

A I 運用の課題をどう解決するか（下）

～課題と対策～

茨城大学大学院 理工学研究科 教授 鈴木智也

前回の上編（10月2日号掲載）では人工知能（A I）運用の現状や関連する金融業務を整理した。まず、執行業務や売買仲介業務などのトレーディング（アルゴリズム取引）は比較的定型処理のためA Iによる自動化の恩恵を受けやすい。一方、資産運用は高度な投資判断を要すためA Iは人間に比べて優位とは限らない。公募投信においては説明責任の事情によりA Iの活用はオルタナティブ（非伝統的）データの情報処理が主であり、投資成績の不振から逆算するとA Iが人間アナリスト以上の情報力を有するかは懐疑的である。ビッグデータの拡張など今後の発展余地はあるものの、現状においては説明責任より投資成績が優先される私募投信（ヘッジファンドを含む）においてA I運用の成功事例が目立つ。その代表事例を踏まえつつ、A I運用の適用可能性を考察する。

A I 運用の成功事例（海外ヘッジファンド）

■ルネッサンス・テクノロジーズ（Renaissance Technologies）：主に短期運用を特徴とする。創始者のジム・シモンズは翻訳和書「最も賢い億万長者 数学者シモンズはいかにしてマーケットを解読したか」（グレゴリー・ザッカーマン著。2020年、ダイヤモンド社刊）でも有名であり、従業員向けファンド「メダリオン」は常勝を誇る。主な戦略は相場予測でなく、アービトラージ（割高銘柄と割安銘柄のゆがみを狙うペアトレーディング）の様子。勝率は50.75%程度だが、何百万もの短期取引により安定的に50%以上の勝率を実現。より詳細な戦略は秘匿されている。機関投資家向けに大規模化した類似ファンドも存在するが、コロナ禍に運用戦略がメダリオンと異質であることが明らかになり資金流出が続いている。これにより短期運用においては流動性の観点により、巨大な資金を運用する大規模ファンドは不向きだと考えられる。

■ツーシグマ・インベストメント（Two Sigma Investments）：短期～中期運用を特徴とする。運用戦略は短期的なアービトラージやイベント

ドリブンに加え、従来のクォンツ分析やファンダメンタル分析など幅広い手法を採用。平均保有期間は2週間以下。ビッグデータの処理にA I技術を活用し、1万以上のデータソースから2,000万G B以上のオルタナティブデータを取得し、リアルタイムに収益機会を検出する。

■ヌメライ（Numerai）：週次の中期運用を特徴とし、積極的に相場予測する。1週間後の将来株価を予測させるトーナメントを毎週開催し、上位者の予測結果を利用するオープンイノベーション的発想。A Iの機械学習を統合する「集団学習法」を、A Iを活用する人間を統合する「集合知」に置き換えている。Numerai自身は一切モデルを作らず、参加者らの数十万モデルのうち優秀な数百モデルを統合する。過去の優秀事例の選出にはデータ・スヌーピング・バイアス（後述）を伴うが、複数モデルを統合することでバイアスを分散させている。

■リベリオン・リサーチ（Rebellion Research）：長期運用を特徴とし、積極的に相場予測する。平均保有期間は4カ月程度。後述するように長期予測はデータ不足により過学習しやすいが、独自A Iシステム「スター」では確率分布を用いるベイズ学習を採用することで過学習対策をしている。さらに確率分布を用いる利点として、予測の自信度（予測確率）を算出できるため、自信度が高い場合のみ予測結果を採用することで、A Iシステム全体の予測精度を高めているようである。筆者もかつて「集合知A I」なる銘柄選択モデルを提唱したが、このベイズ学習でも同様の効果を期待できる。

Rebellion Researchのように長期運用の事例もあるが、成功事例の多くは「短期的な投機」である。理由は、エントリーからクローズ（もしくはリバランス）までの期間を延長するほど長期予測が必要となり、様々な困難が発生する。以下にA I運用が抱える課題を述べる。

A I 運用の課題

■学習データの不足：長期予測ほどデータの

時間間隔が広がるため、データの個数が少なくなる。その結果、AIの学習に用いる情報量が低下する。

■将来の不確実性：長期予測ほど予測対象までの因果や相関が薄れるため、予測が困難になる。例え話に「風が吹けば桶屋がもうかる」とあるが、実際に「桶屋がもうかる」確率は低い。間にある複数の因果を連続で実現する必要があり、因果を経るたびに実現確率は低下する。

