

感度分析によるAIトレーダーの 投資判断アルゴリズムの解釈

株式会社かんぽ生命保険
運用企画部 運用リスクマネジメント担当
石原 龍太¹

1 はじめに

金融機関では現在、いわゆるフィンテックの進展の中で、融資判断や保険金支払査定、不正取引の検知など、その業務に幅広く人工知能（以下、AI）が活用されている。資産運用においても、直近の情報と将来の資産価格の間に存在する複雑な関係性を発見する技術として、市場予測や投資戦略に活用し、高い運用成果を上げているところもある。

一方、深層学習モデルをはじめとするAI内部の処理プロセスは複雑であり、その判断の背後にある因果関係の解釈が容易でないという、いわゆるブラックボックス化の問題が指摘されている。資産運用でも、高い運用成果への期待から、人間の理解を超える投資判断を行うAIに対するニーズが高まり、人間がその妥当性を検証できない取引が増大することになれば、将来予期せぬリスクが顕在化し、金融機関の財務の健全性や市場の安定性に影響を与える可能性も考えられる。

近年、AIのブラックボックス性を緩和する目的から、AI内部の処理プロセスを解釈しようとする研究が、画像認識の分野を中心に数多くなされている。資産運用の分野でも、例えば塩野(2018)が、AIモデルをマクロ経済理論モデルに整合させる手法により、予測精度と解釈性のバランスがとれたリターン予測AIの構築を行う等、AIの解釈可能性に対する関心が高まってきている。

本研究では、将来の日経225先物のリターンに対する説明力（以下、予測精度）をもったAIトレーダーを構築し、感度分析により、その入力変数（市場データ）と出力値（投資判断）の関係性を表現することで、AI内部の処理プロセスの解釈を試みる。

2 AIトレーダーの概要

本研究で構築するAIトレーダーは、7層（入力層が1層、中間層が5層、出力層が1層）からなる順伝播型のニューラルネットワーク²を用いた日経225先物のリターン予測モデルである。

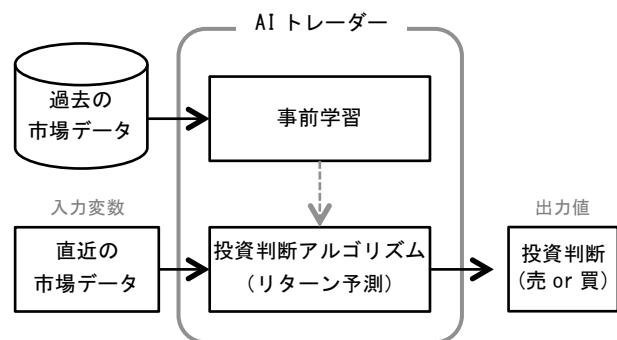
AIトレーダーは、直近の市場データを基に将来の日経225先物価格の変動（上昇または下落）を予測し、当該予測結果から投資判断（上昇を予測：買、下落を予測：売）を導出する。また、過去の市場データを事前学習することで、予測精度を有する投資判断アルゴリズムを経験的に獲得することができる。これらの関係を整理すると図1のようになる。

2.1 予測対象銘柄と入力変数

(1) 予測対象銘柄

AIトレーダーの予測対象銘柄は、大阪取引所で取引される日経225先物（ラージ）の期近限月とする。

図1 AIトレーダーの構成



（出所）石原（2017）（筆者により一部修正）

表1 市場データ（日経225先物の四本値）

時点	始値	高値	安値	終値
1	NKfOP ₁	NKfHI ₁	NKfLO ₁	NKfCL ₁
:	:	:	:	:
t	NKfOP _t	NKfHI _t	NKfLO _t	NKfCL _t
:	:	:	:	:
T	NKfOP _T	NKfHI _T	NKfLO _T	NKfCL _T

