結果としての運用成績をベースにしたものに留まるものであった。これに対して、今回、我々が提案した手法では、運用行動をダイレクトに分析することによって、エビデンス・ベースでかつリアルタイムなスタイル分析を可能にした。これにより、GPIF は、より精度の高い評価・選定手法を手に入れることになる。

また、調査研究内容の二つ目の項目である「人工知能技術が運用会社のビジネスモデルへ与える影響」については、人工知能に関する深い理解と経験は有するものの金融分野そのものに属しているわけではない CSL が、いわば第三者的な立場の視点から、既存の思考の枠組みに捕らわれることなく自由な発想のもとに考察を行なった。

第1章

背景：GPIFの抱える課題認識と 本調査研究の目的

海外年金基金と比して委託比率の高い GPIF においては、特にアクティブ運用の委託コスト、人材や知識・スキルおよび委託運用先の一層の機動的かつ精緻な選定能力の向上等に課題意識を強くもっている。平成 28 年度業務概況書 [1] をもとに、直近 10 年間のアクティブ運用における報酬控除後の超過収益率を年率で試算すると、国内債券 -0.12%、国内株式 -0.29%、外国債券 +0.64%、外国株式 -0.78% と、外国債券以外はアルファが出ていない状況である。一方、運用受託機関及び資産管理機関への支払手数料（3 年累計）は、国内債券約 99 億円、国内株式約 137 億円、外国債券約 128 億円、外国株式約 345 億円となっており、アクティブ運用において実績連動型報酬制度、外部評価の併用、等の様々な改善施策の推進・検討を行っている。この状況を受け、平成 29 年度 11 月および 12 月の経営委員会議事概要 [2, 3] によると、アクティブ運用のマネジャー選定に関しては次のような議論がなされている：

「今あるファンドや、過去に契約のあったファンドとの比較だけをしていて、もっとほかにいいファンドがあるのかという比較が出来ていない」

「ユニバース全体に対していいファンドを選んでいるかという考え方にしていきたい」

「定性評価は恣意性があるのではないか、客観性に欠けるのではないか、という類の批判を浴びる懸念がある」

更に、本調査研究において GPIF の運用担当者に対して行なったヒアリングからも、少数精鋭の担当者による工数的に極めて強い制約の下で、アクティブ運用を評価している実態が判明した。

こうした課題認識から、従来のアクティブ運用の評価手法に、担当者の 3K+1D（勘・経験・気合+度胸）を伴った選定能力を補完する、アクティブ運用の選定に寄与する AI 活用への期待が高いことが分かった。また、Two sigma[4, 5]、Renaissance Technologies[6, 7]、Investifai[8, 9, 10] など、深層学習に代表される最新の AI 技術を活用したファンドも登場し始めており、こうした新しいタイプのファンド評価方法に関する課題もあることが分かった。

AI の現状と今後の展開に関する技術的な理解と認識に基づき、AI が現在または今後における GPIF の中核業務である年金積立金の長期運用における課題を解決しうるものなのか、どの課題が対象となりうるのか、どのように推進・発展させるのか、そして付随する対処すべき課題を明確にし、それを裏付ける検証を本調査研究では行う。また、合わせて運用会社のビジネスモデルへの影響についても考察する。

本調査研究を通じて、GPIF におけるパフォーマンス向上や効率化、そして最終的には年金被保険者に実際的かつ確実に貢献することを最終的な目的とする。

第2章

年金積立金の長期運用への活用可能性

マネジャー・ストラクチャーへの適用

年金積立金の長期運用にあたっての課題解決のためには、GPIFの中核業務の一つであるマネジャー管理、その中でもとりわけ「マネジャー・ストラクチャー」のプロセスにAI技術を導入することが最もインパクトの大きい貢献をなし得ると考えた。この仮説のもと、深層学習技術を応用しファンド・マネジャーの売買パターンからファンドの運用スタイルを学習・推定する Style Detector Array システムを考案した。以下では、その原理試作をいくつかの实在の国内株ファンドに適用して分析を試みた結果について述べる。

2.1 ファンドの多様性

各々のファンドは投資の基本哲学、戦略、手法等に基づいて類型化された資産運用の形態すなわち運用スタイルを持つ。そのスタイルによって各々のファンドが特徴づけられることになるが、端的にその違いが現れるのは日々の取引行動である。まずは、高度な分析手法を用いなくとも、これをシンプルに可視化するだけでも各々の多様なファンドの一側面を見ることができるとを以下に見ていく。

図 2.1 に、国内株を扱ういくつかのファンドについて、2014 年 4 月 1 日から 2018 年 3 月 30 日までのデータから抽出した取引行動を可視化したものを示す。それぞれのチャートにおいて、横方向には 2018 年 3 月末時点での時価総額の大きい順に左から右へ銘柄を並べ、縦方向には上から下へ時間軸（日次）を取っている。青のドットは縦軸に該当する日に横軸に該当する銘柄を「買い」、赤のドットは逆に「売り」の取引を行なったこと、無色は取引を行わなかったことを意味する。

例えば、B 社のチャートでは右方に空白が目立ち大型株中心の銘柄を扱うファンドであることを反映したのになっている一方で、小型株を主に扱う P 社のチャートでは大型株を表す左端が空白になっている。また、L 社のチャートは数理的な判断に基づいて機械的に多範囲の投資対象の売買を行うクオンツスタイルの特徴がよく現れている。その対極として、ディスクリーショナルと呼ばれる手法で人手による綿密な調査に基づいて銘柄選定を行うスタイルを採る O 社のチャートからは、少数の銘柄のみにターゲットを絞った運用を行なっていることが見て取れる。

以上のように、それぞれのファンドの取引行動には運用スタイルに応じた大きな違いがあることが分かる。また、濃淡のパターンから、売買取引が高頻度で集中的に行われた特定期間の存在も見える。ファンドに新たな投資資金が加わって幅広く買い付けを行なったり、何らかのマーケットの変化に伴い構成銘柄を大きく入れ替えたり、大規模なリバランスを行なったりすると、こうしたパターンが現れる。

