



人工知能 (AI) による
ファンド行動学習についての委託研究業務
中間報告書

株式会社ソニーコンピュータサイエンス研究所

2019 年 12 月

ExecutiveSummary

1 2017 年度調査研究の振り返りおよび 2018-2019 年度研究の方向性

2018 年 10 月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 (AI) によるファンド行動学習についての委託研究業務」についての中間報告を行う。

本委託研究業務に先立つ 2017 年度の調査研究において、深層学習を活用した「運用スタイル分析器 (StyleDetectorArray、以下 SDA)」の原理試作を行っており [1]、その成果は国内外のアセットオーナー等から認知されることとなり海外メディアからの受賞にも結びついた。その成果を踏まえ、今期は SDA を応用発展させた “Resembler” の開発を行っている。これは運用会社の「特徴や独自性」(クセ) といった定性的な情報を定量化するもので、GPIF の問題意識にある「定性評価に対する恣意性や主観性」や「定性評価は属人的プロセスに依存」の解決に寄与するものである。

	2017 年度	2018 年 10 月～2020 年 3 月
対象アセット	スモールユニバース (国内株 100 銘柄)	ラージユニバース (国内株および外国株 1,000 銘柄)
検知する内容	典型的なファクターベースの投資スタイル	運用会社の「クセ」
開発内容	スタイル検知可能性を検証するための原理試作	試験活用に対応する新規モデルやシステムの各種刷新

本報告書は 2018 年 10 月から 2019 年 10 月末時点の途中成果であり、仕掛途上のものを多く含む。全期間通じた成果は 2020 年に最終報告書として別途発表を予定している。

2 方法論:投資運用行動データからファンドの特性を探る

SDA および Resembler は、深層学習技術をコアとしたファンドの特性分類・検出システムである。その仕組みと動作は同一であるが、SDA が仮想ファンドマネジャーのシミュレーションによって得た仮想取引データを訓練に用いるのに対して、Resembler は実在のファンド・マネジャーの取引データを使うという点が異なる。その結果、前者が検知の対象とするのはファクター・エクスポージャーで定義される「投資スタイル」といった客観的な指標であるのに対して、後者は「ファンドらしさ」といった相対的な指標となる。

本年度は特に SDA の発展形としての Resembler に関する研究とその応用開発を進めてきた。過去の自分自身の「特徴や独自性」との比較である self-resemblance や、複数ファンド間の類似度

である mutual-resemblance の評価への応用を目指し、現場での試験活用を交えながら発展させている。

一方、SDA に関しては、2017 年度にプロトタイプを開発済みであるが、検知対象とするファクターの再検討とともに、銘柄ユニバースのラージスケール化やラウンドロビンサンプリングを用いた銘柄選定による情報量の拡大と、訓練用のデータを生成する VFM の取引ロジックの洗練化を施すことで SDA の精緻化を図っている。

なお、今年度より国立研究開発法人産業技術総合研究所が運用している AI 橋渡しクラウド (AI Bridging Cloud Infrastructure、以下 ABCI) を利用している [2, 3]。多数の GPU をクラスターで結合した計算プラットフォームである ABCI は、膨大な計算量を必要とする SDA や Resembling の深層学習ネットワークに特に適合した環境を提供する。コストパフォーマンスに優れた ABCI の利用により、2017 年度に比して大幅な研究開発の効率化を図ることができた。今後もますます活用していく予定である。

SDA や Resembling といったコア技術の開発だけでなく、分析をより深化させるのに有用な手法の一つとして自己組織化マップ (Self Organizing Map、以下 SOM) によるファンド特性の可視化にも取り組んでいる。これを用いることで、あるファンドの銘柄保有の傾向の時間的な変化を追ったり、ファンドの実力評価へと繋げる応用の可能性を探っている。

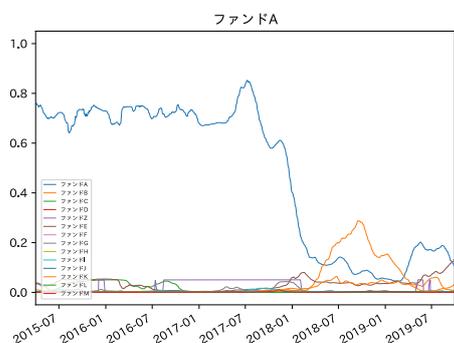
3 GPIF 現場における試験活用結果

GPIF が委託する全ての国内株および外国株アクティブ運用ファンドを対象に SDA および Resembling の試験活用を行った。そのうち、本中間報告書では我々が着目した 4 つを事例 1~4 として取り上げて論じている。(以下ではさらに抄録として 2 つを簡単に紹介する。)

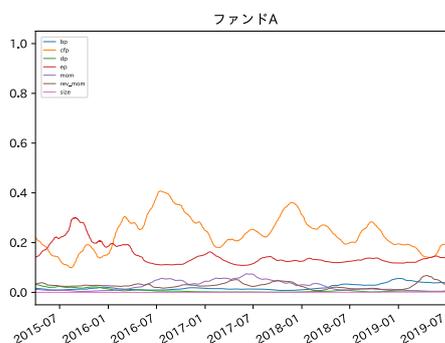
事例 1 においては、観測期間中に Resembling の自社成分の値が一度大きく減少してしばらく低位で安定するとともに他社成分がやや増加し、その後再び自社成分が値を戻すという、SDA 上では見られなかった変化を検知した。その要因としては、銘柄保有の傾向や回転率などの売買行動の変更といった複合的な要因が挙げられ、主にパフォーマンスの面での改善が図られるタイミングで見られるものと考えられる。GPIF は、モデル変更予定また集中度合変更等に関して、委託先のファンドより個別の事柄として都度レポートを受けている。しかし、GPIF と委託先の間でのコミュニケーションは多岐にわたり、論点も多く存在し、個々の各論を断片的に把握認識することはできても、事象を連続した流れとして捕捉することが困難であることは実務上起こり得る。Resembling はこうした大きな流れを適切に捉えて新たな仮説立てを可能とし、これに論点を絞った上でパフォーマンス改善に向けた協議を支援し得る。また、従来はファンドの変化が担当者の違和感として感覚的にしか捉えられなかったような場合でも、Resembling の出力によりその変化を定量的に記録する実務的な改善手段を提供し得る。

つぎに、事例 4 においては、Resembling では様々な他社成分を一定程度に、かつ変化を伴いながら検知しており、当該ファンドが様々な運用戦略を状況にあわせて臨機応変に変更する手法をとるファンドであることが捉えられている。この場合には「固着した自分らしさの無さ」が「自分ら

しき」を表しており、これはこれで一つの運用哲学と言える。逆にこの種のファンドで、長期にわたって固着した自分らしさが持続して柔軟性が失われた場合や、柔軟性が維持されていてもこれが市場環境変化に対し後手に回り始めた場合は、より詳細な確認をすべきであろう。

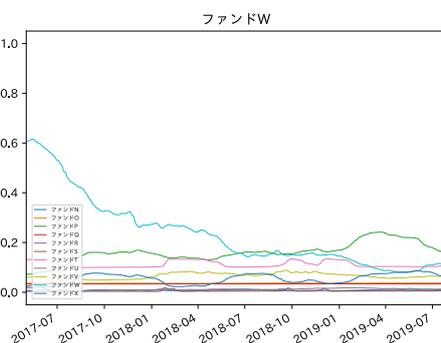


(a) Resembler によるファンド A の出力



(b) SDA によるファンド A の出力

事例 1



事例 4: Resembler によるファンド W の出力

試験活用の中間総括

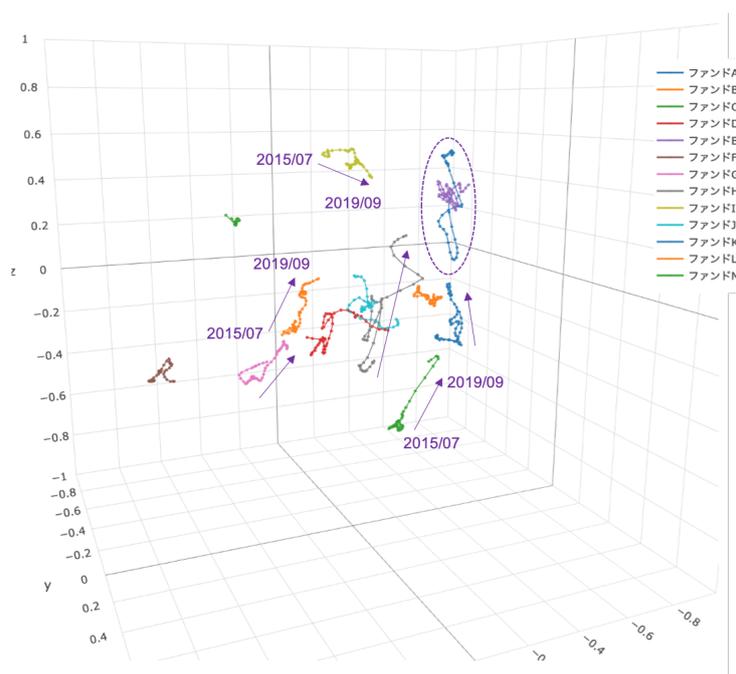
AI を現場で活用するにあたり、1)AI(Resembler および SDA) 検知、2) 検知された変化に対する要因解析、3) 現場で即活用可能なコンテンツへの落とし込み、の3つのステップが期待されていることが分かった。特に2) に関しては、処理を途切れさせることなく迅速に対処するための体系的な仕組みが必要となり、例えば、トピック分析ないし VAE 等のアイデアの適用を引き続き模索する。3) に関しては、委託先との円滑かつ効率的な協議を可能にすべく、変化の要点を人間が理解できるテキストの形で出力する既存の情報システムとのインテグレーションの方策を試験活用継

続する中で整理していく。

4 実験的取り組み

Resembler や SDA の開発と並行して、いくつかの実験的な試みも進めている。

その一つとして、Resembler を応用して、複数のファンド間の「特徴や独自性」(クセ)の類似度である mutual-resemblance を算定し、その時系列変化を相空間上で視覚的に表現する手法について模索している。類似度マップ上で表現される各社の特徴が、当初は適度に分散していたのが、時間経過とともに図では右上部に位置する二つのファンドの方へと徐々に収斂しつつあることが分かった。2019年の市場環境が、リスク水準を抑えたより広範な銘柄への投資戦略を行う運用に有利に働く状況下にあるため、全体的にこれに寄ってくる傾向にあることが推察される。運用会社の「特徴や独自性」(クセ)という、従来のファクターベースの分散度検証とは異なる観点で、よりハイレベルかつ広範な要素を踏まえた分散・収斂度検証が可能となる。このような分析を行うには複数の異なるファンドを跨いだデータが必要であり、GPIFのような巨大なアセットオーナーとしての立場だからこそ実現できる応用発展事例である。



国内株ファンドの類似度マップ

もう一つの実験的な試みとして、アクティブ運用の「ウデ」の評価を定量的に行う手法についても研究開発を進めている。運用報告のときに、パフォーマンスが良好な場合には自身の實力によるものと誇示し、逆にパフォーマンスが悪い場合には市況など自身ではコントロールできない外部環境に原因を帰して偶然として説明する心理的なインセンティブが運用委託先には働く。そこで、

ファンドのあげたプラスリターンあるいはマイナスリターンのうち「ウデ」に帰す部分と「偶然」に帰す部分とに分けるシステムティックな方法があれば、個々の運用委託先の説明に引っ張られることなく共通の土俵で評価を行うことができる。こうした考えのもと、アクティブウェイトのパターンから意図した部分と意図しない部分に分けて、SOMを用いた可視化により、それぞれにおけるアクティブリターンの水準を相対比較する試みを行った。その結果、強く意図してアクティブウェイトを取った銘柄群において意図通りにアクティブリターンが取れているものもあれば逆に読みが外れてマイナスリターンになっているものがあったり、リスク管理上取らざるを得なかった意図せぬ領域で期せずしてアクティブリターンを得ているものがあったり、様々な状況を捉えることが可能であることが分かった。

5 AIにより真価を発揮する GPIF

GPIF 現場の変革

試験活用および実験的取り組みでは GPIF 担当官と実務レベルでの要件を密に詰めながら進めている。GPIF 担当官からは「モニタリング情報量のアップ」および「既存運用者評価の効率化」という具体的なベネフィットや、「予想ベースのモニタリング」、「新規選定の自動化」ないし「モデル運用者の複製」といった応用発展の期待についてフィードバックを得ており、AI への活用や期待のコンセンサスが醸成されつつある。

本研究開発が目指すのは、究極的には、定性評価の恣意性や属人的プロセスへの依存という課題に対する解決であり、具体的な応用としては、委託先レポートの検証、パフォーマンス改善行動実施度合確認、未報告内容の検知等が考えられる。これらは「委託先とのより建設的かつ効率的な対話の強化」ならびに「GPIF に蓄積される膨大かつ豊富なデータ活用によるスキルの平準化/コモディティ化」を行うための基盤となる。

「魅せるクジラ」

既存契約者は、アセットオーナーとの付き合いを通じたノウハウなどの関係性という財産に依存してきた。またアセットオーナーも、付き合いのある先なら新規先よりも信頼できると感じてしまう信頼バイアスに漬かっていた。しかし、今後の AI 実用化により既存委託先と新規が同等に評価され、既存委託先が築き上げてきた優位性はなくなり、ビジネスモデル変革につながる可能性がある。また、GPIF 取引ではレポーティング負担が大きく、リソースに限界ある小規模運用者の参入障壁であったが、AI 出力でレポートの大部分が代替されて負担減となり、GPIF 取引開始の参入障壁は低減し、委託候補のロングテールはより伸延することとなる。また、レポーティングリソースを運用の高度化・強化に振向けることにより運用業界全体にとってもメリットになるのではないか。GPIF 等のアセットオーナーは多数のデータを収集できる立場で、この観点ではアセットマネジャーを凌ぐ立場にあり、今後の AI 利用活発化により有意義な分析結果を導き出せ、その優位性は際立つだろう。従来のアセットマネジャーに専門性がありアセットオーナーは情報劣位

者とのパラダイムが変わり、SABRmetrix で強豪チームを築いた “Moneyball” にあったように、“GPIF-metrics” ともいうべき新手法により、従来の価値観に依拠しない「マネジャー・チーム」の編成やこれに惹かれた若者やプロフェッショナルのキャリアにも影響もあると考えられ、大変興味深い。

6 今後の研究内容

本研究開始当初は基礎調査レベルであったが、途中より試験活用という応用フェーズにシフトして現場から多くの示唆や解決すべき面が明確となった。今後は「試験活用の拡大」(日本株・外国株アクティブ運用全ファンドの Resembler と SDA を月次検知)・「試験活用結果を踏まえた深化・改善・具体化」(AI 検知の要因解析の効率化、出力コンテンツ優先度、学習期間整理やフルスケール化等)・「技術基盤の整理や統合」の 3 点を並走予定である。

7 本研究を通じての所感

- 世界最大の公的年金基金 GPIF、世界トップレベルの処理能力の産総研 ABCI と AI に深い知見と実績を持つソニー CSL による、ユニークネスの高い日本発 3 社により初の AI 試験活用が実現出来たこと
- 本研究成果を汎アセットオーナーレベルに昇華し、「地震が起きてクジラが騒ぐのか、クジラが騒いで地震となるのか」のような市場運用の本質的問題を解決するアセットオーナー「グローバルデータコンソーシアム組成」の提言
- 本 AI 活用に対する学術的見解の余地
- AI 活用実現化に向けて検討時期に来ている新たな人材活用の明確化

目次

ExecutiveSummary	i	
1	2017 年度調査研究の振り返りおよび 2018-2019 年度研究の方向性	1
1.1	2017 年度調査研究の振り返り	1
1.2	2018-2019 年度研究の方向性と内容	2
2	方法論:投資運用行動データからファンドの特性を探る	3
2.1	深層学習技術によるファンド特性の分類・検出システム	3
2.2	自己組織化マップによるファンド特性の可視化	10
3	GPIF 現場における試験活用結果	13
3.1	国内株の事例	13
3.2	外国株の事例	19
3.3	試験活用の中間総括	22
4	実験的取り組み	23
4.1	Resembler ベースの分散度検証	23
4.2	アクティブ運用の「ウデ」評価	25
5	AI により真価を発揮する GPIF	30
5.1	GPIF 現場の変革	30
5.2	「魅せるクジラ」	31
6	今後の研究内容	33
7	本研究を通じての所感	35
付録 A	分析の全出力	38
A.1	国内株ファンドの Resembler 出力	38
A.2	国内株ファンドの SDA 出力	41
A.3	外国株ファンドの Resembler 出力	44
A.4	外国株ファンドの SDA 出力	46

1 2017 年度調査研究の振り返りおよび 2018-2019 年度研究の方向性

本報告書は、2018 年 10 月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より受託した「人工知能 (AI) によるファンド行動学習についての委託研究業務」について、その途中経過を報告するものである。

1.1 2017 年度調査研究の振り返り

CSL は 2017 年に GPIF「人工知能が運用に与える影響」の調査研究を受託した。当該年度の AI 活用の方向性としては、GPIF の中核業務の一つである、年金運用資産を運用会社 (= ファンドあるいはマネジャー) への委託配分の組成および管理を行う「マネジャー・ストラクチャー」において、マネジャーの運用行動が当初申告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か警戒すべきか、などをより精度高く検知することを目指すものであった。

開発内容としては、人工知能 (以下 AI) 技術の 1 つである深層学習を活用した「運用スタイル分析器 (Style Detector Array、以下 SDA)」システムの原理試作を行なった。SDA は、委託先運用会社の運用取引行動のデータを入力にとり、バリュー、サイズ、モメンタムといったファクターベースの投資運用スタイルを成分強度として出力する。システムの仕組み上、出力する成分として任意のものを設定することが可能であるが、まずは GPIF および金融関係者に馴染みがあり理解を得やすい典型的スタイルとした。動作原理の確認が主目的であったため、全上場銘柄ではなく日本株式市場における時価総額の大きいものを中心に代表的な 100 銘柄を切り取ったスモールユニバースを想定したが、委託先運用会社の運用行動のダイレクトな分析により、エビデンス・ベースかつリアルタイムなスタイル分析が可能であり、より精度の高いマネジャーの評価および選定を GPIF が出来る可能性があることを確認した。

この調査研究報告書 [1] は 2018 年に公開され、GPIF および CSL プロジェクトメンバーはアセットオーナーおよびヘッジファンド向け金融専門誌である EQDerivatives 誌より “The Volatility & Risk Premia Awards 2019: Academic Research Paper Of The Year - Machine Learning & Big Data” を日本法人として初受賞した。非金融機関が受賞したのも初めてとのことである。また、GPIF は本調査研究等の取り組みが評価され、アジア地域の機関投資家向け金融専門誌である AsianInvestor 誌より “Institutional Excellence Awards 2018” を 4 年連続で受賞した。