¹ 連絡先：ryouta.ishihara.hw@jp-life.jp

本研究の内容は、筆者個人に属するものであり、筆者の所属組織の公式見解を示すものではありません。また、本研究に含まれる誤りは全て筆者の責に帰するものです。

² 「人間の脳内の神経細胞が、別の神経細胞から受け取った信号を次の神経細胞へと伝達していく流れの中で、様々な情報処理を行う仕組み」を模擬した数理モデル。

(2) 入力変数

AIトレーダーの入力変数である市場データには、大阪取引所の日中立会の四本値(日次)を用いる(表1)。なお、期近限月の四本値データをそのまま用いると、限月切替時にデータの断絶が発生し、データの連続性を保つことができないため、限月スプレッド³を用いた補正を行い、データの連続性を保つ⁴ものとする。

2.2 投資判断アルゴリズム

AIトレーダーの投資判断アルゴリズムには、石原(2017)のアルゴリズム(図2)を用いる。

(1) 入力層

入力層は7個のノードで構成する。入力層のノード y_{kt}^{in} は市場データを入力変数として、表2の式で計算した出力値を中間層1のノードに受け渡す。ここで k を入力層を構成するノードの識別番号($k=1, \dots, 7$)とする。

(2) 中間層

中間層は、上昇系(up)と下降系(down)の並列構造をもつ5層構成とし、両系とも1つの層あたり10個のノードで構成する。

$\omega_{jkk}^{s-1(s)}$ を j 系における s 層のノード k と $s-1$ 層のノード k' の間の結合ウェイト、 L を定数項(アルゴリズムのハイパーパラメータ、本研究では5%とする)、 $f(x)$ を0または1の値をとるステップ関数(x が0より大きい場合は1、そうでなければ0を返す)としたとき、中間層1のノード y_{jkt}^{mid1} の出力値は以下のように表現できる。

$$y_{jkt}^{mid1} = f(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

$$x = \omega_{j1k}^{in(mid1)} y_{1t}^{in} + \dots + \omega_{j7k}^{in(mid1)} y_{7t}^{in} + \omega_{j8k}^{in(mid1)} \times L$$

また、中間層2~5のノード y_{jkt}^{mid2} , y_{jkt}^{mid3} , y_{jkt}^{mid4} , y_{jkt}^{mid5} の出力値は以下のように表現できる。


$$y_{jkt}^s = f(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

$$x = \omega_{j1k}^{s-1(s)} y_{j1t}^{s-1} + \dots + \omega_{j10k}^{s-1(s)} y_{j10t}^{s-1} + \omega_{j11k}^{s-1(s)}$$

³ 期近限月と期先限月との価格差。「期先限月の終値-期近限月の終値」の式で算出する。

⁴ SQ日に、例えば日経225先物の日次リターンを計算する場合、「 $\log\{\text{新期近限月の当日終値}/(\text{旧期近限月の前営業日終値} + \text{前営業日の限月スプレッド})\}$ 」のように補正する。

図2 AIトレーダーの投資判断アルゴリズム



(注) 丸はノード、矢印はノード間の結合と処理の流れを示す。
(出所)石原(2017)(筆者により一部修正)

表2 入力層ノードの出力値

ノード	計算式
y_{1t}^{in}	$\log(NKfCL_t/NKfOP_{t-1})$
y_{2t}^{in}	$\log(NKfCL_t/NKfHI_{t-1})$
y_{3t}^{in}	$\log(NKfCL_t/NKfLO_{t-1})$
y_{4t}^{in}	$\log(NKfCL_t/NKfCL_{t-1})$
y_{5t}^{in}	$\log(NKfCL_t/NKfOP_t)$
y_{6t}^{in}	$\log(NKfCL_t/NKfHI_t)$
y_{7t}^{in}	$\log(NKfCL_t/NKfLO_t)$

(注) 表中のlogは自然対数を意味する。

ここで j を系($j=up, down$), s を層($s=in, mid1, mid2, mid3, mid4, mid5$), $s-1(s)$ を層間の結合($s-1(s)=in(mid1), mid1(mid2), mid2(mid3), mid3(mid4), mid4(mid5)$), k を j 系の s 層を構成するノードの識別番号($k=1, \dots, 10$)とする。