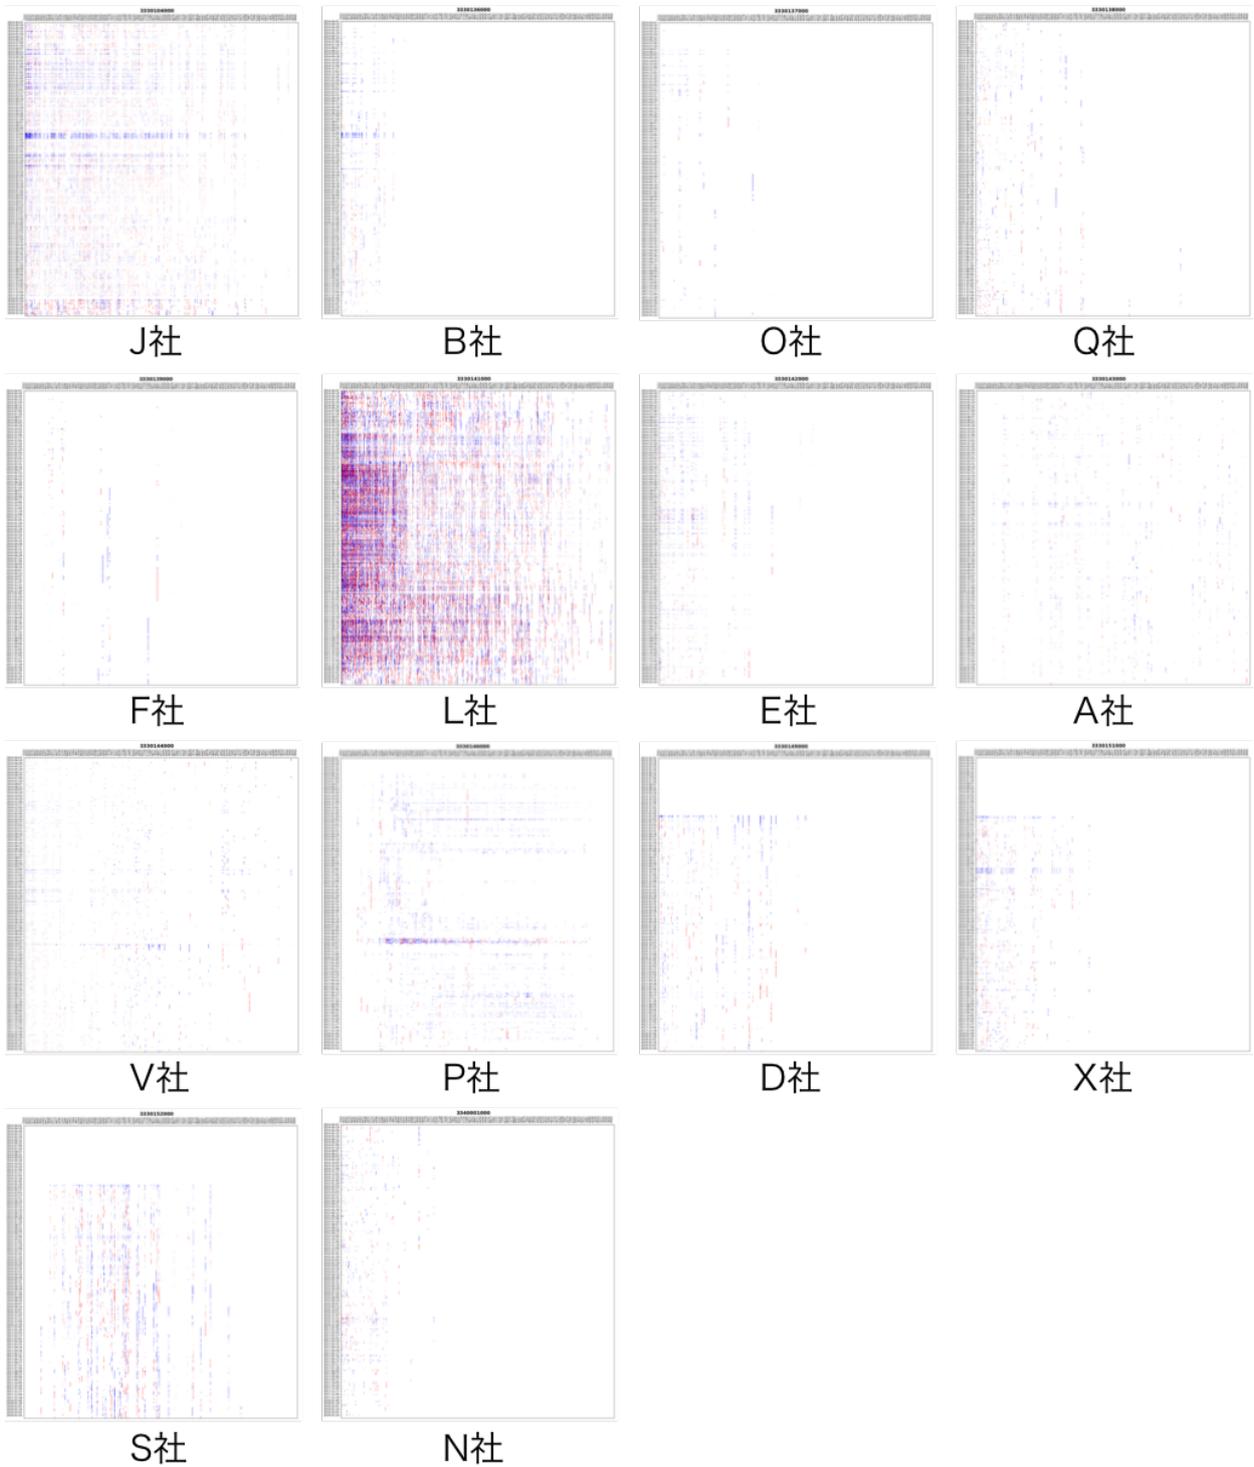


図 2.1: ファンド・マネジャーの取引行動の可視化

2.2 深層学習による運用スタイル分析器 (Style Detector Array) の開発

より詳細かつ定量的にファンドの運用スタイルを評価するために、現在の AI ブームを支える重要な技術の一つである深層学習を活用した運用スタイル分析器 (以下、Style Detector Array) のシステムを考案し、いくつかの国内株ファンドに適用して分析を試みた。なお、本調査研究では、まずは動作原理の確認を主目的としたため、全上場銘柄を扱うのではなく、時価総額の大きいものを中心に代表的な 100 銘柄のみを切り取った小さなユニバースを想定して原理試作を行なった。開発は Python 上で行い、ニューラルネットワーク関連のライブラリとしては tensorflow[11]、Keras[12] を、結果の可視化には matplotlib[13] や plotly[14] を、その他のライブラリとして SciPy パッケージ [15]、numpy[16]、pandas[17]、Scikit-learn[18]、iPython[19] を活用した。データの整形や前処理には R 言語 [20] も用いた。

2.2.1 Style Detector Array システムの枠組み

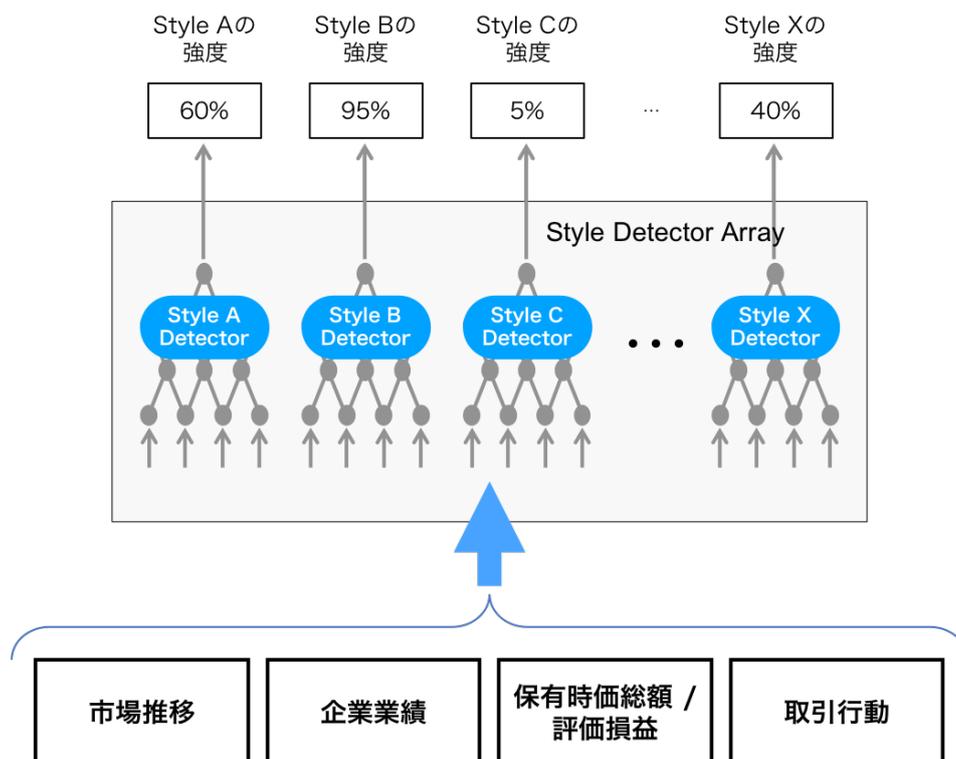


図 2.2: 運用スタイル分析器 (Style Detector Array)

Style Detector Array はレファレンスとなる運用スタイルのそれぞれについての強度を評価する別個の識別器 (以下、Detector) が並置された構成を取っており、各々の Detector は深層学習ニューラルネットワークで実装されている (図 2.2)。市場環境、企業の業績推移といった外部シナリオに加えて、ファンドの構成銘柄の内容 (各時点での保有時価総額や評価損益) と日々の取引行動を時系列の入力として受け取り、いくつかレファレンスとしてあらかじめ用意した典型的な運用スタイルのそれぞれに対する類似強度を成分とした属性ベクトルとして、分析対象となるファンドの運用スタイルを出力する。

仮想ファンド・マネジャーによる訓練データの生成

あらかじめ用意するレファレンスとしての運用スタイルへの分類能力を Style Detector Array に獲得させるために、Detector を構成するニューラルネットワークに、運用スタイルと対になった運用行動を訓練データとして与えて学習させる必要がある。しかし、レファレンスとする運用スタイルを具現化した運用行動データは実在しないケースが多い。そこで、ここでは、典型的な運用スタイルのロジックを仮想ファンド・マネジャーとして実装し、そのシミュレーションにより生成した仮想の取引データを訓練データとして Style Detector Array の学習に用いることにした。

今回の試作においては以下の 8 つの運用ロジックを Style Detector Array におけるレファレンススタイルと設定した。設定にあたっては、資産運用において典型的と思われるものを念頭に、株価に基づいて判断するもの、企業業績などのファンダメンタルを考慮するもの、任意の一時点の数値のみではなくウィンドウサイズとして定めた過去の時系列推移を含めて判断するもの、特定の少数銘柄のみを保有するもの、全ユニバースにまたがった銘柄を保有するものなど、ロジックに多様性を持たせるように配慮した。

- **High Dividend**

配当利回りの高いものを選定して保有する戦略。

- **Minimum Volatility**

過去 20 営業日から成る期間のボラティリティが小さいものを選定して保有する戦略。

- **Momentum**

過去 20 営業日間の株価上昇率が高いものを選定して保有する戦略。

- **Value**

PBR の低いものを選定して保有する戦略。

- **Growth**

PER の高いものを選定して保有する戦略。

- **Quality**

「営業キャッシュフロー / 時価総額」で算出される値の高いものを選定して保有する戦略。

- **Fixed Weight**

全銘柄の時価総額が均等になるようにターゲットポートフォリオを設定した戦略。

- **Technical**

長期の移動平均線と短期の移動平均線の推移のパターンに基づいて銘柄の入れ替えを行う戦略。

2005 年 11 月 1 日から 2017 年 8 月 3 日までの市場推移や企業業績推移のヒストリカルデータを用いて、上記の運用戦略を実行する仮想ファンド・マネジャーの行動をシミュレーションすることで仮想的な取引データを生成した。

教師データを用いたスタイル評価器の学習

次に、それぞれの仮想ファンド・マネジャーによる仮想的な取引データを用いて、Style Detector Array を構成する各々の Detector を訓練する。Detector の実体であるニューラルネットワークの入力側には、市場および企業業績に関する項目（株価、出来高、配当利回り、PBR、PER、設備投資額、フリーキャッシュフローなど）とファンドに関連する項目（各銘柄の保有量や評価損益と売買取引行動など）が、ユニバースを構成する全ての銘柄のそれぞれについて、ウィンドウとして過去に遡る日数分だけ与えられる。ここで、想定しているユニバースを構成するのは 100 銘柄で、それぞれの銘柄に付随する項目数が

