

AI（人工知能）による投資主体間の交雑
株式保有移転と株価変動に関する深層学習
—日本の証券市場における投資主体の行動様式変化と
株価予測への影響に関する考察—

深瀬 澄・内海 正郎¹

Deep learning on the relationship between cross-stock transfers
among investors and stock price fluctuations by AI
A Study on Changes in The Behavior Of Invest entities in the
Japanese Securities Market and their Impact on Stock Price
Forecasts

Kiyoshi FUKASE · Masao UTSUMI

目 次

はじめに

第 I 章 証券市場における AI の導入と資産運用

第 II 章 学内における先行研究

第 1 節 桑井(1998)

第 2 節 Fukase & Morimoto (2004)

第 3 節 内海 (2014)

第 III 章 投資主体の売買行動の特徴

第 1 節 実証分析に用いる時系列データと基本統計

第 2 節 株価変動と投資主体の行動

第 3 節 投資環境変化と投資主体の行動

第 4 節 投資主体別行動における独自性の変化

第 VI 章 投資行動と株価形成

第 1 節 交雑株式保有移転学習法 (CPTL)

第 2 節 株価の自己相関

¹ 本学経済学部非常勤講師、本学経済学部卒業生

第3節 多変量グレンジャー因果検定

第V章 AI導入による株価予測への影響

第1節 分析方法

第2節 分析結果と評価

第3節 考察

第VII章 総括

キーワード 行動ファイナンス、証券市場におけるAI導入と投資行動の変化、投資主体間の株式保有移転、投資行動と株価形成における内生性問題、ベクトル自己回帰モデル、深層学習、フラクタル次元

はじめに

Google検索やGoogleアシスタントの音声認識など、世界最先端ともいえるグーグルのAI（人工知能）技術の開発を進めたトロント大学名誉教授のジェフリー・ヒントンは、2006年にオートエンコーダ（次元圧縮アルゴリズム）やディープ・ビリーフ・ネットワーク理論を発表している。後にディープ・ラーニング（深層学習）と呼ばれるこの理論は、従来のニューラル・ネットワークの技術的な問題点を解消し、音声・画像・自然言語の機械学習の性能を飛躍的に向上させた。そして、2010年代からの第3次AIブームの誘発に寄与した。

AIブームの技術史

ブーム	主要な技術の提唱・開発等
第1次AIブーム （探索と推論） ・探索・推論 ・自然言語処理 ・ニューラルネットワーク ・遺伝的アルゴリズム エキスパート・システム	1943年、ウォーレン・マカロックとウォルター・ピッツが形式ニューロンを発表。
	1958年、フランク・ローゼンブラットがパーセプトロンを発表。
	1969年、マービン・ミンスキーとシーモア・パパートが著書『パーセプトロン』で、単純パーセプトロンは線形分離不可能なパターンを識別できない事を示した。
	1979年、福島邦彦がネオコグニトロンを発表し、文字認識に使用。後に畳み込みニューラルネットワークへと発展する。
第2次AIブーム （知識表現） ・知識ベース ・音声認識 ・データマイニング ・オントロジー （ウェブ・ビッグ・データ）	1982年、ジョン・ホップフィールドがホップフィールド・ネットワーク（再帰型ニューラルネットワーク）を提案。
	1985年、ジェフリー・ヒントンらがボルツマンマシンを提案。
	1986年、デビッド・ラメルハートらが誤差逆伝播法（バックプロパゲーション）を提案（再発見）。
	1988年、畳み込みニューラルネットワークを Homma Toshiyuki らが音素の認識に使用。
第3次AIブーム （機械学習） ・ディープ・ラーニング	1989年、Yann LeCun らが多層の畳み込みニューラルネットワークを文字の認識に使用（後にディープラーニングの一種に分類される）
	2006年ジェフリー・ヒントンらがオートエンコーダおよびディープ・ビリーフ・ネットワークを提案。この理論が2010年代にディープ・ラーニングと呼ばれる分野を形成。

岡田・松田（2021）卒業論文。

日本の証券業界でもAI導入が加速し、例えば、国内業界最大手の野村ホールディングスは、2010年からシステム改革に着手し、2012年にビッグデータの整理、2014年にAIアルゴリズムのシステム開発を進め、2016年4月からはアルゴリズム取引をするすべての機関投資家に対して、AIによる「5分先の株価」予測サービスを提供しているという²。

特にデイ・トレーダーやディーラーにとっては、利根的な将来でも高い精度の情報が得られれば、利益につなげることができるだろう。また、AIを搭載したプログラムによる株式売買の市場参入は、小刻みな取引を促し、売買件数の増加、投資主体間の行動様式の類似化、を通じて、株式市場や株価形成に影響し、さらに同調行動が下落・高騰局面を増幅して市場を不安定化してしまうことも考えられる。

そこで、本稿では、行動ファイナンスの視点から、証券投資におけるAIの導入が収益を目的とする投資主体の売買行動様式をどのように変化させ、さらに、その結果として株式市況の予測にどのような影響が生じているのか、を実証的に考察する。

第I章 本稿の目的

従来の株価予測手法はファンダメンタル分析とテクニカル分析に大別される。これらに対し、Fukase & Morimoto(2004)は、行動ファイナンスの視点から、第3の予測手法を提案した。すなわち「株価形成は、証券市場における投資家間の株式売買行動の結果である」という仮説の下に、両者の関係をAI（ニューラル・ネットワーク）を用いて機械学習させ、投資主体の株式売買行動から株価を予測するのである。この予測手法を「交雑株式保有移転学習法」（Cross-Position Transfer-Learning：CPTL）と呼ぼう。

CPTLを用いて、株価が上昇するか／下落するかを2値選択で予測した結果は、95%を超える精度で的中し一喜したが、事後に「ぬか喜び」であったことが判明した。株価は過去の値と高い自己相関をもつため、機械学習データに過去の株価情報も含めたことが、CPTLの予測精度を過大に高めてしまったものと思われる。

そもそも株価等の金融資産価格の将来予測が可能なのか、学術的にも結論が曖昧である。ジョン・メイナード・ケインズが、金融市場における投資家の行動を美人投票に例えたように³、企業業績や金利などファンダメンタルズと呼ばれる実体によって決定されるわけではない。しかし無関係とも言えず、資産価格決定要因の実証的分析の研究で、2013年秋に、ユージン・ファーマ（米シカゴ大学）、ラース・ピーター・ハンセン（同）、ロバート・シラー（米イェール大学）の3氏にノーベル経済学賞が授与されたが、3氏の金融資産市場の効率性に関する見解

² President on Line, 2018.5.18付け、松崎 隆司「AIは野村証券の働き方を激変させるのかー業務の自動化が付加価値を生む」

³ 『雇用・利子および貨幣の一般理論』第12章第5節。

は全く異なる⁴。すなわち、ファーマ氏は、市場に生じる何らかのショックが即座に価格に反映するため、ショックを予測しない限り価格変動は予測できないとした（効率的市場仮説）。一方、ハンセン氏は資産価格決定の合理的な理論を検証するのに適した統計的方法（一般化モーメント法：GMM）を開発し、これを応用して資産価格決定の理論を修正すれば資産価格を説明できるとした。さらにシラー氏は、合理的な市場参加者を前提とせず、合理的な行動からの乖離（資産バブル）に焦点を当てる行動ファイナンス理論によるアプローチの基礎を築いた。

近年、日本の証券市場にも急速にAI（人工知能）が導入され、以前よりも、株価予測の精度は向上し、売買も効率化されていると考えられる。このことに伴い、投資主体別の投資行動に何らかの変化が生じ、さらに、株価形成にも影響が及んでいる可能性が予想される。

そこで本稿では、Fukase & Morimoto（2004）から17年を経て、CPTLが現在でも機能し得るのか、データ処理ツールをニューラルネットワーク（ANNs）からDeep Learningへと進化させて実証的な検証を試みる。このテーマについて、以下の構成で展開していく。第Ⅱ章で学内における先行研究を整理し、第Ⅲ章では、個人投資家や海外投資家をはじめとする11の投資主体の行動の特徴と変化を分析し、第Ⅳ章でAI導入によるこれらの投資行動の変化について考察する。第Ⅴ章では、Fukase & Morimoto（2004）を踏襲した分析のフレームワークを示し、第Ⅵ章で、AIを用いて「投資主体間の株式保有移転」と株価形成の関係を深層学習させ、株価予測を行う。第Ⅶ章ではAI導入による株価予測への影響を考察し、第Ⅵ章で総括する。

第Ⅱ章 学内の先行研究

本章では、本学の教員による証券市場に関する先行研究を参照し、本稿の第Ⅴ章で示す分析モデルの詳細部分を補足する。

第1節 桑井（1998）

大学院生時代の桑井（1998）は、Beltratti & Margarita（1996）を参考に、ニューラル・ネットワーク（Artificial Neural Network, ANNs）および遺伝的アルゴリズム（genetic algorithms, GAs）を人工の証券市場モデルに適用することを想定し、図表Ⅱ-1-1に示す3類型、5モデルのデザインを提案している。AIを用いた仮想実験の設計を論じたものだが、現実の証券市場をどのように捉え分析するかについて、貴重な示唆を与えている。

（1）「ワンエージェントモデル」は図表Ⅱ-1-2に示される最も単純な枠組みのモデルである。

⁴ 1600年代に、光の本質をめぐり、光の粒子説を唱えたクリスティアーン・ホイヘンスと光の波動説を唱えたアイザック・ニュートンの論争は、後世に、アルベルト・アインシュタインやルイ・ド・ブロイらの研究に引き継がれ、「光や電子などの現象は、粒子のような性質と波動のような性質を併せ持つ」と結論付けられ、決着が付いている。しかし、金融資産価格については、未だに結論に至っていない点が重要である。

エージェントは市場に対して相対的に小さいので、市場に影響を与えない。また、所与の市場価格の下でプライステーカーとして、入手した情報を学習し、期待株価を予測する。そして、環境要因と自らの投資経験から学習し、利益率を最大化するようにルールを解釈する。

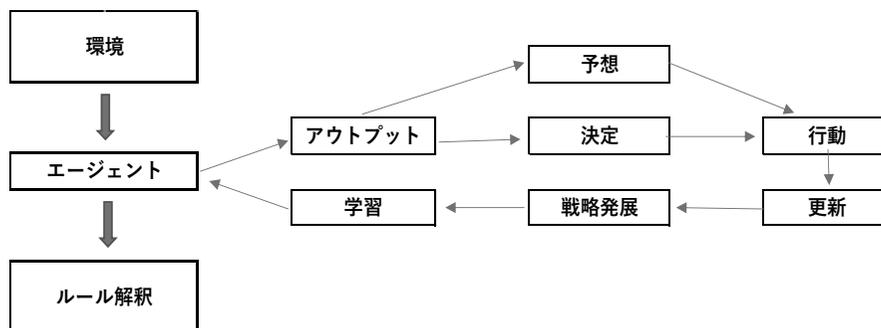
- (2) 「ワンポピュレーションモデル」では市場価格は所与ではなく、「同質」だが学習能力が異なるエージェント間の相互作用の結果として決まる。エージェントは期待収益にのみ関心を持つが、①「コンピューショナル ANNs」ではリスク中立的で株式投資のみによる、②「ビヘイビジュアル ANNs」ではリスク回避的で他の資産も視野に入れた、運用を想定する。
- (3) 「マルチポピュレーションモデル」は、複数の「異質」なワンポピュレーションモデルから構成される。それぞれが、相異なるネットワークをもち、相異なる学習能力で考えた意思決定ルールを用いて、相異なるゴールに到達する。①「人工生命」は、資産運用に費やすコスト（情報収集やアドバイス）とそれによる効率性の差、②「戦略の共存」は、プライスマーカー（ディーラー）とプライステーカー（トレーダー）間の利害対立を想定している。

図表Ⅱ-1-1 人工エージェントを用いた株式市場モデル

	モデル	エージェントの性質	意思決定ルール
(1)	ワンエージェントモデル	エージェントは一人	外生的ルール
(2)	ワンポピュレーションモデル		
(2)①	コンピューショナル ANNs	同じ構造のエージェント	外生的ルール
(2)②	ビヘイビジュアル ANNs	同じ構造のエージェント	内生的ルール
(3)	マルチポピュレーションモデル		
(3)①	人工生命	異なる構造のエージェント	外生的ルール
(3)②	戦略の共存	異なる構造のエージェント	内生的ルール

梶井(1998)、p.76 表 4.1

図表Ⅱ-1-2 人工エージェントを用いた株式市場モデル



梶井(1998)、p.77 図 4.1

本稿では、異なる行動様式をもつ11の投資主体間の株式売買活動を考察するため、(3)「マルチポピュレーションモデル」を想定し、これを構成する(2)「ワンポピュレーションモデル」を各投資主体に対応させ、それぞれの異質性を想定することから (3) ①「人工生命」が最も

近いモデルであると考え。ただし、焦点を主体間の株式売買活動に当てて考察するため、(2)「ビヘイビジュアルANNs」のように証券以外の資産を含めたリスクヘッジについては想定しない。

第2節 Fukase & Morimoto (2004)

株式市場を構成する投資主体が、「買い方」と「売り方」に分かれることによって株式売買の取引が成立する(次章、図表Ⅲ-1-4)。Fukase & Morimoto⁵(2004)の前半では、各取引時点において、同一の経済環境を共有しているにもかかわらず、需要側と供給側に分かれるのはどのような要因によるのか、時系列分析による下記のモデルを用いて考察した。

なお、投資主体は11部門あるが、A)証券会社、B)個人、C)外国人、D)投資信託、E)事業法人、F)生保・損保、G)長銀・都銀・地銀、H)その他金融機関の8部門について、モデルのパラメータを推計することによって、各々の投資行動特性を類型化した。

分析モデル

$$X_{i,t} = \left\{ \sum_{j=1}^J \alpha_{i,j} \cdot X_{i,t-j} \right\} + \left\{ \sum_{j=1}^J \beta_{i,j} \cdot \Delta P_{t-j} \right\} + \gamma_{i,t} r_t + \phi_{i,t} R_{i,t} + \psi T_{i,t} + u_{i,t}$$

i : 投資主体

t : 当期(期末時点)、 j : 遡る期間の長さ

$X_{i,t,j}$: 投資主体 i のネットの買越額(買付額-売却額)

$\Delta P_{i,j}$: j 期前と比較した当期の日経平均株価上昇率(年率換算値、単位: %)

r_t : 無リスク資産の利率

$R_{i,t}$: 12ヶ月間の株価上昇率についての分散

$T_{i,t}$: タイムホライズンの代理変数として以下を用いた。

$$\text{売買回転率} = \frac{\text{過去1年間の買付額} - \text{過去1年間の売却額}}{\text{当日期首保有残高} + 12\text{ヶ月前の保有残高}}$$

このモデルにおいて、例えば、 X のパラメータ α の推計値がマイナスならばポジション管理が機能していることが、 ΔP のパラメータ β がマイナスならば順張り、プラスならば逆張りの投資戦略が用いられている、ことなどがうかがえる。各パラメータの推計値より、それぞれの

⁵ 共著者の森本紘文は本学経済学部卒業生。現在は株式会社IHI本社 航空・宇宙・防衛領域、生産改革推進室に勤務。

投資主体の行動特性は、図表Ⅱ－２－１のようになった。

図表Ⅱ－２－１ モデルのパラメータ推計結果

投資主体	投資行動の特徴
A) 証券会社	<ul style="list-style-type: none"> ・ X の係数が交互に正負に変わり、ポジション管理をしている。 ・ 最近の価格変化に対する感応度は俊敏。 ・ ボラテリティのリスクをとることには無関心。
B) 個人投資家	<ul style="list-style-type: none"> ・ ポジション管理には無関心。 ・ 安く買い、高く売るという「順張り」。 ・ ボラテリティのリスクを好む。
C) 海外投資家	<ul style="list-style-type: none"> ・ 価格上昇時に買い越す「逆張り」にみえる。 ・ 安全資産の金利にも反応。 ・ 4 半期のサイクルでポジションを管理。
D) 投資信託	<ul style="list-style-type: none"> ・ 順張り戦略。 ・ 大局的には買い。 ・ 金利に影響される。
E) 事業法人	<ul style="list-style-type: none"> ・ 株価上昇時に売り越す順張り。 ・ 回転率を重視。 ・ ポジション管理はせず、売り手または買い手のどちらかに徹する。
F) 生保・損保	<ul style="list-style-type: none"> ・ 順張り戦略
G) 長銀・都銀・地銀	<ul style="list-style-type: none"> ・ 過去のポジションと株価上昇率のみに依存。 ・ 大局的には買い手または売り手に徹する（わずかながらポジションを管理） ・ 大局的には順張りだが、ブレーキもかかる。