あわせて日本国内外のアセットオーナー、運用会社、ポートフォリオアドバイザー会社または法曹関係の実務家など各方面より様々な反響を得た。その内容は、検知対象となるアセットクラスの今後の展開に関する要望、SDA と既存ツールとの差異といったスタイル検知に関するもの、パフォーマンスとの関連性に関するもの、ないしは「AI のブラックボックス性」についての問題意識など多岐にわたった。

1.2 2018-2019 年度研究の方向性と内容

2017 年度調査研究の成果を踏まえて実際の運用への適用の可能性を探るため、「人工知能 (AI) によるファンド行動学習についての委託研究業務」として 2018 年 10 月～2020 年 3 月の期間で研究を行っている。昨年度の調査研究報告書で挙げた今後の発展 (ユニバース拡大、開発モデル精緻化および異なるアセットクラスへの展開等) および GPIF 内外で深めた議論に基づき、2018 年 10 月以降の研究は次の方向性としている：

	2017 年度	2018 年 10 月～2020 年 3 月
対象アセット	スモールユニバース (国内株 100 銘柄)	ラージユニバース (国内株および外国株 1,000 銘柄)
検知する内容	試験ケースとして設定した典型的なファクターベースの投資スタイル	“Resemblance”(運用会社の「クセ」)
開発内容	スタイル検知可能性を検証するための原理試作	試験活用に対応する新規モデルやシステムの各種刷新

表 1: 2017 年度と現在の研究開発との相違

平成 30 年度業務概況書 [4] の「運用機関の選定プロセス」にある通り、投資方針、運用プロセスおよび組織・人材といった定性評価を重視する一方で、平成 29 年度経営委員会議事概要の「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」との記載があることや、GPIF 担当官へのヒアリングにより「定性評価に際して属人的プロセスに大きく依存」との問題意識があることを知った。つまり、投資方針、運用プロセスおよび組織・人材より形成される運用会社の「特徴や独自性」(クセ)の一貫性または変化を定量的に検知することができれば、より公平かつ適正な選定や評価に寄与し、また現場レベルでも「この委託先は最近何か違う」といった第六感的に察していたものが定量的に計測可能となり、懸念や問題意識に対する解決となり得ることが分かった。

そこで、2017 年度調査研究の時点では説明のしやすさのために、バリュー、サイズ、モメンタムといった GPIF および金融関係者に馴染みがあり理解を得やすい典型的スタイルを出力想定としていた SDA のコア技術はそのままに、従来定量評価が難しいとされた投資方針や運用プロセスといった運用会社の「クセ」という定性情報を検知可能なものに応用発展させるべく研究を進めてきた。

本報告書で以降に述べていくものは、2018 年 10 月から 2019 年 10 月末時点までの途中成果に関するものであり、仕掛途上のものを多く含むことをご留意いただきたい。本研究の全期間通じた成果については 2020 年に最終報告書として別途発表を予定している。

2 方法論:投資運用行動データからファンドの特性を探る

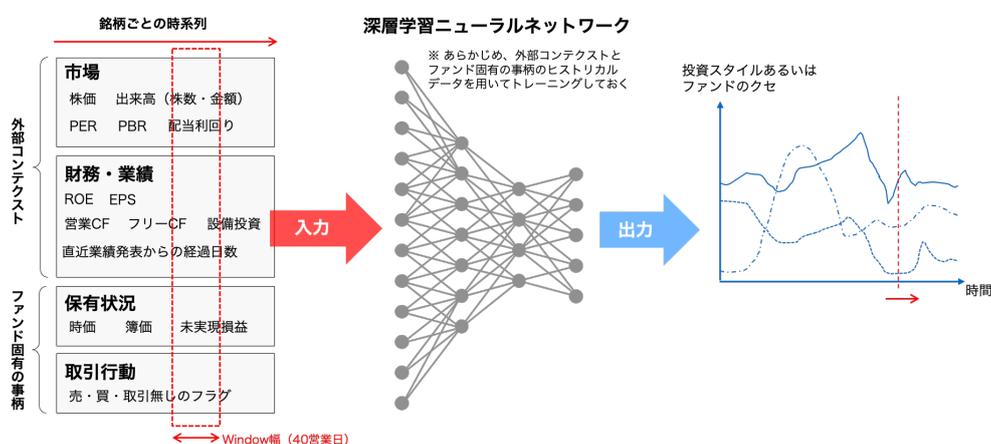


図 2: SDA および Resembler の概略

人工知能の分野において昨今注目を浴びている技術の一つに深層学習技術がある。深層学習とは、生物の神経回路網 (ニューラルネットワーク) を模したシステムであり、人間による明示的なプログラミングに頼ることなく、大量のデータを識別・分類する規則を訓練データの中から自動的に獲得する。音声・画像・自然言語を対象とする問題に対して従来の手法では成しえなかった成果を挙げ [5, 6]、今日の人工知能のブームに大きく寄与している。我々は、この深層学習技術を投資運用行動のデータからファンドの特性を探ることに応用すべく、Style Detector Array ならびにその発展系である Resembler の研究開発を進めてきた。

また、同じく人工知能分野における一手法である自己組織化マップを用いて、ファンドの特性ならびにその変化を別の側面から、人間が見て直感的に判断しやすい形で可視化する手法についても研究開発を進めている。

本節では、我々のとった方法論について、主に技術的な側面について述べていく。

2.1 深層学習技術によるファンド特性の分類・検出システム

Style Detector Array (以下 SDA) および Resembler とは、いわばファンド特性の分類・検出システムであり、ともに、深層学習を技術基盤としている。両者は、分類・検出器として機能させるにあたって事前に訓練を施す必要があるが、その際に用いるデータが異なるだけで、システムの構成は基本的には同一である。システムの動作としては、市場環境およびファンド行動のデータを入力にとり、着目したい単一あるいは複数の特性値の強度をベクトルとして出力する (図 2)*1。入

*1 SDA (array) の名称は、複数特性値の強度ベクトルを並列で出力することに由来している。

力として時系列データを与えることで、時間経過に伴う特性ベクトルの変遷を追うことができる。ファンド行動のデータだけでなく市場環境といった外部コンテキストを入力に加えるのは、特定の外部環境というコンテキスト下で取る行動パターンの対応こそがファンドの特徴であると考えられるからである。

2.1.1 Style Detector Array (SDA)

SDA は、バリュー、サイズ、クオリティ、モメンタムなどといった資産運用のドメインで典型的に用いられてきた「投資スタイル」をレファレンスとして、ファンドの行動パターンからそれぞれのレファレンスの強度を出力することを目的としたシステムである。プロトタイプの開発は 2017 年度の調査研究の時点において実現済みであるが [1]、当時は動作原理の確認を主たる目的としていたために、必ずしも実務の現場での適用を十分に考慮したものではなかった。そこで、今年度の研究開発の一項目として、SDA の刷新に取り組んでいる。

SDA にどの行動パターンがどのスタイルに特有のものであるかを適切に出力させるためには、システムの主たる構成要素である深層ニューラルネットワークをあらかじめ訓練する必要がある。その訓練にあたって、我々は仮想ファンドマネジャー (Virtual Fund Manager、以下 VFM) による仮想取引データを用いるアプローチを取っている。したがって、SDA によるファンド分析の手順は以下の 3 ステップから成る (図 3)。

1. VFM のシミュレーションによる仮想取引データの生成
2. 仮想取引データを用いての SDA の訓練
3. 訓練済みの SDA に分析対象となる実在ファンドの取引データを入力し推論

仮想取引データを SDA の訓練に用いるのは、上に挙げたレファレンスに基づいた純然たる取引を、訓練に必要な程度に長期にわたって行うファンドが実在しないためである。

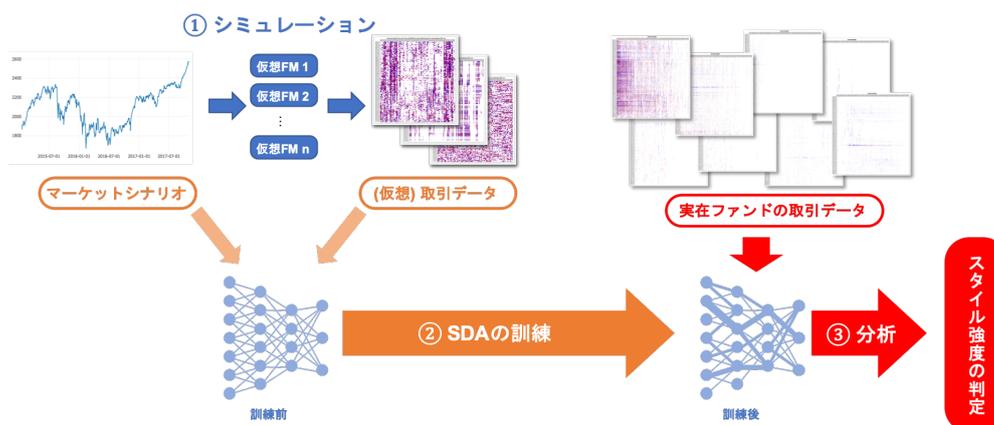


図 3: SDA によるファンド分析のフロー

Virtual Fund Manager (VFM) の改善による SDA の刷新

VFM とは、レファレンスとする運用スタイルをロジックとして具現化したエージェントプログラムであり、マーケットのヒストリカルデータなどを所与の外部条件として取引のシミュレーションを行うものである。したがって、SDA の有効性は訓練に用いる仮想取引データの源である VFM の実装の質に大きく依存するものであり、SDA の刷新は VFM の改善によってもたらされるものである。以下に、現行 VFM における従来プロトタイプからの改善点を述べる。

- ユニバースのラージスケール化

プロトタイプの開発では、限られたプロジェクトの期間制約の中で試行錯誤の回数をなるべく稼ぐために、SDA の学習に要する実行時間を抑える必要があった。そのため、時価総額の大きなものから上位 100 に絞ったスモールユニバースを仮定して、VFM のシミュレーションおよび SDA の学習を行っていた。これに対して、現行の VFM および SDA では 1000 銘柄とサイズの大きなユニバースの上で実行されるようになっており、取り込む情報量の増加を図っている。技術的には 1000 銘柄に限定せずに情報をフルサイズのユニバースを想定することも可能ではあるが、SDA の検証を段階的に進めていることに加えて、次に述べるラウンドロビンサンプリングを併用することで当面の分析においては十分な情報が確保できると判断したため、現状ではテスト環境として 1000 銘柄のユニバースを設定している。

- ユニバース設定におけるラウンドロビンサンプリング

単純に時価総額順に上位を切り取ったスモールユニバースを想定していた SDA のプロトタイプでは、ユニバースに含まれないものが保有銘柄の大多数を占めるようなファンド、すなわち小型銘柄を主に扱うファンドの分析を行うことが不可能であった。そこで、現行の SDA では上記のユニバースのラージスケール化とともに、GPIF の委託先のファンドが保有する数量に応じて銘柄を各ファンドから順繰りに（ラウンドロビンで）ピックアップすることでユニバースを構成するように変更した (図 4)。これにより、1000 銘柄とユニバースに上限を設定した場合においても、GPIF が委託している全アクティブファンドが保有する銘柄を時価ベースで 98%(国内株ファンドの場合) カバーすることができ (図 5)、手元にあるデータをなるべく無駄にすることなく、有効な分析を行うことができる対象ファンドを広げることが出来るようになった。

- レファレンスとして採用する戦略スタイル

プロトタイプでは動作原理の確認という目的のもとで極めてシンプルでナイーブな戦略スタイル群を設定していたのに対して、現行の VFM では現場応用を意識してその構成を再考した。具体的には、Fama-French の 3 ファクターモデル [7] や、Carhart の 4 ファクターモデル [8] 等の学術的な研究で有効性が示された理論的な枠組みを参考にしつつ、ボトムアップのファンド・マネジャーが共通して意識しているであろうリスクファクターとしてオーソドックなものを追加し、バリュー系として、BP(純資産)、CFP(キャッシュフロー)、DP(配当利回り)、EP(利益水準)、MOM(直近 1 年のモメンタム)、Rev-MOM(直近 1 か月の逆モ

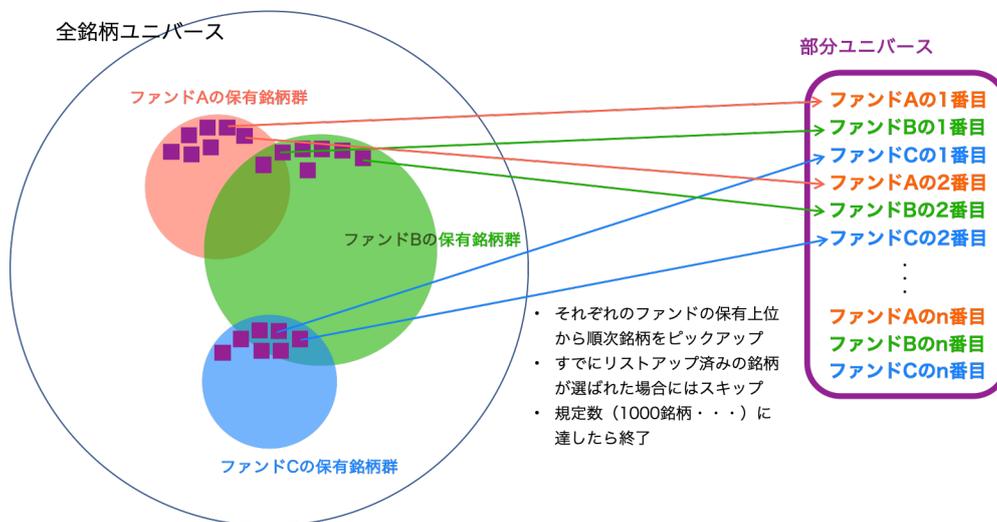


図 4: ラウンドロビンサンプリング

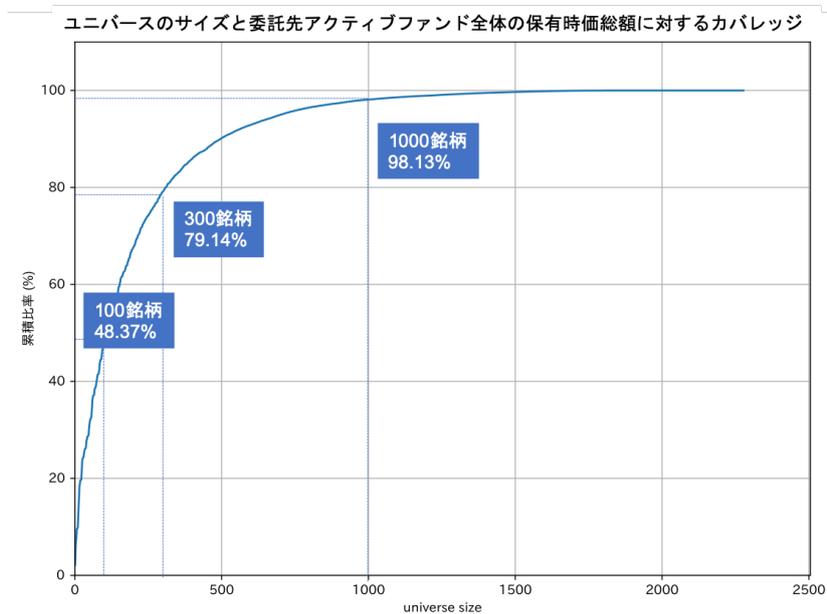


図 5: ユニバースサイズと時価ベースでのカバレッジ

メンタム)、SIZE(時価総額)の7つの指標に基づいて銘柄を選好するVFMを定義している(いずれも、ファクター名にPがついているものは純資産対比の割安度合いを示したものである。)

なお、表現力の精緻化にあたって、こうした指標を次々に追加して数を増していくという考え方もあるが、我々はSDAの基盤である深層学習技術の持つ非線形性がこれを一部担うとの考えに基づいて、むやみに数を増やしていくことについては基本的には控えるスタンスをとっている。もっとも、これまでの試行において、現場感覚との隔たりが完全には解消できていないことが分っているため、用いる指標の組み合わせについては適切なものに改変していく予定である。

- サブVFM群の集合としてのVFM

プロトタイプVFMでは一体の行動主体が取引を行う形態を取っており、かつ取引のロジックとしてはシンプルなものを実装していたため、銘柄の入れ替えが極端なもの(all buyもしくはall sell)になる傾向があった。現行VFMでは、ロジック自体はシンプルに保ったまま、より自然な投資運用行動を表現できるように、取引を行うタイミングを少しずつシフトさせた複数のサブVFMの集合体として一つのVFMを構成している。これにより、非連続な銘柄入れ替えを抑止してノイズを抑えるとともに、任意の戦略を取る市場参加者全体を模倣することができる。

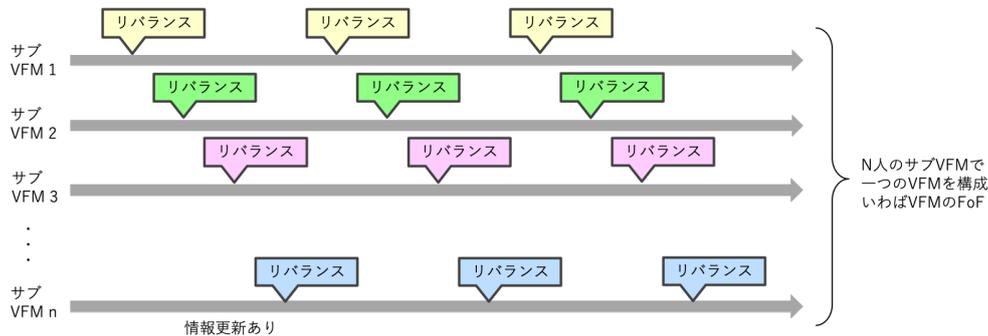


図6: 複数のサブVFMの集合体としてのVFM

- 銘柄選択時におけるカテゴリ別の平滑化

プロトタイプVFMでは、業種や国地域などの区別をすることなく、ユニバースをモノリシックに捉えて、戦略スタイルに紐づいた指標をユニバース内の全銘柄で横並び比較して保有・非保有の選定を行っていた。しかし、これらの指標は業種や地域などのカテゴリごとに平均基準が異なるため、上記を単純に行うと、保有銘柄が特定のカテゴリに偏ってしまう恐れがあった。したがって、現行VFMではカテゴリごとに重みを調整して、偏りなく銘柄選定を行うロジックを導入している。