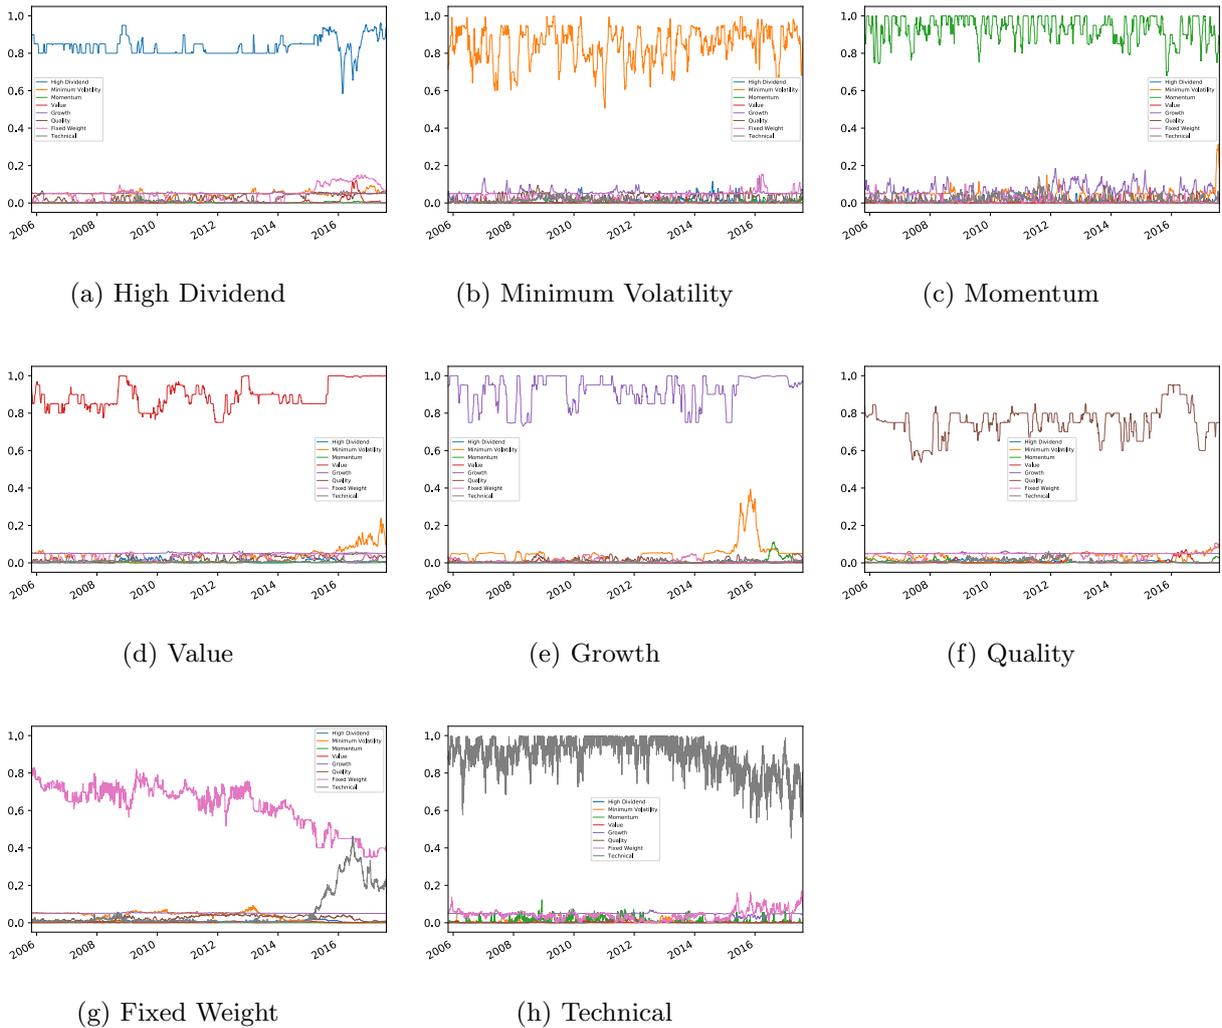


図 2.3: 学習後の Detector の出力値

19 個、ウィンドウとしては過去 40 日を設定するので、Detector であるニューラルネットワークへの入力、 $40 \times 19 \times 100$ の 3 階テンソル（入力ユニットの総数 76,000 個）となる。それぞれの仮想ファンド・マネジャーについて、仮想取引データのうちの 2005 年 11 月 1 日から 2015 年 2 月 24 日の期間に該当するデータを訓練セットとして順次与えていき、該当する運用スタイルの Detector のみが応答するように、Style Detector Array の訓練を行う。なお、仮想取引データのうち終盤の 2015 年 2 月 25 日から 2017 年 8 月 3 日のものは、訓練データとしては使わずに訓練後の Detector が運用スタイルの識別能力を獲得できたかを評価するための検証用データとして確保した。

ところで、一般に、ニューラルネットワークの学習において、特に学習対象が複雑な問題である場合には、訓練開始時にランダムに初期化されるパラメータに依存して試行ごとに結果が大きくばらつくことが分かっている [21, 22, 23]。そこで、個別に訓練を行った 20 個のニューラルネットワークの出力のアンサンブル平均を取ることで Style Detector Array の出力値とした。訓練後の Style Detector Array に、それぞれの仮想取引データを入力として与えたときの出力値を示したのが図 2.3 であり、検証用として訓練時には与えなかった期間も含めて、8 つのレファレンススタイルをおおむね適切に識別でき、十分な汎化能力も備えた上で学習が為されたことが分かる。

2.2.2 Style Detector Array による国内株ファンドの分析

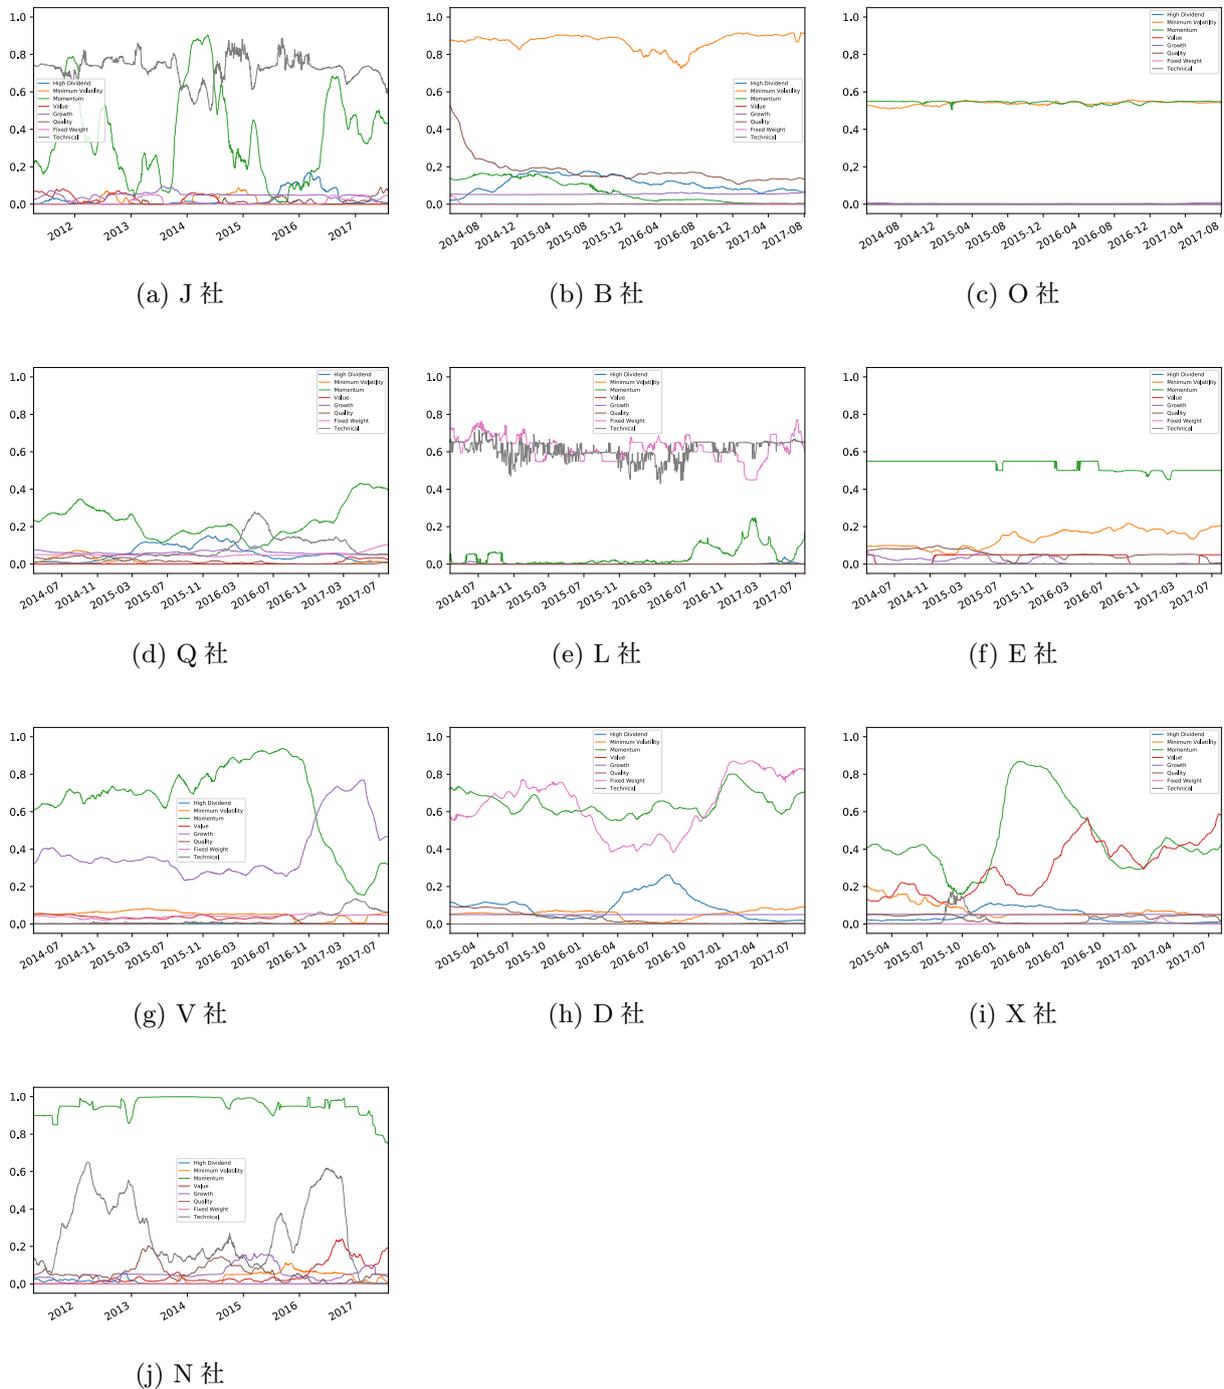


図 2.4: Style Detector Array による国内株ファンドの分析

次に、リファレンス・スタイルの十分な識別能力を獲得した Style Detector Array に、実在するリアルな国内株ファンドのデータを入力として与えた。分析するのにあたって十分な量のデータが利用可能だった 10 の国内株ファンドについて、Style Detector Array を適用した結果の一覧が図 2.4 である。ファンドごとに特徴の違いがあること、同じファンドでも時間の経過とともに各々 Detector の出力値が変化し