第3節 内海（2014）

バブル経済崩壊後、Banerjee（1992）をはじめとするハーディング理論（herd behavior theory）によってバブルの発生要因が解明された。ハーディング現象（同調行動）とは、行動経済学において「人間は、合理的な観点から物事の判断をしたり、自らの行動を決定するよりも、多くの人々と同じ行動をとることに安心感を抱き、周りに同調したり他人の行動に追随してしまう傾向がある」という群衆心理に基づく行動である。例えば、株式投資に関する知識がなく抵抗感を抱いていても、友人や近隣、親戚など身近な人達が4人連続して株式投資で儲けたという話を聴くと、自分も投資してみたいくなる。このことは、簡単な期待値計算で示すことができる⁶。投資家の同調行動が、市場の過熱や暴落などの混乱を招く恐れも考えられる。AIにより投資家が下落相場を事前に予知できるようになれば、このような懸念はより現実性を増すだろう。

内海（2014）は上記の問題意識をもち、前半でAnderson & Holt（1997）による具体的な数値例を挙げて理論を説明している。後半では仮想証券先物取引市場（U-Mart⁷）によるマルチエージェント・シミュレーションを用いたパソコン実験を行い、①個人投資家の同調行動の存在を確認し、さらに、②具体的に投資家を特定できることを検証した。実験では、38体のマシ

⁶ Banerjee（1992）を参照。

⁷ U-Mart システムは金融市場の制度デザインの研究目的で科研費事業で開発され、教育面でもは工学、経済学における優れたコースウェアとして活用されている。

ンエージェント（コンピュータ・プログラム）と2名の学生被験者が先物証券の売買に参加し、実験群（同調あり）と比較群（同調なし）のA群とB群に分かれ、同時に売買を行い、注文データのログを記録し、さらに、両群の役割を交換してこの実験を繰り返した。分析結果として、ヒューマンエージェントとマシンエージェントの注文データの相関には、同調行動の有無による有意な差は認められず、タイムラグをとっても相関は高まらなかったが、判別分析より同調行動をとったマシンエージェントを高い精度で識別できた、としている。

図表Ⅱ－3－1 実験計画

		マシン・エージェント		ヒューマン	合計
		同調	ランダム	被験者	
1回目	A群	10体	9体	1人	20
	B群	0体	19体	1人	20
2回目	B群	10体	9体	1人	20
	A群	0体	19体	1人	20

内海(2014)より作成。

第Ⅲ章 投資主体の特徴

Fukase & Morimoto (2004) の研究から17年が過ぎた。最近では株式市場にAIが導入され以前よりも株価予測の信頼度が向上し、また、アルゴリズムによる自動発注の普及によって小刻みな売買も可能となり、売買件数の増加、投資主体間の行動様式の類似化など、投資主体の行動も変化していることが考えられる。そこで、本章ではあらためて、A) 自己、B) 個人投資家、C) 海外投資家、D) 証券会社、E) 投資信託、F) 事業法人、G) その他法人、H) 生保・損保、I) 都銀・地銀等、J) 信託銀行、K) その他金融機関、の11投資主体の投資行動の特徴を考察する。第1節で分析に使用する時系列データとその基本統計を示し、第2節で株価変動と投資主体の行動、第3節で投資環境変化と投資主体の行動、第4節では投資主体間でみられた行動様式の独自性の変化、について考察する。

第1節 実証分析に用いる時系列データと基本統計

本稿の分析に用いたのは、図表Ⅲ－1－1に示す変数の2002年7月から2020年12月までの月次の時系列データである。①投資主体の株式売買行動として売りと買いの枚数、また、②投資環境として、日経平均株価（225、月末値）、日経平均株価の値上がり率（対数差分）、通貨平均残高、貨幣流通高、貸出約定平均金利、為替レート（英国）⁸、為替レート（米国）を用いた。

⁸ 田代純（2002）は、日本の株式市場に大きな影響を与えながらも、あまり知られていないロンドンでの日本株の取引を解説している

AI（人工知能）による投資主体間の交雑株式保有移転と株価変動に関する深層学習

また、これらの変数の基本統計量は同図表に示すとおりである。これより、証券市場における各投資主体の影響力等を平均、最大値、最小値等から判断できる。なお、歪度は分布形状の歪みを示し、プラス値ではピークが左に、マイナス値では右に歪んでいることを示す。

図表Ⅲ－１－１ 分析に用いる主なデータの基本統計

投資主体 ポジション	自己		個人		海外投資家		証券会社	
	売り	買い	売り	買い	売り	買い	売り	買い
平均	7,084,336	7,036,314	9,615,942	9,504,223	17,347,927	17,516,413	711,775	707,651
標準誤差	165,400	155,829	308,554	300,661	522,979	522,023	33,778	33,657
中央値（メジアン）	6,753,045	6,606,180	8,809,451	8,578,497	16,699,557	16,863,553	593,845	611,140
最頻値（モード）	6,753,045	6,555,546	17,789,023	15,712,471	23,039,535	25,052,626	1,324,921	1,223,274
標準偏差	2,469,951	2,327,017	4,607,689	4,489,826	7,809,737	7,795,459	504,416	502,612
尖度	0.19	-0.20	6.21	6.26	0.11	0.26	4.18	3.81
歪度	0.55	0.46	1.95	1.95	0.41	0.45	1.79	1.74
範囲	14,286,338	12,565,928	32,631,430	32,403,936	41,213,457	42,480,984	3,009,961	2,930,848
最小	2,727,668	2,813,601	2,331,540	2,495,219	3,130,524	3,017,634	147,946	175,766
最大	17,014,006	15,379,529	34,962,970	34,899,155	44,343,981	45,498,618	3,157,907	3,106,614
合計	1,579,806,843	1,569,097,986	2,144,355,018	2,119,441,750	3,868,587,689	3,906,160,152	158,725,809	157,806,200
データの個数	223	223	223	223	223	223	223	223

投資主体 ポジション	投資信託		事業法人		その他法人		生保・損保	
	売り	買い	売り	買い	売り	買い	売り	買い
平均	596,958	600,156	448,270	478,376	69,637	115,402	107,850	67,995
標準誤差	13,753	13,047	12,743	11,309	3,123	2,695	4,011	2,248
中央値（メジアン）	596,298	610,513	399,801	452,080	59,164	106,789	97,179	60,931
最頻値（モード）	593,942	702,026	541,002	561,523	70,338	157,833	122,043	47,235
標準偏差	205,379	194,831	190,293	168,885	46,642	40,248	59,893	33,569
尖度	0.04	-0.02	1.92	1.21	21.94	0.69	2.18	0.97
歪度	0.13	0.23	1.30	1.04	3.87	1.00	1.36	1.00
範囲	1,164,706	996,902	1,082,991	892,914	398,796	190,622	323,914	168,484
最小	23,556	176,232	183,228	207,500	19,691	56,910	32,047	14,806
最大	1,188,262	1,173,134	1,266,219	1,100,414	418,487	247,532	355,961	183,290
合計	133,121,641	133,834,817	99,964,136	106,677,927	15,529,133	25,734,652	24,050,500	15,162,791
データの個数	223	223	223	223	223	223	223	223

投資主体 ポジション	信託銀行		都銀・地銀等		その他金融機関	
	売り	買い	売り	買い	売り	買い
平均	1,528,015	1,531,254	65,507	37,094	52,025	47,025
標準誤差	35,163	33,825	2,611	1,563	3,081	1,501
中央値（メジアン）	1,501,080	1,535,089	56,529	31,684	44,155	41,818
最頻値（モード）	1,262,136	1,574,185	52,978	39,973	54,242	91,497
標準偏差	525,097	505,110	38,998	23,340	46,011	22,416
尖度	-0.25	0.62	5.81	23.54	96.53	3.13
歪度	0.43	0.49	2.02	3.84	8.47	1.47
範囲	2,435,703	2,929,152	261,657	200,902	594,618	132,009
最小	574,277	528,798	16,690	6,843	11,563	12,375
最大	3,009,980	3,457,950	278,347	207,745	606,181	144,384
合計	340,747,415	341,469,664	14,608,093	8,272,035	11,601,590	10,486,484
データの個数	223	223	223	223	223	223

基本統計量	日経平均株価 (月末値)	通貨平均残高	貨幣流通高	日経平均株価 (%)	通貨平均残高 (%)	貨幣流通高 (%)	為替英国	為替米国
	平均	14,852	2,277,128	45,854	0.58%	0.92%	0.08%	110
標準誤差	332	113,580	115	0.004	0.002	0.000	1	1
中央値（メジアン）	14,632	1,144,208	45,364	0.009	0.006	0.001	106	110
標準偏差	4,951	1,696,108	1,712	0.054	0.025	0.003	11	9
分散	24,508,768	2,876,783,712.667	2,930,000	0.003	0.001	0.000	132	73
尖度	-0.996	-0.895	0.100	1.332	3.777	1.272	-1.343	-1.135
歪度	0.366	0.869	0.672	-0.554	0.626	0.151	0.489	-0.074
範囲	20095.0	5256737.0	7964.0	0.4	0.2	0.0	36.4	33.4
最小	7568.4	857469.0	42522.0	-23.83%	-9.06%	-0.78%	93.9	93.1
最大	27663.4	6114206.0	50486.0	15.04%	11.62%	1.22%	130.3	126.5
合計	3,312,050	507,799,584	10,225,523	1.293	2.043	0.173	24,528	24,180
データの個数	223	223	223	223	223	223	223	223

東京証券取引所 HP、日本銀行 HP、財務省 HP よりデータを入手し作成。

投資主体別の売買枚数の規模（月平均）を図表Ⅲ－１－２より比較する。取引規模（買い＋売りの合計）の大きい投資主体は、「海外投資家」、「個人」、「自己」、「都銀・地銀等」の順となっている。これらの投資主体では、売りと買いの均衡が比較的に取れており、保有株式のポジション管理がされている。しかし、売りと買いの差はわずかでも、取引規模が巨大であるために影響力が大きく、図表Ⅲ－１－３に示すように、「海外投資家」は買い手、「個人」と「自己」は売り手に回り、市場の需給を均衡させている。

一方、さほど取引規模は大きくないが、「生保・損保」、「信託銀行」、「その他金融機関」では売り越し、「その他法人」、「事業法人」では買い越しとなっている。つまり、マクロ的には、株式保有が、金融系の投資主体から法人系の投資主体へと移転しているようにもみえる。これには、18年半におよぶ時系列データの初期⁹では、銀行が保有していた会社株を企業グループの持ち株会社（HD）が買い戻したことや、敵対的企業買収を懸念した防衛策、企業内でのストック・オプションの進展などの影響も考えられる。

各投資主体の買い越し枚数を長期にわたり累計すると、図表Ⅲ－１－４のように、売り手と買い手に分かれた。買い手側には「海外投資家」、「その他法人」、「事業法人」が、売り手側には「個人」、「自己」、「生保・損保」、「都銀・地銀等」、「信託銀行」がまわった。分析期間の後半に、「個人」については売り越しが加速し、「自己」はポジションを管理する方向への転換がみられる。

図表Ⅲ－１－２ 投資主体別の売買枚数（月平均）

投資主体	売買合計	買い越し	買い越し率	行動パターン
自己	14,120,649	-48,022	-0.34%	ポジション管理
個人	19,120,165	-111,719	-0.58%	ポジション管理
海外投資家	34,864,340	168,486	0.48%	ポジション管理
証券会社	1,419,426	-4,124	-0.29%	ポジション管理
投資信託	1,197,114	3,198	0.27%	ポジション管理
事業法人	926,646	30,107	3.25%	買い越し
その他法人	185,039	45,765	24.73%	買い越し
生保・損保	175,844	-39,855	-22.67%	売り越し
都銀・地銀等	3,059,269	3,239	0.11%	ポジション管理
信託銀行	102,601	-28,413	-27.69%	売り越し
その他金融機関	99,050	-5,000	-5.05%	売り越し

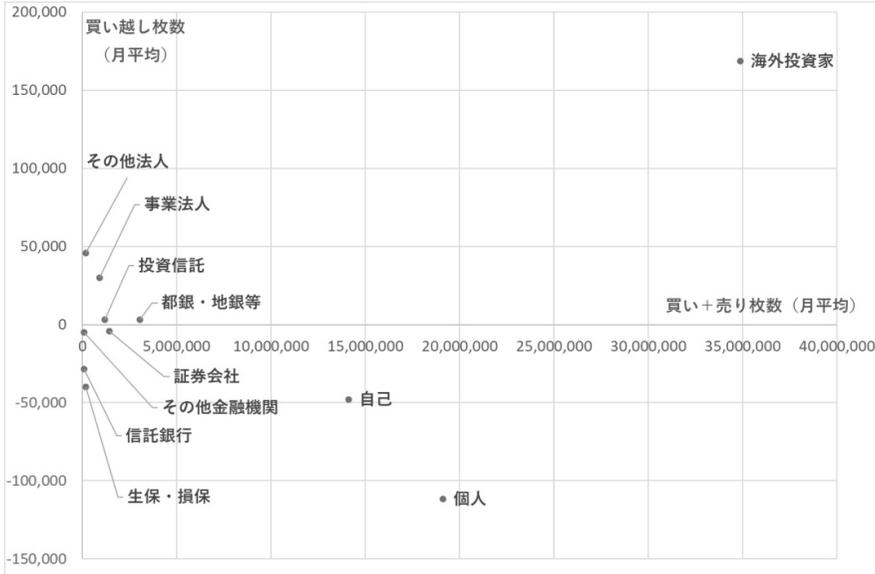
注 売買合計＝「買い」枚数＋「売り」枚数

買い越し＝「買い」枚数－「売り」枚数

買い越し率＝ $\frac{\text{「買い」枚数} - \text{「売り」枚数}}{\text{「買い」枚数} + \text{「売り」枚数}}$

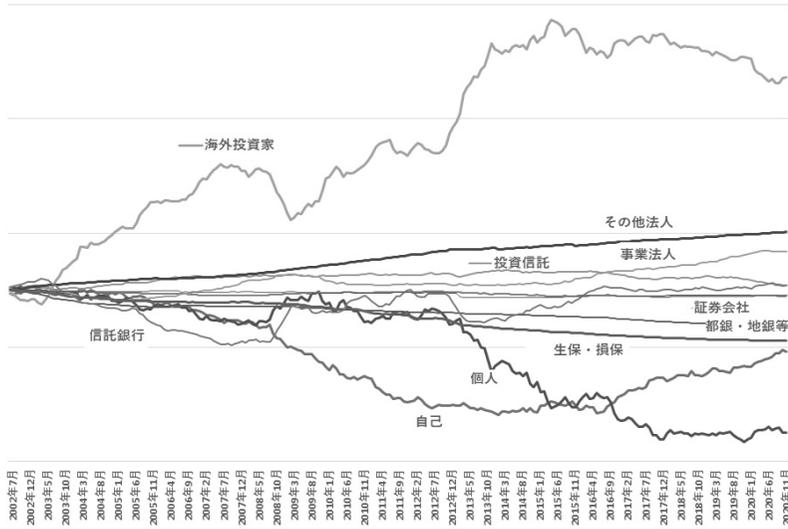
⁹ 田代純（2002、前掲）は、不良債権処理にかかわる株式持合いの解消で、わざわざロンドンで売却していると説明している。その理由は、またロンドン市場では日本企業銘柄の人気も高く、円建てでの取引も可能で、手数料も日本国内よりも安かったことなど。