上記の考えを元に、刷新を施した最新のSDAを用いて、国内株および外国株の実在するアク

ティブファンドの特性を分析した。その結果を用いて行ったいくつかのファンドをケーススタディとして取り上げた議論を第3節で展開する。ケーススタディ以外のファンドを含む結果の一覧については、末尾の Appendix に掲載する。従前のプロトタイプよりも現場感覚に近い結果が得られつつはあるものの、まだ完全に違和感が解消されるに至っていない。この点については、ファクターの内容の再検討や VFM のロジックの変更により改善を図っている途上である。

2.1.2 Resembler

SDA の刷新と並行して、その発展形態として、Resembler の研究開発を進めている。

SDA では、ファンドの投資運用行動のパターンから、あらかじめ設定したバリュー、サイズ、クオリティ、モメンタムといった投資スタイルをレファレンスとしてその強度を出力する。第1節でも述べたとおり、当初 2017 年度に動作原理の確認を目的にプロトタイプを開発した際には、技術的な内容と応用の可能性を第三者に説明しやすいように、学習させるレファレンスとして金融や投資運用の従事者にとって馴染みの深いこれらのスタイルを選んだ。しかし、我々の提案するシステムの特徴は、分類・検出器を訓練データを用いた学習によって構築していく点にあり、これによって着目するレファレンスに応じた訓練用データを用意することでその内容を利用者が自由自在にカスタマイズできることである。

その一つの発展応用が Resembler である。Resembler には訓練用データとして、SDA のように VFM による仮想取引データを用いるのではなく、実在するファンドの取引データを与えて構築する。したがって、Resembler の出力は、客観的な投資スタイルではなく「ファンド A らしさ」「ファンド B らしさ」といった尺度をレファレンスした実在ファンドとの類似度 (resemblance) を反映した時系列ベクトルとなる。訓練に用いるデータが異なるだけでシステムの構成と作動原理は SDA と全く同一であるが、実在するファンドとの類似度という観点からの分析によって、SDA だけでは捉えきれないファンドの行動特性を明るみにできる (表 2)。

	SDA	Resembler
訓練データ	VFM の出力する仮想取引データ	実在ファンドマネジャーの取引データ
検知の対象	ファクター・エクスポージャーで定義される「投資スタイル」といった客観的な指標	「ファンド A らしさ」などの相対的な指標

表 2: SDA と Resembler の違い

Resembler の応用事例として、現時点では以下の二つの方向性で研究開発を進めている。もっとも、Resembler の応用はこの二例に限定されるわけではなく、ほかの応用の可能性についても探っている。

- Self-resemblance の評価：過去の自分自身の「特徴と独自性」(クセ) との比較

過去の自分自身の投資運用パターンを訓練用データに含めておくことで、自分自身の「特徴と独自性」(クセ) がどの程度維持されているのか、あるいは、変化してきたのかの指標である Self-resemblance として分析することができる。具体的な手順としては、分析対象とする全アクティブファンドのデータを用いて分類・検出器を訓練し、これによって得られた Resembler に各ファンドのデータを入力として与える。「自分らしさ」を強く維持している間は Self-resemblance も期間を通じて安定して高い値を示すことになるし、逆に「自分らしさ」を失う局面では Self-resemblance も低下する。また Self-resemblance を表す数値が常に上下に変動する場合には*2、「自分らしさ」を持たない、もしくは定義できないファンドという判断になる。

ここで留意すべきは、SDA の変化と Resembler の変化とは独立しており、両者が同時に起こるケースもあれば、一方が変化しているのに他方は変化しないというケースもある。これは SDA と Resembler とではファンド特性の異なる側面を捉えていることを示唆している。SDA ではバリュー、モメンタムといった第三者視点に基づく投資スタイルという観点からファンドの行動特性を捉えるのに対して、Resembler では当該ファンドの運用のクセやその一貫性といった従来は定性的にしか評価しえなかった側面を定量化していると考えられる。SDA と Resembler による分析を組み合わせることで、ファンドの行動特性をより多面的に捉えられると期待できる。こうしたフレームワークで、国内株ファンドおよび外国株ファンドについて行ったいくつかの分析例をケーススタディとして第3節で取り上げる。全ファンドに対しての Self-resemblance の出力結果一覧については、Appendix に掲載する。

- Mutual-resemblance の評価：他者との比較

いくつかの限定された数のファンドをアンカーとして選び、これらの行動データを用いて訓練された Resembler があるとする。これに分析対象となる他のファンドのデータを入力として与えることで、そのファンドを個々の「アンカーファンドらしさの組み合わせ」として特徴付けられたアンカーの数と次元を同一にするベクトル値を得ることができる。複数のファンドについて求めたこれらのベクトル値の間の距離を測定することで、それぞれのファンド間の類似度である Mutual-resemblance を評価することができる。なお、アンカーとするファンドについては、目的に応じて適切な組み合わせを選定する必要がある。原則的には、なるべく特徴が異なるもの同士をアンカーとして選ぶことが重要であるが、例えばクオンツファンドという括りの中での限定的に類似度を評価したい場合にはクオンツファンドの中からそれぞれ特徴が異なるものを選ぶべきである。

このようにして得られる類似度が時間の経過とともにどのように変化していくかを追うことで、マネジャー・ストラクチャーにおける多様性が適切に維持できているかどうかの判断材料を提供できる可能性がある。この考えに基づいた現在進めている実験的な取組みの詳細については、第4節で触れる。

*2 同時に「他者らしさ」を表す数値が混入してくるケースも多い

2.1.3 ABCI の活用による SDA および Resembler の開発効率の向上

SDA および Resembler を実行するにあたっては調整可能な外部パラメータが多数あり、有効な結果を得るためには、これらの適切な組み合わせを探し出す必要がある。そのチューニングの過程では、少しずつ条件を変えた数多くの試行錯誤を重ねる必要がある。

また、パラメータの組み合わせを同定した後においても、深層ニューラルネットワークの学習において、特に学習する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出力結果が大きくばらつくことが分かっている [9, 10, 11]。そこで我々は、同じデータセットを用いた訓練を複数回実行し、これらの独立した試行の結果得られた出力のアンサンブル平均を取ることで SDA および Resembler の安定出力値を得るアプローチを取っている。

上記のいずれの過程においても膨大な計算を必要とする。2017 年度のプロトタイプの開発にあたってユニバースとしてスモールサイズを想定して簡素化していたのには利用可能な計算資源の制約も大きな理由の一つとしてあった。

本年度より、国立研究開発法人産業技術総合研究所が運用している AI 橋渡しクラウド (AI Bridging Cloud Infrastructure、以下 ABCI) を利用して研究開発を行っている [2]。ABCI は、GPU を搭載したノード 1088 台の接続によって構成されたクラスターであり、深層学習を並列に実行させるのに最適な計算インフラストラクチャを提供する [3]。同時に並列可動させるノード数にもよるが、我々の典型的な利用法においては、試行を 1 サイクル回すのに従来は 1 週間程度を要したのが、1 日半程度で結果が得られるようになった。結果として、我々の研究開発において 2017 年度に比して大幅な効率化に繋がっている。今後も多大な試行錯誤を要することが想定されており、コストパフォーマンスに優れた ABCI は、ますます我々の研究開発の成否を左右する重要な鍵となる。

2.2 自己組織化マップによるファンダ特性の可視化

SDA および Resembler の技術的基盤である深層ニューラルネットワークは、膨大なデータの中に一見ただけでは分からない規則を自動的かつ瞬時に見出し、これを人間がコンピュータプログラムとして形式的に記述することなく、パターン検知やパターン分類などの諸問題に応用することを可能にする。一方で、規則を形式的に記述することを必要としないメリットは、逆にニューラルネットワークの挙動をブラックボックスとして受け入れざるを得ないデメリットと表裏一体となっている。GPIF などの公益を追求する機関の意思決定においては、その判断根拠に対する説明責任が問われるため、ニューラルネットワークのこうしたブラックボックス性は好ましくないものである。実際のところ、SDA や Resembler によって何らかの変化が検知された場合に、なぜそのような変化がもたらされたかの理由が分からないと、その次の意思決定や行動に進めないことが多い。

そこで、我々も SDA や Resembler によって検知された変化の要因を探るべく、既存の様々な技術的な手法を適用して有効なユースケースを模索している。その中の有望な要素の一つとして、自

自己組織化マップ (Self Organizing Map、以下 SOM) をファンド特性の可視化技術として応用する手法について注目している。

SOM とは、ニューラルネットワークの一種であり、膨大な「要素」を個々の属性の類似度を二次元 (ないしは三次元) のマップ上での距離として表現するモデルである。その本質は、教師なしで複雑で高次元の情報を持つ「要素」がクラスタリングされることにあり、これにより人間が生の情報からでは理解が困難な全体的な傾向や相関を視覚的に捉えることを手助けしてくれる。SOM の動作原理を簡単に述べると以下のとおりである。

1. クラスタリングの対象となる「要素」の一つが入力として与えられる。
2. 「要素」の持つ属性ベクトルとマップ上の各ユニットが持つ参照ベクトルとを比べて、最も一致度の高いユニットを選ぶ。
3. 一致度の最も高いユニットに「要素」を配置するとともに、選ばれたユニットの周囲のユニットの参照ベクトルが「要素」の持つ属性ベクトルに近づくように更新される (暴露)。
4. 1 に戻る

上記の手順を十分な回数繰り返されることで、最終的には属性ベクトルが互いに似た「要素」どうしが集まったグループがマップ上に形成される^{*3}。

我々の応用事例においては、「要素」とはファンドが保有する個々の銘柄であり、属性ベクトルの構成としては時価総額、PER、PBR といったファンドに非依存で共通な値に加えて、アクティブウェイトやアクティブリターンといったファンド毎に異なる値を含めている。このような手続きを経てファンドの保有する銘柄を二次元マップ上に配置した上で、着目したい属性について値に応じた連続的なカラーマップで表現することで、ファンドの特性や時間経過に伴う変化を視覚的に容易に捉えることが可能になる。言わば SOM を視覚化の前段階の処理として利用しているに過ぎないわけであるが、その有効性は言葉で表現する以上に大きい。例えば、銘柄コード自体は人為的に設定されたものであって銘柄の特徴が反映されたものではないため、単純に銘柄コード順に並べた状態で属性値の色による視覚化を試みても、乱雑な色のパターンが現れるだけで、そこから有益な構造を見出すことは困難である。

例として、図 7 に、あるファンドが保有する銘柄を SOM によりクラスタリングした上で、それぞれのユニットをそこに属する銘柄群のアクティブウェイトの水準に応じて色付けしたものを示す。赤く着色された部分がオーバーウェイトで保有している銘柄群、青く着色された部分がアンダーウェイトしている銘柄群になる。なお、ユニットの詳細を見ることで、具体的な銘柄をはじめ PER や PBR のような指標、サイズやセクター等を特定することも可能である。

このようにして描いたアクティブウェイトの SOM 図を時系列で出力することで、ファンドの銘柄保有傾向の変化を視覚的に追うことが可能となる。これを Resembling の変化の要因分析の一手法として活用した事例については第 3 節で述べる。

*3 予備知識 (教師) なしで自己組織化されるようにクラスタリングが形成されることから、自己組織化マップの名がつけられている。

また、ユニットと銘柄の対応を固定することで、異なる属性でそれぞれ色付けした図を比較して分析を行うことができる。例えば、アクティブウェイトとアクティブリターンのそれぞれの水準で色付けした SOM 図を見比べることにより、アクティブウェイトを高めに設定している中でアクティブリターンが得られているのがどの銘柄群であるのか、といったことが視覚的に捉えやすくなる。これを運と実力を分離して評価する Distiller と我々が呼ぶ実験的取組に応用を試みた事例について第 4 節で紹介する。

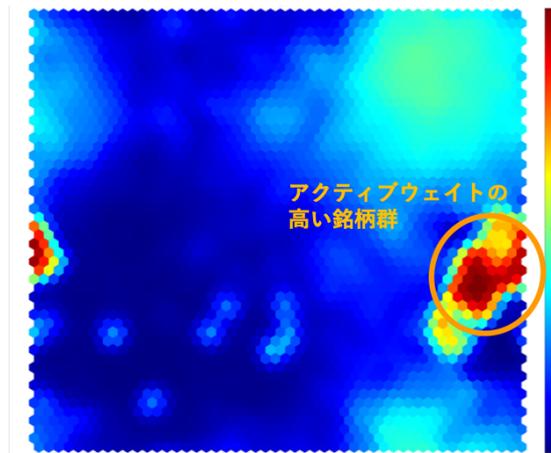


図 7: SOM による銘柄保有パターンの視覚化

3 GPIF 現場における試験活用結果

前節で述べた研究開発内容の有効性を確認するとともに今後の実活用に向けての改善点や必要となる新たな要件の洗い出しをすべく、GPIF の現場にて試験活用を行った。試験活用にあたっては、GPIF が実際に委託をしている (一部解約済みのものも含む) 国内株および外国株の全てのアクティブ運用ファンドを対象とした。主たる分析として Resembler および SDA によってファンドの特徴を見た上で、必要に応じて注目すべき事柄について他の技術的手法を用いて要因分析を進めるという手法を取っている。

全てのファンドについての Resembler および SDA の出力結果は末尾の Appendix に掲載するが、以下ではその中から我々が特に考察に値すると判断した 4 つの事例を選んで述べていく。

3.1 国内株の事例

事例 1：全期間データを通じての検証

事例 1 ではファンド A の分析を取り上げる。本事例では、全期間データ通じて、過去の変化の有無およびその変化の要因を検証し、今後 GPIF が業務の中で Resembler をどのように活用し得るかについて考察した。

<変化の検知>

図 8a に示した Resembler の出力からは以下の 3 つの動きが確認される。

- 2017 年 7 月～2018 年 1 月に自社成分がやや上昇した後に大きく下落した動き
- 2018 年 1 月～2019 年 3 月に自社成分が低位安定している間に、他社成分が増加した動き
- 2019 年 3 月～に再度自社成分がやや増加した動き

一方、同タイミングにおいて、スタイルを検知する SDA の出力には目立った変化は見られなかった (図 8b)。これは、従来のファクターという視点からのスタイル変化は認められないものの、「独自性や特徴」(クセ) という視点から何らかの変化を Resembler が検知したことを意味する。

<変化の要因解析>

以下に述べるいくつかの観点から、Resembler 変化の要因解析を試みた。

- アクティブウェイト図 9 は、銘柄を SOM でクラスタリングしたものにアクティブウェイトの水準に応じて色付けをすることで、保有傾向のパターンの推移を視覚的に追うものである。
 - 2017 年 1 月 (図 9a) に比べて 2019 年 1 月 (図 9b) では、実線で囲んだ部分の濃い赤色の面積が縮小すると同時に、点線で囲んだ部分の領域の濃い赤色の面積が増加してい

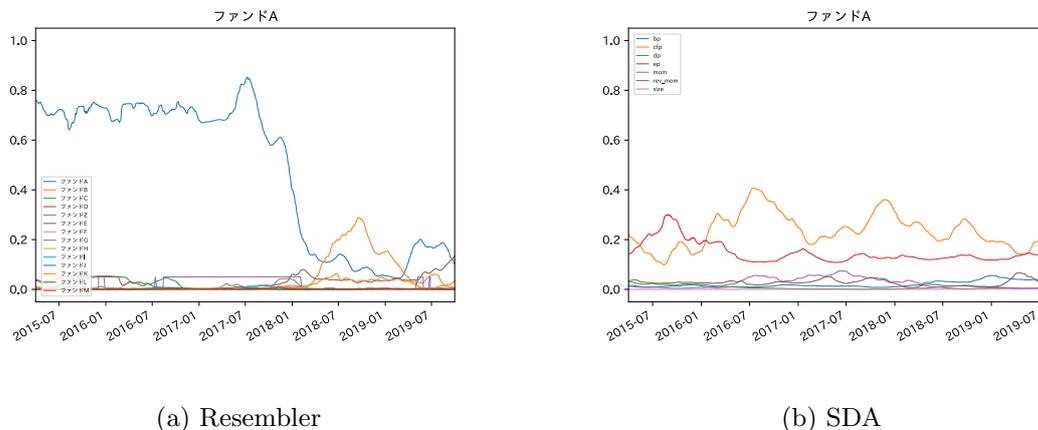


図 8: 事例 1:特徴の分析

る。これは強いオーバーウェイトとなっている銘柄が一部入れ替わっていることを示している。同時にマップ全体では濃い赤色の面積が縮小していることから、強いオーバーウェイトを取る銘柄の集中度合いが増していることが見て取れる。

- 2019年6月(図9c)には実線で囲んだ部分のオーバーウェイトの領域が拡大しており、かつてのファンドAらしさが復調しつつあることが示されている。しかし、引き続き点線で囲んだ部分に強いオーバーウェイトが残っていることや、マップ全体でのオーバーウェイトの増加が限定的であることから、以前ほどのファンドAらしさを取り戻すには至っていないと考えられる。
- いずれの変化も Resembling の変化するタイミングと一致していることから、Resembling の出力がここで述べた銘柄の保有傾向の変化を反映している可能性がある。

- 保有銘柄数

2017年7月～2018年1月、2018年1月～2019年3月および2019年3月に Resembling が変化したタイミングとおおよそ同じ時期に保有銘柄数の増減が顕著に見られることから、こうした銘柄数変化も Resembling が捉えた可能性がある(図10)。

- 回転率

Resembling が変化したタイミングの前後で、回転率変化の周期が変化しているように見受けられる。上記のアクティブウェイトのパターン変化や保有銘柄数変化との間に認められるほどの強い関連は見られないが、Resembling 変化の要因の1つを成している可能性は否定できない。(図11)。

< GPIF における業務活用についての考察 >

ファンドAに関しては、GPIFには2016年に複数回のモデル改良を行うとの事前報告があり、Resemblingでも2017年7月～2018年1月の変化として追検証できている。加えて、Resembling