(3) 出力層

出力層は、上昇系のノード $z_{up t}$ と下降系のノード $z_{down t}$ で構成する。 $\omega_{jkt}^{mid5(out)}$ を j 系における出力層のノードと中間層5のノード k' の間の結合ウェイト、 y_{jkt}^{mid5} を中間層5のノード k' から受け取る値、 $f(x)$ を0または1の値をとるステップ関数としたとき、出力層のノード z_{jt} の出力値は以下のように表現できる。

$$z_{jt} = f(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

$$x = \omega_{j1}^{mid5(out)} y_{j1t}^{mid5} + \dots + \omega_{j10}^{mid5(out)} y_{j10t}^{mid5} + \omega_{j11}^{mid5(out)}$$

$z_{up t}$ と $z_{down t}$ が日経 225 先物価格の変動の兆候を示す⁵としたとき、時点 t における AI トレーダーの投資判断は、 $z_{up t}$ と $z_{down t}$ の値から表 3 のとおり定まる。

表 3 時点 t における AI トレーダーの投資判断

		上昇系 $z_{up t}$	
		0	1
下降系 $z_{down t}$	0	時点 $t-1$ の判断を維持	買い判断
	1	売り判断	時点 $t-1$ の判断を維持

3 AI トレーダーの事前学習

AI トレーダーの予測精度は、投資判断アルゴリズムのネットワーク構造（各ノード間の結合ウェイト $\omega_{jkk}^{s-1(s)}$ の組み合わせ）によって定まるため、予測精度をもった AI トレーダーの構築には、過去の市場データを用いた適切なネットワーク構造の探索（事前学習）が必要である。

事前学習では、AI トレーダーが特定の期間のデータに過学習していないか確認することが重要になる。AI トレーダーが特定の期間のデータに過学習してしまう場合、異なる期間のデータにおいて期待する予測精度が得られないこともある。そこで、AI トレーダーが特定の期間でのみ有用なものではないことを確認するのが一般的である。

3.1 基本設定

(1) ポジションの表現

本研究では、前述の投資判断に基づき日々ポジションのリバランス⁶を行った場合のリスクとリターンを計測し、AI トレーダーの予測精度を具現化する。このとき、AI トレーダーのポジションは、日経 225 先物の組入比率⁷ x_t を用いて以下のように表現する。

$$x_t = \begin{cases} 100\%, & \text{時点 } t \text{ の投資判断が"買い"} \\ 0\%, & \text{時点 } t \text{ の投資判断が"売り"} \end{cases}$$

⁵ $z_{up t}$ が“1”の場合は上昇、 $z_{down t}$ が“1”の場合は下落の兆候を示すものとする。

⁶ リバランスの取引は、投資判断を行なった日の大引（終値）で行うものとする。なお、AI トレーダーが行う取引は、“新規買”と“返済売”のみとする（売建は行わない）。

⁷ 日経 225 先物の組入比率の初期値 x_0 は 100%とする。

(2) リターンの表現

本研究では、日経 225 先物の日次収益率 $NKfr_t$ と無リスク資産の日次収益率 $Cashr_t$ を以下のように表現する。

$$NKfr_t = \log\left(\frac{NKfCL_t}{NKfCL_{t-1}}\right)$$

$$Cashr_t = 0\%$$

ここで $Cost_t$ を執行コスト⁸としたとき、AI トレーダーの日次収益率 AIr_t は以下のように表現できる。

$$AIr_t = NKfr_t x_{t-1} + Cashr_t(1 - x_{t-1}) - Cost_t$$

$$Cost_t = \begin{cases} 5bp, & \text{取引発生日} \\ 0bp, & \text{それ以外} \end{cases}$$

また、 N を m 月の営業日数としたとき、 m 月における AI トレーダーの月次収益率 AIr_m と日経 225 先物の月次収益率 $NKfr_m$ は以下のように表現できる。

$$AIr_m = \sum_{t=1}^N AIr_t$$

$$NKfr_m = \sum_{t=1}^N NKfr_t$$

(3) リスクの表現

日経 225 先物に対する AI トレーダーのトラッキングエラー $\sigma(e)_{AI}$ は、前述のリターンの表現を用いて以下のように表現できる。

$$\sigma(e)_{AI} = \sqrt{\frac{\sum_{m=1}^M \{(AIr_m - NKfr_m) - (\overline{AIr} - \overline{NKfr})\}^2}{M - 1}}$$

$$\overline{AIr} = \frac{\sum_{m=1}^M AIr_m}{M}$$

$$\overline{NKfr} = \frac{\sum_{m=1}^M NKfr_m}{M}$$

ここで M を計測期間の月数とする。

(4) 適合度の表現

本研究では、AI トレーダーの適合度⁹を以下のように表現する。

$$IR_{AI} = \frac{(\overline{AIr} - \overline{NKfr} - \varepsilon) \times 12}{\sigma(e)_{AI} \times \sqrt{12}}$$