■市場の構造変化：政治的または経済的な変化によって金融市場の構造が変化する可能性があるため、AIの学習に用いるデータは常に鮮度を保つ必要がある。これにより更に学習データの不足を引き起こす。

■市場予測の困難性：そもそも金融市場には学習や予測ができるほどの法則性が存在するのか不明である。よって前回（上）で紹介したように、小型株効果や割安株効果などのアノマリー（一種のリスクプレミアム）やミスプライスの修正作用に期待する運用が現実的である。

■AIの不透明性：複雑なAIは判断根拠が理解困難になるため、顧客への説明責任が果たせない。一方、AIを単純にすれば理解しやすくなるが、高い予測力を発揮できない。よって現在の公募投信においては、AIの活用はオルタナティブデータの情報処理が主であり、AIでスコア化した後の投資判断は人間のファンドマネージャーでも構わない。

■過学習：高い予測力を期待してAIを複雑にするほど、過去の学習データには良く機能するが、肝心の将来の実運用においては全く機能しない場合がある。この技術的な問題を過学習という。上記のRebellion Researchのように、ベイズ学習や集団学習を活用することで過学習を緩和する工夫が必要となるが、予測力も緩和される。

■技術の大衆化：オルタナティブデータの有効性はデータ収集コストに比例する。収集コストを下げるためにAI技術を活用するが、データやAI技術は汎用的で模倣しやすいため、競争優位性を発揮しにくい。結局はデータとAIをどのように使うのか、アイデアの勝負となる。

■マズローのハンマー：AIのような強い武器（ハンマー）を手にすると単に好奇心で使い

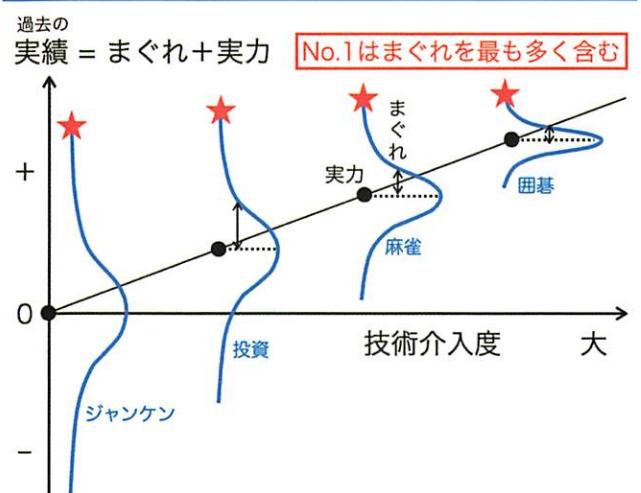
たくなる一方、何でもハンマーで解決したくなる人間の心理バイアス。手段が目的化してしまうことで、真の目的（解くべき課題）を見誤る可能性がある。近年では、生成系AI（ChatGPT等）の活用にも注意を要する。機械であるAIの長所は「高速性・大量性・不休性・客観性・安定性」にあるため、どの長所を活用することで何を実現したいのかを良く見極めて運用戦略（アイデア）を構築する必要がある。

■証券取引の公平性：AI等の機械や特殊データの過度な活用は、証券取引における公平性の観点により、今後規制される可能性がある。このような制度的なリスクにも注意を要する。

■運用対象の流動性：AIは人間アナリストよりも大量の銘柄をカバーできるが、人間が気付きにくい収益機会は小型銘柄に発生しやすい。しかし公募投信は運用額が大きいため、マーケットインパクトを考慮すると流動性が少ない小型銘柄は運用対象になりにくい。つまりAIのメリットを生かしにくい。

■データ・スヌーピング・バイアス：複数の候補からNo.1を選出すること（スヌーピング）で偽の実績（まぐれ）が混入する。図1に示すように、「過去の実績」は「まぐれと実力」で構成され、技術介入度が低いゲームほど「まぐれ」の割合が増加する。AI運用はパラメータや学習データ等の選択余地が豊富なため、単に見栄えだけが良い偽の実績（バックテスト）