図表Ⅲ－１－３ 投資主体別の売買枚数



筆者作成。

図表Ⅲ－１－４ 投資主体別の売買枚数



筆者作成。

第2節 株価変動と投資主体の行動

本節では、日本の株式市場に参加している投資主体が、投資活動における意思決定にどのような特徴を有しているのか、過去の売買データから考察したい。各投資主体の特徴を論じる前に、近年の日本の株式市場の状況を確認しておく。まず、2000年代初頭、ITバブルの崩壊に端を発し、株式市場は下げ相場となる。日経平均株価は8000円を割る状況であった。その後、米国の株価上昇に伴い日本の株式市場も上昇傾向に入る。しかし、2007年のサブプライムショックおよび2008年のリーマンショックで、株価は急落する。その後、株価は数年間回復しなかったが、2013年頃からアベノミクス相場と呼ばれる上昇相場が続くことになる。これが、2000年頃から現在までの日本の株式市場の概要である。

このように、2000年代、2010年代の日本の株式市場は、上昇と下落を繰り返していたのであるが、そのような状況の中で、各投資主体はどのような投資行動を取っていたのであろうか。それを確認するために、各投資主体の日本の株式市場における株式の買い越し枚数の時系列データを用いて分析を行う。

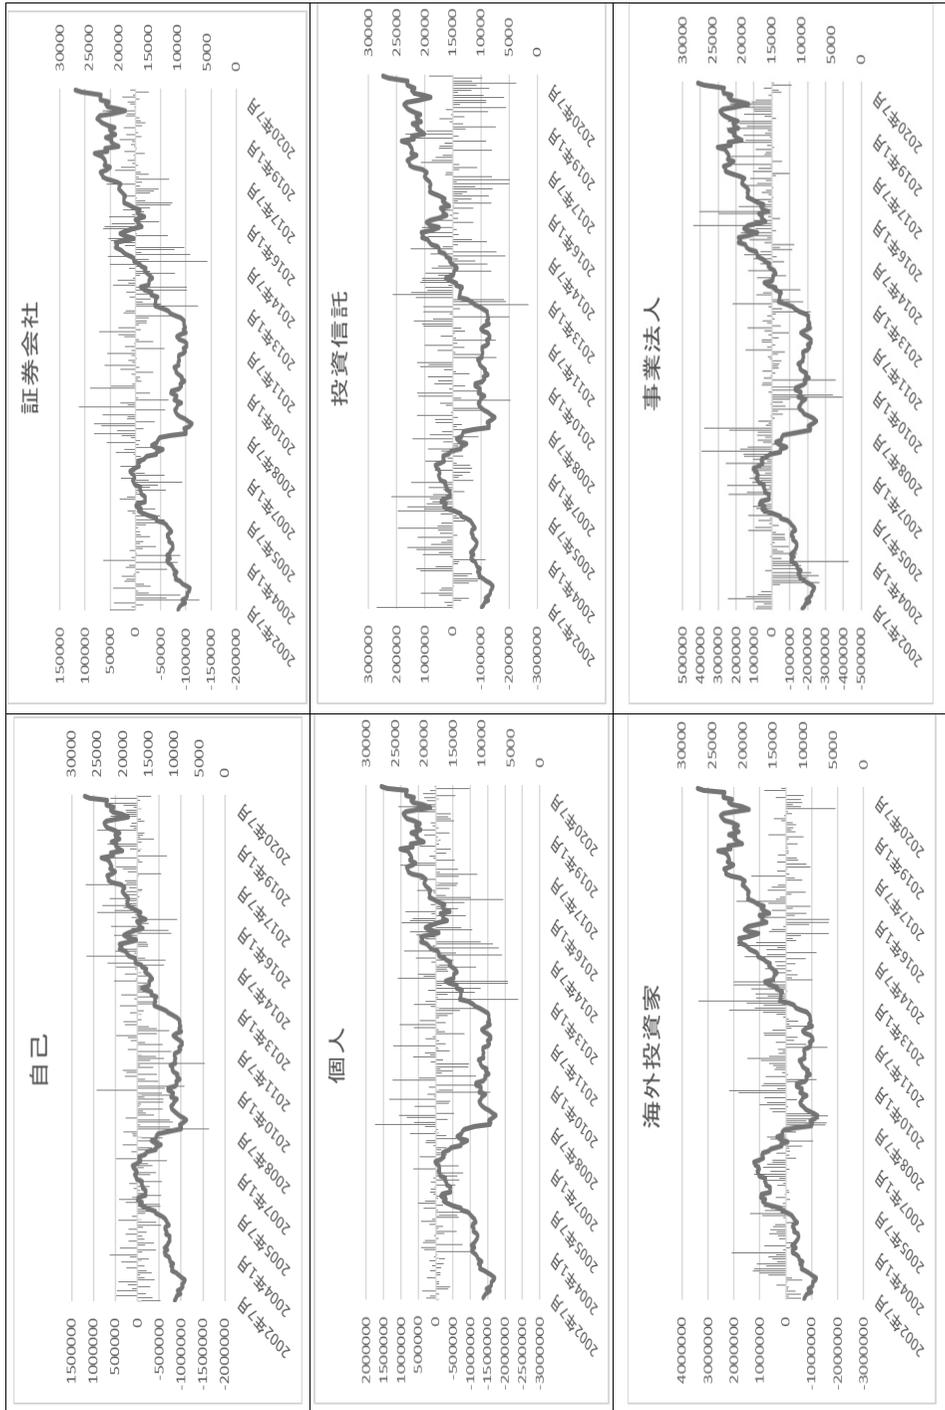
さらに、買い越し枚数の月次データと日経平均株価の折れ線グラフで、二軸グラフを作成した。このグラフで、株式市場が好況の時、不況の時に各投資主体はどのような投資行動を取っていたかを確認する。

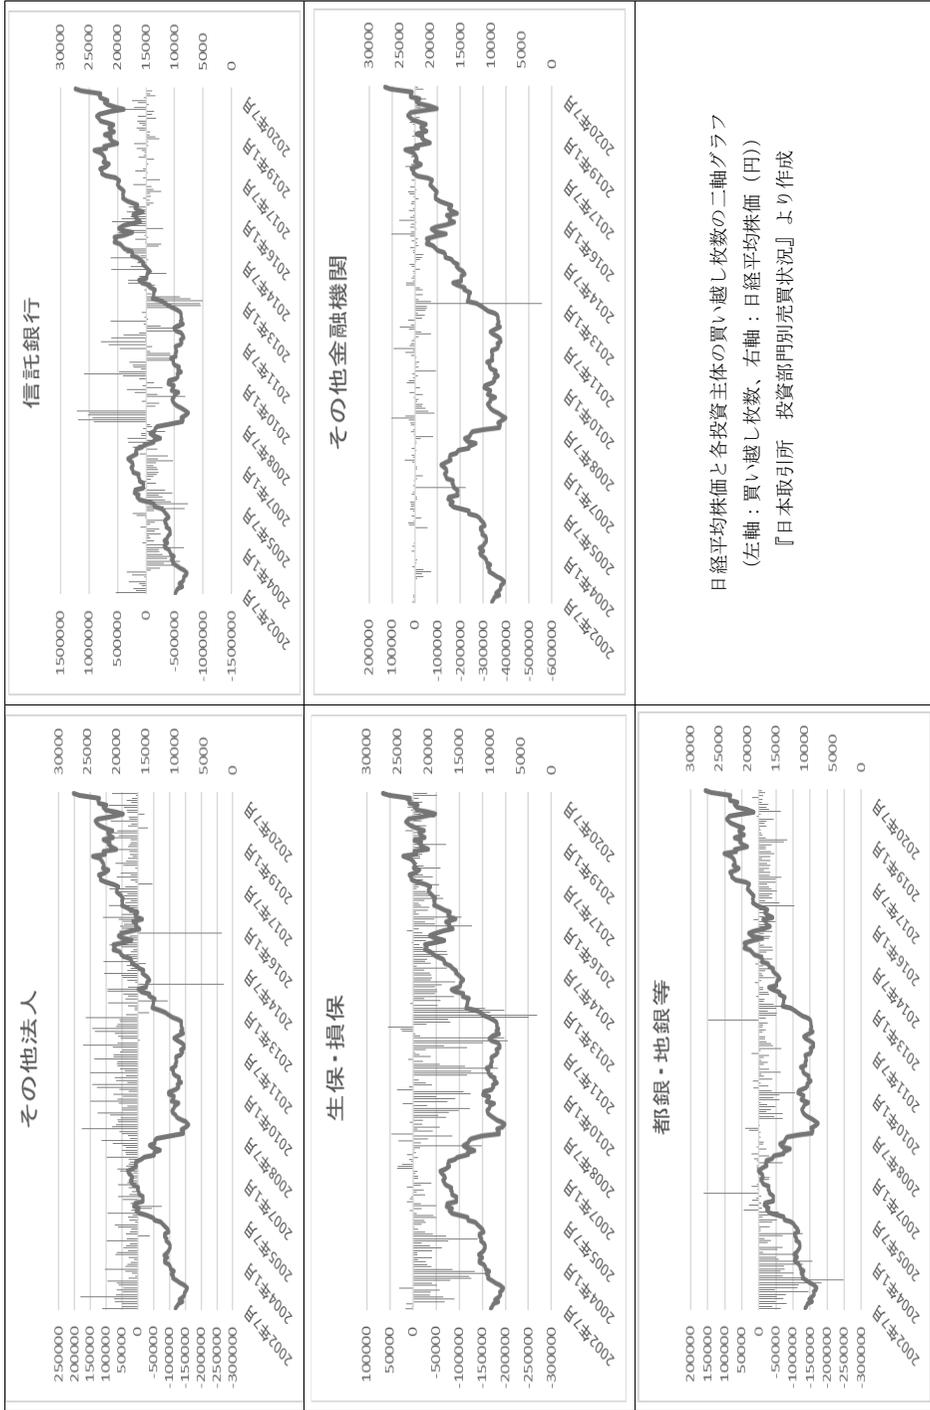
これらの投資主体の買い越し枚数の月次データと日経平均株価の折れ線グラフで、二軸グラフを作成した。このグラフで、株式市場が好況の時、不況の時に各投資主体はどのような投資行動を取っていたかを確認する。図表Ⅲ—2—1に示される11枚の図は、前述の月次データから作成した買い越し枚数と日経平均株価の比較グラフである。

グラフの左軸が株式の買い越し枚数、右軸が日経平均株価である。買い越し枚数は、各経済主体の買い枚数から売り枚数を差し引いた値で算出している。0以下は売り越しという事である。

まず、A)の自己売買から見ていきたい。2000年代初頭からリーマンショックの発生までは、売り越しと買い越しがバラバラに発生しているように見える。しかし、分析期間の開始時点である2002年7月から中盤の2012年末までの日経平均の騰落率（変化率）と、買い越し枚数の時系列データの相関係数は、約0.46である。つまり、この上昇相場では、投資行動の意思決定において、買いに偏っていたと言える。その後の、リーマンショック後から株価が回復基調に入るまでは、買い越しがマイナス、つまり売り越しに偏っている。グラフ後半のアベノミクス相場と呼ばれる上昇相場に入ると、再び買い越しに偏る傾向が見て取れる。検証期間後半の2013年から2020年末までの相関係数も約0.44で、おおよそではあるが、上昇相場では買い越し、下降相場では売り越しという日経平均株価のトレンドに連動した意思決定を行っている傾向が見て取れる。

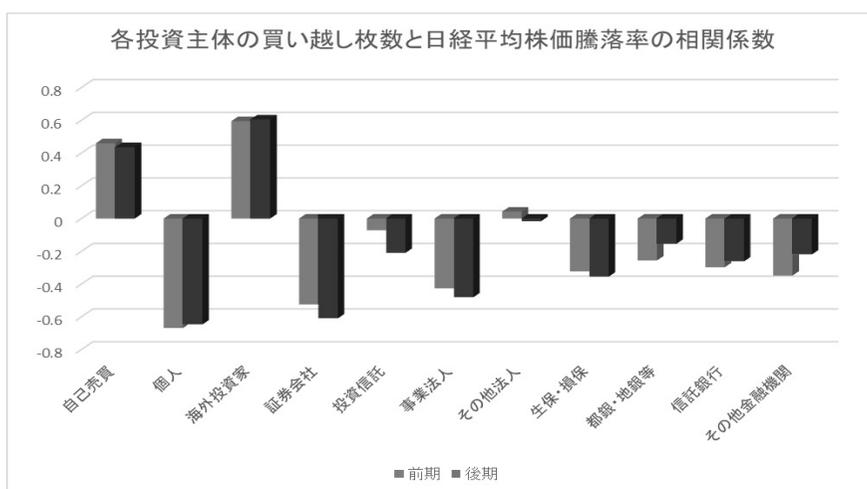
図表Ⅲ-2-1 日経平均株価と投資主体の買越し枚数ポジション





次の図表Ⅲ-2-2は、各投資主体の買い越し枚数と日経平均株価の騰落率の相関係数を棒グラフにしたものである。各変数は比較し易くするために標準化したものを用い、相関係数を算出している。相関性を算出するにあたり、検証期間を前半と後半の半分に分割して相関係数を求め、年代によって相関性に差異が無いかも検証する。図の左端の棒グラフが自己売買の買い越し枚数と日経平均株価の騰落率との相関係数を表している。前期と後期で、ほぼ同等の相関係数であることが見て取れる。それに対して隣のグラフの個人投資家の売買行動は、前期、後期ともにほぼ逆相関を示している。

図表Ⅲ-2-2 各投資主体の買い越し枚数と日経平均騰落率の相関係数



グラフ左側：前期、グラフ右側：後期
『日本取引所 投資部門別売買状況』より作成

図表Ⅲ-2-1の二軸グラフに戻り、買い越し枚数の月次データがどのようになっているか確認する。

個人投資家のグラフでは、データ開始時からリーマンショックまでの上昇相場では、投資行動は売り越しに偏っている。その後、リーマンショックによる下降相場と、続く低迷期はやや買い越し月が目立つ。後半のアベノミクス相場の上昇トレンドに入ると、再び売り越しが増加するようになっている。

自己売買と個人投資家の投資行動は、次のような特徴を持っていると考えられる。

自己売買は、上昇相場では買い越し傾向であるが、下降相場では売り越し傾向である。

個人投資家は、上昇相場では売り越し傾向であるが、下降相場では買い越し傾向である。つまり、自己売買の投資行動は相場のトレンドに逆らわない順張り方式であり、個人投資家は相場のトレンドに反する逆張りのスタイルであると言える。

3つ目の投資主体の**海外投資家**は、自己売買よりも強い相場との相関性を示している。つ

まり、海外投資家も市場のトレンドに合わせる順張りの投資スタイルであるといえる。自己売買との違いは、検証期間中盤の低迷期の小さな上昇、下降トレンドでも、細かく順張りの売買行動を行っている点と、検証期間終盤の上昇トレンドで、あまり買い越し月が見られない点である。

図表Ⅲ－2－2の相関係数の棒グラフを見てみると、相場のトレンドと正の相関をもつのは、自己売買と海外投資家のみである。他は、相関がほぼ無いか、負の相関ばかりとなっている。

4つ目の投資主体の**証券会社**も、個人投資家に次ぐ負の相関性を有している。図1の二軸グラフで確認してみると、やはり個人投資家と同様に逆張りの投資スタイルであった。

5つ目以降の投資主体も同様の傾向であるが、相関係数が小さ過ぎたり、全検証期間を通してほぼ売り越し、もしくは買い越し一辺倒であったりするなど、単純な売買動向の比較だけでは正確な検証は行い辛いと考えられる。また、検証期間を前半と後半に分割して検証を行ったが、相関係数に大きな差異が現れたものは見受けられなかった。