⁸ 本研究では取引の都度、約定金額の 5bp (0.05%) が発生するものとする。

⁹ AI トレーダーの予測精度の優劣の判断に用いる評価尺度。

なお ε を 0 としたとき、この式は日経 225 先物に対するインフォメーションレシオを意味する。適合度にインフォメーションレシオを用いて事前学習を行う場合、AI トレーダーの投資判断アルゴリズムが極端にリスク抑制的となる（適合度の分母が 0 に収束してしまう）可能性があるため、本研究では ε を以下の式により設定する。

$$\varepsilon = \frac{\sum_{m=1}^M \text{NKf}\sigma_m}{M} \times 0.05$$

$$\text{NKf}\sigma_m = \sqrt{\frac{\sum_{t=1}^N (\text{NKf}r_t - \text{NKf}r_m/N)^2}{N-1}} \times \sqrt{N}$$

3.2 事前学習

本研究の事前学習は、訓練データ（過去の市場データ）を学習データと検証データに分別し、①学習（学習データに対して高い適合度を示す投資判断アルゴリズムを探索）、②検証（学習した投資判断アルゴリズムが、学習データに過学習していないか検証データを用いて確認）の 2 ステップにより行う。

(1) 学習

遺伝的アルゴリズム¹⁰の手法を用いて、学習データに対して高い適合度を示す投資判断アルゴリズムを探索する。具体的には、①まず初期個体として、異なる遺伝子型を持つ個体を 200 個体生成させる。ここで、各個体は投資判断アルゴリズムのネットワーク構造を表す遺伝子型（各遺伝子の値¹¹は、投資判断アルゴリズムのノード間の結合ウェイト $\omega_{jkk}^{s-1(s)}$ を表す）として定義される。②次に各個体の適合度を評価¹²し、適合度の高い個体が生き残るような方法で選択、交叉、突然変異の処理（遺伝的操作¹³）を行う。③こうして作られた次世代についても同じ処理（適合度の評価と遺伝的操作）を 10000 回繰り返す。

¹⁰ 「生物が生存していくなかで、選択、交叉、突然変異を繰り返しながら環境に適合していく仕組み」に基づく、数理モデルの最適化手法。

¹¹ 各遺伝子の値は区間 $[-1, +1]$ の実数値とし、初期個体の遺伝子及び突然変異で置換する遺伝子の値は区間 $[-1, +1]$ の乱数で決定する。

¹² 学習データに対する適合度は、投資シミュレーションを 2 回実施し、その平均値を採用するものとする。

¹³ 本研究の遺伝的アルゴリズムのハイパーパラメータは、選択の方法をエリート選択、交叉の方法を 1 点交叉、突然変異の方法を置換、突然変異率を 3% とする。

なお、学習ステップの適合度の計算においては、確率的に選別¹⁴した時点 t における出力層ノードの値を反転（0→1, 1→0）させることで、AI トレーダーが学習データに過学習してしまうことを防ぐものとする。

(2) 検証

学習ステップで探索した投資判断アルゴリズムが、学習データに過学習していないか検証する。具体的には、①まず学習ステップの遺伝的操作回数が 10, 20, …, 10000 回の各時点において、適合度が最も高い個体を抽出する。②次に抽出した個体の検証データに対する適合度を評価し、検証データに対する適合度が上位 10% となる個体群を学習データに過学習していないものと判断する。

3.3 投資判断アルゴリズムの決定

検証ステップで過学習していないと判断した個体群から、未知データに対する予測精度が最も高いと期待される投資判断アルゴリズムを選択する。具体的には、検証ステップで過学習していないと判断した個体群について、訓練データ（学習データと検証データの通算）に対する適合度を評価し、訓練データに対する適合度が最も高い個体を AI トレーダーの投資判断アルゴリズムに決定する。