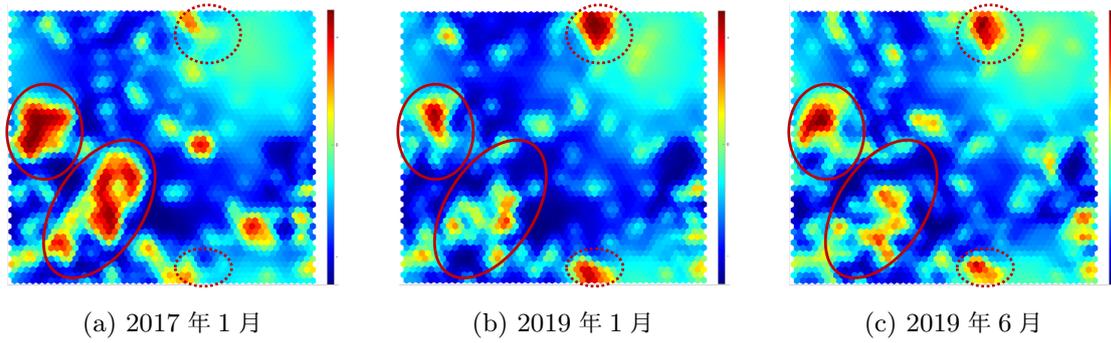


図9: 事例1:保有傾向 (アクティブウェイト) のパターンの推移

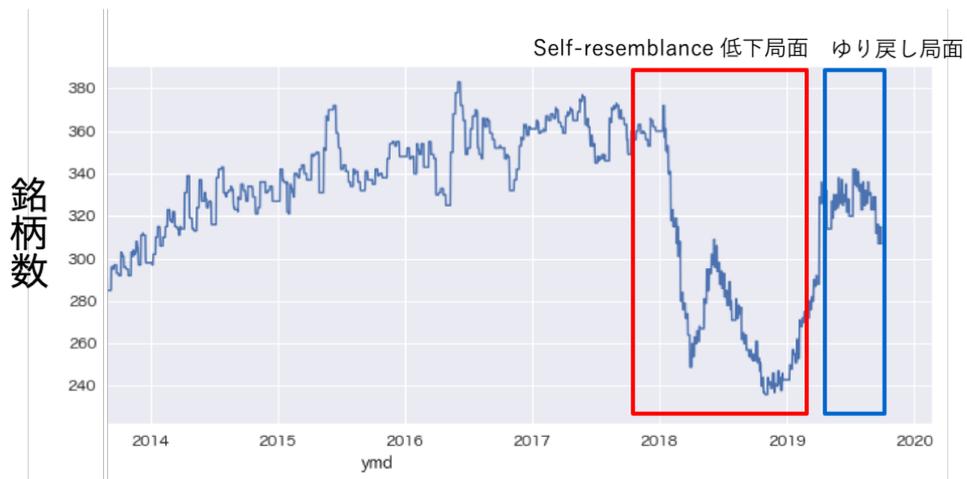


図10: 事例1:銘柄数の推移

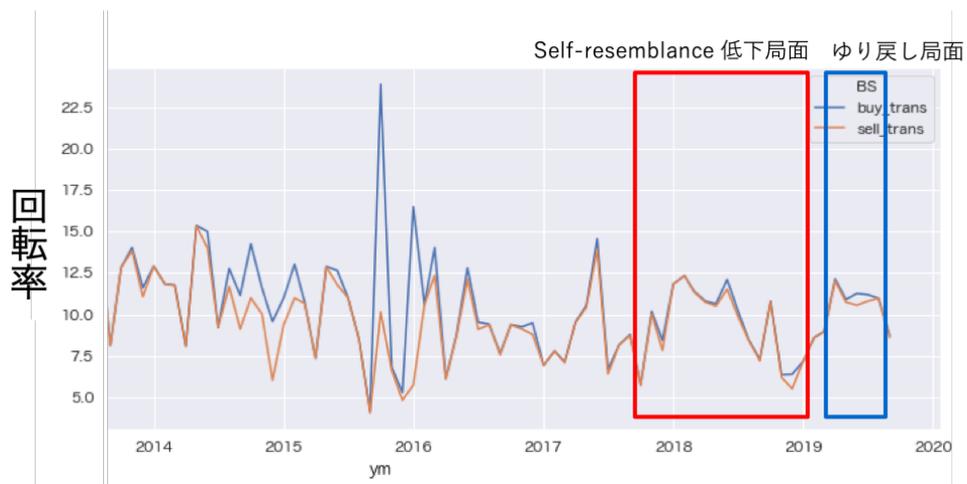


図11: 事例1:回転率の推移

は 2019 年 3 月以降、再度自社成分がやや増加する変化も検知しており、この期間内の保有銘柄数や回転率のパターンの変化を反映したものと思われる。後者の変化についても、GPIF と委託先との間で個々のアクションとしての認識合わせは為されているが、当該ファンドのパフォーマンスの状況に鑑みると、個々の単発アクションとしてではなく、状況改善に向けての大きな質的变化の一部として注視すべきものである可能性もある。

GPIF と委託先間のコミュニケーションは多岐にわたり、論点も多く存在するため、委託先との都度のコミュニケーションによって各論を断片的に把握認識してはいても、背景に流れる一連の大きな変化、もしくはその予兆に気づかないことは実務上起こり得る。Resembling はこのような個別各論を一連の大きな流れとして検知して新たな仮説立てを可能とするものであり、この仮説検証に論点を絞った上でパフォーマンス改善に向けた協議を支援し得るものである。

さらに Resembling は委託先の変化点をログとして定量的に記録する実務的な改善にも寄与し得る。ファンドの変化が第六感的に担当者の違和感としてしか捉えられなかった場合、たとえその違和感が強いものだとしても、記録を残す根拠としては弱いものにならざるを得ない。しかし、Resembling による変化であれば記録を残す定量的な根拠として使うことができ、そこを起点として一連のモニタリングを開始することができる。言い換えると、これまで記録の根拠として使われてきたパフォーマンスの低下やキーマンリスクに、新しい要素を加えることができる。これによりモニタリングの頻度や内容が増加し、その結果として長期的にはファンド選定およびモニタリング能力の向上に効果を発揮するものと考えられる。

事例 2：現在進行中の変化の検知

次に取り上げるファンド F は、過去長期間に渡って Resembling の出力に顕著な変化が見られず、直近になって変化が見られるようになった事例である。本事例は、月次のデータ更新により分析を継続する場合を想定し、変化の開始が Resembling でどのように捉えられるのかについて考察するものである。

<変化の検知>

当該ファンドについては、2019 年 6-7 月頃に至って Resembling が過去には見られなかった変化を検知している (図 12a)。一方、SDA では同時期で同様の変化は検知していない (図 12b)。ここでも、従来のファクターという視点からのスタイル変化は認められないものの、「独自性や特徴」(クセ) という視点から何らかの変化を Resembling が検知したことを意味している。

<変化の要因解析>

次に、Resembling 変化の要因をいくつかの観点から探ってみた。

- アクティブウェイト

- 2018 年 6 月 (図 9a) に比べて 2018 年 12 月 (図 9b) は、左右真ん中にある強いオーバー

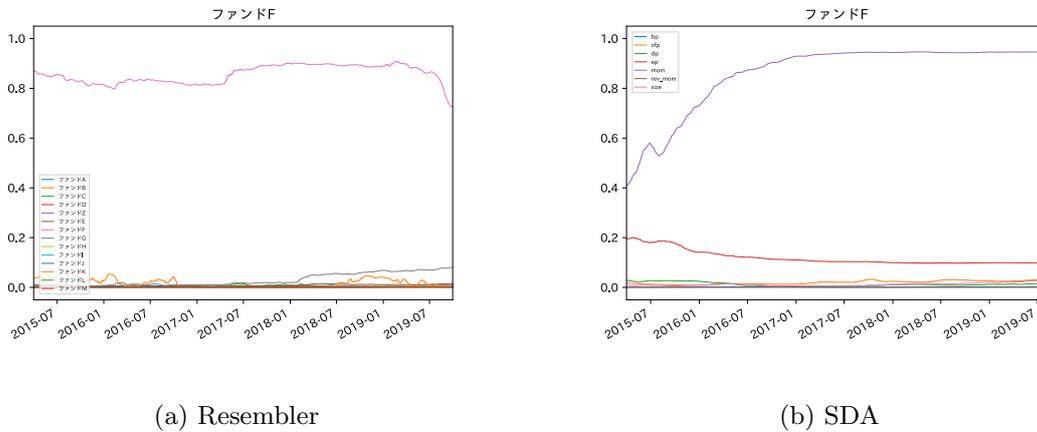


図 12: 事例 2: 特徴の分析

ウェイトの領域 (実線で囲んだ部分の濃い赤色の領域) が若干縮小し、中心の点線で囲んだ部分にわずかに青白い点が出現していることが確認出来る。この時点では若干の変化が認められる程度である。

- 一方、2019年6月 (図 9c) は、実線で囲んだ部分の強いオーバーウエイトの領域が明確に縮小している。また、点線で囲んだ部分に新たなものも含めて青白い点の出現がはっきりと確認でき、これはオーバーウエイトの縮小に呼応する形で強いアンダーウエイト (濃い青色) がニュートラル (青白) に変化したことを示す。これは銘柄選定を従来のものから変更していると同時に、アクティブリスクを若干低下させていることを反映している。

いずれの変化も Resembling の変化するタイミングと合致していることから、これを Resembling が捉えた可能性がある。

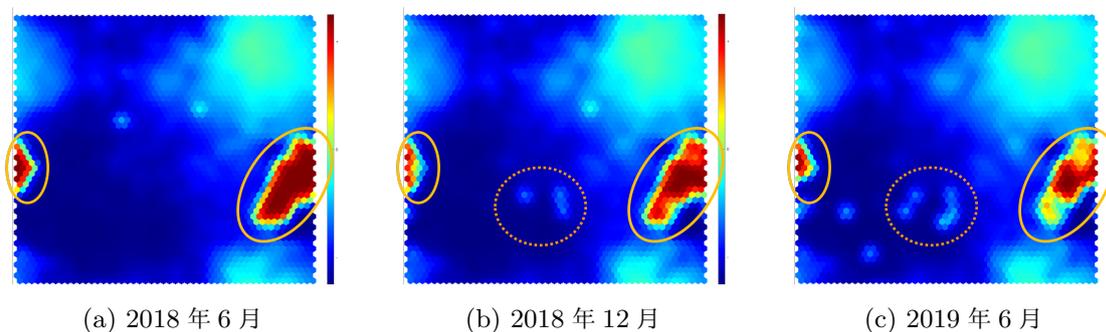


図 13: 事例 2: 保有傾向 (アクティブウエイト) のパターンの推移

< GPIF における業務活用についての考察 >

Resembler が変化を検知している直近において、ファンド F は良好なパフォーマンスを示している。一般論として、良好なパフォーマンスが出ているうちは投資方針やモデル等を敢えて変更するモチベーションは起こりにくいと思われる中で、Resembler は「従来に無い銘柄選定パターンの出現」・「集中投資スタイルに関する変化」を検知した。

GPIF は委託先との間で「個々の変化」を「異なる時間軸」で「都度報告を受ける」形でこの変化を認識していた一方で、Resembler は「現在起こりつつある連続した」変化を検知している可能性がある。GPIF 業務の実態と AI 検知を連続性および時間軸の観点でシームレスに統合するにあたり、「良好なパフォーマンスの委託先の変化を注視する意義」および「GPIF 現場で活用可能なコンテンツへの落とし込み」という 2 つの論点を整理する必要がある：

- 「良好なパフォーマンスの委託先の変化を注視する意義」

GPIF の業務は広範かつ多岐にわたり、その多くの業務量を少数の人員数で対応していることから、相対的にパフォーマンスの悪いファンドをより注視して優先的に対応せざるを得ない実態があると推察する。一方、事例 2 のようにパフォーマンスが良好なファンドではあっても、これが持続するものとは限らない。悪い結果に予兆があり、それをもたらす変化が徐々に訪れるものであるならば、事前に検知できることは有益であるに相違ない。今回ファンド F について検知した変化が、悪い結果につながるものとは現時点では必ずしも断定はできないが、少なくとも変化が発生しつつあることは Resembler および SDA によりシステムチックに見落とすことなく検証可能となる。ある一定の閾値を超えた時点で「変化予兆あり委託先」として高優先度対応の対象とすることで、業務の負担を過度に増やすことなく、注視先の範囲を広げることができる。

更に、良好なパフォーマンスのファンドはその成果を維持するため不断の努力を継続しており、今回検知した変化は今後の市場環境を見越した能動的な対応の可能性もある。Resembler、パフォーマンス、投資行動変化ないし市場環境を組み合わせることにより、良いファンドの投資行動の動きを定量的に知見として蓄積し、GPIF 内での知識ベースの更なる底上げや担当官間での定量的な知見共有に活用し得る。良いものを知ることにより良いものを見つけられる、そのセレクション能力の更なる向上への応用展開も合わせて提言する。

- 「GPIF 現場で活用可能なコンテンツへの落とし込み」

Resembler 変化検知の要因を別の手法も用いて解析した結果、「これまでに無い銘柄選定のパターンの出現」や「集中投資スタイルに関しての当初目論見からの変化点」を可能性として挙げた。しかし、GPIF 現場からは、「集中投資スタイルに関しての当初目論見からの変化点」の場合、「通常のファクターローテーションでないとしたら、その変化の内容はどのように説明し得るのかももう少し噛み砕いたテキストがあると良い」とのフィードバックを得ている。背景として、GPIF および委託先双方は、銘柄選定の変更やリバランスの方針変更といった個別の改善は日常的に行われているが必ずしも 1 つの大きな変化の流れとして認識

できていない可能性がある。一方で、Resembler はシステマティックに 1 つの流れとして変化検知しており、現場と AI の間に認識の乖離が起こることによるものと考えている。この乖離を解消するためにフィードバックで挙げられたようなコンテンツへの落とし込みが必要となる。具体的には、現場で活用可能なコンテンツを出力する業務ないし情報システムにおける適切なモジュールシステムと AI をインテグレートすることを想定しており、どのようなシステムが必要かは優先度や重要度等を加味して継続整理する。また、SOM の適用により変化の要因を視覚的に捉えやすくなる手法を提案しているとは言え、その評価の方法や解釈を専門外の者が現場で活用できるようになるためには相応の学習コストが発生する。要因解析の出力のインターフェイスにおいても、より視覚的かつ直感的に理解可能なものに改善していく必要がある。

3.2 外国株の事例

外国株事例は国内株事例と視点を変えて、「委託先からの報告内容の妥当性検証」および「自分らしさの無さ」が自分らしさとして検出された 2 つの事例を挙げる。

事例 3：委託先からの報告内容の妥当性検証

事例 3 としてファンド N を取り上げる。本事例では、委託先からの過去の報告内容に関し、妥当なものであったかを GPIF 側で検証した。

このファンドについては、2018 年に組織上のやや重要なイベントがあり、このことについて GPIF は委託先より事前に報告を受けていた。また、当該イベント後も従前と変わらぬ運用を継続する旨の報告も併せて受けており、実際に GPIF 側でも既存ツールにてファクター等による変化有無の確認を行っている。ここでは、さらに Resembler でも再検証してみた。その結果、ほぼ変化が見られず、従前通りの運用を継続していることが確認できた (図 14)。

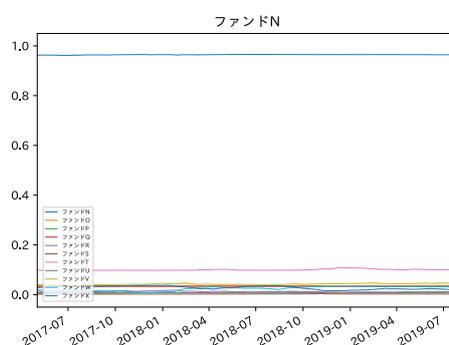


図 14: 事例 3: 特徴の分析 (Resembler 出力)

また、いくつかの補助的な解析手法を用いて別の視点から追加検証を行うことで、ファンドの運用行動に特筆すべき変化がないことを確認した。

- 銘柄数

イベント発生した 2018 年に銘柄数の若干の変化が見受けられるが、過去の運用行動からの重大な変化とはみなされていない (図 15)。

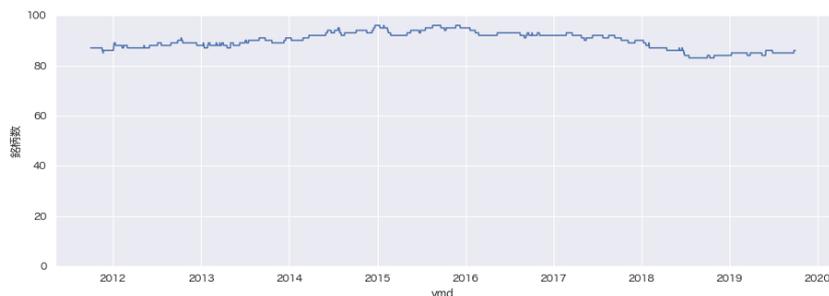


図 15: 事例 3:銘柄数の推移

- 銘柄の出入り

銘柄数関連で、銘柄の出入りについてイベント発生後の 2018 年以降の変化を確認したところ、変化が皆無とは言えないが、顕著なものとは言えないことが確認できる (図 16)

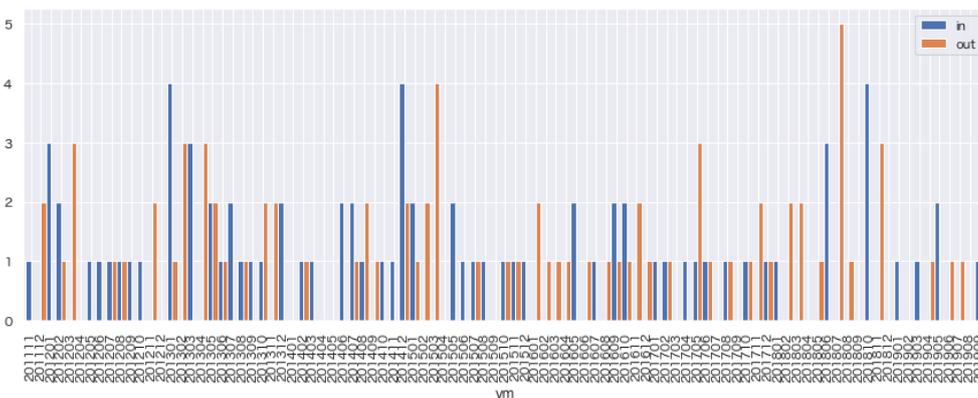


図 16: 事例 3:銘柄の入れ替え

- ポートフォリオ構成銘柄の変化

任意の月のポートフォリオとその半年前のポートフォリオとの間で、銘柄保有比率の相関係数と保有銘柄の一致率を計算した (図 17)。保有比率の相関、銘柄一致率ともに高い値で安定しており、運用のスタイルがイベント後も維持されているといえる。

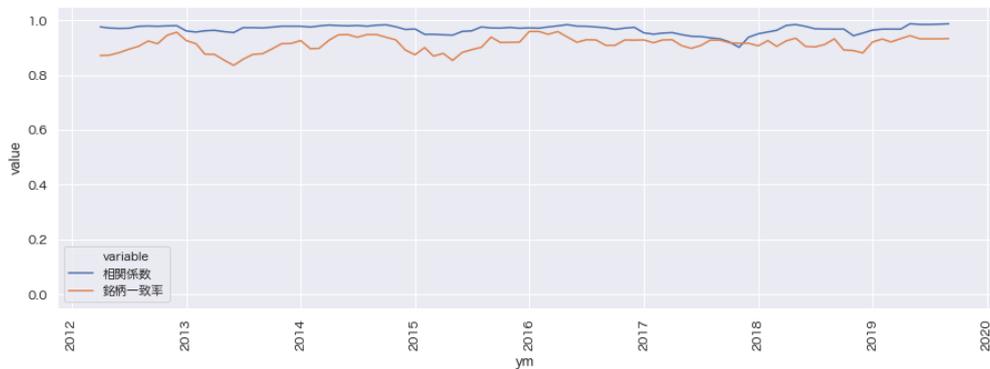


図 17: 事例 3 における銘柄保有比率の相関係数と保有銘柄の一致率

委託先は GPIF に報告義務があり、その内容に基づき GPIF では既存ツールの範囲で検証をしている。Resembler は、スタイルやファクター等を超えた、既存ツールでは捉えきれない、よりハイレベルかつ広範な変化を検知するものであり、委託先の変化有無を異なる視点でより高精度に再検証可能とするものである