以上の検証結果により、各投資主体の投資スタイルの特徴がある程度判明した。自己売買や海外投資家は、市場のトレンドと強い相関を示している順張りのスタイルであり、個人投資家や証券会社は、市場のトレンドに対して強い逆相関を示す逆張りのスタイルであった。その他のハッキリとした相関係数が現れない投資主体については、他の検証手法を用いる必要があると思われる。

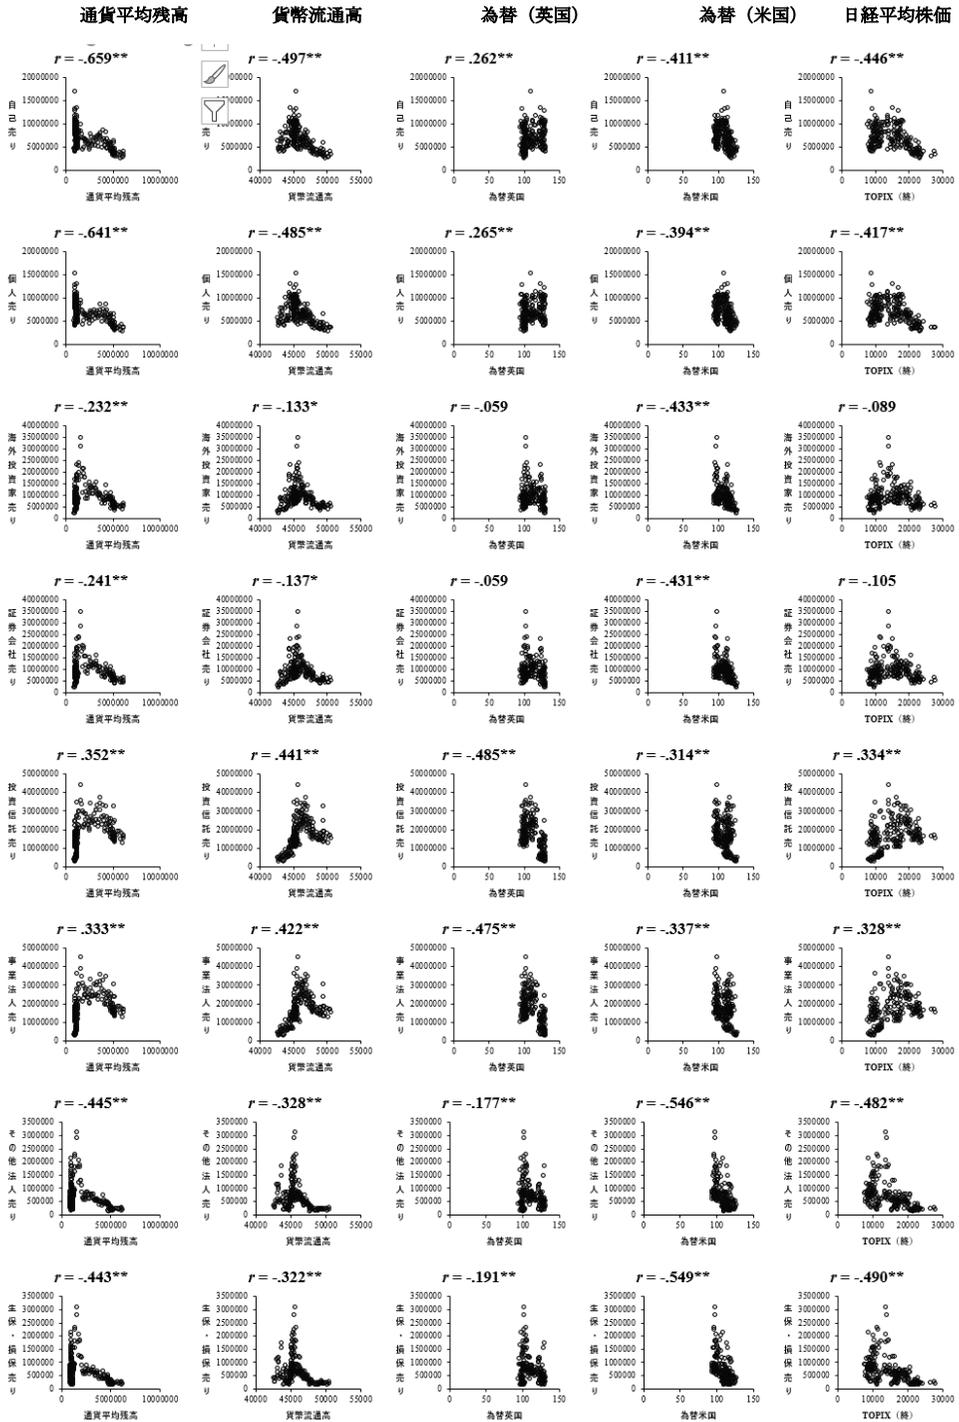
第3節 投資環境変化と投資主体の行動

前節では、日経平均株価（225、月末）と各投資主体の買い越し枚数の関係を分析したが、本節では、株価以外の投資環境として、通貨平均残高、貨幣流通高、貸出約定平均金利、為替レート（英国）、為替レート（米国）との関係について考察する。

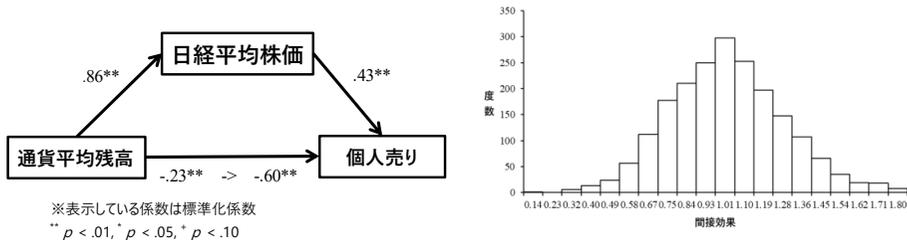
まず、これらの経済変数の変化と「売り」の枚数との関係を図表Ⅲ－3－1の散布図に示す。多くの変数には閾値（しきいち）がみられ、一定の値を超えると「売り」控えが始まる傾向がみられる。

通貨平均残高の増加による「売り」控え現象について、個人投資家を事例として分析した。図表Ⅲ－3－2に示すように、日経平均株価を介在させて、媒介効果分析を行ったところ、ブートストラップ検定結果から間接効果の存在が有意となった。すなわち、通貨平均残高が1増加すると、**直接効果**として個人投資家は「売り」を0.6減少させる。しかし同時に、**間接効果**により、日経平均株価が上昇するために「売り」を0.37（ 0.86×0.43 ）増加させる。個人投資家は、これらの相反する2つの効果の影響を受け、**総合効果**として「売り」を0.23（ $0.6 - 0.37$ ）減少させる。

図表Ⅲ-3-1 投資環境の経済変数と「売り」の枚数



図表Ⅲ－3－2 個人投資家の「売り」に関する媒介効果分析の結果



媒介変数なし

変数名	係数	標準化	標準誤差	df	t値	p値
個人売り<-通貨平均残高	-0.629	-.232	0.178	221	-3.539	.000

媒介変数あり

変数名	係数	標準化	標準誤差	df	t値	p値
日経平均株価<-通貨平均残高	0.003	.861	0.000	221	25.177	.000
個人売り<-日経平均株価	.399.292	.429	117.002	220	3.413	.001
個人売り<-通貨平均残高	-1.633	-.601	0.342	220	-4.781	.000

検定法	係数	標準化	標準誤差	Z値	p値
Sobel	1.004	.369	0.297	3.382	.001
Aroian	1.004	.369	0.297	3.379	.001
Bootstrap	1.004	.369	0.257	3.899	.000

図表Ⅲ－3－3 経済変数と投資主体の売買の相関係数

変数	日経平均株価	通貨平均残高	貨幣流通高	貸出約定平均金利	為替英国	為替米国
自己売り	-0.446	-0.659	-0.497	0.549	0.262	-0.411
個人売り	-0.089	-0.232	-0.133	-0.021	-0.059	-0.433
海外投資家売り	0.334	0.352	0.441	-0.584	-0.485	-0.314
証券会社売り	-0.482	-0.445	-0.328	0.163	-0.177	-0.546
投資信託売り	0.113	0.121	0.270	-0.325	-0.463	-0.363
事業法人売り	-0.314	-0.435	-0.406	0.299	0.204	-0.252
その他法人売り	0.072	-0.010	0.038	-0.091	-0.074	-0.127
生保・損保売り	-0.604	-0.453	-0.435	0.222	-0.063	-0.387
都銀・地銀等売り	-0.297	-0.190	-0.392	0.282	0.242	0.248
信託銀行売り	-0.596	-0.708	-0.665	0.597	0.365	-0.339
その他金融機関売り	0.019	0.002	0.051	-0.119	-0.139	-0.148
自己買い	-0.417	-0.641	-0.485	0.545	0.265	-0.394
個人買い	-0.105	-0.241	-0.137	-0.015	-0.059	-0.431
海外投資家買い	0.328	0.333	0.422	-0.573	-0.475	-0.337
証券会社買い	-0.490	-0.443	-0.322	0.159	-0.191	-0.549
投資信託買い	0.021	-0.017	0.140	-0.227	-0.366	-0.438
事業法人買い	-0.156	-0.329	-0.277	0.229	0.232	-0.166
その他法人買い	-0.263	-0.202	-0.116	0.055	-0.209	-0.271
生保・損保買い	-0.654	-0.516	-0.512	0.366	0.062	-0.264
都銀・地銀等買い	-0.197	-0.242	-0.239	0.184	0.156	-0.092
信託銀行買い	-0.672	-0.684	-0.612	0.549	0.239	-0.327
その他金融機関買い	0.105	0.141	0.163	-0.265	-0.209	-0.094
TOPIX (終)	1.000	0.861	0.828	-0.649	-0.240	0.415
通貨平均残高	0.861	1.000	0.916	-0.847	-0.534	0.493
貨幣流通高	0.828	0.916	1.000	-0.841	-0.656	0.225
貸出約定平均金利	-0.649	-0.847	-0.841	1.000	0.737	-0.143
為替英国	-0.240	-0.534	-0.656	0.737	1.000	0.209
為替米国	0.415	0.493	0.225	-0.143	0.209	1.000

図表Ⅲ－3－3では、経済変数と投資主体の売買行動との相関係数において、「売り」と「買い」を比較した。両者で少し数値は異なるが同符号であった。絶対値で0.4以上の相関をみると、通貨量の変数は、多くの投資主体の売買と負の相関がみられたが、「外国人投資家」のみ正の相関がみられた。また、金利と正の相関をもつ主体は「自己」と「信託銀行」であり、負の相関をもつ主体は「外国人投資家」のみであった。

以上の結果を踏まえて正準相関分析を行い、投資主体（ $n=11$ 変数）と投資環境の経済変数（ $m=5$ 変数）とを対応づけ、図表Ⅲ－3－4に示す散布図上に落とし込んだ。なお、図が煩雑にならないよう、データには「買い」と「売り」を合計した取引枚数を用いた。また、散布図の2軸の座標には、構造係数ベクトルを用いた。このような分析を、期間を前期（2002年7月から2012年12月）と後期（2013年1月から2020年12月）に分けて行い、分析結果を比較して行動様式の変化を考察する。

正準相関分析とは、複数の目的変数（ m 個）に対し、複数の説明変数（ n 個）がどのように影響しているのかを調べることができる分析手法である。目的変数、説明変数のそれぞれについて、次式のような各変数群内の変数を線型一次結合によって総合評価（要約）する正準関数を考える。

$$X = a_1x_1 + a_2x_2 + \cdots a_nx_n$$

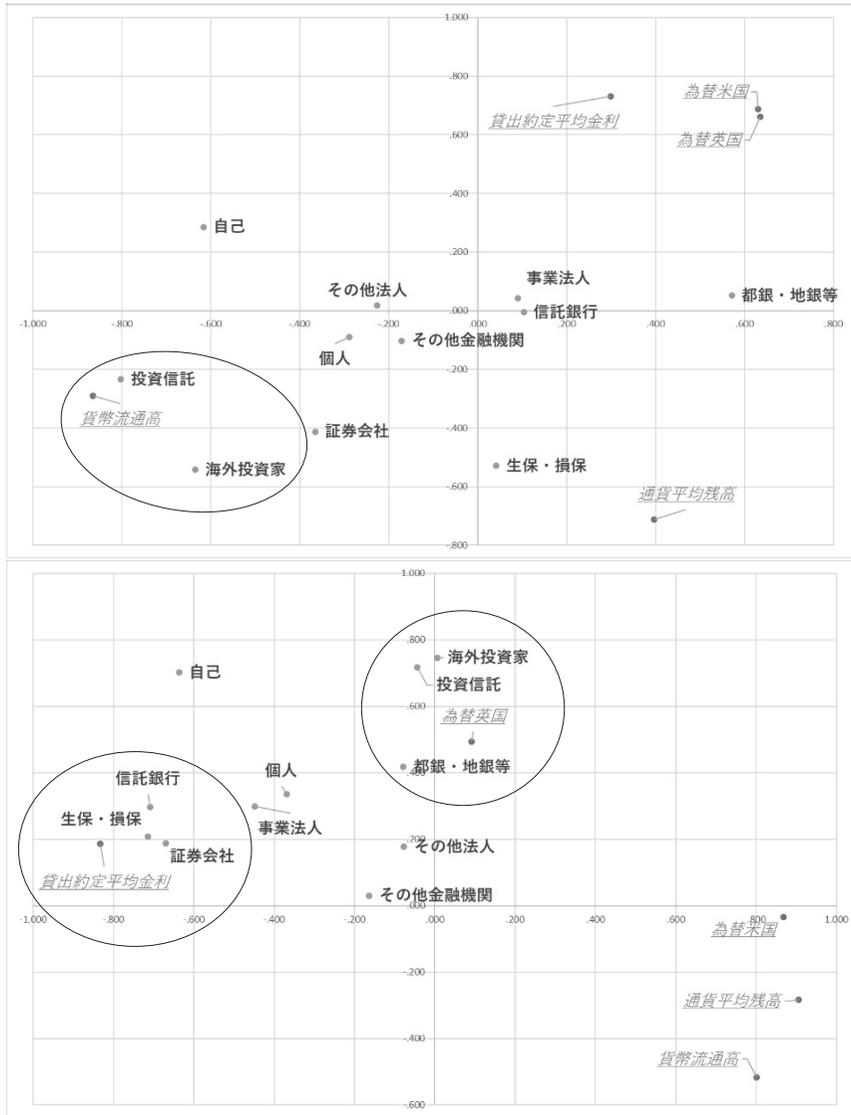
$$Y = yx_1 + b_2y_2 + \cdots b_my_m$$

このような評価関数 X, Y の値は、重みベクトル a_1, a_2, \cdots, a_n と b_1, b_2, \cdots, b_n の値の選び方に依存して変化するが、 X, Y の相関 r_{XY} を最大化するような重みベクトルを探索する方法が、正準相関分析である。この相関係数の最大値を正準相関係数（canonical correlation coefficient）と呼ぶ。正準相関は、変数の個数が少ない変数群の個数（ $\text{Min}[m,n]$ ）だけ求められる。目的変数が1つの変数しかもたないとき、正準相関係数は、重相関係数に一致する。得られた最適な重みベクトルを正準相関変数といい、その変数群に属する各変数との相関係数より構成される、相関係数ベクトルを構造ベクトルという。正準相関変数についての重みベクトル（ $a_1, a_2, \cdots, a_n, b_1, b_2, \cdots, b_n$ ）については、一般に不安定であり、解釈が難しいとされるため、構造係数ベクトルを用いて分析を行う。重みベクトルについては、正準相関変数を示す偏回帰係数のVIFが10を超えるものがあり、通説のとおり不安定であった（図表Ⅲ－3－5）。