4 投資シミュレーション

本章では、前 2 章の方法により AI トレーダーを構築し、投資シミュレーションによる性能評価を行う。具体的には、①まず日経 225 先物のデータセット（訓練データと評価データ）を用意する。②次に 5 個体の AI トレーダーを構築し、訓練データを用いて事前学習を行う。③次に事前学習を行なった AI トレーダーについて、評価データを用いた投資シミュレーション¹⁵を行う。④そして、投資シミュレーション結果から日経 225 先物に対するリスク調整後リターン α ¹⁶を計測し、その予測精度を評価する。

なお、異なる市場環境下での予測精度を評価するため、本研究の投資シミュレーションは 2 つのデー

¹⁴ 時点 t の選別は、3% の確率で上昇系と下降系で別々に行う。

¹⁵ 評価データに対する再学習は行わないものとする。

¹⁶ α の値は、回帰式「AI トレーダーの月次収益率 = $\alpha + \beta \times$ 日経 225 先物の月次収益率 + e 」により推定する。

タセット (①上昇シナリオ：(訓練データ) 2007年10月～2016年9月 (評価データ)2016年10月～2019年9月, ②下落シナリオ：(訓練データ)1998年1月～2006年12月 (評価データ)2007年1月～2009年12月) に対して行う。

4.1 上昇シナリオ

(1)AIトレーダーの事前学習

2章で説明したAIトレーダーを5個体構築し, 3章の方法によりAIトレーダーの事前学習を行う。なお, 訓練データの分別は「(学習データ) 2007年10月～2013年9月, (検証データ) 2013年10月～2016年9月」のとおり行うものとする。

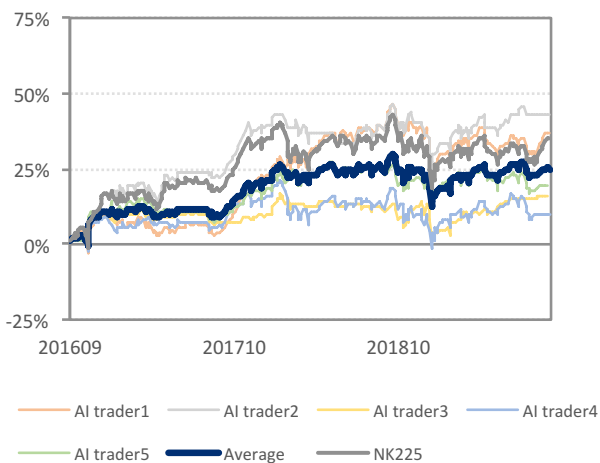
(2)シミュレーション結果

表4に投資シミュレーション結果, 図3に評価データ期間 (2016年10月～2019年9月) におけるAI

表4 投資シミュレーション結果 (上昇シナリオ)

	収益率 (年率)	標準偏差 (年率)	α (年率)	β	決定係数
AIトレーダー1	12.07%	14.67%	2.23%	0.86	0.74
AIトレーダー2	14.35%	12.97%	5.41%	0.78	0.78
AIトレーダー3	5.17%	9.00%	0.25%	0.43	0.49
AIトレーダー4	3.15%	11.54%	-4.75%	0.69	0.77
AIトレーダー5	6.30%	10.65%	0.27%	0.52	0.53
平均	8.21%	11.77%	0.68%	0.65	0.66
標準偏差	4.77%	2.17%	3.69%	0.18	0.14
日経225先物	11.51%	14.74%	-	-	-

図3 上昇シナリオにおける累積収益率の推移



トレーダーと日経225先物の累積収益率を示す。AIトレーダーの α は半数以上の個体でプラスとなっていたが, α の平均は若干のプラスにとどまっていた。このことから, AIトレーダーは概ね予測精度を獲得していたものの, その水準は高くはなかったといえる。

4.2 下落シナリオ

(1)AIトレーダーの事前学習

2章で説明したAIトレーダーを5個体構築し, 3章の方法によりAIトレーダーの事前学習を行う。なお, 訓練データの分別は「(学習データ) 1998年1月～2003年12月, (検証データ) 2004年1月～2006年12月」のとおり行うものとする。