て特徴が変化する場合もあることなどが分かる。

以下では、例として V 社と D 社を取り上げて、その結果を掘り下げて検討する。

例 1：V 社の分析

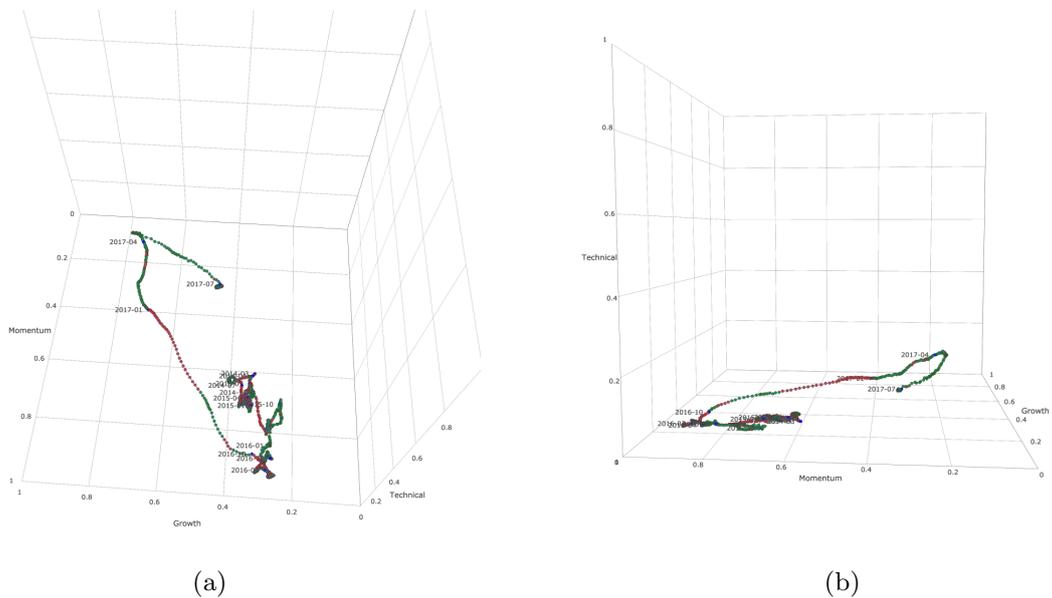


図 2.5: 運用行動の相空間上での軌跡：V 社

当該ファンドは、小型の Growth 株の扱いが多く、資金を特異的な方針およびスタイルで分散させて運用を行うファンドである。

時間軸に沿って、図 2.4g を、より仔細に見ていくと、はじめは Momentum スタイルの属性の強度が最も強く、これに Growth スタイルが続く形で出ているのが、2016 年 11 月の頃を境に両スタイルの順序が入れ替わり、Growth が首位に立つようになる。それと同時に、それまではほとんど強度成分としては現れていなかった Technical スタイルが若干の立ち上がりを見せている。それ以外のスタイルの属性強度は全体を通じて低い値のままであった。なお、Growth スタイルの強度が全体を通じて相対的に強めに出ているのは、小型の Growth 株メインを扱う当該ファンドの特性と整合する。こうした Style Detector Array の出力値の推移から、2016 年 11 月前後で V 社の運用スタイルに何からかの変化があったことが読み取れる。実際、GPIF の当該ファンドの管理担当部署にヒアリングを行なったところ、ちょうど 2016 年の 11 月前後にマネジャーの構成に変化が施されていることが確認された。こうしたファンドの内部事情の変化が、Style Detector Array の出力パターンの変化として検知されていると見られる。

次に、Style Detector Array を構成するそれぞれのスタイルの Detector の出力を軸として張った相空間を定義し、その中での軌跡として運用スタイルの時間的な推移をより直感的に把握する試みを行なった。本原理試作での Style Detector Array は 8 つの Detector から構成されているため本来であれば 8 次元の相空間となるが、出力値のうち支配的な上位 3 つのスタイルのみを軸として選び 3 次元の相空間上に可視化した。図 2.5 は、Momentum、Growth、Technical を 3 軸として定義した 3 次元空間内の V 社の運用スタイルの軌跡を、角度を変えたいくつかの視点から眺めたものを示したものである。各時点での、Style Detector Array の中の Momentum、Growth、Technical のそれぞれの Detector の出力値の三つ組みが相空間内において対応する座標の点として表現されている。先に見た 2016 年 11 月前後

で Momentum と Growth の強度が入れ替わる様子は、相空間表現においては、例えば図 2.5a における軌跡の右下から左上の方への移動として表現されている。さらに、図 2.4g では、2017 年 4 月頃を境に、Growth の強度が下がり、Momentum の強度が上がる両者間の関係の若干のゆり戻しの動きが見られるが、図 2.5 の相空間表現でも 2017 年 4 月頃の点を頂点とした軌跡の屈曲として表現されている。

例 2：D 社の分析

当該ファンドの運用は、相場の局面に応じて投資スタイルを一定の手法で分析して機動的にローテーションする低リスク型の運用スタイルを採っている。あらかじめ設定される基本的な戦略・方針をベースとしながらも運用担当者の判断によって投資が行われるジャッジメンタル色の強い手法である。

図 2.4h を見て分かるように、全体を通じて支配的なのは、Momentum、Fixed Weight、High Dividend のスタイルで、時系列的な大きな変化としては、2015 年 5 月、2016 年 1 月～4 月、2016 年 11 月前後に、支配的な強度のスタイルの入れ替わりが見られる。

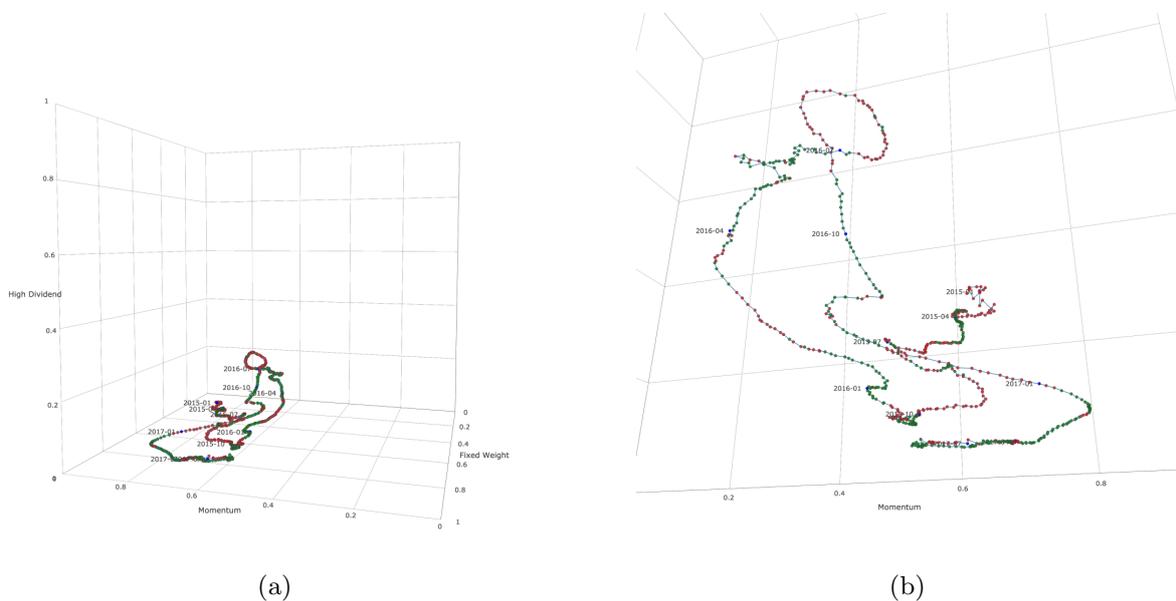


図 2.6: 運用行動の相空間上での軌跡：D 社

先に行なったのと同様に、上記 3 つの支配的なスタイルを 3 軸に選んで定義した相空間上でのスタイル変遷の軌跡を、角度を変えた視点でいくつか表したのが図 2.6 である。相空間上で運用スタイルが特定の強度の組み合わせに長期間留まることがなく、期間全体を通じて軌跡が彷徨している様子は、まさに当該ファンドの採るローテーション戦略の特徴の現れと考えられる。その対極として、運用スタイルにほとんど変化がない、もしくはあったとしても少ない O 社 (図 2.4c) と L 社 (図 2.4e) の相空間上での軌跡をそれぞれ示した図 2.7a、図 2.7b と比較すると、その違いは明らかである。これらの軌跡は、相空間内での動きがほぼ見られないもの、あるいは、動きがあったとしても何らかの時空間的な構造を伴ったものではなく定点の周囲をランダムに摂動するようなものとなっている。

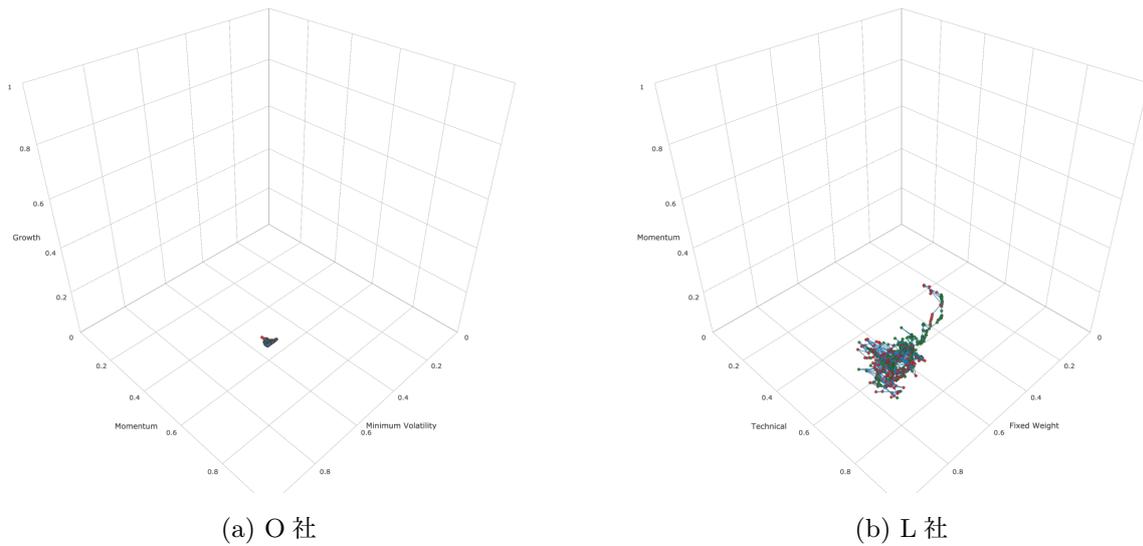


図 2.7: 運用スタイルの変動の少ないファンド

2.3 複数ファンドの挙動の同時視覚化

マネジャー・ストラクチャーを構成するファンド群に多様性があるか、経済局面によって似通った挙動に収斂するようなことがないか、その収斂は不可避なものなのか、収斂することが検知されたときにマネジャー・ストラクチャーの多様性を維持するためにはどのような措置を講ずればよいのか、などといったことはロバストなマネジャー・ストラクチャーを実現するにあたって重要な点である。これらのことを検討するにあたっては、これまで行なってきたように個々のファンドに対する個別の分析に加えて、対象となる全てのファンドの挙動を並置して同時に眺めることができるのが望ましい。ここでは、対象となる全てのファンドの挙動を t-SNE[24] と呼ばれる次元圧縮の手法を用いて一つの相空間上に軌跡として同時に視覚化することを試みる。