構造係数に基づき、正準相関分析を行った結果、図表Ⅲ－3－4のように、前期（2002年7月から2012年12月）と後期（2013年1月から2020年12月）とで以下の変化がみられた。

「投資信託」や「海外投資家」は前期には貨幣流通高の周辺に布置していたが、後期は英国為替の近くに移動した。また、後期は「信託銀行」、「証券会社」や、前期には通貨平均残高の周

図表Ⅲ－3－4 正準相関分析の結果
2002年7月から2012年12月（上図）と2013年7月から2020年12月（下図）の比較



2002年7月から2012年12月

2013年1月から2020年12月

モデル適合 ※PillaiとはPillaiのトレースを意味しています

変数名	R^2	Pillai	F値	df1	df2	p 値	R^2	Pillai	F値	df1	df2	p 値
全体	.993	2.716	12.326	55	570	.000	.968	1.845	6.063	55	570	.000

説明変数の多変量検定

変数名	標準化	偏 η^2	F値	df1	df2	p 値	標準化	偏 η^2	F値	df1	df2	p 値
通貨平均残高	.122	.578	13.675	11	110	.000	.888	.490	9.618	11	110	.000
貨幣流通高	.251	.705	23.879	11	110	.000	.439	.347	5.320	11	110	.000
貸出約定平均金利	.087	.274	3.773	11	110	.000	.178	.181	2.208	11	110	.019
為替英国	.189	.630	17.042	11	110	.000	.243	.608	15.532	11	110	.000
為替米国	.198	.543	11.859	11	110	.000	.317	.267	3.650	11	110	.000

AI（人工知能）による投資主体間の交雑株式保有移転と株価変動に関する深層学習

辺に布置した「生保・損保」等が、貸し出し約定金利の周辺に集まっている。

前節で確認した株価と異なり、経済指標に対する投資主体の反応には変化がみられた。

図表Ⅲ－３－５ 正準相関変数（重みベクトル）、参考

標準化偏回帰係数 2002年7月から2012年12月												
変数名	自己	個人	海外投資	証券会社	投資信託	事業法人	その他法人	生保・損保	都銀・地銀等	信託銀行	その他金融機関	VIF
通貨平均残高	-.317 **	-.207 *	-.136 *	.049	-.126 *	.200 +	.054	.089	-.194 *	-.158	-.092	1.657
貨幣流通高	.822 **	.807 **	.144	-.106	.674 **	.267	.677 **	-.709 **	-.755 **	.023	-.120	4.043
貸出約定平均金利	-.053	-.176	-.178 *	.266 *	.038	.003	-.314 *	.097	.406 **	-.134	-.234	3.059
為替英国	.107	.152	.126	-.925 **	-.369 **	.020	.283 +	-.725 **	-.500 **	-.077	.114	3.216
為替米国	.333 +	.482 *	-.698 **	.090	.171	.352 *	.426 *	-.283 +	-.002	.099	-.036	5.051
R^2	.421 **	.250 **	.667 **	.420 **	.616 **	.047 **	.175 **	.391 **	.481 **	.020 *	.052 **	
標準化偏回帰係数 (2018年1月から2020年12月)												
変数名	自己	個人	海外投資	証券会社	投資信託	事業法人	その他法人	生保・損保	都銀・地銀等	信託銀行	その他金融機関	VIF
通貨平均残高	-.562 *	-.033	-.073	-.788 **	.364	-.599 +	-.065	-.995 **	.293	-.588 *	-.711	25.282
貨幣流通高	-.647 **	-.301	-.773	.117	-.1049 **	-.087	-.201	.165	-.808 **	-.132	.189	11.134
貸出約定平均金利	-.068	-.252	-.486	-.205	-.255	-.268	-.068	-.096	-.004	-.081	-.274	4.426
為替英国	-.055	-.163	.300	-.029	.135 +	.042	.009	-.097 +	-.123	-.075	-.060	1.170
為替米国	.428 **	-.349	.298	-.210 +	.280	-.045	.102	.024	.362	-.108	.133	8.484
R^2	.566 **	.278 **	.288 **	.487 **	.217 **	.270 **	.019 +	.505 **	.103 **	.528 **	.047 **	

** $p < .01$, * $p < .05$, + $p < .10$

第4節 AI導入による影響

野村ホールディングスがAIによる「5分先の株価」予測サービスを開始した2016年を境に、前期を2011年1月から2015年12月、後期を2016年1月から2020年12月、いずれも5年間とし、投資主体の行動様式にみられた独自性に変化が生じているか、検証した。まず、株式の「売り」と「買い」の枚数について、2期間の投資主体間の相関係数行列（図表Ⅲ－４－１）を作成した。次に、売りと買いについて、2期間の相関係数行列の平均値において差が生じているか、2元配置の分散分析（ANOVA）を用いて検定した。

図表Ⅲ－４－１ 投資主体間の「売り」枚数および「買い」枚数の単相関係数行列

投資主体	「売り」の相関行動											投資主体	「買い」の相関行動										
	自己	個人	海外投資家	証券会社	投資信託	事業法人	その他法人	生保・損保	都銀・地銀等	信託銀行	その他金融機関		自己	個人	海外投資家	証券会社	投資信託	事業法人	その他法人	生保・損保	都銀・地銀等	信託銀行	その他金融機関
人	1	0.492	0.597	0.498	0.509	0.499	0.292	0.465	0.409	0.734	0.275	人	1	0.5909	0.6512	0.5598	0.6304	0.6009	0.3527	0.3803	0.287	0.5547	0.3363
工	0.492	1	0.744	0.905	0.552	0.846	0.330	0.354	0.529	0.522	0.394	工	0.5909	1	0.8248	0.9038	0.6185	0.7818	0.2495	-0.039	0.0953	0.1097	0.176283
知	0.597	0.744	1	0.554	0.698	0.560	0.329	0.074	0.367	0.389	0.233	知	0.6512	0.8248	1	0.6214	0.843	0.675	0.0248	-0.001	0.2281	0.2696	0.382503
能	0.498	0.905	0.554	1	0.330	0.806	0.279	0.500	0.474	0.618	0.381	能	0.5598	0.9038	0.6214	1	0.4014	0.6873	0.3371	0.1486	0.0964	0.161	0.019669
情	0.509	0.552	0.698	0.330	1	0.569	0.178	0.335	0.488	0.558	0.330	情	0.6304	0.6185	0.843	0.4014	1	0.4935	0.0905	0.0158	0.2943	0.4227	0.413651
報	0.499	0.846	0.560	0.806	0.569	1	0.304	0.578	0.622	0.659	0.505	報	0.6009	0.7818	0.675	0.6873	0.4935	1	0.2769	0.0173	0.2053	0.1572	0.192149
提	0.292	0.330	0.329	0.279	0.178	0.304	1	0.085	0.226	0.142	0.107	提	0.3527	0.2495	0.0248	0.3371	0.0905	0.2769	1	0.2464	-0.039	0.2769	-0.005019
供	0.465	0.354	0.074	0.500	0.335	0.578	0.085	1	0.522	0.779	0.414	供	0.3803	-0.039	-0.001	0.1486	0.0158	0.0173	0.2464	1	0.1883	0.5505	0.237552
前	0.409	0.529	0.367	0.474	0.488	0.622	0.226	0.522	1	0.562	0.646	前	0.287	0.0953	0.2281	0.0964	0.2943	0.2053	-0.039	0.1883	1	0.355	-0.018446
後	0.734	0.522	0.389	0.618	0.558	0.659	0.142	0.779	0.562	1	0.397	後	0.5547	0.1097	0.2696	0.161	0.4227	0.1572	0.2769	0.5505	0.355	1	0.272604
	0.275	0.394	0.233	0.381	0.330	0.505	0.107	0.414	0.646	0.397			0.3363	0.1763	0.3825	0.0197	0.4137	0.1921	-0.005	0.2376	-0.018	0.2726	1
人	1	0.7918	0.9182	0.8593	0.8364	0.7075	0.3587	0.7551	0.6317	0.8106	0.454336	人	1	0.8303	0.8901	0.8743	0.8835	0.6386	0.4077	0.7047	0.16165	0.842	0.786417
工	0.7918	1	0.7089	0.9016	0.7173	0.7593	0.4248	0.6362	0.6563	0.6994	0.354409	工	0.8303	1	0.8296	0.8906	0.8071	0.6283	0.5005	0.6581	0.4686	0.7018	0.650509
知	0.9182	0.7089	1	0.7804	0.7972	0.6599	0.3438	0.7157	0.5871	0.7592	0.620123	知	0.8901	0.8296	1	0.8669	0.8532	0.6708	0.3835	0.7659	0.5688	0.8611	0.804146
能	0.8593	0.9016	0.7804	1	0.8171	0.7576	0.3452	0.6679	0.5674	0.7388	0.393404	能	0.8743	0.8906	0.8669	1	0.8497	0.6279	0.4758	0.7039	0.5931	0.7704	0.721099
情	0.8364	0.7173	0.7972	0.8171	1	0.7231	0.4024	0.6432	0.602	0.8439	0.498884	情	0.8835	0.8071	0.8532	0.8497	1	0.6312	0.4547	0.606	0.5499	0.8568	0.701253
報	0.7075	0.7593	0.6599	0.7576	0.7231	1	0.5345	0.676	0.765	0.7576	0.407254	報	0.6386	0.6283	0.6708	0.6279	0.6312	1	0.4464	0.5988	0.5141	0.5669	0.582892
提	0.3587	0.4248	0.3438	0.3452	0.4024	0.5345	1	0.2747	0.4807	0.3314	0.378628	提	0.4077	0.5005	0.3835	0.4758	0.4547	0.4464	1	0.2833	0.245	0.3141	0.342217
供	0.7551	0.6362	0.7157	0.6679	0.6432	0.676	0.2747	1	0.5974	0.6792	0.28873	供	0.7047	0.6581	0.7659	0.7039	0.606	0.5988	0.2833	1	0.4984	0.6326	0.635321
後	0.6317	0.6563	0.5871	0.5674	0.602	0.765	0.4807	0.5974	1	0.6324	0.320875	後	0.6165	0.4686	0.5688	0.5931	0.5499	0.5141	0.245	0.4984	1	0.5988	0.659108
	0.8106	0.6994	0.7592	0.7388	0.8439	0.7576	0.3314	0.6792	0.6324	1	0.41914		0.842	0.7018	0.8611	0.7704	0.8568	0.5669	0.3141	0.6326	0.5988	1	0.725372
	0.4543	0.3544	0.6201	0.3934	0.4989	0.4073	0.3786	0.2887	0.3209	0.4191			0.7864	0.6505	0.8041	0.7211	0.7013	0.5829	0.3422	0.6353	0.6591	0.7254	1

検定結果は図表Ⅲ－４－２に示される。「売り」「買い」とともに、相関係数行列の「平均」の値は情報提供後の方が大きい。分散分析表において、2期間を比較した「標本」のp値みるといずれも0に近い数値であり、両期間の平均値に有意な差が認められた。また、投資主体間を比較した「列」についてもp値は1%未満であり有意な差が認められた。

これらの結果から、投資主体間に独自性は残存するが、2016年以降、投資主体間の相関が高まったことから、行動様式の独自性が弱まり、行動が画一化していると考えられる。

図表Ⅲ－４－２ 分散分析（2元配置）の結果

概要	自己 売り	個人 売り	海外投資 家売り	証券会 社売り	投資信 託売り	事業法 人売り	その他法 人売り	生保・ 損保売り	都銀・地 銀等売り	信託銀 行売り	その他金 融機関売 り	合計
人工知能情報提供前												
データの個数	11	11	11	11	11	11	11	11	11	11	11	121
合計	5.770945	6.667769	5.544355	6.345235	5.548641	6.945692	3.27138	5.105837	5.845797	6.36	4.680752	62.08641
平均	0.52463	0.60616	0.50403	0.57684	0.50442	0.63143	0.2974	0.46417	0.53144	0.57818	0.42552	0.51311
分散	0.0411	0.05348	0.06768	0.0552	0.04888	0.03658	0.06211	0.07315	0.03822	0.05135	0.05592	0.05672
人工知能情報提供後												
データの個数	11	11	11	11	11	11	11	11	11	11	11	121
合計	8.123572	7.650013	7.890433	7.828609	7.881485	7.747772	4.874857	6.934149	6.840653	7.671529	5.135784	78.57886
平均	0.73851	0.69546	0.71731	0.71169	0.7165	0.70434	0.44317	0.63038	0.62188	0.69741	0.46689	0.64941
分散	0.03705	0.03439	0.03017	0.0418	0.02922	0.022	0.03935	0.04099	0.02805	0.0351	0.03936	0.04111
分散分析表												
変動要因	変動	自由度	分散	観測され た分散比	P-値	F 境界値						
標本	1.123971	1	1.123971	25.72702	8.3E-07	3.884075						
列	1.929018	10	0.192902	4.415407	1.1E-05	1.873923						
交互作用	0.199683	10	0.019968	0.457063	0.91592	1.873923						
繰り返し誤差	9.611434	220	0.043688									
合計	12.86411	241										
人工知能情報提供前												
データの個数	11	11	11	11	11	11	11	11	11	11	11	121
合計	5.944206	5.3111	5.519493	4.936617	5.223763	5.087227	2.810985	2.744192	2.692537	4.129856	3.007246	47.40722
平均	0.54038	0.48283	0.50177	0.44878	0.47489	0.46248	0.25554	0.24947	0.24478	0.37544	0.27339	0.3918
分散	0.04052	0.13917	0.1159	0.11058	0.08595	0.09718	0.08062	0.09399	0.07857	0.06512	0.08079	0.0945
人工知能情報提供後												
データの個数	11	11	11	11	11	11	11	11	11	11	11	121
合計	8.474083	7.965376	8.494148	8.373678	8.193406	6.905953	4.85324	7.086819	6.312262	7.869784	7.608335	82.13708
平均	0.77037	0.72413	0.7722	0.76124	0.74486	0.62781	0.4412	0.64426	0.57384	0.71543	0.69167	0.67882
分散	0.02765	0.02678	0.02963	0.0238	0.02798	0.01929	0.0411	0.03041	0.03208	0.03451	0.02587	0.03604
分散分析表												
変動要因	変動	自由度	分散	観測され た分散比	P-値	F 境界値						
標本	4.984146	1	4.984146	83.86318	3.8E-17	3.884075						
列	2.231847	10	0.223185	3.755303	0.00011	1.873923						
交互作用	0.357794	10	0.035779	0.602024	0.81133	1.873923						
繰り返し誤差	13.07501	220	0.059432									
合計	20.6488	241										

第IV章 投資行動と株価形成

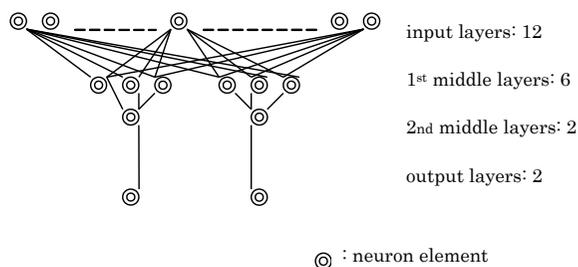
第1節 交雑株式保有移転学習法（CPTL）

金融商品価格の予測のために多様な統計手法が開発されたが、株式市場において主に使用される手法はファンダメンタル分析とテクニカル分析であった。伝統的な時系列予測モデルでは、企業の決算開示、消費者物価指数や鉱工業生産などのマクロ指標、金利や為替などのマーケットデータ等、一般的な公開情報の過去のデータを用いて未来を予測してきた。しかし、2000年代前半はIT技術が発展し、国際間の金融市場のみならず他の商品市場との連動が強まり、市場の価格調整が効率化されたことなどから、従来の分析手法の予測精度が低下した。