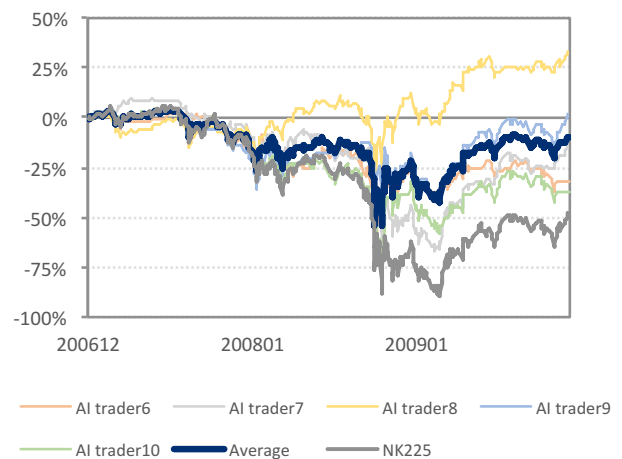
(2)シミュレーション結果

表5に投資シミュレーション結果, 図4に評価デ

表5 投資シミュレーション結果 (下落シナリオ)

	収益率 (年率)	標準偏差 (年率)	α (年率)	β	決定係数
AIトレーダー6	-10.56%	18.79%	-2.82%	0.47	0.44
AIトレーダー7	-4.96%	25.27%	8.76%	0.83	0.76
AIトレーダー8	10.91%	20.13%	20.01%	0.55	0.53
AIトレーダー9	0.13%	20.15%	10.48%	0.63	0.68
AIトレーダー10	-12.35%	22.98%	-0.57%	0.72	0.68
平均	-3.37%	21.46%	7.17%	0.64	0.62
標準偏差	9.37%	2.62%	9.20%	0.14	0.13
日経225先物	-16.46%	26.43%	-	-	-

図4 下落シナリオにおける累積収益率の推移



一ヶ月間（2007年1月～2009年12月）におけるAIトレーダーと日経225先物の累積収益率を示す。本シナリオでも、AIトレーダーの α は半数以上の個体でプラスとなっており、さらに α の平均は上昇シナリオと比較して大きくプラスとなっていた。このことから、AIトレーダーは高い予測精度を獲得していたといえる。

5 感度分析

本章では、感度分析により、AIトレーダーの入力変数（市場データ）と出力値（投資判断）の係数性をAIトレーダーの特徴として表現することで、4章で構築したAIトレーダーの投資判断プロセスの解釈を試みる。また、感度分析により得られた結果とリスク調整後リターンの水準から、AIトレーダーの特徴と予測精度の関係についても考察する。

5.1 感度分析の方法

4章の訓練データを用いて各入力層ノードの感応度 δy_k^{in} を計測¹⁷し、AIトレーダーの特徴を表現する。なお、感応度 δy_k^{in} は「入力層ノードkの値が10bp変化した場合における、AIトレーダーのポジションの変化」を表すものとする。

表6 感度分析結果

	δy_1^{in}	δy_2^{in}	δy_3^{in}	δy_4^{in}	δy_5^{in}	δy_6^{in}	δy_7^{in}	σ
AIトレーダー1	0.0%	-3.2%	-0.2%	-0.2%	-0.4%	2.8%	-3.9%	2.2%
AIトレーダー2	-0.8%	0.4%	-0.5%	0.3%	-1.7%	-1.6%	-1.7%	0.9%
AIトレーダー3	1.4%	-0.7%	-2.9%	1.0%	-4.2%	-0.8%	0.7%	2.1%
AIトレーダー4	-2.2%	1.6%	-0.5%	0.8%	-2.1%	-1.7%	-1.1%	1.5%
AIトレーダー5	-1.0%	0.6%	-0.1%	0.4%	-1.0%	-1.2%	-1.6%	0.8%
AIトレーダー6	0.3%	0.0%	-0.9%	0.2%	-1.7%	0.9%	-0.3%	0.9%
AIトレーダー7	0.6%	-3.2%	3.9%	1.2%	-0.9%	-1.7%	-0.8%	2.3%
AIトレーダー8	1.6%	1.3%	-0.1%	-4.1%	-6.4%	2.7%	1.8%	3.4%
AIトレーダー9	-2.2%	2.0%	1.7%	-2.6%	2.9%	-6.7%	-1.8%	3.4%
AIトレーダー10	-3.8%	-2.0%	-0.5%	4.9%	-3.2%	-4.2%	-3.9%	3.2%
平均	-0.6%	-0.3%	-0.0%	0.2%	-1.9%	-1.1%	-1.3%	2.1%
標準偏差	1.7%	1.9%	1.8%	2.4%	2.4%	2.9%	1.8%	1.0%