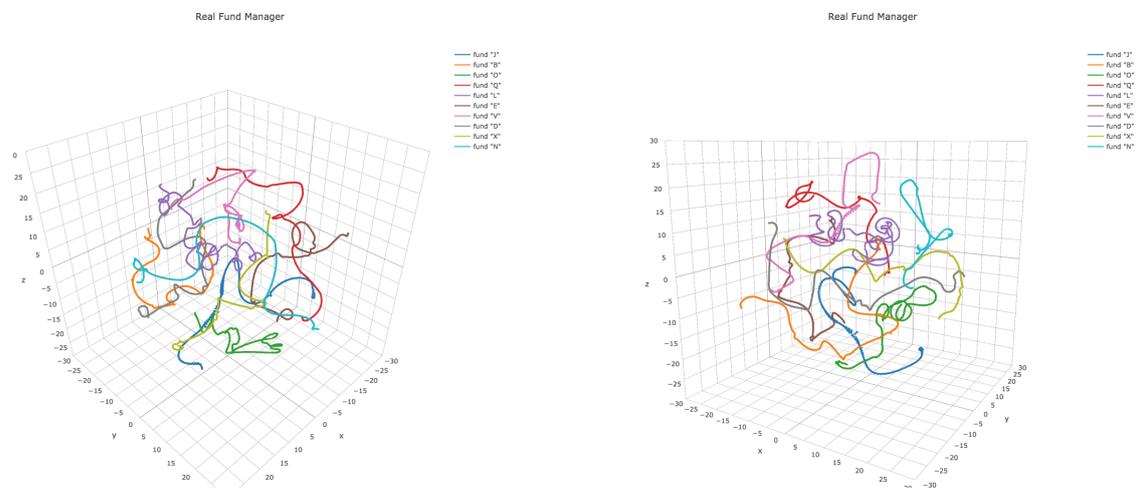


図 2.8: 実在ファンドの運用行動：次元圧縮による同時表示 (2015/01~2017/04)

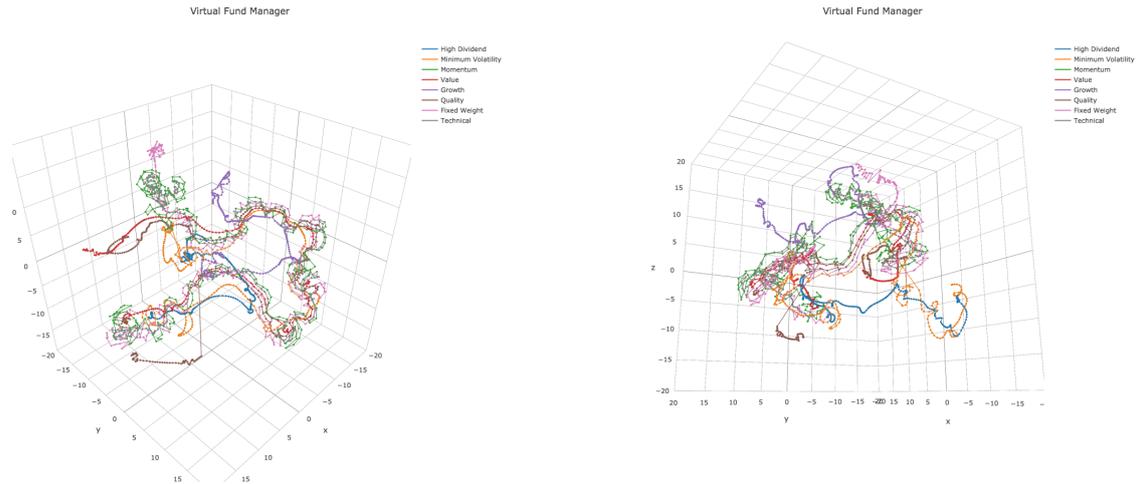
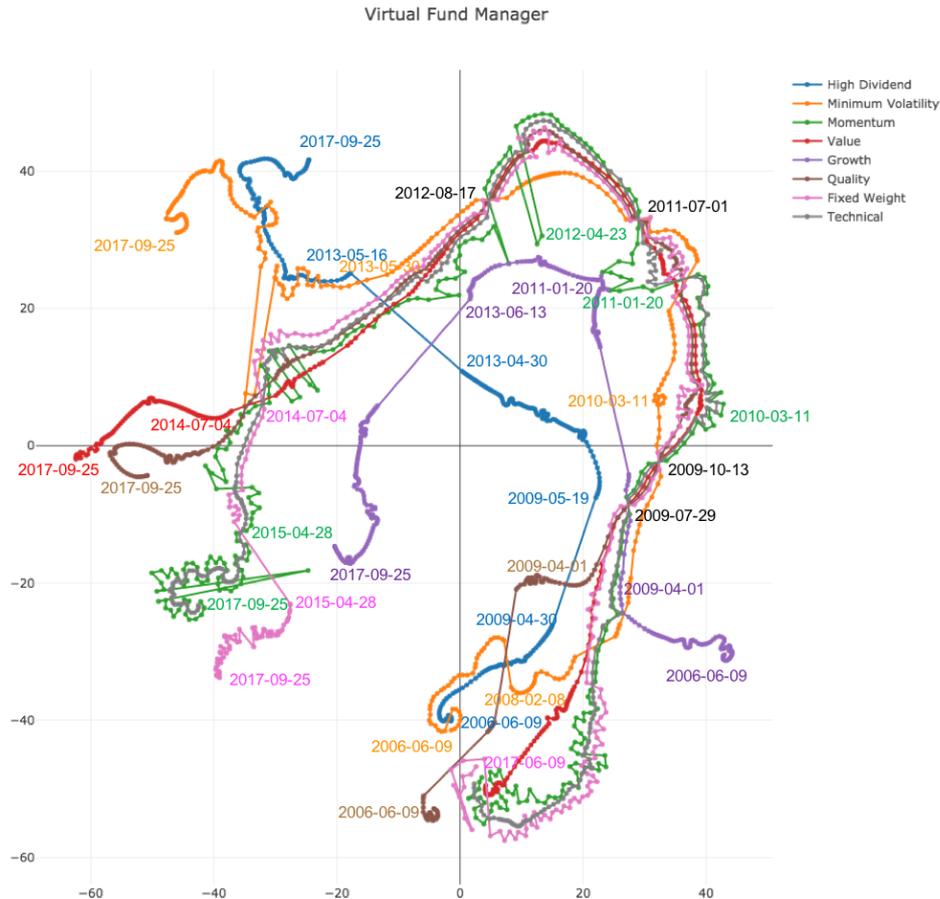


図 2.9: 仮想ファンドの運用行動：次元圧縮による同時表示（2006/06～2017/04）

図 2.8 は、実在の国内株ファンドの振る舞いを相空間上の軌跡として表したものである。これを見ると、運用スタイル変遷を表す軌跡の位置や形状がそれぞれのファンドごとに異なることなどが一望できる。

ところで、実在の国内株ファンドに関しては、今回の原理試作では 2015 年 1 月から 2017 年 4 月までという短期間のデータしか利用できなかった。マネジャー・ストラクチャーのロバスト性の評価などといった観点から言えば、本来であれば、例えば 2008 年に経験したサブプライムローンを契機としたリーマンショックなどの重要イベントを含む、より長期的な経済局面の変遷の中での分析を行いたい。そこで、実在の国内株ファンドの分析の代替として、仮想ファンド・マネジャーの生成した 2006 年 6 月から 2017 年 4 月までの仮想取引データを用いた分析も合わせて行なってみた。仮想ファンドの振る舞いを、3次元の相空間上での軌跡で表したものを図 2.9 に、同手法で 2 次元平面にまで次元圧縮したものを図 2.10 に示す。期間が限定されたデータを用いて得た図 2.8 では特筆すべき構造的な変化が見られなかったのに対して、今度は、時間経過にともなって軌跡が収斂したり、ほどけたりする様子などが見られた。例えば、2009 年 4 月から High Dividend と Growth 以外の 6 つの仮想ファンドの軌跡が収斂し、2013 年 5 月 30 日あたりで Minimum Volatility が離脱するまでほぼ重なるような軌跡を描いており、その後も 2014 年 7 月 4 日あたりまで残りの 5 つの仮想ファンドの軌跡はほぼ似通っている。Momentum、Fixed Weight、Technical の 3 つの仮想ファンドは 2015 年 4 月 28 日以降を除くほとんどの期間においてほぼ同一の軌跡を描いており、特に Momentum と Technical に関しては 2015 年 4 月 28 日以降も最後まで軌跡が重なっていること、High Dividend と Minimum Volatility は 2009 年 4 月 30 日あたりから 2013 年 5 月 16 日あたりまで途中ばらける期間があるが、それ以外の両端の期間では軌跡が重なる期間の多いことなども分かる。一方で、Growth の仮想ファンドだけは、2009 年 4 月 1 日あたりから 2009 年 7 月 29 日までを除いて、ほぼ全ての期間で他の仮想ファンドとも重ならない独自の軌跡を描いている。

相空間内での軌道が似通ったものになるのは、異なる指標やロジックを元に運用行動をするように設計された仮想ファンド・マネジャーであっても背景の経済局面によっては似通った振る舞いをすること、すなわちマネジャー・ストラクチャーの多様性が損なわれていることを意味している。純粋なロジックを盲目的に実行する仮想ファンド・マネジャーですら多様性の収斂が起こるということは、楽観や恐怖などの感情や恣意性の入り込む人手の介入のある実在のファンド・マネジャーにおいては、その傾向はさらに顕著に現れることが予想される。これを不可避なものとして受け入れるのか、いかなる状況でも多様性を維持することを目指すのかは、意思決定の範疇の問題であるが、多様性の維持を重要視するのであれば運用