そこで、Fukase&Morimoto（2004）では、株式市場を構成する様々な投資主体の売買行動に着目し、ニューラルネットワークを用いた新しい株価予測手法を開発した。各投資主体が「買い手」と「売り手」に別れて取引される結果は、マクロな証券市場におけるストックとしての保有量（投資主体の構成比）の変化として観察される。各投資家の戦略や方針はそれぞれ異なり、株価の変化への影響も異なるが、投資主体間で保有する株式が移動するたびに、需要と供給の関係に応じて株価が変動する。この関係に何らかの秩序が存在すれば、ランダムに変動しているように見える株価を予測できる可能性がある。そこで、それぞれの投資対象が保有する株式の動きと株価の複雑な関係を分析するために、ニューラルネットワークを用いたパターン認識学習を導入した。この手法を「交雑株式保有移転学習法」（Cross-Position Transfer-Learning：CPTL）と呼ぼう。

Fukase&Morimoto（2004）において、株価予測に用いたニューラルネットワーク（ANNs）は図表IV-1-1に示される4層構造のもので、入力層（12素子）と2層の中間層（6素子、2素子）、出力層（2素子）で構成された。

図表IV-1-1 Fukase&Morimoto（2004）で用いたニューラルネットワークの構造



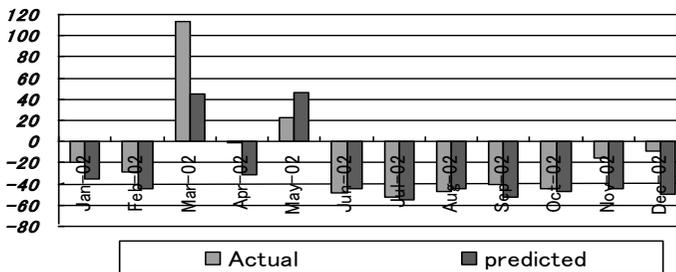
入力信号には、学習用として自己売買を除いた投資主体（10主体）間の株式移転（月次の買

越枚数)に1ヶ月前の月末日経平均株価を加えた11変数を、教師信号には当月の日経平均株価(225、月末)を使用した。これらの変数から、当期の月末日経平均株価とその値上がり率を予測させ出力させた。分析に使用したのは、10年間(120期間)の月次の時系列データである。120期間の時系列データを、学習に96期間、バリデーションに12期間、予測に12期間をアロケートして、最急降下法により10,000回の機械学習をさせた。

予測結果は図表Ⅳ-1-2に示されるように、値上がり率については誤差を含むが、株価が上昇するか下落するかの方向性(2値選択)の予測については、95%を上回る予測精度で的中した。CPTL開発当初はこの結果に一喜した。

しかし、次節で示すように、株価は過去の株価と高い自己相関をもつため、機械学習データに過去の株価情報も含めたことが、CPTLの予測精度を過大に高めてしまったものと思われる。そこで、実利目的ではなく、CPTLのパフォーマンスを評価するという本稿の研究目的の主旨から、株価情報を教師信号としてのみに用い、過去の株価情報については説明変数から除外する。

図表Ⅳ-1-2 株価上昇率の予測結果



Fukase&Morimoto(2004)

第2節 株価の自己相関

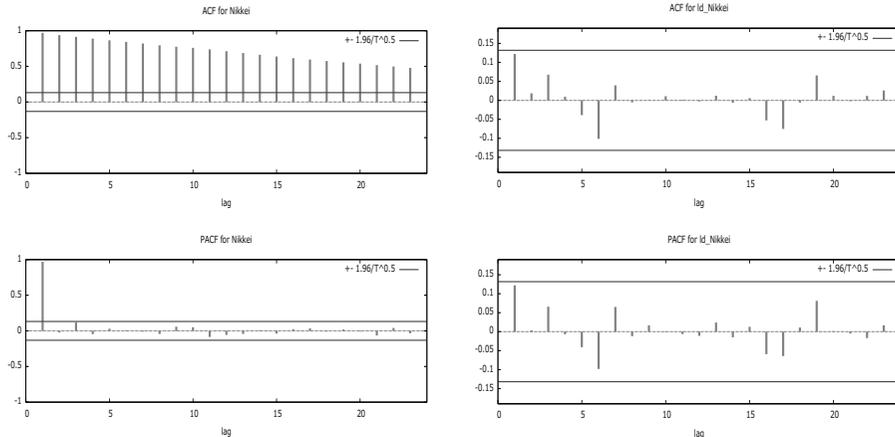
本節では、将来の株価に対して過去の株価がどの程度、影響しているのかを検証した。日経平均株価の月次の時系列データ(2002年7月~2020年12月)を用いて、①株価、②値上がり率(対数差分)について、1期前の値との自己相関および偏自己相関(それ以前の値の影響を除去)をとり、コレログラムを描き視覚化した。

結果は図表Ⅳ-2-1のとおりで、有意水準5%で、株価の自己相関(ACF)については長期にわたり過去の株価の影響が継続し、偏自己相関(PACF)についても1か月間は影響することが確認された。これより、投資行動と株価形成との関係を考察するにあたり、過去の株価情報を用いるのは好ましくない、また、同様に値上がり率についても、1か月のラグについてはp値が6.7%となり5%を上回るものの無視はできない、という結果になった。

図表IV－2－1 日経平均株価の自己相関係数および偏自己相関係数

Nikkeiの自己相関係数					Id_Nikkeiの自己相関係数				
***, **, * (は、有意水準1%, 5%, 10%を示す 標準誤差 1/T ^{0.5} を使用)					***, **, * (は、有意水準1%, 5%, 10%を示す 標準誤差 1/T ^{0.5} を使用)				
LAG	ACF	PACF	Q-stat.	[p-value]	LAG	ACF	PACF	Q-stat.	[p-value]
1	0.9689 ***	0.9689 ***	211.2138	[0.000]	1	0.1223 *	0.1223 *	3.3492	[0.067]
2	0.9373 ***	-0.0224	409.7918	[0.000]	2	0.0187	0.0038	3.4278	[0.180]
3	0.9139 ***	0.1171 *	599.4484	[0.000]	3	0.0676	0.0658	4.4600	[0.216]
4	0.8886 ***	-0.0459	779.5807	[0.000]	4	0.0095	-0.0068	4.4804	[0.345]
5	0.8649 ***	0.0304	951.0084	[0.000]	5	-0.0388	-0.0409	4.8245	[0.438]
6	0.8430 ***	0.0083	1114.6220	[0.000]	6	-0.1015	-0.0983	7.1866	[0.304]
7	0.8206 ***	-0.0118	1270.3592	[0.000]	7	0.0394	0.0652	7.5436	[0.375]
8	0.7959 ***	-0.0445	1417.5563	[0.000]	8	-0.0054	-0.0118	7.5503	[0.479]
9	0.7756 ***	0.0586	1558.0016	[0.000]	9	0.0008	0.0168	7.5505	[0.580]
10	0.7596 ***	0.0506	1693.3513	[0.000]	10	0.0109	0.0009	7.5783	[0.670]
11	0.7380 ***	-0.0847	1821.7036	[0.000]	11	0.0017	-0.0063	7.5790	[0.750]
12	0.7128 ***	-0.0580	1942.0279	[0.000]	12	-0.0028	-0.0109	7.5808	[0.817]
13	0.6872 ***	-0.0427	2054.4012	[0.000]	13	0.0121	0.0240	7.6158	[0.868]
14	0.6631 ***	0.0098	2159.5181	[0.000]	14	-0.0064	-0.0148	7.6256	[0.908]
15	0.6378 ***	-0.0382	2257.2453	[0.000]	15	0.0059	0.0128	7.6340	[0.938]
16	0.6151 ***	0.0235	2348.5704	[0.000]	16	-0.0529	-0.0593	8.3058	[0.939]
17	0.5959 ***	0.0362	2434.7190	[0.000]	17	-0.0753	-0.0643	9.6765	[0.917]
18	0.5754 ***	-0.0108	2515.4325	[0.000]	18	-0.0057	0.0109	9.6845	[0.942]
19	0.5564 ***	0.0196	2591.2717	[0.000]	19	0.0657	0.0813	10.7383	[0.932]
20	0.5388 ***	-0.0102	2662.7365	[0.000]	20	0.0120	0.0013	10.7734	[0.952]
21	0.5174 ***	-0.0654	2728.9755	[0.000]	21	-0.0021	-0.0048	10.7745	[0.967]
22	0.4985 ***	0.0409	2790.7600	[0.000]	22	0.0117	-0.0169	10.8086	[0.977]
23	0.4790 ***	-0.0339	2848.0843	[0.000]	23	0.0260	0.0168	10.9773	[0.983]

コレログラム



第3節 多変量グレンジャー因果検定

投資主体の売買行動は株価形成に影響すると考えられるが、逆に株価変動が投資主体の行動に影響するという内生性も考えられる。そこで、多変量グレンジャー因果検定を行い、両者の因果関係を確認した。分析には、Fukase & Morimoto (2004) において、各投資主体の投資行動特性を特定するために用いた単一方程式モデルを、ベクトル・モデルに拡張した多変量自己回帰 (Vector Auto Regressive ;VAR) モデルを用いた。ただし、投資環境を共変量として扱い、コントロールした。また、自己相関による分散不均一性の影響を考慮し、バリエーションによる標準誤差の頑健化を施してOLSによる推定を行った。

VARモデルによる分析結果として、11主体の投資主体および株価のそれぞれについて、個別

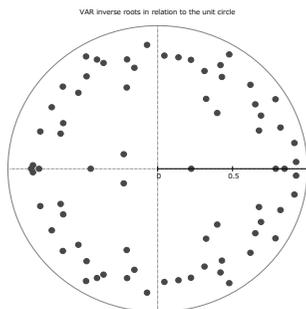
図表Ⅳ－３－１ VARモデルによる日経平均株価の推定結果

Mean dependent var 14949.42 S.D. dependent var 4862.283
 Sum squared resid 90526231 S.E. of regression 807.0117
 R-squared 0.98219 Adjusted R-squared 0.972453
 F(76,139) 173.9451 P-value(F) 6.50E-110
 rho 0.009564 Durbin-Watson 1.978742

ラグ	係数	標準誤差	t値	p値	
自己	-1	1.96E-03	1.5E-03	1.32	0.19
	-2	1.19E-03	1.6E-03	0.73	0.46
	-3	1.75E-04	1.8E-03	0.10	0.92
	-4	-0.000239	1.9E-03	-0.12	0.90
	-5	-0.000955	1.9E-03	-0.50	0.61
	-6	-0.000294	1.6E-03	-0.17	0.86
個人	-1	2.17E-03	1.6E-03	1.37	0.17
	-2	1.57E-03	1.7E-03	0.90	0.37
	-3	2.75E-04	2.0E-03	0.14	0.89
	-4	2.19E-04	2.0E-03	0.11	0.91
	-5	-0.001041	2.0E-03	-0.52	0.60
	-6	6.05E-05	1.7E-03	0.03	0.97
海外投資家	-1	1.84E-03	1.5E-03	1.23	0.22
	-2	1.45E-03	1.6E-03	0.88	0.38
	-3	3.57E-04	1.8E-03	0.19	0.85
	-4	-7.21769e	1.9E-03	-0.03	0.97
	-5	-0.001174	1.9E-03	-0.61	0.54
	-6	-0.000135	1.6E-03	-0.08	0.93
証券会社	-1	-0.000254	3.5E-03	-0.07	0.94
	-2	2.15E-03	3.5E-03	0.62	0.54
	-3	9.32E-04	3.5E-03	0.27	0.79
	-4	-0.005165	3.6E-03	-1.42	0.16
	-5	-0.005316	4.2E-03	-1.25	0.21
	-6	-0.003354	3.6E-03	-0.94	0.35
投資信託	-1	3.36E-03	1.6E-03	2.13	0.03 **
	-2	-7.70185e	1.9E-03	-0.04	0.97
	-3	7.53E-04	2.1E-03	0.36	0.72
	-4	-0.001417	2.0E-03	-0.70	0.48
	-5	-0.001571	2.1E-03	-0.73	0.46
	-6	-0.000184	1.7E-03	-0.10	0.92
事業法人	-1	1.96E-03	1.7E-03	1.14	0.25
	-2	5.60E-04	1.8E-03	0.31	0.76
	-3	-0.000787	2.0E-03	-0.40	0.69
	-4	1.20E-03	2.0E-03	0.60	0.55
	-5	-0.001187	2.3E-03	-0.52	0.60
	-6	-0.000958	1.7E-03	-0.54	0.58
貨幣発行残	0.0006987	0.000285	2.453	0.02 **	
通貨流通高	-0.377999	0.240896	-1.56	0.12	
約定金利	-438.748	568.416	-0.77	0.44	
米国為替	-13.3382	15.7428	-0.84	0.4	

ラグ	係数	標準誤差	t値	p値	
その他法人	-1	9.43E-04	2.227E-03	0.42	0.67
	-2	2.81E-03	2.134E-03	1.32	0.19
	-3	-0.002238	2.320E-03	-0.9648	0.34
	-4	-0.000410	2.108E-03	-0.1946	0.85
	-5	-0.002817	2.522E-03	-1.117	0.27
	-6	5.95E-04	2.280E-03	0.26	0.79
生保・損保	-1	5.04E-13	1.181E-13	4.27	0.00 ***
	-2	2.12E-13	1.089E-13	1.95	0.06 *
	-3	1.48E-13	1.159E-13	1.28	0.21
	-4	2.39E-13	1.056E-13	2.27	0.03 **
	-5	-2.57E-13	1.341E-13	-1.92	0.06 *
	-6	0.00E+00	1.357E-13	-0.72	0.48
都銀・地銀等	-1	1.68E-04	2.486E-03	0.07	0.95
	-2	5.65E-03	2.639E-03	2.14	0.03 **
	-3	2.32E-03	3.043E-03	0.76	0.45
	-4	3.61E-03	3.256E-03	1.11	0.27
	-5	-0.000484	3.213E-03	-0.1506	0.88
	-6	-0.000240	2.672E-03	-0.09015	0.93
信託銀行	-1	1.58E-03	1.588E-03	1.00	0.32
	-2	1.34E-03	1.641E-03	0.82	0.42
	-3	-0.000363	1.889E-03	-0.1925	0.85
	-4	3.01E-04	1.961E-03	0.15	0.88
	-5	-0.000719	1.929E-03	-0.3731	0.71
	-6	-0.000324	1.684E-03	-0.1926	0.85
金融機関その他	-1	-0.001144	2.149E-03	-0.5326	0.60
	-2	1.62E-03	2.018E-03	0.80	0.42
	-3	8.91E-04	2.185E-03	0.41	0.68
	-4	-0.000546	2.587E-03	-0.2113	0.83
	-5	-0.003256	2.606E-03	-1.250	0.21
	-6	-0.004335	1.942E-03	-2.232	0.03 **
日経平均_1	1.02E+00	1.397E-01	7.33	0.00 ***	
日経平均_2	-0.102238	1.910E-01	-0.5354	0.59	
日経平均_3	-0.098786	2.030E-01	-0.4867	0.63	
日経平均_4	5.92E-02	1.943E-01	0.30	0.76	
日経平均_5	-0.016741	1.841E-01	-0.09096	0.93	
日経平均_6	-0.018154	1.305E-01	-0.1391	0.89	
const	4.15E-06	1.53E-06	2.72	0.01 **	

図表Ⅳ－3－2 定常性の過程の検証（方程式の逆根と単位円）



図表Ⅳ－3－3 多変量グレンジャー因果検定

VARモデル,	ラグ次数: 6	
最小二乗法(OLS)	推定値, 観測:	2003(T= 216)
Log-likelihood	=	-31060.215
共分散行列の行列式の値	=	1.29E+110
AIC	=	296.1501
BIC	=	310.5888
HQC	=	301.9834
かばん検定(Portmanteau test):	LB(48) =	6547.63, df= 6048 [0.0000]