(注) 網掛のセルは、感応度のマイナスを表す。

¹⁷ δy_k^{in} は「 $(y_{kt}^{in}$ が10bp上昇した場合の買建比率 - y_{kt}^{in} が10bp低下した場合の買建比率) ÷ 2」の式で算出する(他の入力層ノードの値は元の値で固定する)。なお、買建比率は「 $\sum_{t=1}^T x_t / T$ 」とする。

5.2 入力層ノードの感応度

感度分析の結果を表6に示す。各入力層ノードの感応度は概してマイナスであったことから、4章で構築したAIトレーダーには、直近の日経225先物のリターンが正であるとき、リスク回避的なポジションをとる傾向(負の相関)があるといえる。ただし、どの入力層ノードの感応度もAIトレーダー毎の個体差が大きく、全てのAIトレーダーの投資判断に大きな影響を与える特定の市場データの存在を示唆するものではなかった。

5.3 AIトレーダーの特徴と予測精度の関係

各入力層ノードの感応度 δy_k^{in} と感応度の標準偏差 σ ¹⁸を説明変数、4章で計測したリスク調整後リターン α を被説明変数として、説明変数毎に行なった単回帰分析の結果を表7に示す。ここで、 δy_4^{in} と σ の決定係数が大きかったことから、当該2つの説明変数について、リスク調整後リターンとの関係を考察する。ただし、これらの関係は本研究で構築した少数(10個体)のAIトレーダーにおいて示されたものであり、これらの関係の普遍性を確認するためには、他の個体や異なるデータセットを用いた更なる検証が必要である。

(1) 感応度 δy_4^{in}

図5に感応度 δy_4^{in} とリスク調整後リターン α の関係を示す(なお、入力層ノード y_{4t}^{in} は日経225先物の日次リターンを意味する)。 δy_4^{in} と α の間には負の相関が見られる。これは「日経225先物の日次リターンに強いリバーサル特性を見出すAIトレーダーほど、予測精度が高くなる」傾向を示しており、行動ファイナンスの先行研究¹⁹とも整合するものである。このことから、既に普遍性や有用性が確認されてい

表7 感応度 δy_{kt}^{in} の α に対する単回帰分析の結果

(説明変数)	δy_1^{in}	δy_2^{in}	δy_3^{in}	δy_4^{in}	δy_5^{in}	δy_6^{in}	δy_7^{in}	σ
切片	0.05	0.05	0.04	0.04	0.03	0.04	0.06	-0.05
傾き	1.71	0.63	1.84	-2.20	-0.49	0.25	1.72	4.36
決定係数	0.16	0.03	0.19	0.49	0.03	0.01	0.17	0.37

¹⁸ 感応度の標準偏差 σ は、入力層ノード1～7の感応度について、以下の式で算出したもの。

$$\sigma = \sqrt{\sum_{k=1}^7 \{ \delta y_k^{in} - (\sum_{k=1}^7 \delta y_k^{in} / 7) \}^2 / 6}$$

¹⁹ 高橋(2004)は、日本の先物市場(株式)では、日次リターンにリバーサル特性(負の相関)が見られることを報告している。

る理論や経験則に整合した投資判断プロセスを有しているAIトレーダーほど、その予測精度は高くなりやすいといえる。

(2) 感応度の標準偏差 σ

図6に感応度の標準偏差 σ とリスク調整後リターン α の関係を示す。 σ と α の間には正の相関が見られる。これは「感応度の標準偏差が大きなAIトレーダーほど、予測精度が高くなる」傾向を示している。このことから、市場データに対する感応度のバランスがとれた（全ての入力層ノードの感応度が正又は負の一方に偏っていない）投資判断プロセスを有しているAIトレーダーほど、その予測精度は高くなりやすいといえる。