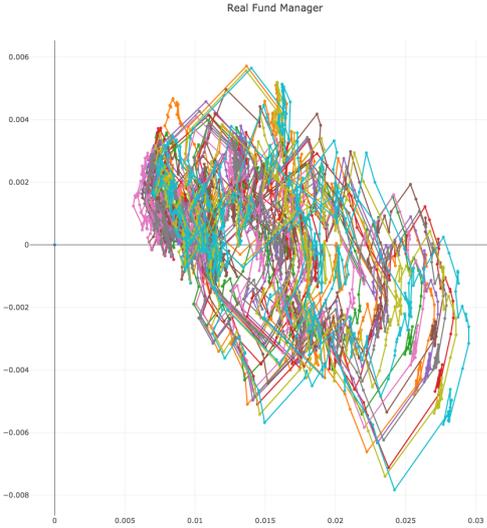


スタイルの異なるファンド・マネジャーを揃えるだけでは不十分で、別の工夫や施策が必要であることを示唆している。

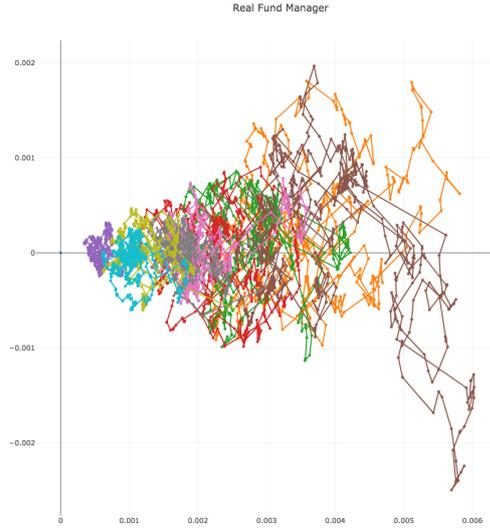
2.4 リスク・リターン分析

ここでは、比較のための参考として、これまで分析の対象としてきた国内株ファンドに対して、伝統的なリスク・リターンの分析を試みる。リターンは対前日比の日次収益率を20日分の移動平均を取ったものとし、リスクは同じく20日分の日次収益率の標準偏差とした。横軸にリスク、縦軸にリターンを取って両者の相関を示したものが図 2.11、2.12 である。それぞれの図において、左側 (a) に絶対リターンとリスクの相関を、右側 (b) に対ベンチマークの相対リターンとリスクの相関を示した。

図 2.11 は 2015 年 1 月 26 日から 2017 年 4 月 6 日まで、利用可能なデータの期間全てを用いて作図したものであり、図 2.12 は市場が大きく動いた 2015 年 5 月 1 日から 2015 年 10 月 1 日までの期間のデータのみを抽出して作図したものである。後者は、2015 年の 6 月と 8 月のチャイナショックを含む期間を選んだ。この期間では、2015 年 6 月 12 日に上海総合指数がリーマンショック後の高値をつけた後にピークアウトしその後の 3 週間で 3 割下落、2015 年 8 月 11 日に中華人民銀行が人民元相場の 20 年ぶりの大幅切り下げに踏み切ったことにより、為替相場のみならず世界中の株式相場も大混乱に陥り急落、その後 8 月 18 日に上海株が再び急落したことをきっかけに 8 月 26 日まで世界中に株安が連鎖した。

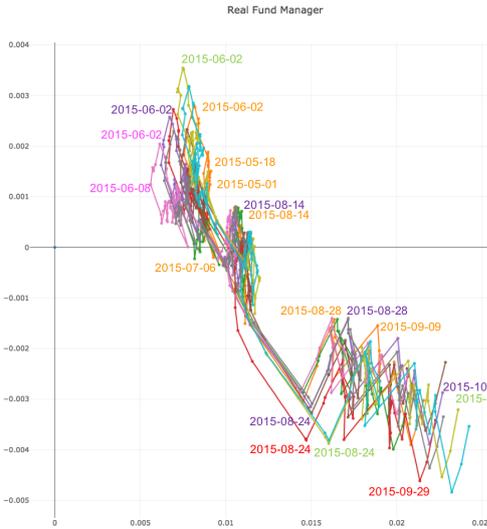


(a) 絶対リターンおよびリスク

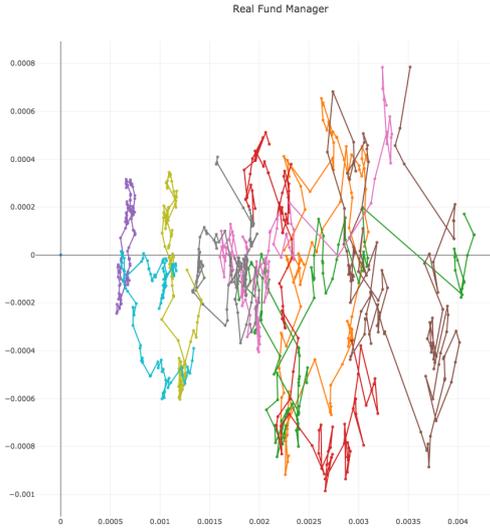


(b) 対ベンチマークの相対リターンおよびリスク

図 2.11: Risk-Return 相関図 (2015/01/26~2017/04/06)



(a) 絶対リターンおよびリスク



(b) 対ベンチマークの相対リターンおよびリスク

図 2.12: Risk-Return 相関図 (2015/05/01~2015/10/01)

これらの図から共通して言えるのは、絶対リターンとリスクとの相関を見たとき（各図の左側）には個々のファンドの違いがはっきりと現れないことである。特に市場が大きな変動があった時のみを取り出した図 2.12a を見ると、全てのファンドがほぼ同調して動いていることが分かりやすく示されている。一方で、対ベンチマークの相対リターンで見ると（各図の右側）、それぞれのファンドの違いが多少現れてくる。L 社や N 社がそれぞれのベンチマークに対してリスクを抑えた運用スタイルを採っているのに対して、これらに比べて E 社や B 社はより高いリスクまで許容する運用スタイルを採っている。このように対ベンチマークで見た時には各ファンドの運用スタイルには多様性があるとみなすことは出来るもの

の、絶対リターンで見た時には各ファンドの動きにはあまり大きな違いは見られない。

2.5 Style Detector Array の提供する価値

ここで、我々の開発した Style Detector Array によるファンド・マネジャーの分析システムがもたらす本質的な価値についてを整理すると以下のとおりとなる。

運用行動ベースのダイレクトな分析

従来からの Barra モデルや Aladdin などのように、収益率の変動を複数のファクターと各ファクターに対する感応度を見るのではなく、ファンド・マネジャーの運用行動をダイレクトに分析対象とすることで、スタイルドリフトの検知を、よりダイレクトに、より早く行えるようになった。また、申告内容と実際の行動との整合性評価を行うにあたり、従来はヒアリングのみに頼っていたものを定量的な分析をもとにエビデンス・ベースで行うことができるようになった。これは、GPIF 側の担当者のファンド・マネジャーに対する対話力が大幅に向上することに繋がる。

分析のテイラーメイド化

Style Detector Array を訓練するのに必要な、レファレンスとして設定する運用スタイルは、今回の原理試作で用いた 8 つに限定する必要はなく、数を増減させてもよいし、全く別の運用スタイルをレファレンスとして設定して置き換えても構わない。また、レファレンスとして設定するのは必ずしも仮想ファンド・マネジャーによる純粋な運用スタイルである必要もなく、実在するリアルなファンド・マネジャーの行動をデータとして用いることも可能である。従来のツールのように、あらかじめ内包された尺度に束縛される必要はなく、目的や用途に応じて分析内容を柔軟にカスタマイズ可能となる。

訓練フェーズと利用フェーズの分離

豊富な計算資源を要求する訓練フェーズにおいては外部のクラウドサービスなどを利用せざるを得ないケースも想定されるが、Style Detector Array の訓練にあたっては、必ずしも秘匿性の高いデータを使う必要はないため、情報セキュリティの面での懸念が生じない。一方、訓練後の Style Detector Array を適用して分析に用いる際には、担当者の手元にあるデスクトップあるいはノート型 PC 程度のもので十分実行可能である。これにより、高度な計算資源（外部のクラウドサービスなど）への依存と情報セキュリティへの配慮とを両立した分析システムの運用が可能となる。

AI ファンドの評価

AI 運用ファンドなど、従来の手法では評価をすることが難しい新しいタイプのファンドが登場し始めている。特に、深層学習は中身がブラックボックスのため、その挙動を人間が理解可能な表現で説明することが難しい。これらのファンドについても Style Detector Array を用いることでスタイル分析が可能となる。中身がブラックボックスとは言え、人手による恣意性が排除された運用ロジックとなるため、Style Detector Array による分析にあたっては、むしろ、従来型のファンドよりも適合する可能性がある。

第3章

運用会社のビジネスモデルへの影響

3.1 AI 資産運用システム導入によるビジネスモデルへの影響

AI の資産運用への応用には多様なアプローチが可能であり、全てを網羅することは困難であるが、その中で、典型的なアプローチとなる、市場データや経営指標などのデータを基盤とした AI 運用システムが導入される場合を考える。このような AI システムが導入される場合、機械学習により市場データから株価や株価変動の方向とその度合いを予測する、または、人手では到底不可能な市場全体を網羅するレベルで投資対象が何らかの理由で本来の価格から乖離していることを検出するなどいくつかのアプローチがあり得る。ここで、重要なのは、AI システムを利用した場合、広範な投資対象に対して、網羅的に予測や検出が可能になることである。そして、このようなシステムが、多数導入された場合を考える。その場合、価格の乖離は、複数のシステムで検知される可能性が高まり、短時間でこうした乖離は解消される可能性がある。一方で、AI システムの特性は学習データなどで決定されることに加え、そもそも独立に開発された AI システムが全て同じような検出や価格変動予測を行うことになるわけではない。この場合、一部の AI システムの挙動が、乖離を作り出す可能性も大きい。このとき、この乖離が短期間で解決されるのかは、明確ではなくなる。仮に乖離を検出したとしても、その成因が、自然に発生したものなのか、他の AI システムの影響によるものかは、判定が困難である。同時に、AI システムは、このような市場の特性を反映したデータからの学習を進めることになり、時間の経過と共に、戦略的に収束していくことが想定される。この場合、市場を介した N-Player Game でのナッシュ均衡に到達する可能性がある。これが、意味することは、市場データや経営指標などのデータに依存した場合、深層学習などの統計的機械学習に基盤を置く AI 運用システムは、漸近的に INDEX 運用に接近する可能性が大きいということである。もちろん、Two Sigma などに見られるように、市場情報のみならず、衛星画像なども含めた広範なデータから企業業績を迅速に予測しようとする手法もあり、全ての AI 運用システムが、同じようなアプローチを取るわけではない。これらは、オルタナティブとして別の枠組みで扱う必要がある。しかしながら、多くの AI システムは、市場データや企業データとその周辺情報を基盤に構築されると想定され、その場合に、ここで議論したシナリオになる可能性が高い。この場合、対象市場の INDEX をベンチマークとした超過収益を生み出す AI システム投資と運用報酬体系のバランスが、ビジネスモデルを決定する。効率的に超過収益を生み出すシステムの開発維持に失敗したファンドは、市場から退場するか、INDEX 運用に回帰すると思われる。