投資主体から日経平均株価への影響

結果			原因			
日経平均株価	All	lags of	自己	F(6, 139)	=	0.50378 [0.8047]
日経平均株価	All	lags of	個人	F(6, 139)	=	0.51362 [0.7973]
日経平均株価	All	lags of	海外投資家	F(6, 139)	=	0.48479 [0.8188]
日経平均株価	All	lags of	証券会社	F(6, 139)	=	1.3197 [0.2523]
日経平均株価	All	lags of	投資信託	F(6, 139)	=	1.0111 [0.4207]
日経平均株価	All	lags of	事業法人	F(6, 139)	=	0.48795 [0.8165]
日経平均株価	All	lags of	その他法人	F(6, 139)	=	0.81645 [0.5589]
日経平均株価	All	lags of	生保・損保	F(6, 139)	=	1.5377 [0.1702]
日経平均株価	All	lags of	都銀・地銀等	F(6, 139)	=	1.1414 [0.3416]
日経平均株価	All	lags of	信託銀行	F(6, 139)	=	0.3179 [0.9268]
日経平均株価	All	lags of	その他金融機関	F(6, 139)	=	1.2747 [0.2729]
日経平均株価	All	lags of	Nikkei	F(6, 139)	=	31.863 [0.0000] ***
日経平均株価	All	vars, lag		6 F(12 139)	=	2.2819 [0.0112]

日経平均株価から投資主体への影響

結果			原因			
自己	All	lags of	日経平均株価	F(6, 139)	=	2.255 [0.0416]
個人	All	lags of	日経平均株価	F(6, 139)	=	0.85622 [0.5289]
海外投資家	All	lags of	日経平均株価	F(6, 139)	=	1.1646 [0.3288]
証券会社	All	lags of	日経平均株価	F(6, 139)	=	2.3493 [0.0342] **
投資信託	All	lags of	日経平均株価	F(6, 139)	=	0.71935 [0.6346]
事業法人	All	lags of	日経平均株価	F(6, 139)	=	1.878 [0.0887] *
その他法人	All	lags of	日経平均株価	F(6, 139)	=	1.7021 [0.1248]
生保・損保	All	lags of	日経平均株価	F(6, 139)	=	2.6576 [0.0180] **
都銀・地銀等	All	lags of	日経平均株価	F(6, 139)	=	1.7884 [0.1057]
信託銀行	All	lags of	日経平均株価	F(6, 139)	=	1.5585 [0.1638]
その他金融機関	All	lags of	日経平均株価	F(6, 139)	=	0.64309 [0.6956]

第V章 AI導入による株価予測への影響

第1節 分析方法

1. 分析の方針

前章では、投資主体による売買行動と株価形成の関係について、グレンジャー的な意味で長期の因果関係は認められなかったが、単月では大口の取引をする金融系の投資主体の売買行動が株価に影響していることが確認された。さらに、これまでの分析結果から、日本の証券市場における投資主体の行動様式に変化がみられ、全体的にはそれぞれの独自性が薄れ、協調行動的な様相を帯びつつあることが確認された。

株価の将来予測の可能性をめぐる学術的な決着はついていないが、本章では、このような証券市場の変化が株価予測にどのように影響しているのか、Fukase & Morimoto (2004) において開発した「交雑保有株式移転学習法」(CPTL) を用いて検証する。今回はニューラルネットワークに代えてDeep Learningを用いるが、資産運用による実利ではなく、CPTLによる予測精度の変化の評価を研究目的とするため、以下の理由で、予測精度がFukase & Morimoto (2004) を下回ると予想される。しかし、証券市場のAI導入前後の日経平均株価および変動を同じ条件で予測し、2期間の予測的中率を比較する目的なので支障はない。

(1) 株価データを教師信号としてのみに使用し、過去の株価情報を説明変数に使用しない。

理由は、第IV章第2節で株価の時系列では自己相関が大きく、将来株価に影響することが確認されたが、Deep Learningでは、重回帰分析のように、個別の説明変数ごとの偏回帰係数が推計できず、CPTLのみの説明力を評価することが難しいからである。

(2) バリデーション過程を省きオープン評価。

Fukase & Morimoto (2004) 当時は、データを3区分して、学習用、バリデーション(検証)用、予測用に分けてアロケートするのが一般的であった。しかし最近では、データを2区分して学習用に80%、予測用に20%が目安とのことなので¹¹、時流に倣いバリデーションを省く。

2. 分析方法

(1) 使用データ

分析に使用したデータは、第III章で示したとおり、①教師信号の日経平均株価(225、月末)およびその値上がり率(対数差分)、②投資主体(11主体)の各「売り」と「買い」の枚数データ、③投資環境要因の経済データとして、通貨平均残高、貨幣流通高、貸出約定平均金利、為替レート(英国)、為替レート(米国)、であり、それぞれについて、2002年7月から2020年12

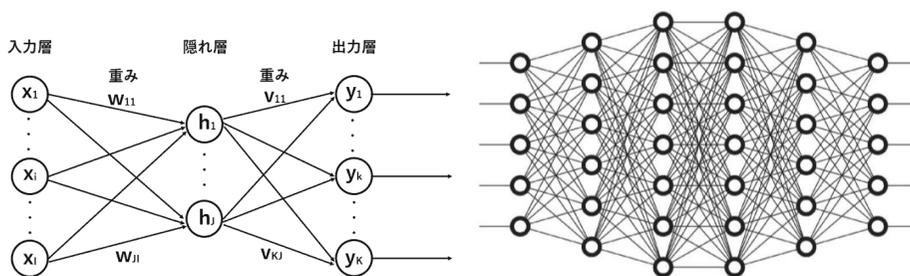
¹¹ 国の研究機関である産業技術総合研究所人工知能研究センター長を務める麻生秀樹氏のセミナー(行動計量学会、2021.11)

月までの月次の時系列データを使用した。

(2) 分析に用いたDeep Learningモデル

第IV章で行ったVARモデルを用いた分析の結果では、株価形成への影響が有意とならない投資主体もみられた。しかし、ニューラルネットワークを踏襲し、4層以上の中間層（隠れ層）をもつDeep Learning（図表V-1-1）では、株価形成に影響しないデータについては、バックプロパゲーションの過程で、出力の閾値を下回るようにウェイトが自動調整され、不要な入力信号は伝達されないで、全ての投資主体のデータを使用した。

図表V-1-1 ニューラルネットワーク（左）とDeep Learning（右）



Deep Learningモデルを用いて、図表V-1-2に示す4通りの学習用データをCPTLにより学習させ、日経平均株価とその値上がり率（対数差分）を予測した。学習1～4は、まずCPTLにおいて、①「売り」と「買い」をそのまま学習するものと、②両者の差をとり買い越しに集約した学習に分け、これに、投資環境要因に関する経済データの有無を加えて、場合分けをした組合せである。

図表V-1-2 学習モデル

	CVTL用学習データ（説明変数）	参考データ（制御変数）	入力
学習1	11主体の買い越し（買い-売り）枚数		13
学習2	11主体の売り枚数+買い枚数		24
学習3	11主体の買い越し（買い-売り）枚数	貨幣供給量+通貨流通高+約定金利+英国為替+米国為替	18
学習4	11主体の売り枚数+買い枚数	貨幣供給量+通貨流通高+約定金利+英国為替+米国為替	29
出力	教師信号（目的変数、学習1～4共通）	日経平均株価、日経平均株価（対数差分）	2

(3) 分析手順

CPTLの予測精度について、以下のようなクローズド評価とオープン評価を行い、学習1～4のパフォーマンスを比較する。オープン評価については、野村ホールディングスがAIによる「5分先の株価」予測サービスを開始した前後で2期間に分けて実施し（図表V-1-3）、両者の予測パフォーマンスを比較する。

①分析1：クローズド評価

2002年7月から2020年12月までの月次データを全て学習データとして使用し、クローズド評価を行う。

②分析2：前期オープン評価

2002年7月から2015年12月までの月次データを機械学習用（149ヶ月）と予測検証用（24ヶ月）に分けて使用し、24ヶ月先までの予測結果についてオープン評価を行う。

③分析3：後期オープン評価

2007年7月から2020年12月までの月次データを機械学習用（149ヶ月）と予測検証用（24ヶ月）に分けて使用し、24ヶ月先までの予測結果についてオープン評価を行う。

④分析4：前期と後期のオープン評価の比較

株価水準については、実績値を基準とする誤差10%以内を的中、株価値上がり率については上昇/下落の2値選択の合致を的中とし、的中率を比較するほか、誤差平方和を予測検証期間の月数で除した平均誤差平方和を用いて、予測精度を比較する。

図表V-1-3 使用する時系列データのアロケーション

期間	月	AIによる株価予測サービス	
		提供前	提供後
機械学習	開始	2002-Jul	2007-Jul
	終了	2013-Dec	2018-Dec
	月数	149	149
予測検証	開始	2013-Jan	2019-Jan
	終了	2015-Dec	2020-Dec
	月数	24	24

第2節 分析結果

①分析結果1：クローズド評価（全期間）

2002年7月から2020年12月までの月次データを全て学習データとして使用して、株価およびその対数差分を予測した結果は図表V-2-1のとおりである。買い越し枚数を用いた学習1に比べて、「売り」と「買い」を分けて用いた学習2の予測精度にはかなりの改善がみられる。経済データを与えた学習4の予測精度は、さらに改善されていることがわかる。なお、入力層、3層の中間層、出力層から構成されるニューラルネットワーク（ANNs）を設定して用いても予測結果はほとんど変わらなかった。

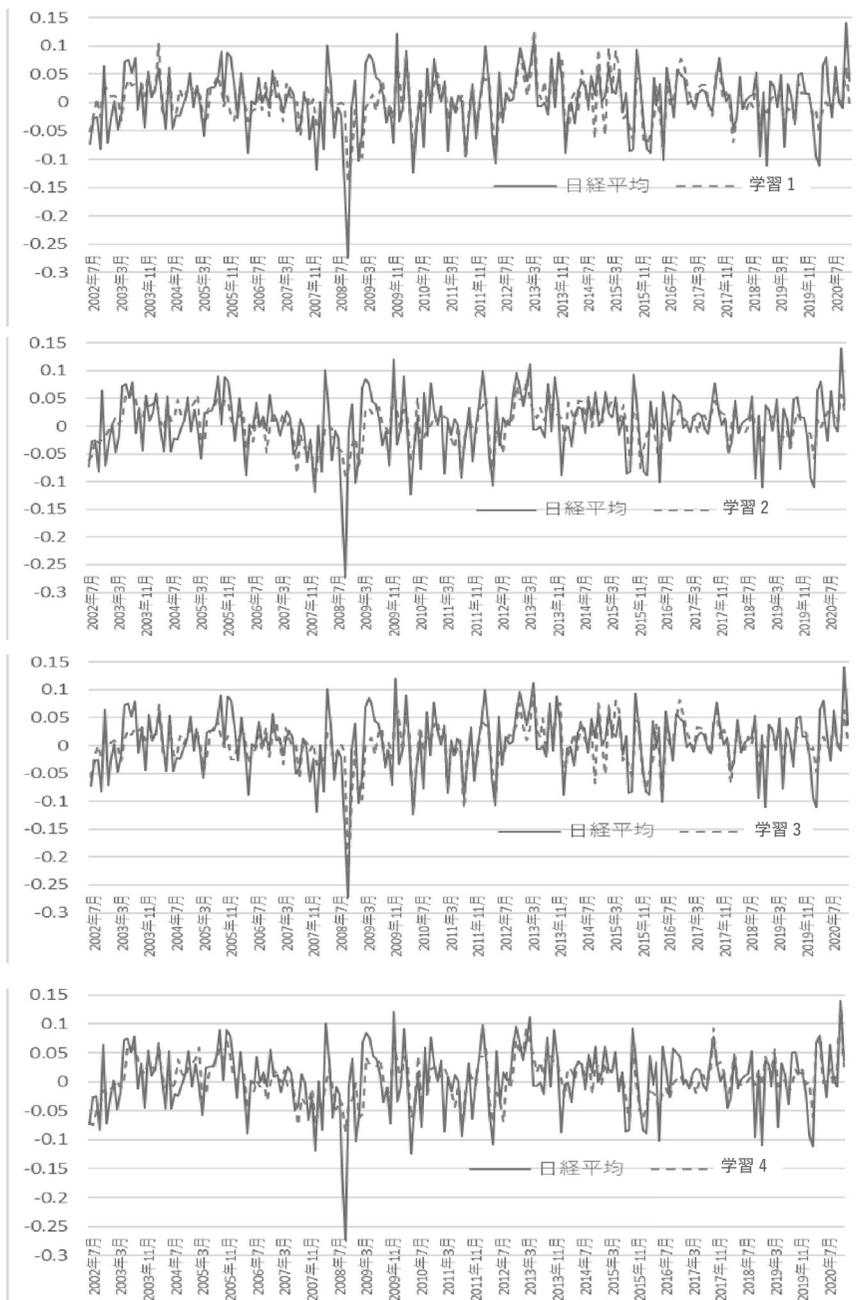
対数差分の予測では、学習1と学習3は変動幅が大きいいため、2008年のリーマンショックの下落をかなり予測したが、2014年後半などの比較的安定した相場を大きく外している。学習2と学習4は振れ幅が安定しており、リーマンショックによる落ち込みを過小に予測した。学習

4 は2018年後半の下落を予測できなかったものの全体的には変動をよく捉えている。

図表V-2-1 2002年7月から2020年12月までのクローズド予測評価（日経平均株価）



2002年7月から2020年12月までのクローズド評価（株価対数差分）

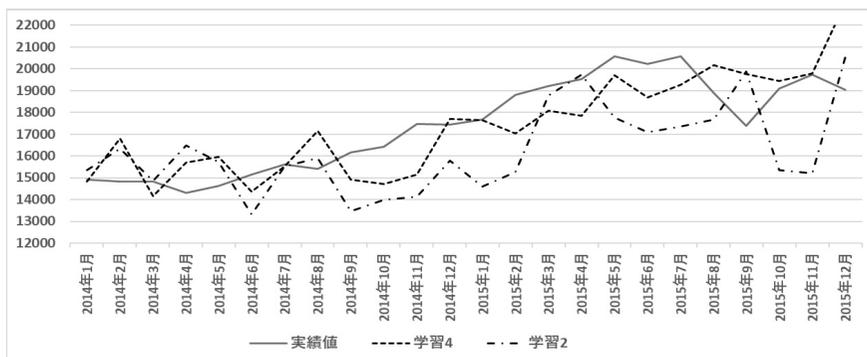


②分析結果2：オープン評価（前期）

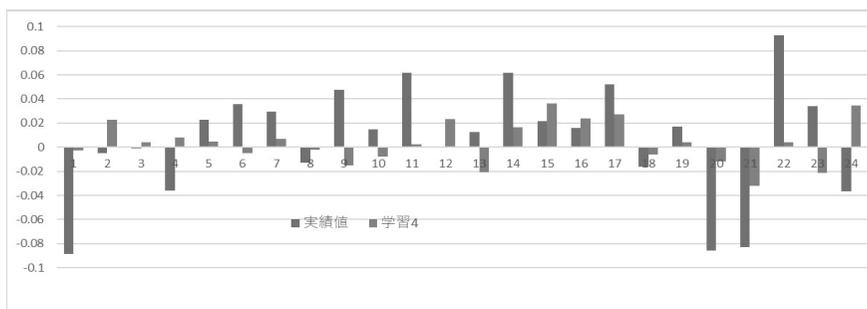
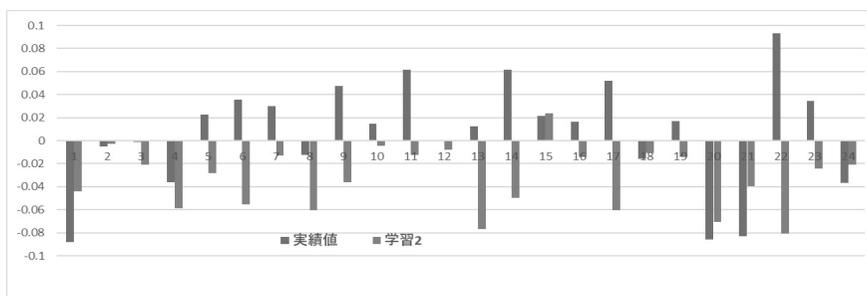
AIによる「5分後の株価」予測提供前の24ヶ月について、オープン評価による予測検証の結果を図表V-2-2に示す。株価予測では、CPTL学習用データを「売り」と「買い」を分け