事例 4 : 「自分らしさの無さ」が自分らしさ

事例 4 ではファンド W を取り上げる。このファンドは、特定の決まった運用戦略を持ち続けるのではなく、市況に応じて臨機応変に運用戦略を変更する手法をとる。Resembler の出力では、自社成分が大きく低下していく一方で、様々な他社成分のそれぞれが一定程度に、かつ変化を伴いながら現れている。ある意味「自分らしさの無さ」という「自分らしさ」を表しており、かつその「自分らしさの無さ」が一貫していることを検知している (図 18)。

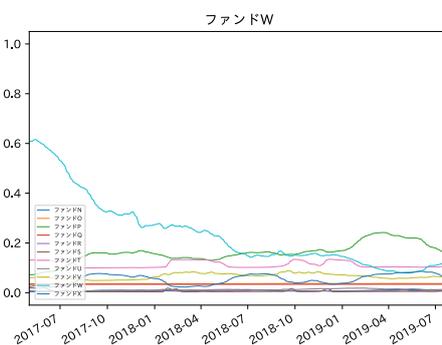


図 18: 事例 4:Resembler

このように当初から決まった運用戦略に固定しないことを掲げているファンドにおいて、自覚的かつ先見的に「自分らしさ」を変えているのであれば、それは一つの運用哲学であると言える。逆にこの種のファンドにおいて、同じスタイルが長期にわたって持続するなど「自分らしさ」の柔軟性が失われた場合や、「自分らしさ」の変更が市場環境の変化に対して後手に回り始めた場合は、より詳細なヒアリングが必要になる兆候と考えられる。

3.3 試験活用の中間総括

AI を現場で試験的に活用するにあたり、3つのステップが必要であることが判明した：

1. AI(Resemblers および SDA) による検知

最初のステップでは、AI(Resemblers および SDA) によって変化の有無が検知される。ここで検知される変化は、ファクターやスタイルという観点での変化にとどまらず、運用会社の「特徴や独自性」(クセ) という定性的でとらえにくいファンドの特性の変化を含む。

2. AI による変化検知に対する要因解析

次に変化の要因解析が必要となる。上記事例研究では SOM ないし感応度分析等により一部システマティックに対応したが、多くは人手によるアドホックな解析作業であった。AI による変化検知の後、迅速かつ途切れなく分析を行えるようなシステマティックな仕組みが必要となる。例えば、トピック分析、様々なクラスタリング手法、Variable Auto Encoder 等がアイデアベースではあるが、引き続き研究を継続する。

3. 要因解析に基づく現場で即活用可能なコンテンツへの落とし込み事例 2 で述べたように、GPIF 現場での活用においては、Resemblers が変化を検知した際に「端的に何から何になったのか」ないし「もう一步噛み砕いたテキストがあると良い」とのフィードバックを得ている。その背景としては、仮に変化検知した際に委託先に問い合わせても、委託先自身が認識していない変化を AI が検知していた場合に議論が深まらない可能性があること、また、管理ないし対処する委託先は多数あるが、AI 検知結果が容易に理解できるレベルに落とし込まれていれば作業負荷削減につながり、従来出来なかった対応の実現性がより高まることにある。これを実現するにあたっては、我々の開発するシステムと既存の業務ないし情報システムとの間での情報のやり取りが必要になるが、そのインテグレーションのあり方については、今後の試験活用の中で継続して整理していく。

4 実験的取り組み

4.1 Resemler ベースの分散度検証

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り、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、収斂が検知されたときに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、などといったことを考慮することは重要である。

パフォーマンスやファクターベースでファンド群の多様性を評価することはこれまでも行われてきたが、ここでは、「特徴や独自性」(クセ) を出力する Resemler の枠組みを用いて委託先ファンド群の分散・収斂度合いを評価する実験的な取り組みについて紹介する。具体的には、2.1.2 節で述べたように Resemler で複数ファンド間の類似度である Mutual-resemblance を算定し、多次元尺度構成法 (Multi-Dimensional Scaling、以下 MDS)[12] と呼ばれる次元圧縮の手法を用いて一つの相空間上に視覚化した。

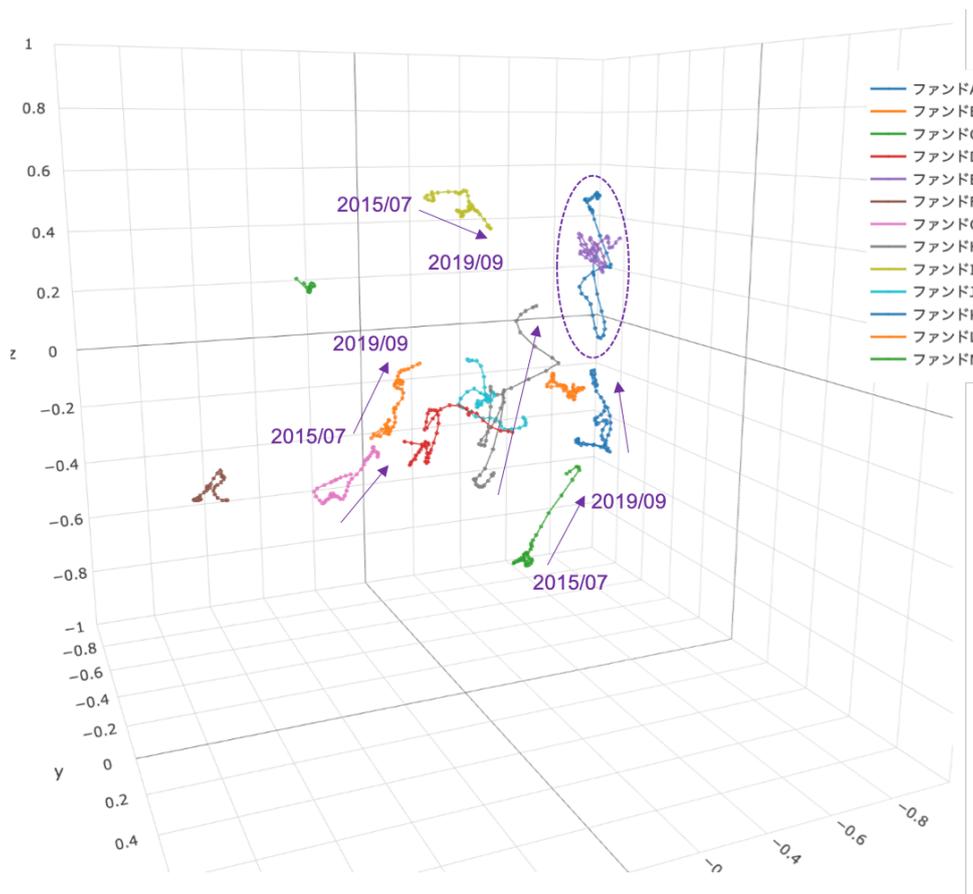


図 19: 複数ファンド間の類似度マップ

類似度マップを得るためには、基準となるいくつかのファンドをアンカーとして選ぶ必要がある。ここでは大域的な視点で全ファンドの特徴の類似度を評価したいため、投資手法やパフォーマンスの良し悪しなどの観点で互いになるべく異なった特性を持つ4つのファンドの組み合わせをアンカーとして選んだ。このようにして、国内アクティブ運用ファンド間の類似度を算定して2015年7月～2019年9月の変遷を描いたのが図19である。軌跡の始点から終点へ方向(図中の紫色の矢印)を見たところ、当初はある程度分散していた各社の「特徴や独自性」(クセ)が、時間経過とともに右上部に位置するファンドAとファンドEの方へと徐々に収束しつつあることが判明した。収束の傾向が現れる要因としては様々なものが考えられるが、一例としてファンドマネージャーがポートフォリオのリスクをどの程度の水準にしているかを計算したものが図20である。計算の方法としては、投資している各銘柄の過去1年間をベースにした分散共分散行列とポートフォリオのアクティブウェイトで加重合計し、その平方根をとったもの^{*4}である。2019年に入り、複数のファンドが一定のレンジ内のリスクに納まっていることが見て取れる。これは、各ファンドのポートフォリオのアクティブリスクが類似していることを表している。これについては、2019年の市場環境が、リスクを一定程度に抑えたより広範な銘柄への投資戦略を行っている運用の方がパフォーマンス良く、全体的にこの戦略に追随している可能性が高いのではないかという見方がある。いずれにせよ、特定のファクターに依拠した検証とは異なり、運用会社の「特徴や独自性」(クセ)という、よりハイレベルかつ広範な要素を踏まえた分散・収束度検証であり、本実験的取り組みで見られた収束がどのようなリスクを引き起こすかは別途評価が必要となる。また、このような傾向は個別のファンドマネージャーは把握ができず、複数のファンドマネージャーに運用を委託するGPIFのみが把握できる情報である。従って、個別のファンドマネージャーは運用パフォーマンスを最大化するためにベストを尽くしているにもかかわらず、GPIFのポートフォリオ全体として単一の要因に対するリスクが上昇するという事象を引き起こしてしまう可能性がある。もっとも、「特徴や独自性」(クセ)が収束することが必ずしも避けるべきことであるとは限らず、状況によっては、こうした収束を許容する、もしくは敢えて積極的に収束を図っていくと意思決定する局面もあり得る。いずれにせよ、全体の情報を把握してGPIFにとっての運用ポートフォリオの最適化を行うことにも活用可能であると考えられる。

なお、このResemblerベースの分散度検証を更に応用させ、新規委託先のセレクションの際、新規委託先のデータ提供により、「特徴や独自性」(クセ)が既存委託先のどこと類似しているか、現在のマネジャー・ストラクチャーにおいて過度に収束することにならないか、等の視点で考課することも可能になる。この既存委託先との類似性評価においては、その距離感や類似性の要因解析を通じて「特徴や独自性」(クセ)を定量的に評価することが可能となり、従前よりGPIF内で課題となっていた「定性評価の恣意性」の一部解決につながる。AIから要因解析までのシステム化により、新規委託先のデータ提供を通じて多数の候補委託先の定性情報を考課することが出来るようになり、GPIFにおける少数のリソースで多数のセレクション候補の広範な定性情報を公正かつ効率的に評価することに関しても一定の改善を成しうると考える。

^{*4} 既存ツールでは推定トラッキングエラーに相当する。

一方、新規委託先からのデータ提供については、そのデータの重要性や守秘性によりどの程度の粒度で事前解析し得るか、慣習的に月次や四半期といった粗い粒度でのデータ提供となった場合でも本研究で用いた手法で適切な出力が得られるかについては引き続き検討を重ねる。仮に詳細なデータ提供を得られない場合でも、データサイエンスの分野で培われたきた様々な技法を駆使することで、完全な形ではないにしても、ある側面での実用に耐える出力が得られる可能性はあると考えている。



図 20: 実績トラッキングエラーの推移

4.2 アクティブ運用の「ウデ」評価

GPIF では全資産の約 2 割をアクティブ運用機関に委託して運用しているが、2014～2016 年度の 3 年間で目標超過収益率を達成したファンドは少数にとどまる。この原因としては主に、GPIF の選定能力の問題に加え、アクティブ運用機関側には目標超過収益率の設定が適切でないもしくはキャパシティ管理より受託残高の増大に注力している等の可能性が考えられ、従来の固定報酬や緩やかな実績連動報酬の仕組みを改め新しい実績連動報酬を導入するなどの対応をとっている [13]。

では、そもそもアクティブ運用ファンドマネージャーは狙った通りにパフォーマンスを出しているのか (実力)、それともマーケット環境などの影響によりリスク管理などの要因で保有していた銘柄でリターンを得ているのか (偶然)、その「打率」を表示し、アクティブ運用のパフォーマンスが実力によるものか偶然によるものか、「ウデ」を評価する実験的取り組みを行った。

図 21a はある国内株アクティブ運用ファンドのアクティブウェイトを SOM により表している。

第 2.2 節で述べたように、TOPIX の全銘柄が一定のルールに従って類似しているもの同士が近くなるように二次元マップ上に配置されている。クラスタリングされる銘柄間のマップ上の距離に意味があり、縦軸と横軸自体には意味はない。当該ファンドがオーバーウェイトしている銘柄は赤、アンダーウェイトは青となり、色の濃さがそれぞれの強さを表す。図 21b は同ファンドのアクティブリターンであり、図 21a と同じ個所でプラスリターンが出ていれば赤、マイナスリターンが出ていれば青となる。つまり、この 2 つのマップを重ねることにより、アクティブウェイトの高い銘柄でアクティブリターンが出ているかを検証できる。同ファンドは、図 21a より、右端と左端の真ん中程にアクティブウェイトを高めにとっている。図 21b と重ねると、同箇所ではプラスおよびマイナスリターンの両方が見られる。一方、図 21a の中央箇所はアンダーウェイトしているが、図 21b ではおおよそのリターンが出ている。なお、これらの図はあらかじめ指定した特定の期間の結果のみを表しているが、時系列を追ってその推移を分析することも可能である。

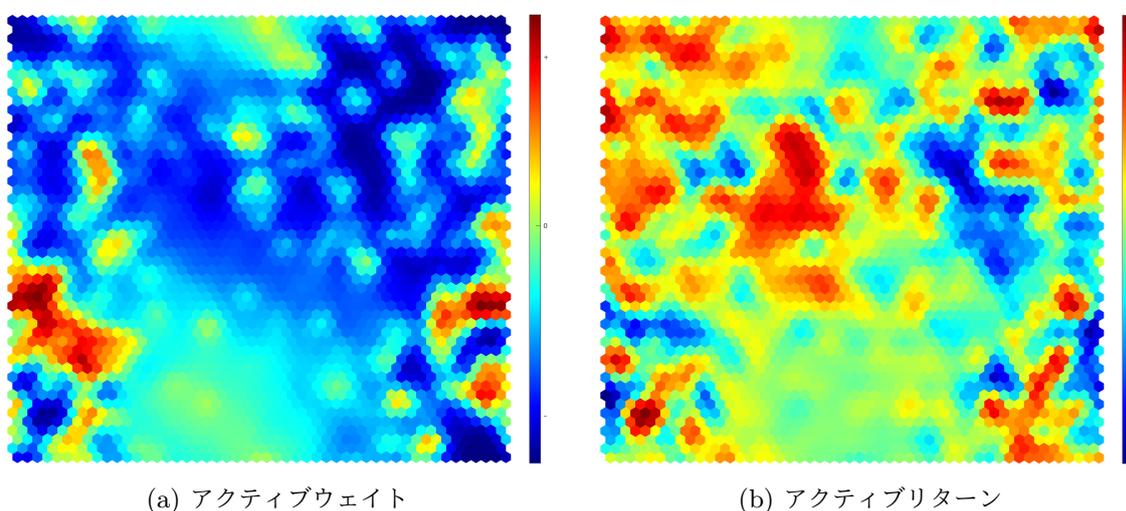


図 21: SOM 上で見るアクティブウェイトとアクティブリターン

次に、アクティブウェイトを以下のように分類し、それぞれのリターンの出方を分類した (図 22) :

- 意図的なアクティブウェイト: ファンドのアクティブウェイトの分布のうち、アクティブウェイトの絶対値が大きな値を取る領域で、ファンドマネージャーが自身の戦略に照らし合わせて有望な銘柄として投資判断を行った領域である。GPIF による運用は原則としてロングポジションのみが可能となっていることから、意図的なアクティブウェイトのうち、正の値をとるものは「意図的なオーバーウェイト」、反対に負の値を取るものはオーバーウェイトの代償として大きくアンダーウェイトした領域である「意図的なアンダーウェイト」の 2 つに区分される。
- 意図しないアクティブウェイト: ファンドのアクティブウェイトの分布のうち、意図的なアクティブウェイトとは反対に、アクティブウェイトの絶対値が小さい値をとる領域を指す。

これは、ポートフォリオのリスク管理の観点から結果として保有する保有比率が小さい銘柄、もしくはポートフォリオでは保有しないがベンチマークに含まれる銘柄により結果として負のアクティブウェイトを取ってしまう領域。この「意図しない」アクティブウェイトについてのパフォーマンスは、正負を合算して算出する。

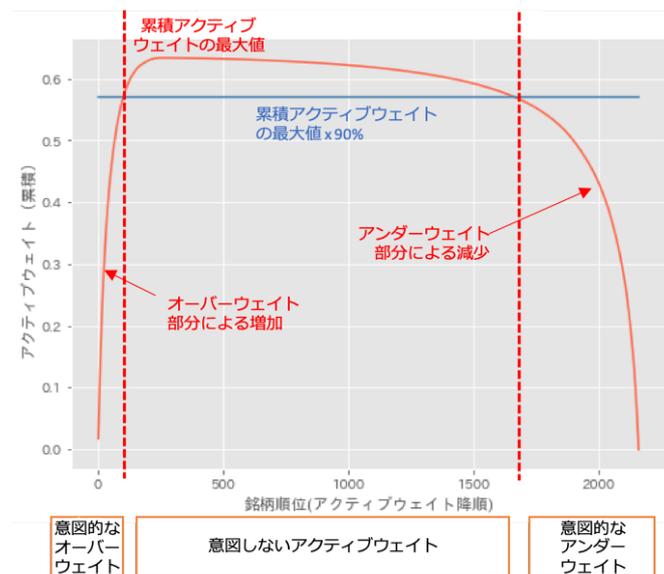


図 22: 累積分布を用いた「意図した・しない」領域の決定

ファンドマネージャーの意図の強さについては以下のような形で算出した。

- 当該ファンドのアクティブウェイトを計算し、符号を含めて大きい順に並べる。
- アクティブウェイトを累積していくと、まずは、ゼロから始まってオーバーウェイトの累積によって増加する。最大値に達した後、アンダーウェイトの累積により減少に転じて、最終的にはゼロに戻る。
- 累積分布の最大値に対して便宜的に 90% の水準以下に該当する左右の領域に含まれる群を「意図的なアクティブウェイト」を取って保有する銘柄群と定義する。水準については運用方針 (集中投資やクオンツ運用等) やアクティブリスクなどを考慮し状況に応じて適宜調整することを想定している。