3.2 GPIF の AI システム導入が与える影響

次に、本調査研究で原理試作した AI システムを、GPIF が本格導入した場合の影響を議論する。この場合、GPIF 自体には、マネジャー・セレクションと運用モニタリングの二つの局面で大きな変化がもたらされると考えられる。マネジャー・セレクションでは、GPIF は、候補となるファンド・マネジャーから事前に運用データを入手することで、その運用スタイルに関する詳細な分析が可能となる。これによって、プレゼンテーションなどでの対話がより精密かつデータに裏付けられたものとなり、より有効性の高いマネジャー・セレクションのプロセスが確立されると考えられる。また、GPIF は、既に運用委託をしているファンド・マネジャーの運用スタイルの分析も行っているため、委託先全体を俯瞰して、次に必要な運用スタイルを有するファンド・マネジャーを選択することが可能となる。また、運用モニタリングでは、各々のファンド・マネジャーの運用実態の分析が可能となり、スタイルの変化に対して迅速に対話することで、相互の意思疎通が効率的かつ明確になると思われる。

委託先のファンド・マネジャーは、GPIF が委託先の運用スタイルなどの詳細な分析をリアルタイムで行う能力があると認識することとなる。特に、GPIF は、全ての運用先の解析が可能となり、全体を俯瞰する眺望を有する立場となる。また、個々のファンド・マネジャーのスタイル・ドリフトは、自動的に検知される。これにより、ファンド・マネジャーに対して一定の規律を与える方向での作用が発生すると思われる。一方で、市場環境の変化に対応した一定のスタイルの変化は、効果的な運用を実現するために必須であるとするならば、そのスタイルの変化を許容すると同時に、その適切性に関して、迅速かつ建設的なコミュニケーションを図るべきであろう。また、全ての局面で、超過収益を生み出す運用は実現困難であり、これは AI 運用システムにおいても同じであろう。つまり、超過収益を生み出さず、INDEX に対してアンダー・パフォーマンスする事態は今後も発生する。

このような事態に対して、ファンド・マネジャーは、適切な説明を行う必要が生ずる。運用会社は、GPIF が運用会社自身の運用スタイルを独自に解析する能力を有するとともにさらに先進的な技術開発を推進する意図を認識することで、定性的な説明や簡略化された数値のみでその結果を正当化することが出来ないことを理解するであろう。その結果、運用会社も同等のデータ解析並びに AI システムの導入により、運用のモニタリングや運用効率の改善に着手するであろう。これは現在、進んでいる AI 支援運用を加速すると思われる。同時に、これは、運用戦略の属人性を排除し、最適化を推進する。また、それにかかる費用は、属人性が薄れる結果、透明性が高くなる。これらの一連の展開は、資産運用のサイエンスとテクノロジーをより推進させることとなる。

また、GPIF は広範な運用会社のデータを入手できる数少ない基金であり、そのデータの統合的解析をさらに進めることで、限定的データにアクセスが限られる個別運用会社に対して、より詳細かつ大局的な理解をすることが可能になる。さらに中長期的には、GPIF は、現在、運用委託先から得ている運用データをデータ解析と最先端の機械学習を含めた AI 手法に応用することを前提にデータ供給を受けることとなる。これによって、多様な運用戦略を網羅した巨大な高精度データベースとそれを利用した高度な運用解析システムを構築することが可能となる。これは、より高度なマネジャー・セレクション・システムの構築に利用できる。さらに、ここで議論した委託運用先での運用プロセスの革新が進めば、GPIF のデータベースからの分析結果を委託先と共有することで、より効率的かつロバストな運用が実現され得る。

第4章

今後の発展

本研究では、GPIFの中核業務の一つであるマネジャー管理のプロセスへの導入を想定したAIシステムの原理試作を行ってきたが、これを踏まえて、今後の発展としてどのようなことが考えられるかについて以下に述べる。目的や優先度に応じて、取り組む項目の選択あるいは取り組む順序などを検討するとよいだろう。

4.1 連続的発展：これまでの拡張

まず一つは、量的な拡大、モデルの精緻化、異なる分析対象への展開など、これまでに開発した原理試作の枠組みをそのまま流用しつつ連続的な発展を追突するという方向性が考えられる。

フル・ユニバース化

今回の原理試作の開発においては、計算時間を抑えて試行錯誤の回数を多く重ねるために、本来は3,600銘柄程度ある国内の上場株式から、産業セクターにバリエーションを持たせつつも時価総額の大きいものを中心に100銘柄のみを選び出して想定した限定ユニバースの上で様々な分析を行なった。現場での実運用を目指すにあたっては、規模を拡大して上場株式の全てを含むフル・ユニバースで Style Detector Array を構築するのが最も素直な発展形態であろう。これにより今回は十分な分析が行えたとは言えない中小型株をメインに扱うファンドについても対象範囲内に含めることができる。

仮想ファンド・マネジャーの精緻化

今回の原理試作で我々が定義した8つの運用スタイルの仮想ファンド・マネジャーの運用ロジックは極めて単純なものになっており、必ずしも洗練されてはいない。本研究ではフレームワークの動作検証を主たる目的としていたため、それでも用途を十分に果たしたが、実運用にあたっては、より現場感に即した精緻化したロジックに置き換えていく必要があるだろう。

異なるアセットクラスへの展開

本調査研究では、データの入手およびその後の整形作業が容易であるという理由により国内株ファンドを対象に、原理試作を行なったが、これを、国内株以外の伝統資産を構成する他の資産クラスである外国株、国内債券、外国債券に展開するという発展形態もある。この際に、外国の資産クラスの場合には社会

の安定性なども含めた地域性の違いや為替の調整、債券の場合には償還期間や利率、発行主体の信用性（格付け情報）など、それぞれの資産クラスに特有の事柄を考慮に入れる必要があり、それに基づいて、データの整形などの準備作業や仮想ファンド・マネジャーのロジックの実装を行う必要は生じる。こうした資産クラスに応じた個別の作業は新たに発生するものの、本研究での原理試作の全体の枠組みはそのまま流用可能である。

4.2 非連続的發展：過去の分析から将来のシミュレーションへ

前節で述べた連続的な發展とは異なり、これまでの開発により得られた知見は活用しつつも、質的に異なる方向への發展を目指す方向性もある。

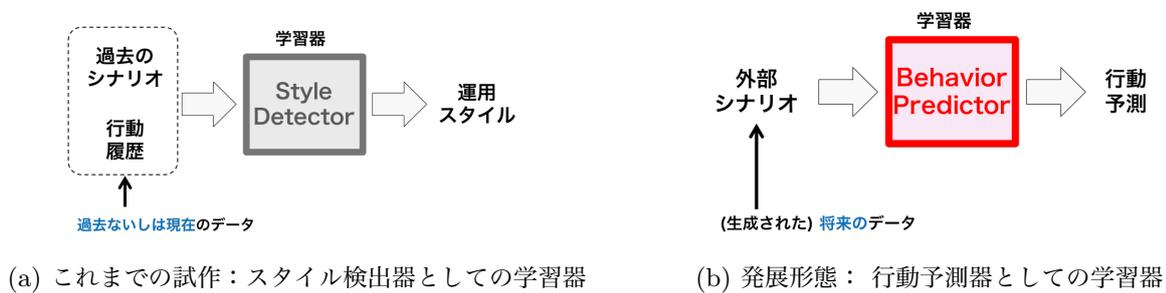


図 4.1: 過去の分析から将来の予測へ

その一つは、ファンド・マネジャーの運用行動自体をモデル化して予測に用いるという野心的な試みである。これまでの原理試作では、図 4.1a にあるようにファンド・マネジャーの行動履歴をベースに運用スタイルを同定するという用途で学習器を設計し利用してきた。こうした過去の分析にとどまらず、図 4.1b に示したように、市場環境などの想定した外部シナリオが与えられたときに対象となるファンド・マネジャーが取るであろう運用行動自体を出力するという、将来の予測装置として学習器を利用する方向の發展も追究していきたい。

これまでのファンドのリスク・リターンの評価は、基本的にはヒストリカルデータの上でのバックテストが中心に行われるものであったし、ストレステストにしても現時点で保有するポートフォリオの内容が与えられたシナリオ下でどのように毀損するかを機械的に計算して評価するレベルにとどまっている。ところが、ファンド・マネジャーの行動予測のモデルが得られると、これに任意のシナリオ下を与えることで対象のファンドの運用行動、ひいてはそのパフォーマンスやリスク特性をシミュレーションによって予測評価することができるようになる。これにより、これまでのように過去の実績に頼るのではなく、真の意味でフォワードルッキングなリスク・リターンの評価やストレステストを行うことができ、よりロバスタなマネジャー・ストラクチャーの組成を構築することに繋がると考えている。

なお、この方向性での發展を目指すには、ファンド・マネジャーの行動のモデル化に加えて、シミュレーションによる予測の前提となるマーケットなどの外部環境の仮想シナリオの生成の方法論についても合わせて考えていくことも有用である。

4.3 提言: GPIF 内での人材について

本調査研究での分析プロセスでの分担は次の通りであった。

- GPIF: 課題の整理、GPIF 固有なデータの取得・提供
- CSL: 課題から要求仕様の定義、市場データの収集、データの整形および前処理、分析システムの構築