図5 感応度 δy_4^{in} と α の関係





図6 感応度の標準偏差 σ と α の関係



6 おわりに

本研究では、感度分析によるAIトレーダの投資判断プロセスの解釈を試みた。これは、AIトレーダーの入力変数（市場データ）と出力値（投資判断）の関係性に注目し、個々のAIトレーダーの特徴を表現したものである。

AIを実運用に用いる際のリスクの1つに、前提とする経済構造や市場構造の変化がある。本研究のAIトレーダーをはじめとする一般的なAIモデルは、伝統的なクオンツモデルと同様に、市場データの統計的性質が不変であることを前提としている。そのため、例えばレジームチェンジ（経済構造や市場構造の大きな変化）の発生等により、市場データの統計的性質が変化するような場合には、期待する運用成果が得られなくなる可能性もある。

経済構造や市場構造の変化による影響を軽減させるには、特徴の異なる複数のAIトレーダーを併用することが有効な戦略となる。このとき、AIトレーダーの投資判断プロセスを解釈し、併用するAIトレーダーの特徴を適切に分散することが、運用成果の向上と安定に繋がるものと考えられる。

参考文献

- [1] 足立高徳, “アルゴリズム取引の問題点と今後の課題”, 先物・オプションレポート 2019年3月号, (2019)
- [2] 石原龍太, “多層ニューラルネットワークとGAを用いたTOPIX運用AI”, 第19回人工知能学会 金融情報学研究会 SIG-FIN-019-07, (2017)
- [3] 笠井彰吾, “金融サービスをめぐるAI活用の経緯 - AI技術の現状を踏まえて-”, 立法と調査 2018.10 No. 405, (2018)
- [4] 川村隆浩, “機械学習の説明可能性への取り組み - DARPA XAI プロジェクトを中心に-”, 2019年度人工知能学会全国大会 (第33回) 2N1-KS-5, (2019)
- [5] 酒井博貴, 亀谷由隆, 曾田尚宏, 有江浩明, “LRP法による畳み込みニューラルネットワークにおける中間層の振る舞いの可視化”, 2018年度人工知能学会全国大会 (第32回) 2A2-04, (2018)
- [6] 塩野剛志, “アセット・リターン予測AIとマクロ経済理論の融合 -マルチタスク学習による正則化と識別-”, 第21回人工知能学会 金融情報学研究会 SIG-FIN-021-07, (2018)
- [7] 高橋典孝, “証券価格変動のモメンタム現象とリバーサル現象に関する考察: 行動ファイナンスの考え方の整理とそれに基づく定量分析”, 金融研究第23巻別冊第2号, (2004)
- [8] 多田智史, “あたらしい人工知能の教科書”, 翔泳社, (2016)
- [9] ツヴィ・ボディー, “インベストメント (第8版)”, マグロウヒル・エデュケーション, (2010)
- [10] 中山慎一郎, 長山昌平, 鳥海不二夫, “システムトレードによる自動取引”, 情報処理 Vol. 53 No. 9, (2012)
- [11] 原聡, “「AIの説明」の現状とこれから”, 第1回AIネットワーク社会推進会議 AIガバナンス検討会, (2018)
- [12] 平林明憲, 伊庭斉志, “遺伝的アルゴリズムによる外国為替取引手法の最適化”, 2008年度人工知能学会全国大会 (第22回) 論文集 3H1-2, (2008)
- [13] 三菱UFJトラスト投資工学研究所 編, “実践 金融データサイエンス”, 日本経済新聞出版社, (2018)

本資料に関する著作権は、株式会社大阪取引所にあります。

本資料の一部又は全部を無断で転用、複製することはできません。

本資料の内容は、株式会社大阪取引所の意見・見解を示すものではありません。

本資料は、デリバティブ商品の取引の勧誘を目的としたものではありません。