このようにして得られたものが図 23 であり、上記の定義に従い左側を意図的なオーバーウェイト、右側下を意図的なアンダーウェイト、それ以外の青点線で囲んだところを意図しないアクティブウェイトと分類する。

この方法論に基づき、日々のアクティブウェイトに対する日次リターンを求め、ポートフォリオ全体で各々の領域に対する質的な結果 (勝率)、量的な結果 (パフォーマンス) を算出し、スキル水準を計測したのが図 24 である。

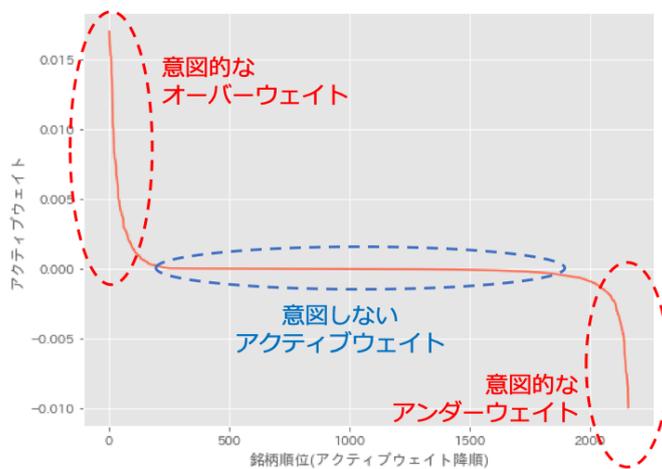


図 23: アクティブウェイトにおける銘柄順位

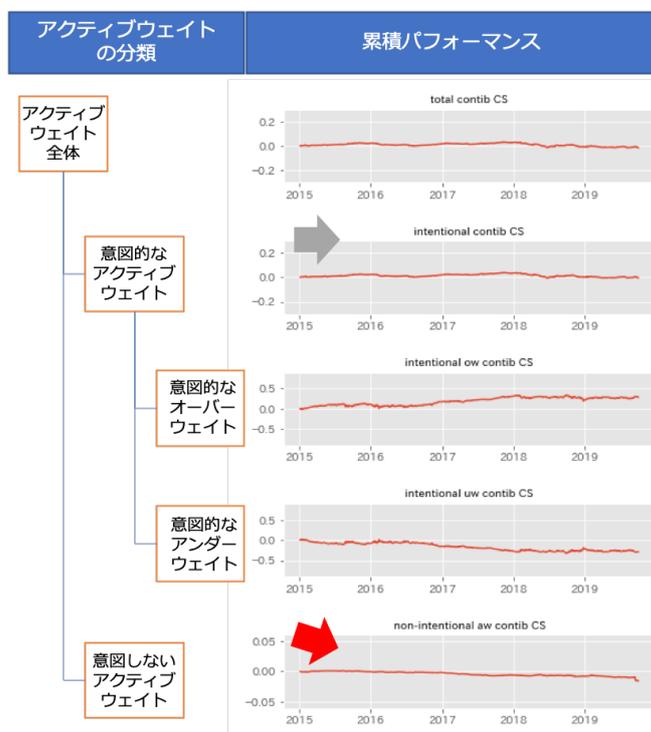


図 24: 累積パフォーマンスの分解

上記計測結果の「意図的なアクティブウェイト」および「意図しないアクティブウェイト」に着目すると、「意図的なアクティブウェイト」では中庸なパフォーマンスであるが、「意図しないアクティブウェイト」はややマイナスリターンが出ており総じて中庸なパフォーマンスとなっている。つまり、狙った銘柄でプラスリターンが出てない一方で意図せずややマイナスリターンが出ており、実力という観点では中庸かややマイナスという評価が出来る。

この実験的取り組みの狙いは以下のとおりである。

- 運用報告のときに、パフォーマンスが良好な場合には自身の実力によるものと誇示し、逆にパフォーマンスが悪い場合には市況など自身ではコントロールできない外部環境に原因を帰して偶然として説明する心理的なインセンティブが運用委託先には働く。短期的な視点では一定の説得力があるものの、長期的な観点での妥当性検証が難しいとのことから、一定のルールの下、意図した/意図しないアクティブウェイト毎のリターン評価を長期に渡り捕捉することが可能な方法論を用いることにより共通の土俵でレビューを行い、また委託先も今後の改善策を考えるにあたっての現状把握の材料を提供し得る。
- アクティブ運用のリターンの出方に関してテキストベースの委託先レポートや既存ツールだけではその妥当性が判断しにくい場合があることを知り、SOMを通じて特徴量を通じた可視化を行い、個別銘柄の情報だけでなく、リターンの出方をドメインとして把握することで、パフォーマンスの要因に対する認識をより高度な概念で共有の上、協議出来るようになる。

これと併せて、昨年度の調査研究に対し「パフォーマンスとの関連性があるとよい」とのフィードバックもあり、Resembler ないし SDA と本節で取り扱った「ウデ」評価の組合せにより、運用会社の「特徴や独自性」(クセ) 一貫性の有無とウデの良し悪しを組み合わせた観点で委託先の評価やセクションにおける、従来と異なる視点での検討材料となることを期待している。本取り組みは、GPIF および委託先のリターン評価方法論を一層把握の上、必要に応じて深めることとしたい。

5 AIにより真価を発揮する GPIF

試験活用の結果や実験的取り組みを踏まえ、AIにより GPIF の現場はどのように変わり得るのか、更には GPIF はアセットオーナーとしてどのようなことを実現しうるのか、現場レベルとマネジメントレベルの2点について考察を加える。

5.1 GPIF 現場の変革

GPIF 担当官の声

試験活用および実験的取り組みにおいては GPIF 担当官と実務レベルでの要件を密に詰めながら進めており、GPIF 内において AI に期待すべきこと、活用すべき対象のコンセンサスが醸成されつつある。このプロセスを通じて、GPIF 担当官から活用によるベネフィットおよび応用発展により期待されることについてフィードバックを得ている：

- モニタリング情報量のアップ
契約書（ガイドライン）に記載されていない組織情報であっても変化があれば AI が捉えてくれるので、GPIF のモニタリングの質向上に資することが期待される。
- 既存運用者評価の効率化
従来ファンドリサーチャが人力で行っていた評価レポートの一部を Resembler による評価で代替する。
- 予測ベースのモニタリング
Resembler の応用により、マーケット環境に応じた運用者の行動予測を行えば、当該運用者とのコミュニケーション準備になるし、ポートフォリオのストレステストとしても活用できる。
- 新規選定の自動化
新規運用候補でも既存運用者と同種・同量のデータを提供さえしてくれば、契約に至っていない段階からファンドのモニタリングを行うことが可能になるので既存取引先との情報格差がなくなる。これにより、入れ替え予定の運用者のクセを事前に把握し、運用が不冴えだった既存の運用者の Resemblance に近い挙動の運用者を避けたり、また、現在のポートフォリオにはないエッジの効いた運用者を精査することができることが期待される。
- モデル運用者の複製
Resembler データを多数蓄積すれば、理想的なクローン運用者を複製できるかもしれない。そのモデル運用者をベンチマークにして、既存マネージャーの採点や新規マネージャーの選定に活かすことができると考える。

AI による GPIF 現場力の強化

2017 年度の調査研究では、GPIF のマネジャー・ストラクチャーにおけるマネジャーの運用行動が当初申告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か警戒すべきか等のより精度の高い検知を AI 活用の方向性とした。それに続く 2018 年 10 月からの研究では、運用機関の選定プロセスにある投資方針、運用プロセスおよび組織・人材といった定性評価を重視する一方で、平成 29 年度経営委員会議事概要の「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」ないし GPIF 担当官からの「定性評価に際して属人的プロセスに大きく依存」といった問題意識の解決、および、その問題意識を具体化した。この問題意識を踏まえた AI 試験活用の結果を受け、GPIF の現場は次のような変革が期待される：

- 委託先とのより建設的かつ効率的な対話の強化
 - － 委託先からの報告にある運用行動に関する変更内容の検証
 - － パフォーマンス改善を要する委託先における改善実行度合いの確認
 - － (報告義務の有無に関わらない) 未報告内容の検知
 - － 海外委託先に関しては、ゲートキーパーからの報告に加え、データを通じた海外ファンドマネジャーの投資行動の直接的な捕捉
 - － 上記実現による委託先の報告コストの一部削減または Call 時間などの削減
- GPIF に蓄積された膨大かつ豊富なデータ活用によるスキルの平準化/コモディティ化
 - － GPIF 内蓄積されたデータの AI 出力により、従前にはない視点かつ独自の仮説を豊富に構築
 - － AI から業務システムまでのインテグレーションにより、経験年数ないしキャリア背景といった属人性に依拠せず、一定品質レベルで対応

5.2 「魅せるクジラ」

ロングテールの伸延

既存契約者は、アセットオーナーとの付き合いを通じたノウハウなどの関係性という財産に依存してきた。またアセットオーナーも、付き合いのある先なら新規先よりも信頼できると感じてしまう信頼バイアスに漬かっていた。しかし、今後本研究が実用化されたら、契約関係がない候補先であっても、既存と同じレベルのデータを提供できる限り、GPIF にとっては同等の存在になり、両者に情報格差がなくなる。そうなると、GPIF と既存委託先であるアセットマネジャーの担当者間で築かれる長期的なりレーションシップの有意性はなくなるかもしれない。従来アセットマネジャーは一度関係性を築くとそれを維持するための担当者を置き、各種情報提供などを補完的にこなうことで他社との差別化を図ることで地位を守ろうとしてきたが、そのような努力の価値は下がってしまうことが見越され、ビジネスモデルの変革につながるかもしれない。逆からみれば、新

規先にとって GPIF と取引を開始するときの参入ハードルがなくなり、GPIF へのアクセスがより広がることとなる。

従来、GPIF との取引ではレポートニング負担が大きく、リソースに限界のある小規模運用者にとって参入障壁になっていると言われてきたが、AI からの出力によってレポートの大部分が代替されるともはやレポート作成は負担とならなくなり、運用力や手法をよりアピールすることが出来るようになる。既存の運用者であれ新規参入希望者であれ、レポートニングに費やしていたリソースを運用の高度化・強化に振り向けることが可能になるはずであり、運用業界全体にとってメリットになるのではないか。

“Moneyball”

GPIF を含めたアセットオーナーは、多数の既存運用委託先のパフォーマンス・取引等の運用実績データに加えて、外部ベンダーやコンサルティング会社から提供される市場情報、運用商品情報およびベンチマーク情報なども収集できる立場なので、多様で大量のデータ蓄積という観点ではアセットマネジャーを凌ぐ立場にある。今後、AI 利用がますます活発化するとデータ優越者ほどより有意義な分析結果を導き出せる世界となり、アセットマネジャーよりもアセットオーナーのほうが情報有利になろう。

これは、今までアセットマネジャーの方にプロフェッショナルとしての専門性がありアセットオーナーは情報劣位者とされてきたパラダイムが変わることを意味する。今後、AI をはじめとする金融にとどまらない様々な統計的手法 (metrics) を用いて運用業界を網羅するデータを解析し、従来の価値観に必ずしも依拠しない「マネジャー・チーム」が編成されうる。さらにはこの解析を行う “GPIF-metrics” に惹かれた若者やプロフェッショナルのキャリアにも影響あると考えられ、大変興味深い。

6 今後の研究内容

2018年10月より開始した研究当初は基礎研究・調査的側面が強かったが、途中から試験活用という応用フェーズにシフトした。その応用フェーズでは基礎研究や調査では得られない現場からの数多くの示唆や解決すべき面が非常に明確となり、今後は「試験活用の拡大」・「試験活用結果を踏まえた深化・改善・具体化」・「技術基盤の整理や統合」の3点を並走していく予定である。

「試験活用の拡大」

本中間報告書は2019年10月末時点のものであり、この時期までは月次で日本株の Resemblem および適宜 SDA 出力を行い、当社が毎月の変化検知と変化検知の要因分析を行い、GPIF 担当官が内部検討と委託先と対話を行ってきた。今後は日本株に加えて外国株、かつ Resemblem のみ毎月対応していたが SDA の出力も合わせて行う。

「試験活用結果を踏まえた深化・改善・具体化」

- AI 変化検知の要因解析出力法の改善および深化：AI (Resemblem および SDA) で変化検知した後の工程として変化検知に対する要因解析がある。その解析手法の1つとして SOM やクラスタリング等で出力してきたが、その評価や解釈は一定の専門性を要し、現場活用において学習コストが発生する。要因解析の出力のインターフェイスにおいても、より視覚的かつ直感的に理解可能なものに改善していく。合わせて、SOM に関しては投資銘柄の変化を解析するために今回活用してきたが、更にその銘柄変更はどのような背景があり変化に至った（例えば、将来成長見通しが大きく変化）かまで深められないか研究を進める。
- 最終出力内容の具体化および整理：AI 変化検知の要因解析の後に、要因解析に基づく変化に関する要点の明示がある。GPIF 現場からは、「委託先とのより建設的かつ効率的な対話の強化」の実現のため、より明示的な要点が必要とのフィードバックを得ている。例えば、「先月 A 銘柄を購入したことはこれまでの投資行動から違和感ありと判定」、「成果が芳しくない B 銘柄への投資を放置していることが、過去の運用行動のパターンと整合しない」などといったレベルにまで具体的なコンテキストとして委託先との対話を深めることを想定している。AI 変化検知から要因解析までの出力をどのような形式で最終出力するか様々なケースがありうると想定しており、その中でも対話内容として従来対応しきれなかったもの、高頻度で発生しうるもの、等の優先度に基づき必要と想定される業務・情報処理システムとのインテグレーションについて整理していく。
- 学習期間の整理：Resemblem 試験活用において GPIF および委託先から、その学習期間について確認を受けた。本報告書では、入手可能な全データに基づき学習してその稼働可能性や出力内容をハイレベルに確認してきたが、活用を深めるにあたり学習期間は目的に応じて整理する必要がある。

- ユニバースの動的変更への対応：現状の SDA や Resembler ではニューラルネットワークの各入力ユニットに固有の銘柄を結合させているため、訓練の時点では存在しなかった新規上場銘柄の登場に対応できない。市場に大きな影響を及ぼし得る時価総額が大きな銘柄が新規上場した場合に、特に SDA の出力が実態と解離する可能性がある*5。こうした問題点の解決のために、ニューラルネットワークに入力として与えるデータ構成に工夫を施す必要があり、その方法について模索していく。
- SDA 改善の継続：Resembler は従来のツールとは異なる観点でのファンドの特徴を出力するものであるが、この出力の妥当性を論じる上で、コアとなるシステムを共通して持つ SDA の動作の妥当性の確認は欠かせない。したがって、SDA に関して、その動作原理の確認は済んだものの、訓練に用いる VFM の仮想データにはまだ改善の余地が残されているため、試験活用でのフィードバックも取り込みながら継続的に改善していく。また、単に Resembler の妥当性の裏付けのためだけでなく、SDA そのものとして従来にない視点を提供するツールとして活用できるよう、その完成度を高めていく。
- セレクションへの応用活用時におけるデータ粒度：Resembler は自社の変化をとらえるだけではなく他社との類似度との距離感も測定可能であり、セレクション時の 1 つの情報として検討しうる。一方、現在の Resembler は日次データで出力しているが、新規委託先からのデータ提供については、そのデータの重要性や守秘性により月次や四半期といった粒度でのデータ提供の可能性はある。この場合、Resembler が適切な出力をし得るかについては引き続き検討を重ねる。併せて、仮に粒度の荒いデータ提供となった場合でも、データサイエンスの手法を駆使して一定程度の品質を保つ出力が出来るよう、この観点でも実験を継続する。

「技術基盤の整理や統合」

2017 年度の調査研究来、数多くの試行錯誤かつ応用的発展や高頻度な改善により研究を続けてきた。本報告書で論じた内容は現状それぞれが個別に稼働し、かつ一部は原理試作レベルのものもある。一方、上記の「試験活用結果を踏まえた深化・改善・具体化」を今後対応し、AI 検知から最終出力、そして GPIF が活用可能とするためには、シームレスにインテグレートする必要がある。これまでの基礎研究から応用活用に向けて、AI や要因解析のプログラム、データクレンジング手法やデータベース構築をはじめ整理・統合する。本対応は、新規開発や試験活用対応と同等またはそれ以上に時間を要するものであり、残期間で然るべき対応をしていく。

*5 Resembler に関しては、過去の自分の「独自性と特徴」(クセ) との比較のため影響は限定的と思われるが、それでも、ユニバースにこれまでに無かった銘柄の登場というイベントの数が重なれば、どこかの時点でその影響は無視できなくなる。

7 本研究を通じての所感

日本発 3 社による初の AI 試験活用の実現

昨年度からの調査研究において常に対応に工夫が必要であったのはデータ関連である。このデータ処理において世界トップレベルの計算処理能力をもつ産官学共同の産総研 ABCI は本研究に大きく貢献している。世界最大の公的年金基金の GPIF、産官学共同の産総研 ABCI と AI に関する長年の基礎研究および応用成果をもつソニー CSL というユニークネスの高い日本発の 3 者の組合せにより、基礎的な研究にとどまらず、世界でも例を見ない巨大な公的年金基金における AI による株式アクティブ運用の行動を検知するという試験活用が実現した。

アセットオーナー間のグローバルデータコンソーシアム組成

本研究は GPIF からの受託で行っており、その研究成果は第一に GPIF に寄与すべきものである。一方、アクティブ運用の委託先の評価はどのアセットオーナーにも共通した課題であり得る。共同活用の一案として、4.1 節にて実験的取り組みとして論じた Resembler の分散度・収斂の検証の手法をマネジャー・ストラクチャーに適用することなどが考えられる。

世界の資産運用におけるアクティブ運用額は 2020 年に 74 兆米ドル、2025 年には 87.6 兆米ドルに達するといわれ [14]、その中で一定の規模を占める国内外アセットオーナー同士のデータコンソーシアムを組成し、そのデータベースから Resembler によるアクティブ運用ファンドの運用行動の収斂度を出力することにより、各アセットオーナー内に閉じたマネジャー・ストラクチャーのリスク評価だけでなく、各運用局面でアクティブ運用ファンドの運用行動について、グローバルアセットオーナーレベルで俯瞰できる。1 つのアセットオーナーのマネジャー・ストラクチャーでは投資行動が分散しているようでも、グローバルデータコンソーシアムでは収斂が見られ、世界のアクティブ運用市場で局所的リスクが高まり、最終的には各アセットオーナーにとってもリスクとなりうる、という汎オーナー的リスク検知である。

市場レベルでの検知はナスダックで行われており、市場取引での不正行為検知の深層学習システムを導入、統計やルールを利用して市場の不正行為の兆候を警告する既存のソフトウェア監視システムに追加する形で取引を監視し、人間のアナリストと協働することで、不正行為の検知能力を漸次高めていくという [15]。