深層学習による運用スタイル評価器の作成および改良の分析システムの構築は CSL が担当したが、このコアとなる分析システムの実装を外部委託にて構築することとなると、GPIF 内にノウハウや知見の蓄積がなされにくいと考えられる。また、分析プロセスではアウトプットが一度で想定した形で出てくるとはならないため、データのインプット自体の見直し等の上流工程からの再考察によるトライアンドエラーによる実行を進めていく必要がある。したがって、今後 GPIF が本調査研究を元に発展的課題に対応していくためには、GPIF 内部にて次のような人材確保および体制を整えていくことが必要と考えられる。

- **人材育成:** 今後の委託先（または共同研究先）の現場に人材を派遣し、そのノウハウを習得する。具体的には次が実行（少なくとも指示）できるようになることが望ましい。これらは本調査研究対象の内容だけでなく、今後の GPIF 内部でのデータ分析全般に貢献すると考えられる。
 - － 探索的データ解析 (EDA: Exploratory Data Analysis) とモデル構築の仮説検証を繰り返すというプロセスを習得すること。
 - － Python, R 等のデータ分析に用いるプログラミング言語（および SQL 文）を適材適所で使用できるようになること。
 - － 抱える問題を解決する適切なアルゴリズムを選択できるようになること。
 - － 論文を読みそのアルゴリズムを特定のプログラミング言語で実装し、現状のアルゴリズムと比較考察できるようになること。
- **開発環境・データインフラ整備:**
 - － データを貯めるためだけでなく活用するための適切なデータベースの選択（オンプレミス・クラウド含む）とデータ構造・データフォーマットの選択できること。
 - － データサイズに応じた適切なデータ分析ツール・ライブラリ（特に off-memory 操作）が選択できること（OS の選定も含む）。
 - － Git^{*1}等のバージョン管理の導入および Git ホスティングサービス (Github/Bitbucket/Gitlab) によるソースコードレビュー体制を導入すること。

これらの人材および分析環境を元に、データドリブンな仮説検証と意思決定のサイクル、およびそれらの分析へのフィードバックを内製化し、業務の PDCA を精緻にかつ高速に実行していく体制を構築することが次の課題と考えられる。

^{*1} プログラムのソースコードなどの変更履歴を記録・追跡するための分散型バージョン管理システム。リモートサーバ等にある中心リポジトリの完全なコピーを手元（ローカル環境）に作成して、そのローカルリポジトリを使って作業を行う。複数の開発者による並行同時作業を行うことによって生じる整合性の競合を視認し容易に解消することなど、大規模なソフトウェア開発に不可欠な機能が備わっている。

第5章

まとめ

「AIの年金積立金の長期運用への活用可能性」については、GPIFの中核業務の一つである「マネジャー・ストラクチャー」に着目し、ここにAIを導入することが最もインパクトの大きな貢献をなし得ると考えた。その仮説の下、現在のAIブームを支える重要な技術である深層学習を活用して、ファンド・マネジャーの行動分析を行う Style Detector Array の原理試作を行なった。仮想マネジャーによって生成された訓練用データを用いて学習させた Style Detector Array に、いくつかの実在の国内株ファンドの行動を入力として与えて分析を試みたところ、ファンドごとに運用スタイルの特徴の違いがあることや、同じファンドでも時間の経過とともにその特徴が変化することなどが分かった。また、特徴が大きく変化した点が、実際のファンドの運営においてマネジャーの組成に変更を加えた時期に一致するなど、スタイルドリフトの有効な検知が行えることなどが分かった。

複数ファンドの振る舞いを次元圧縮により一つの相空間図上の軌跡として同時に可視化する試みにおいては、時間経過に伴って複数の軌跡が収斂したり、ほどけたりする構造の時間的な変化が見られた。相空間内での軌跡が似通ったものになるのは、異なる運用スタイルを採るように設計されたファンドであっても背景の経済局面によっては似通った振る舞いをする、すなわちマネジャー・ストラクチャーの多様性が損なわれていることを意味する。つまり、多様性の維持を至上命題とするのであれば運用スタイルの異なるファンドを揃えるだけでは不十分で、別の工夫や施策が必要であることを示唆している。

今回、我々が原理試作を行なった Style Detector Array は、運用行動をダイレクトに分析することによって、エビデンス・ベースでかつリアルタイムな運用スタイルの分析を可能にした。これにより、GPIFは、より精度の高い評価・選定手法を手に入れることになり、AIによるロバストなマネジャー・ストラクチャーの組成方法に向けての道筋をつけることが出来た。

「AIが運用会社のビジネスモデルへ与える影響」に関しては、AIが運用会社に広く普及することによって、資産運用の環境が市場を介した N-Player Game におけるナッシュ均衡に到達する可能性があり、これにより、深層学習を始めとした統計的学習に基盤を置く AI 運用システムは漸近的に INDEX 運用に接近する可能性があることを述べた。この場合、対象市場の INDEX をベンチマークとした超過収益を生み出す AI システム投資と運用報酬体系のバランスが、ビジネスモデルを決定することとなり、効率的に超過収益を生み出すシステムの開発維持に失敗したファンドは、市場から退場するか、INDEX 運用に回帰する可能性を示唆した。また、GPIF が本調査研究において原理試作を行なったシステムを本格導入した場合には、GPIF が各運用会社の運用スタイルを独自に解析する能力を有し、さらに先進的な技術開発を推進する意図を運用会社は認識することになる。このことが結果的には運用会社のパフォーマンスに対する説明や報酬（費用）の透明性を高め、その一連の展開が資産運用のサイエンスとテクノロジーをより推進することを論じた。

参考文献

- [1] 年金積立金管理運用独立行政法人 (GPIF) . 平成 28 年度 業務概況書, 2016.
- [2] 年金積立金管理運用独立行政法人 (GPIF) 第 3 回 経営委員会議事概要. http://www.gpif.go.jp/operation/management/pdf/keieiiinkai_306.pdf.
- [3] 年金積立金管理運用独立行政法人 (GPIF) 第 4 回 経営委員会議事概要. http://www.gpif.go.jp/operation/management/pdf/keieiiinkai_405.pdf.
- [4] Paul Rosa David Weisberger. Automated equity trading: The evolution of market structure and its effect on volatility and liquidity. Technical report, Two Sigma Securities, 2013.
- [5] Top page of Two Sigma. <https://www.twosigma.com>.
- [6] Michael Markov. The law of large numbers: An analysis of the renaissance fund. Technical report, Markov Processes International, September 2007.
- [7] Top page of Renaissance Technologies. <https://www.rentec.com/>.
- [8] Mathieu Lemay Mary Kate MacPherson Miodrag Bolic Samer Obeidat, Daniel Shapiro. Adaptive portfolio asset allocation optimization with deep learning. *International Journal on Advances in Intelligent Systems*, Vol. 11, No. 1&2, pp. 25–34, 2018.
- [9] Samer Obeidat. Five ways artificial intelligence is disrupting asset management. <https://www.entrepreneur.com/article/312672>, April 2015.
- [10] Top page of Investifai. <https://www.investifai.com>.
- [11] Martín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Ian Goodfellow, Andrew Harp, Geoffrey Irving, Michael Isard, Yangqing Jia, Rafal Jozefowicz, Lukasz Kaiser, Manjunath Kudlur, Josh Levenberg, Dandelion Mané, Rajat Monga, Sherry Moore, Derek Murray, Chris Olah, Mike Schuster, Jonathon Shlens, Benoit Steiner, Ilya Sutskever, Kunal Talwar, Paul Tucker, Vincent Vanhoucke, Vijay Vasudevan, Fernanda Viégas, Oriol Vinyals, Pete Warden, Martin Wattenberg, Martin Wicke, Yuan Yu, and Xiaoqiang Zheng. TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. Software available from tensorflow.org.
- [12] François Chollet, et al. Keras. <https://keras.io>, 2015.
- [13] John D. Hunter. Matplotlib: A 2d graphics environment. *Computing in Science and Engineering*, Vol. 9, No. 3, pp. 90–95, 2007.
- [14] Plotly Technologies Inc. Collaborative data science, 2015.
- [15] Eric Jones, Travis Oliphant, Pearu Peterson, et al. SciPy: Open source scientific tools for Python, 2001–. [Online; accessed {today}].

- [16] Travis E. Oliphant. *Guide to NumPy*. Trelgol, 2006.
- [17] Wes Mckinney. pandas: a foundational python library for data analysis and statistics. 01 2011.
- [18] Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, Peter Prettenhofer, Ron Weiss, Vincent Dubourg, et al. Scikit-learn: Machine learning in python. *Journal of Machine Learning Research*, Vol. 12, No. Oct, pp. 2825–2830, 2011.
- [19] Fernando Pérez and Brian E. Granger. IPython: a system for interactive scientific computing. *Computing in Science and Engineering*, Vol. 9, No. 3, pp. 21–29, May 2007.
- [20] R Core Team. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2014.
- [21] Yi Shang and Benjamin W. Wah. Global optimization for neural network training. *IEEE Computer*, Vol. 29, No. 3, pp. 45–54, 1996.
- [22] M. S. Iyer and R. R. Rhinehart. A method to determine the required number of neural-network training repetitions. *IEEE Trans. Neural Networks*, Vol. 10, No. 2, pp. 427–432, 1999.
- [23] Akarachai Atakulreka and Daricha Sutivong. Avoiding local minima in feedforward neural networks by simultaneous learning. In Mehmet A. Orgun and John Thornton, editors, *Australian Conference on Artificial Intelligence*, Vol. 4830 of *Lecture Notes in Computer Science*, pp. 100–109. Springer, 2007.
- [24] Laurens van der Maaten and Geoffrey Hinton. Visualizing data using t-SNE. *Journal of Machine Learning Research*, Vol. 9, pp. 2579–2605, 2008.

著作：

年金積立金管理運用独立行政法人

〒105-6377

東京都港区虎ノ門 1-23-1 虎ノ門ヒルズ森タワー 7階

Tel: 03-3502-2480

制作：

佐々木 貴宏

小泉 洋夫

田尻 貴夫

北野 宏明

株式会社ソニーコンピュータサイエンス研究所

〒144-0022

東京都品川区東五反田 3-14-13 高輪ミュージズビル 3F

Tel: 03-5448-4380