図1 技術介入度とデータ・スヌーピング・バイアスの関係



(注)AI運用はパラメータや学習データを試行錯誤できるため、まぐれで見栄えが良い実績(バックテスト)を作りやすい。

寄稿

を簡単に作り出せてしまう。運用者のモラルによってスヌーピングを禁止するか、あるいは先述のNumeraiのように複数モデルを統合することでバイアスを分散させる等の緩和策が必要となる。なお、このバイアスは過学習と混同しやすいが、本質は全く異なる。詳細は本稿の範疇を超えるため、ポイントのみを表1に示す。

A I 運用の適用可能性

先述した課題や成功事例を踏まえると、A I技術を適用できる運用領域は、以下が考えられる。

■短期的な投機：主にヘッジファンドや証券会社等の自己勘定取引（プロップ）部門には適するが、中長期な投資を目的とする公募投信には適さない。短期ならば「学習データの不足」、「将来の不確実性」、「市場の構造変化」の問題は弱まるため、ある程度は市場予測も可能かもしれない。しかし「市場予測の困難性」により予測精度には限りがあるため、市場予測ではなく、イベントドリブンやアビトランジなど因果が明確な（確実性が高い）トレーディングが主流となる。A Iの活用事例として、取引所の注文板（売買を希望する価格と数量が記録されている）を常時監視し、需給のゆがみを高速で認識することで、他者より有利な価格で売買する方法等が考えられる。

■異常検知：未来の予測は困難なので、現在の状況理解に発想を切り替える（表2参照）。現実と理想のギャップを異常（ミスプライス）とみなし、経済学的な知見や銘柄間の関係性を活用しつつA Iによって理論株価を推定する。予測は未来という外を埋める「外挿問題」であるが、異常検知は現在という内を認識する「内挿問題」であるため、異常検知の方が難易度は低く、説明責任も果たしやすい。さらに、異常（ミスプライス）を修正するように売買することで、市場正常化および企業支援に資する責任ある運用（Responsible operations）になり得る。市場予測は行わないため、中長期の運用を要する公募投信にも適している。

■オルタナティブデータ：現行のA I運用（公募投信）では明確な有効性を見出せてはいないが、決算発表よりも事前に個別企業の業績を把握する試みは妥当であり、高速・大量演算を得意とするA Iのメリットを發揮できる。ビ

鈴木智也（すずき・ともや）

茨城大学大学院理工学研究科教授。

地域未来共創学環（新設）連携専任教員、大和アセットマネジメント特任研究員、自社ベンチャー代表を兼務。地域創生や金融分野におけるAI・データサイエンスに関する研究に従事。



ックデータ化が進む情報化社会において、まだ伸び代を秘めている可能性は十分にある。さらに有効なデータほど収集コストが高いため、個人投資家が運用会社に信託する動機にもなり得る。A Iは人間アナリスト以上の知見を導けるのか議論はあるが、アナリストやファンダマネージャーの補助ツールとしての活用は既に進んでいる。

いずれの方法においても、実運用に適用する前にはパフォーマンス評価が必須であり、その評価が科学的に正しく行われなければならない。その際には、特に軽視されがちな「データ・スヌーピング・バイアス」に気を付けたい。

表1 過学習とデータ・スヌーピング・バイアスの違い

	オーバー・フィッティング (過学習)	データ・スヌーピング・ バイアス
発生場所	モデルの学習	モデルの評価
原因	S/N比が低い対象について複雑なモデルを適用	S/N比が低い対象について試行錯誤を繰り返す
現象	法則性以外のノイズ部分も学習してしまう	まぐれで良いだけのモデルを選択してしまう
問題	新しいデータに対してモデルが当てはまらない (過去の実績だけでは不十分)	

（注）S/N比は図1の技術介入度と同義。学習データに含まれる法則的成分をシグナル（S）、それ以外の偶然的成分をノイズ（N）と呼ぶ。株価変動などの金融市場はこの比率（S/N比）が低いと想像できる。

表2 予測と異常検知の違い

	予測	→	異常検知
タスク	外挿問題 (Hard)		内挿問題 (Easy)
データ	時系列 (Small)		クロスセクション (Large)
判断根拠	過去の変動パターン ⇒ 将来株価		銘柄間の関係性、財務情報 ⇒ 理論株価
経済合理性	× (統計学)		○ (経済学)
売買の影響	パターンを助長		異常を修正
投資家責任	× (利己的)		○ (企業支援)