「地震が起きてクジラが騒ぐのか、クジラが騒いで地震となるのか」。公的な機関、超長期投資といった同様の役割を担う法人であればこの問題のメカニズムや予兆検知は大きな関心事と考えられる。かつこの大規模な取り組みはアセットオーナー間での協業が必要となる。GPIF、産総研およびソニー CSL による、日本発のユニークネスの高い 3 者による AI 活用が、同目的のアセットオーナー間によるグローバルデータコンソーシアムの組成により、市場の本質的な問題解決に更に発展することを提言したい。

今回の AI 活用に対する学術的見解の余地

昨年度の原理試作による基礎研究から、試験活用という応用にシフトし、その基礎と応用の間にある多く広くそして深い距離感を埋めるため、現場に根付いた作業工数に時間を費やす傾向が高まっている。一方、今回の研究で試験活用を開始した Resembler による運用会社の投資行動の検知において、従来はファクターといった線形モデルにより解釈していたのに対し、今回は非線形モデルによる包括かつより実態に即した検知が可能との想定に基づいている。例えば、投資行動における線形モデルまたは非線形による検知に関する学術的見解はもう一段の深い議論を要すると考えている。その他、日々の試験活用の準備の中で整理しきれていない、学術的に議論を深める余地がある論点が残されている可能性がある。

AI に仕事を奪われるか、AI に仕事を任せるか

本研究は試験活用レベルであり本格活用までに対処すべき多くの事項はあるが、今後、試験活用を継続することによりその事項は具体化し、本活用の実現までのロードマップが徐々に見えつつある。今後この AI システムが実現した場合、GPIF において多くの工数を割いてきた、株式アクティブ運用ファンドのセレクション、モニタリングや評価の業務の一部は AI が担うことになる。合わせて運用会社は GPIF へのレポート工数の一部を削減することが可能となる。この場合、これらの余剰工数はどのようになるか。

「AI に仕事を奪われる」といった刺激的な論評では、この余剰工数は人員削減、つまり人件費削減として処理されることになる。一方、例えば銀行業界において、かつては数値計算に多くの人員工数を割いてきたが、勘定システムの発展や導入により同計算はシステムの的に正確かつ迅速に処理されるようになった。これにより余剰となった工数、顧客対応の充実、新商品の開発や年々複雑となる様々なリスク対応に当てられた。

人間と AI がそれぞれ得意とする領域は各分野にあり、これまで AI 活用されなかったことにより人間が対応してきた業務を AI に任せることが出来るようになった場合、GPIF および運用会社はどの分野に人間の能力をより活用していくのか、AI 導入された際の人材の活用を合わせて具体的検討する時期に来ている。

2017 年度にリリースした報告書に対し多くのフィードバックをいただいた。今回の報告書は中間的なもので仕掛途上を多数含むが、今回も多くのフィードバックをいただきたい。そしてそのフィードバックを踏まえて世界でも例を見ないユニークネスの高い取り組みを Best of Best なものに仕上げていくと同時に、関係各位との議論を深めることにより双方の活動の底上げを図ることが出来たらと考えている。

多忙な業務の中ご対応頂いた GPIF ご担当官各位、高難度な研究を短納期で対応し続けてきた当

社非常勤リサーチャーとアシスタントリサーチャーの皆様、その他関係者各位、ご理解・ご支援・ご協力に対し、末筆ではあるが、多謝申し上げます。

付録 A 分析の全出力

A.1 国内株ファンドの Resembler 出力

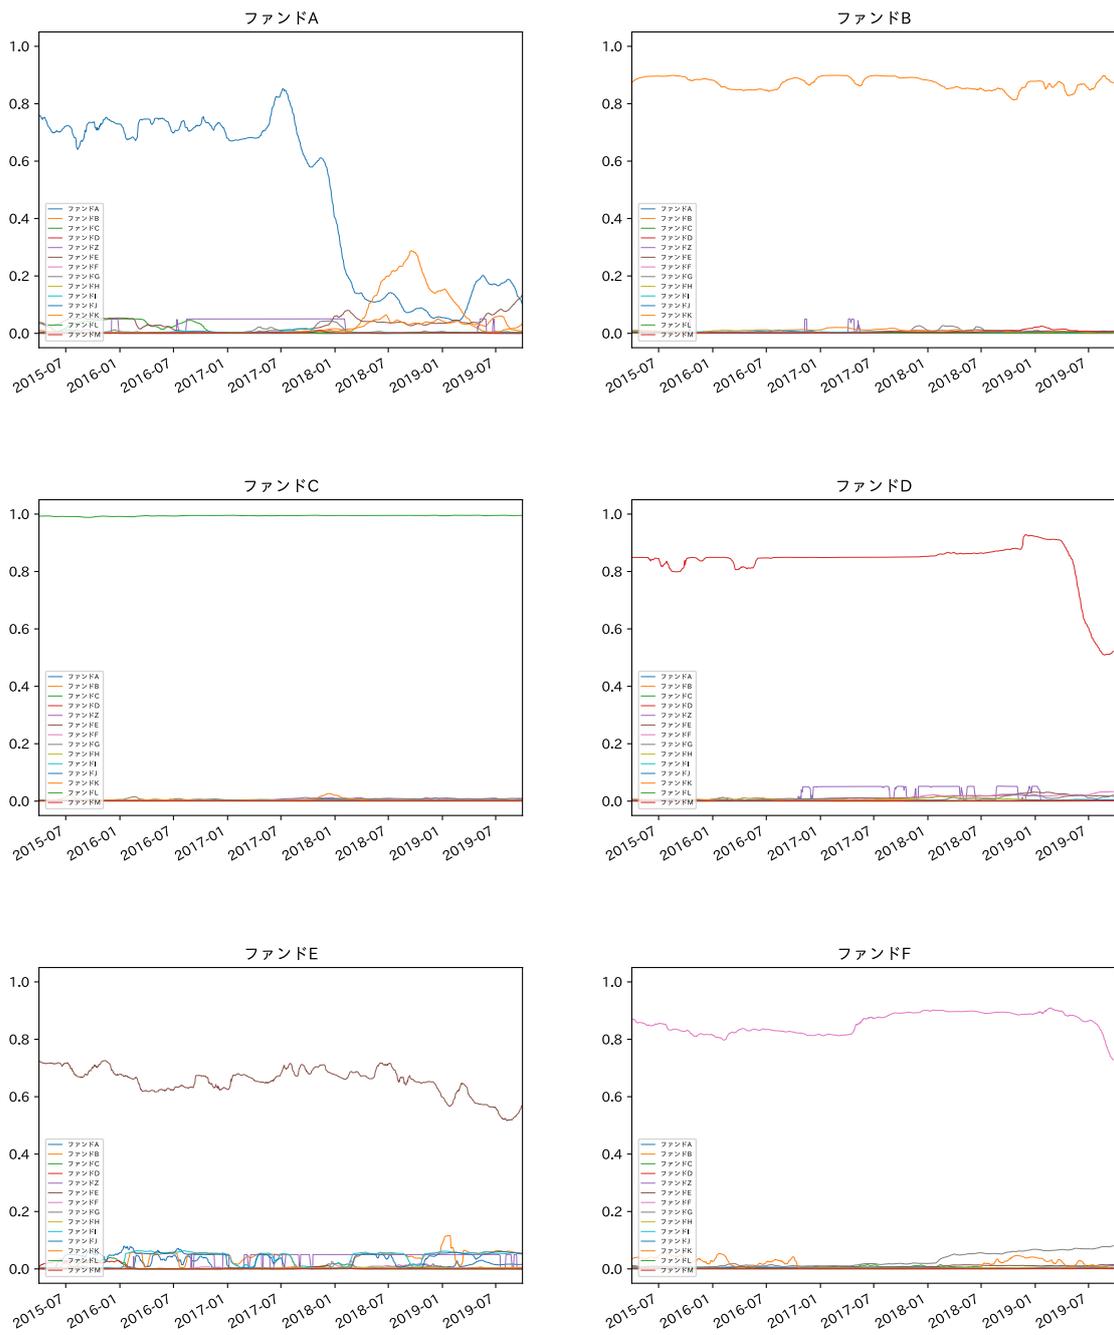


図 25: Resembler 出力 — 国内株ファンド (1/3)

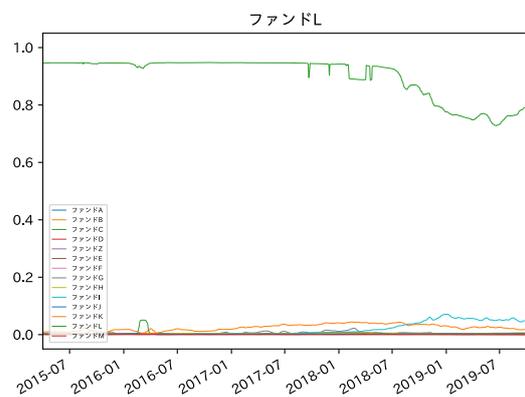
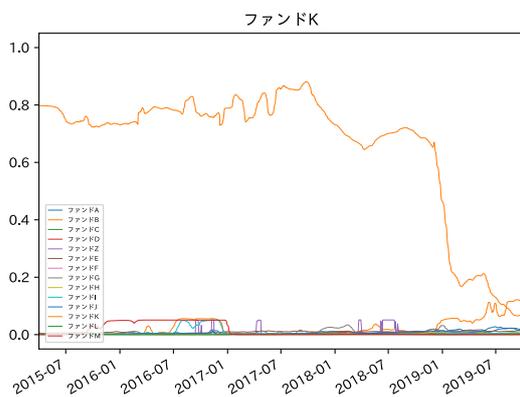
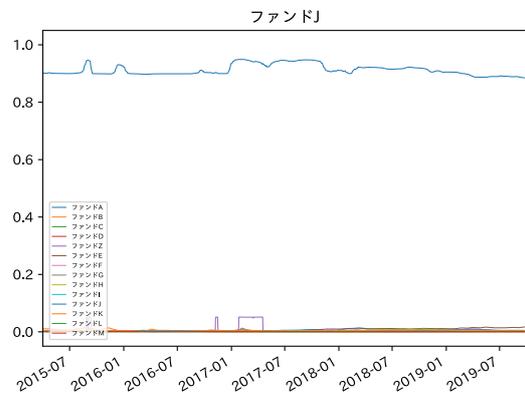
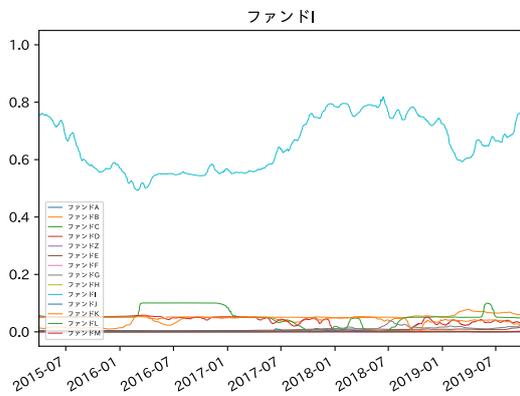
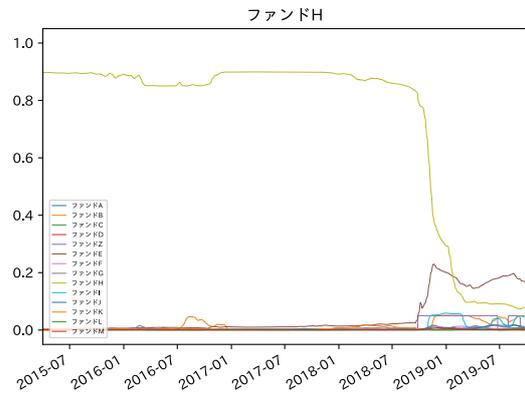
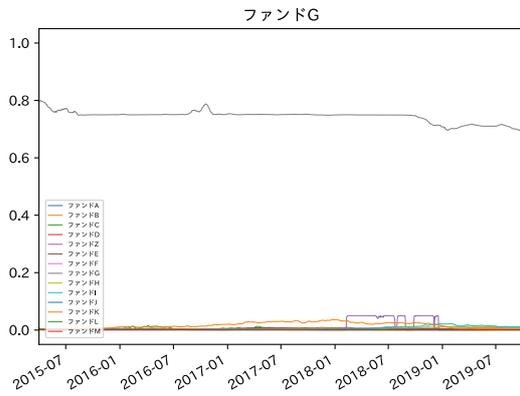


図 25: Resembler 出力 — 国内株ファンド (2/3)

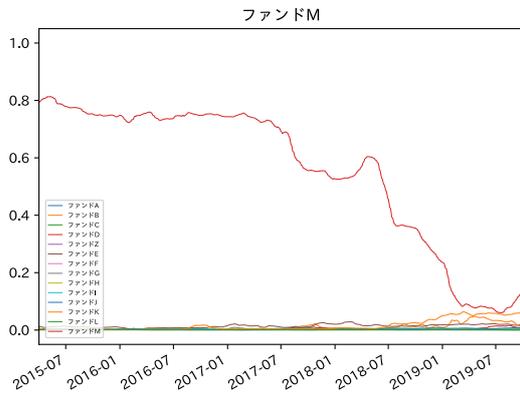


図 25: Resembler 出力 — 国内株ファンド (3/3)

A.2 国内株ファンドの SDA 出力

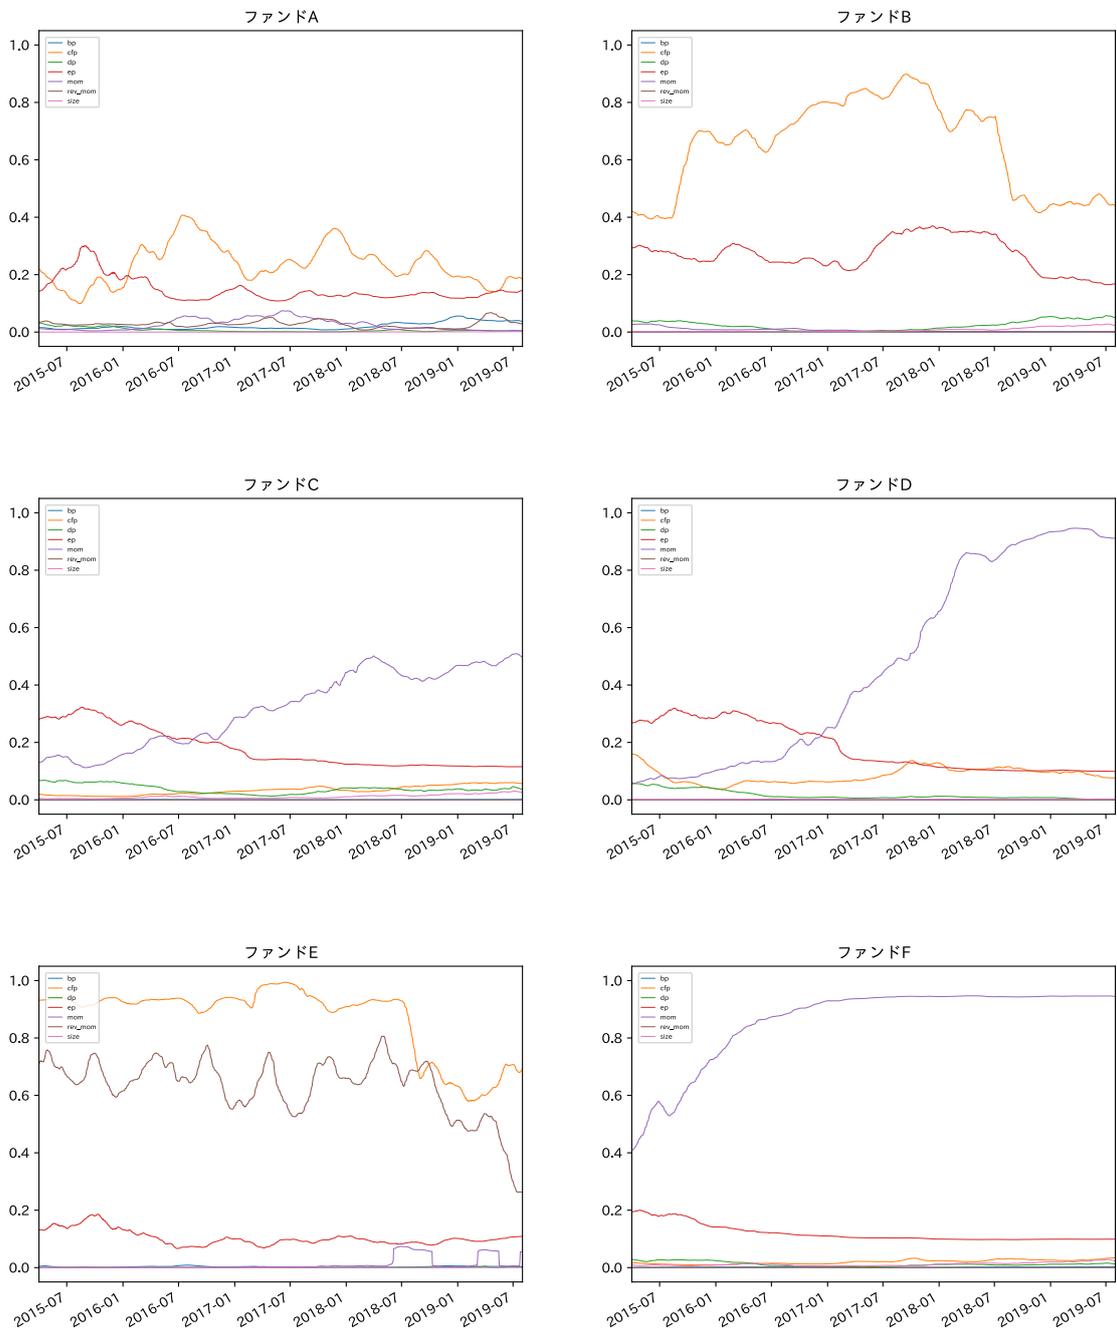


図 26: SDA 出力 — 国内株ファンド (1/3)

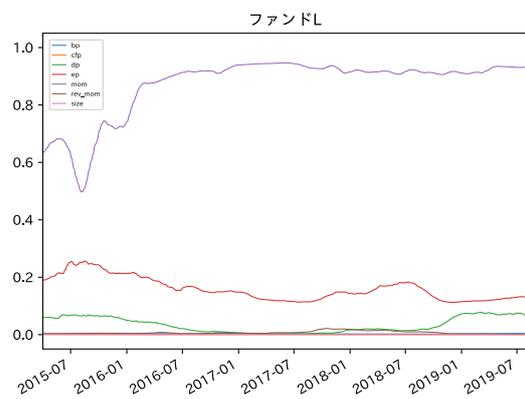
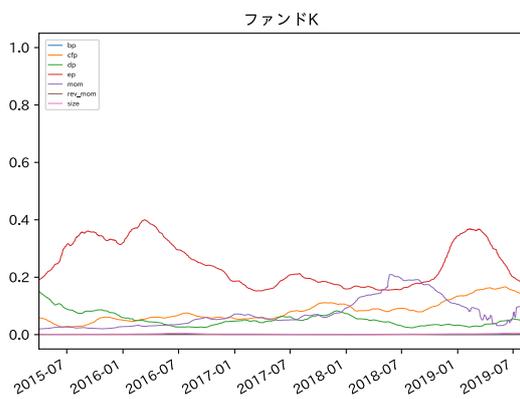
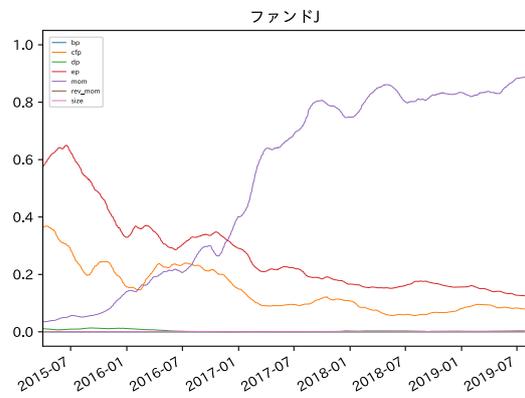
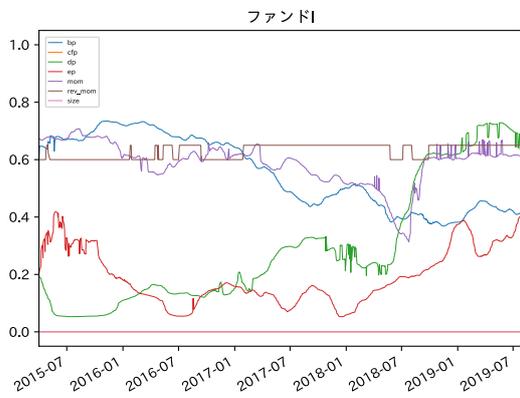
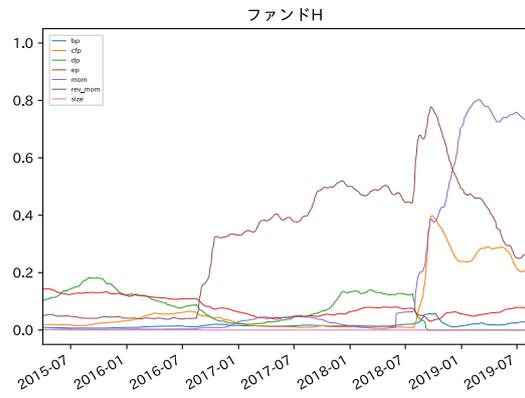


図 26: SDA 出力 — 国内株ファンド (2/3)

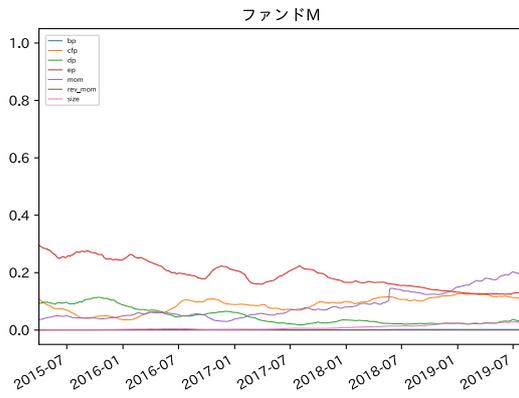


図 26: SDA 出力 — 国内株ファンド (3/3)

A.3 外国株ファンドの Resembler 出力

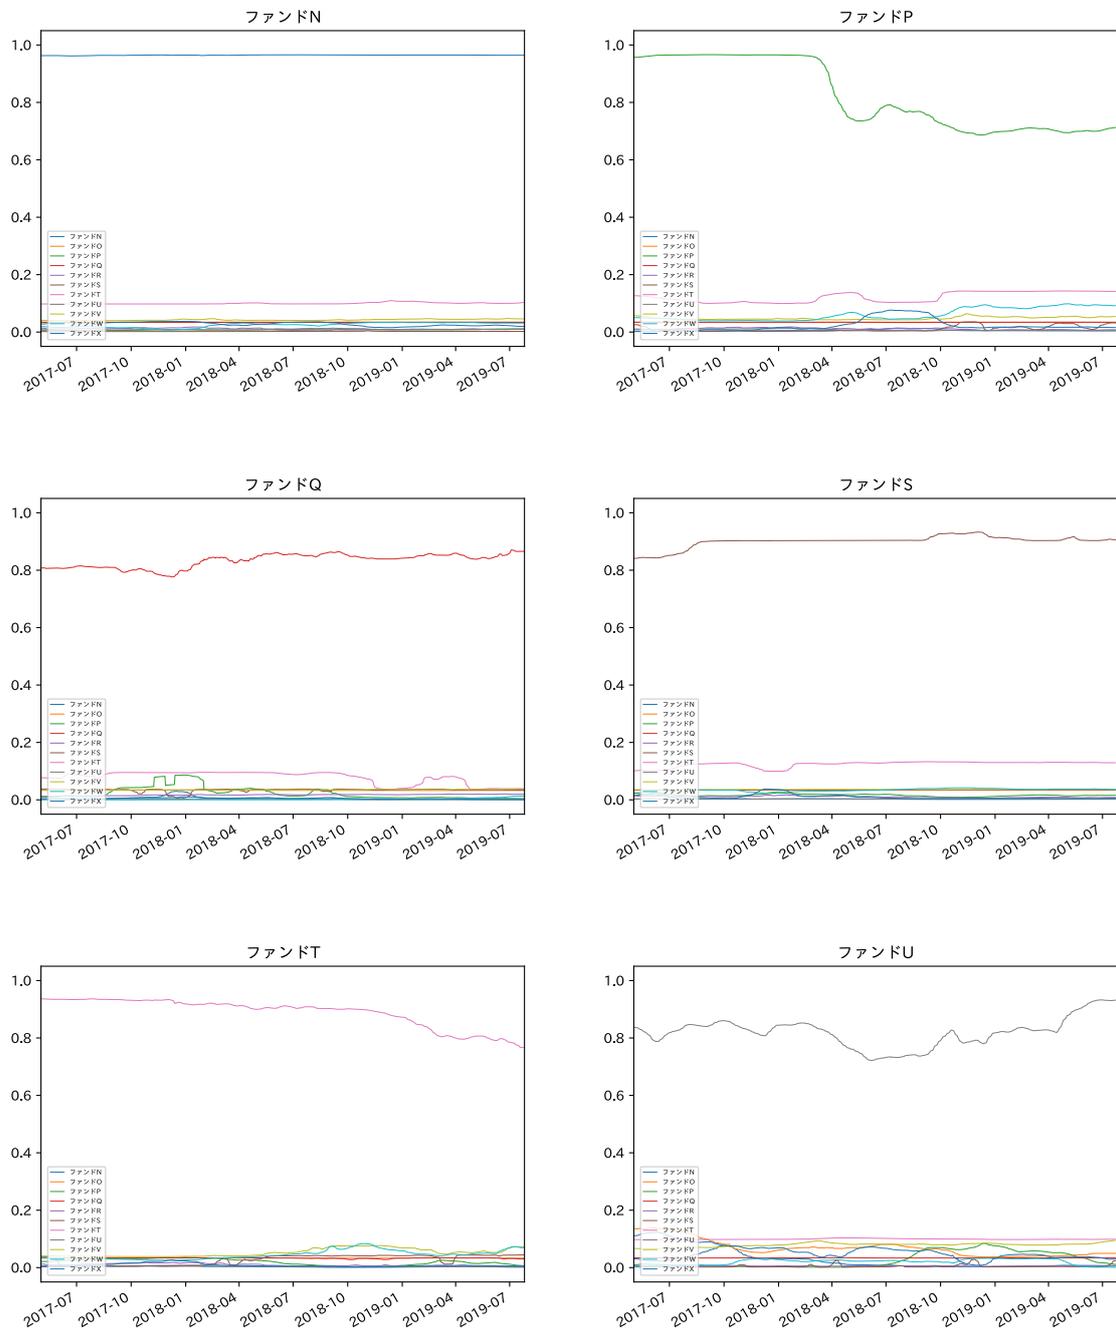


図 27: Resembler 出力 — 外国株ファンド (1/2)

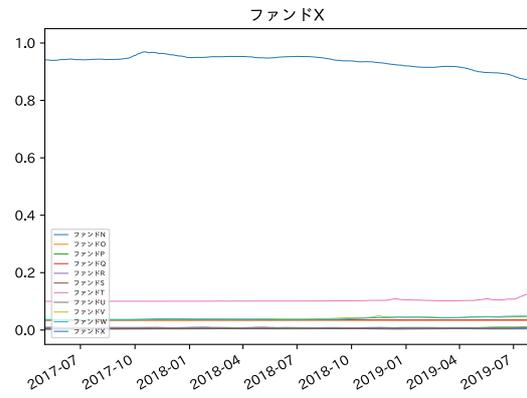
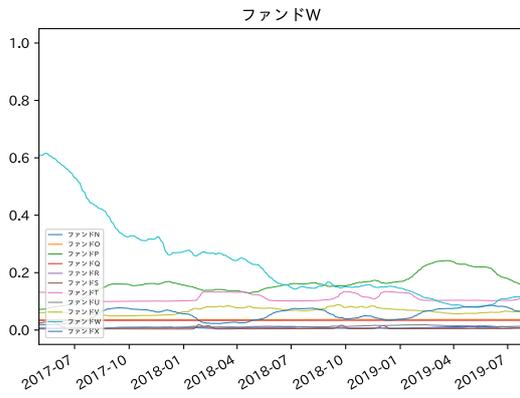


図 27: Resembler 出力 — 外国株ファンド (2/2)

A.4 外国株ファンドの SDA 出力

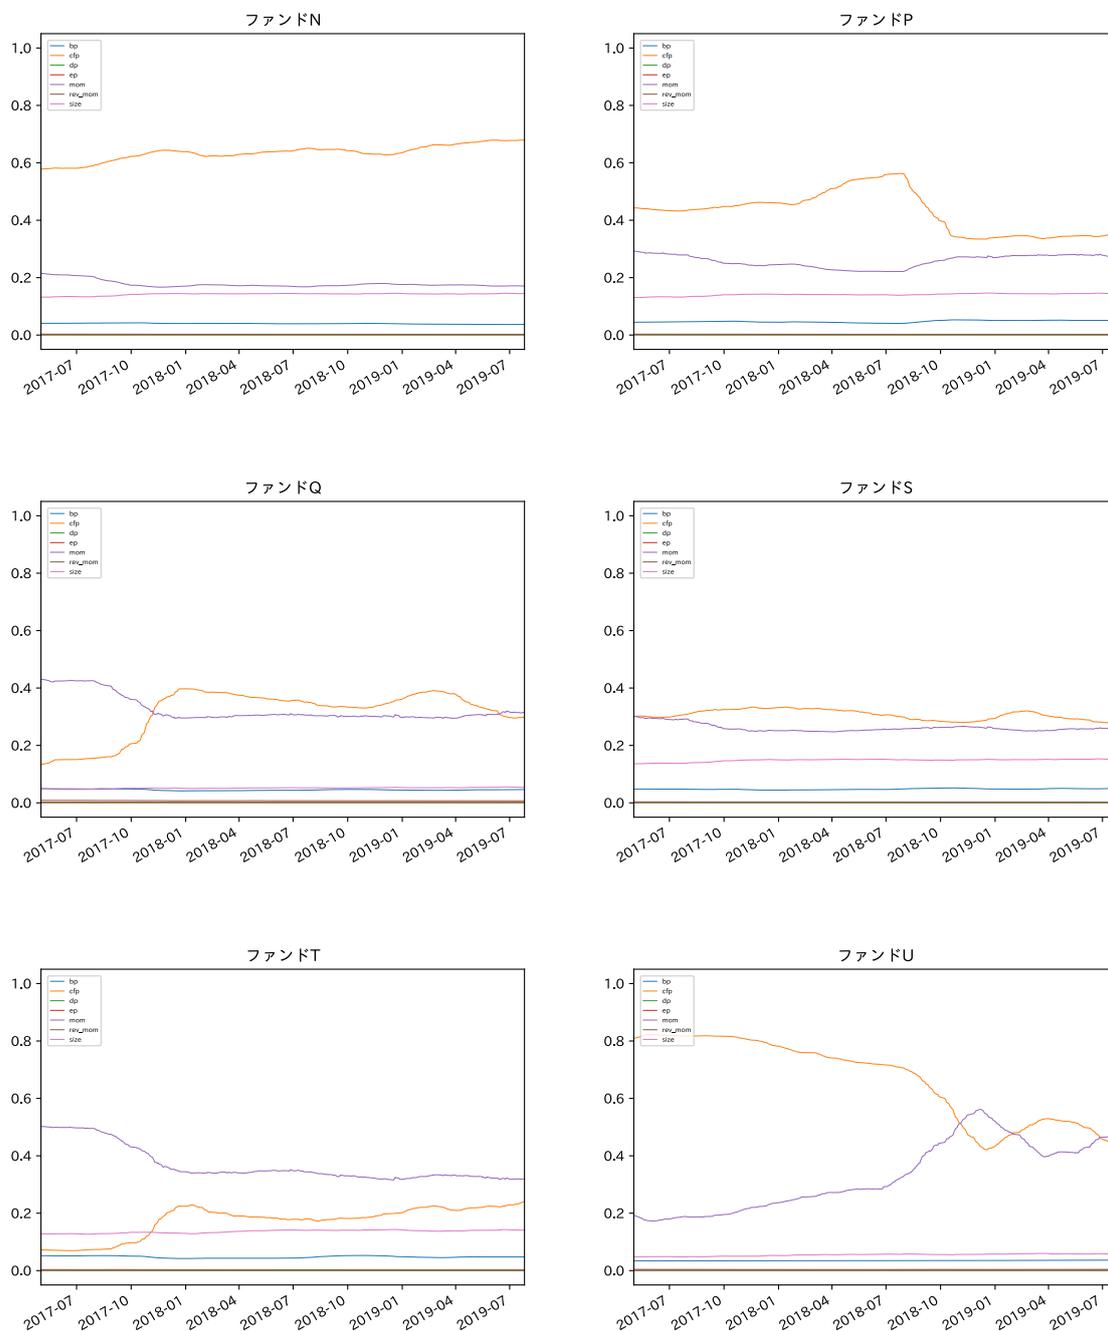


図 28: SDA 出力 — 外国株ファンド (1/2)

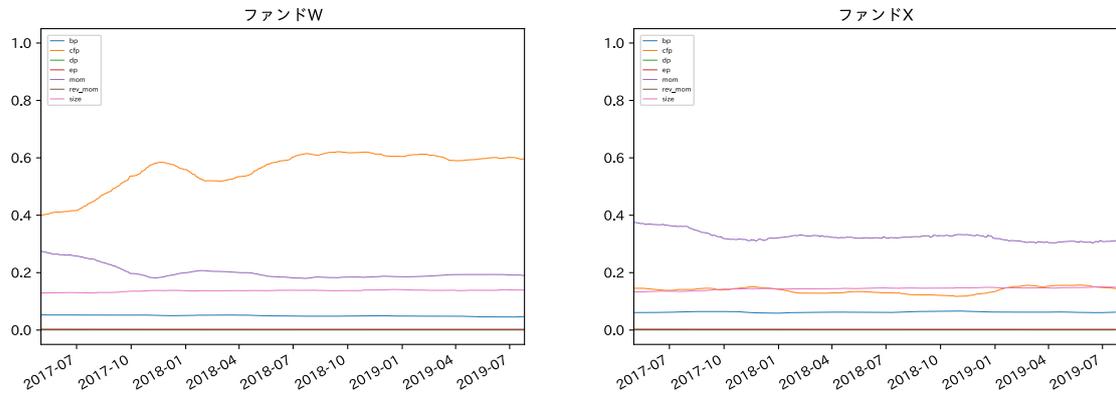


図 28: SDA 出力 — 外国株ファンド (2/2)

参考文献

- [1] Takahiro Sasaki, Hiroo Koizumi, Takao Tajiri, and Hiroaki Kitano. A study on the use of artificial intelligence within government pension investment fund' s investment management practices (summary report). Technical report, Tokyo, Japan: Government Pension Investment Fund, 2018.
- [2] AI Bridging Cloud Infrastructure (ABCI). <https://abci.ai>.
- [3] Fujitsu. Accelerating the societal implementation of AI with AI Bridging Cloud Infrastructure (ABCI) Realizing world-class performance and energy saving with 4,352 GPUs. https://www.gpif.go.jp/investment/pdf/20180611_new_performance_based_fee_structure_jp.pdf, 2019.
- [4] 年金積立金管理運用独立行政法人 (GPIF). 平成 30 年度 業務概況書, 2018.
- [5] G E Hinton and R R Salakhutdinov. Reducing the dimensionality of data with neural networks. *Science*, Vol. 313, No. 5786, pp. 504–507, July 2006.
- [6] Quoc V. Le, Marc'Aurelio Ranzato, Rajat Monga, Matthieu Devin, Greg Corrado, Kai Chen, Jeffrey Dean, and Andrew Y. Ng. Building high-level features using large scale unsupervised learning. In *ICML*. icml.cc / Omnipress, 2012.
- [7] Eugene F. Fama and Kenneth R. French. Common risk factors in the returns on stocks and bonds. *Financial Economics*, Vol. 33, No. 1, pp. 3–56, February 1993.
- [8] Mark M. Carhart. On persistence in mutual fund performance. *The Journal of Finance*, Vol. 52, No. 1, pp. 57–82, March 1997.
- [9] Yi Shang and Benjamin W. Wah. Global optimization for neural network training. *IEEE Computer*, Vol. 29, No. 3, pp. 45–54, 1996.
- [10] 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.
- [11] 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.
- [12] Warren S. Torgerson. Multidimensional scaling: I. theory and method. *Psychometrika*, Vol. 17, No. 4, pp. 401–419, December 1952.
- [13] 陣場隆. GPIF ワーキングペーパー : GPIF の新しい実績連動報酬. Technical report, 年金積立金管理運用独立行政法人 (GPIF), June 2018.
- [14] PwC. アセットマネジメント 2025 資産運用業界における変革への対応, January 2018.
- [15] MIT Technology Review. ナスダックが不正監視に深層学習、アナリストの負

担を軽減 (2019 年 11 月 19 日). <https://www.technologyreview.jp/s/171484/ai-will-now-watch-for-fraudsters-on-the-worlds-largest-stock-exchange/>.

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:

田尻 貴夫

佐々木 貴宏

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