て利用する学習 2、学習 4の方が予測精度は高く、さらに経済データを与えた学習 4が良好な結果となった。値上がり率（対数階差）予測では、学習 2はほとんどの月を下落方向に予測してしまい実用に耐えないが、経済データを与えた学習 4ではかなりの改善がみられた。

図表V-2-2 2014年1月～2015年12月のオープン評価



日経平均株価の値上がり率（対数差分）の予測結果

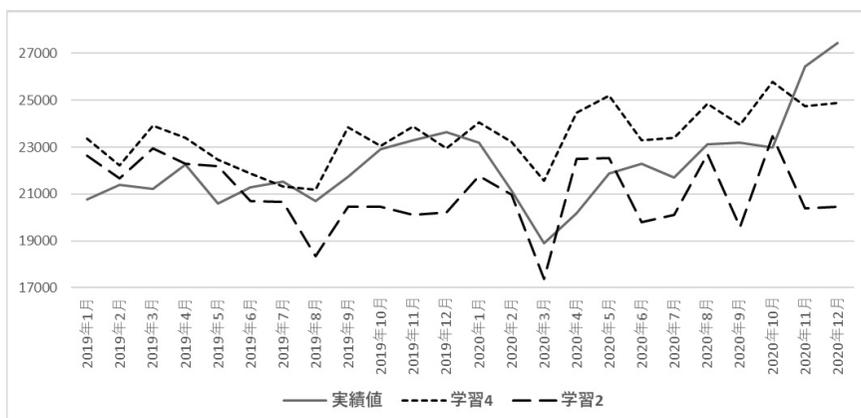


③分析 3：後期オープン評価

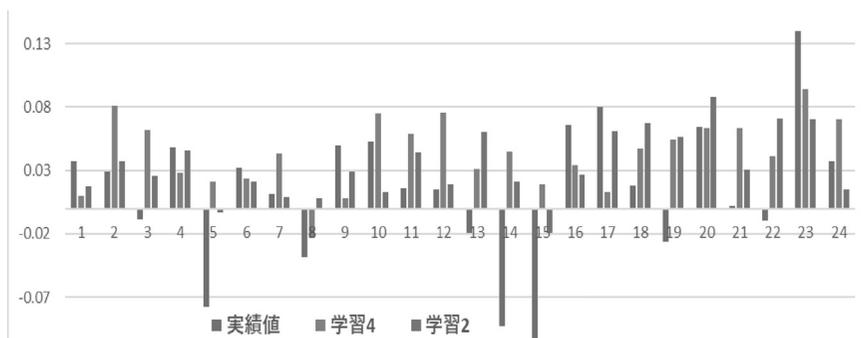
AIによる「5分後の株価」予測提供後の24ヶ月について、オープン評価による予測検証の結果を図表V-2-3に示す。株価予測では、実績値に比べて学習 2が低め、学習 4が高めに予測したため、高値の局面では学習 4、安値の局面では学習 2の精度が高い結果となった。学習 2と学習 4による予測帯域を想定すれば、かなりの月の株価はこの帯域の中に収まる。

値上がり率については、予測期間の株価は上昇傾向にあった中で、3%を超える大きな下落が4回みられた。学習4は2019年8月の下落を予測し、学習2は2019年5月、20年3月の大暴落を軽微な下落として予測したが、いずれも20年2月の大暴落を予測できなかった。上がるか下がるかの方向性では学習2、変動の大きさについては学習4に軍配があがるが、両者は異なる月の下落を的中させており、いずれか一方に代表させられない結果となった。

図表V-2-3 2019年1月～2020年12月のオープン評価



日経平均株価の対数差分の予測結果



第3節 分析結果の評価と考察

前節では、①全期間（2002.7-2020.12）を通じたクローズド評価、②AIによる「5分先の株価」情報提供を境とする、情報提供前（前期）のオープン評価、③情報提供後（後期）のオープン評価の結果を示した。

本節では、CPTLによるこれらの予測結果を評価し、考察を加える。

（1）予測結果の評価

株価の予測については、実績値を基準とする誤差10%以内を的中とし、株価値上がり率（対数差分）の予測については上昇／下落の2値選択の合致を的中とし、的中率を比較するほか、

誤差平方和を予測検証期間の月数で除した平均誤差平方和を用いて、予測精度を比較した。結果は図表V-3-1に示すとおりである。

図表V-3-1 CPTLによる予測結果の評価

①全期間クローズド評価（機械学習）2002.7-2020.12					①全期間クローズド評価（機械学習）2002.7-2020.12				
出力値	株価水準				出力値	株価対数差分			
学習法	学習1	学習2	学習3	学習4	学習法	学習1	学習2	学習3	学習4
売買枚数	統合	個別	統合	個別	売買枚数	統合	個別	統合	個別
経済情報	なし	なし	あり	あり	経済情報	なし	なし	あり	あり
的中月数	57	144	140	165	的中月数	160	161	169	159
的中率	25.7%	64.9%	63.1%	74.3%	的中率	72.1%	72.5%	76.1%	71.6%
平均残差平方和	15,843,655	2,608,681	2,376,749	1,567,271	平均残差平方和	0.001444	0.001735	0.0013199	0.001653

②前期クローズド評価（機械学習）2002.07-2013.12					②前期オープン評価（予測）2014.01-2015.12				
出力値	株価水準		対数差分		出力値	株価水準		対数差分	
学習法	学習2	学習4	学習2	学習4	学習法	学習2	学習4	学習2	学習4
経済情報	なし	あり	なし	あり	経済情報	なし	あり	なし	あり
的中月数	38	79	77	88	的中月数	6	18	11	14
的中率	27.5%	57.2%	32.4%	37.0%	的中率	25.0%	75.0%	45.8%	58.3%
平均残差平方和	7040259.3	22597388	0.390193	0.323123	平均残差平方和	2,385,591	5,575,101	0.003697	0.00207

③後期クローズド評価（機械学習）2007.07-2018.12					③後期オープン評価（予測）2019.01-2020.12				
出力値	株価水準		対数差分		出力値	株価水準		対数差分	
学習法	学習2	学習4	学習2	学習4	学習法	学習2	学習4	学習2	学習4
経済情報	なし	あり	なし	あり	経済情報	なし	あり	なし	あり
的中月数	90	117	97	103	的中月数	15	18	17	18
的中率	65.2%	84.8%	70.3%	74.6%	的中率	63%	75%	70.8%	75.0%
平均残差平方和	1927763.7	1013007	0.00186	0.00169	平均残差平方和	6,807,700	3,812,519	0.003686	0.002682

①全期間のクローズド評価において、売買枚数を買い越しに統合する学習3では入力変数が半減して予測結果が大きく変動するため、学習4に劣ると判断し、オープン評価の比較対象から省いた。実際に株価水準の予測結果については大差がみられた。しかし、事後に対数差分の予測結果では、的中率、平均残差平方和ともに学習4を上回っていたことが判明した。

CPTLの学習において、いずれにも「売り」と「買い」を分けて学習させて予測精度を比較した結果では、経済データを与えた学習4が、与えない学習2を上回った。

②AI予測「5分先の株価」提供前のクローズド評価は、的中率が低調であった。学習期間の初期の2008年に、リーマンショックを経験し予測が難しかったと考えられる。オープン評価の的中率も低調で、クローズド評価よりは良好となったが、暴落局面の予測力が弱い。

③「5分先の株価」情報提供後は、クローズド評価、オープン評価ともに良好な中率となり、全評価値で、学習4が学習2を上回った。しかし、安定した予測をする学習4は重大な暴落の局面を予測できておらず、振幅の大きい学習2との比較で一長一短がある。

（２）考察

第Ⅲ章で、投資主体間の行動様式に変化がみられ、独自性が薄れて同調行動を帯びつつあることが確認された。証券市場におけるAI普及による影響は定かでないが、AIによる「5分先の株価」情報の提供前（2014.1-2015.12）と提供後（2015.1-2019.12）の予測精度を比較すると、クローズド評価、オープン評価ともに、株価水準についてもその対数差分についても、提供後の予測精度が向上している。これについても、投資主体間の行動変化の影響が考えられるが、一方では、期間によって株価予測の難易度が変化したことも考えられる。

そこで、フラクタル次元を用いて株価変動の複雑な動きを計測し、予測の難易度を考察する。フラクタル幾何学においては、複雑さをはかる尺度としてフラクタル次元を定義する。フラクタル次元では、次元の概念を非整数にまで拡張し、通常、非整数の値をもつ。また、金融工学では、株価の変動や為替相場の変動を非整数ブラウン運動ととらえ、完全にランダムな動きをするブラウン運動（ $H = 0.5$ ）からの逸脱の度合いを、ハースト指数 H という指標で測る。ハースト指数 H とフラクタル次元 F とは、 $F = 2 - H$ という関係をもつ。ここでは時系列分析による予測が最も難しい状況のブラウン運動（ハースト指数 $H=0.5$ ）を基準に判断する。次元解析を行った結果は、図表V-3-2のとおりである。

①全期間を通じたハースト指数は $H=0.596859$ であり、過去にランダムに近い変動があったことがうかがわれる。しかし、学習2や学習4でかなり高い精度で予測ができていた。

②前期におけるハースト指数は、機械学習の期間で $H=0.651781$ 、予測期間で $H=0.653155$ であり、いずれもランダムな変動（ $H=0.5$ ）からはプラスの方向に逸脱し、上昇傾向が続いた。つまり、それほど複雑な変動を示したわけではないが、予測的中度が低迷してしまった。この原因として、本稿では機械学習に用いる説明変数に、敢えて過去の株価データを与えなかったことが考えられる。ハースト数の高さは過去の株価の影響を強く受けることを示すため、この情報を与えてやれば予測精度の改善が期待できる。

③後期におけるハースト指数は、機械学習の期間で $H=0.579745$ 、予測期間で $H=0.649958$ であり、ランダムに変動した学習期間の予測は難しかったはずだが、学習4による予測結果は8割を超える的中率となった。予測期間についても、的中率は75%となり評価値としては悪くないが、重要な暴落局面を十分に予測できなかった。学習期間の初期にリーマンショックを学んでしまい、これに比べればその後の暴落は軽微なため、反応が鈍った可能性も考えられる。

第Ⅵ章 総括

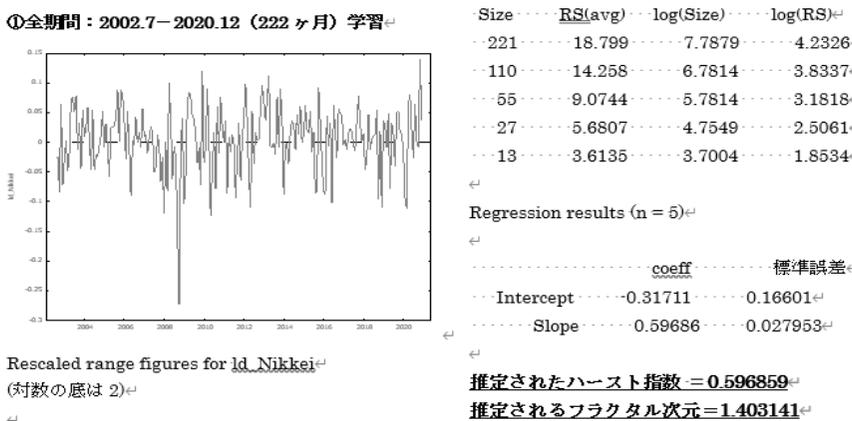
本研究の成果として、AI普及との関係は不明だが、日本の証券市場における各投資主体の行動特性が以前に比べて薄れて同調行動を帯びつつあり、また、ハースト指数からも株価変動がランダム変動から逸脱し、昔よりは株価予測が容易になっているという変化が確認された。

現代のこのような動きの中で、Fukase & Morimoto (2004) において開発した投資主体間株式保有移転学習 (CPTL) 法による株価予測のパフォーマンスを評価した。時系列的な予測が難しいランダムな株価変動局面では精度が向上し、これから逸脱すると低迷した。すなわち、CPTLはテクニカル分析の弱点を補う予測手法として有用であることが検証された。

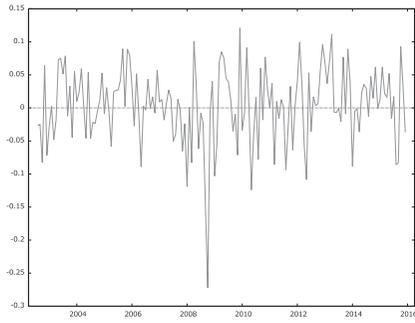
まず、以下の4項目を修正し、CPTLの予測精度がどの程度改善するか、試してみたい。

①学習期間を今回の2002年から過去に延長し、80年代のバブル期の状況も学ばせることにより、暴落局面における予測力の強化を図る。②深層学習に、今回は省いたバリデーション (検証) 過程を復活させて、過剰学習による予測の硬直化をチェックする。③今回は与えなかった過去の株価データも説明変数に加えて学習させ、ランダム変動から逸脱した期間の予測精度を向上させる。④売買枚数でなく売買額を用いる。さらに実利を目指すならば、ザラバ取引の板寄せ情報を集めて、「5分先の株価予測」に利用すれば効果的であろう。

図表V-3-2 株価変動の次元解析結果



②前期：2002.7-2015.12（149ヶ月）学習



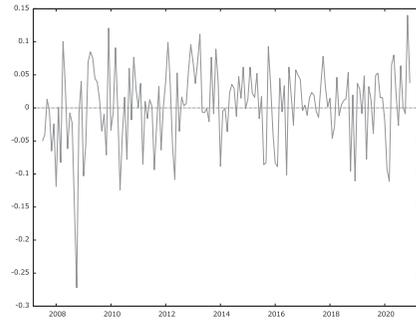
Rescaled range figures for ld_Nikkei
(対数の底は2)

Regression results (n = 5)

	coeff	標準誤差
Intercept	-0.53592	0.23165
Slope	0.65178	0.042049

推定されたハースト指数 = 0.651781
推定されるフラクタル次元 = 1.348219

③後期：2007.7-2018,12（149ヶ月）学習



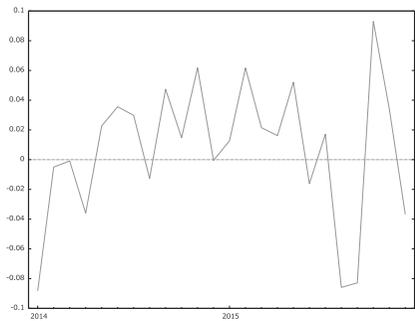
Rescaled range figures for ld_Nikkei
(対数の底は2)

Regression results (n = 5)

	coeff	標準誤差
Intercept	-0.18699	0.16755
Slope	0.57974	0.030377

推定されたハースト指数 = 0.579745
推定されるフラクタル次元 = 1.420255

②前期：2014.1-2015.12（24ヶ月）予測



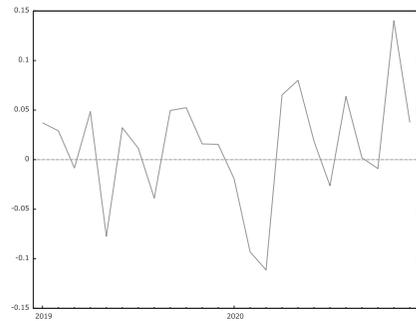
Rescaled range figures for ld_Nikkei
(対数の底は2)

Regression results (n = 5)

	coeff	標準誤差
Intercept	-0.44972	0.19800
Slope	0.65316	0.037548

推定されたハースト指数 = 0.653155
推定されるフラクタル次元 = 1.346845

③後期：2019.1-2020.12（24ヶ月）予測



Rescaled range figures for ld_Nikkei
(対数の底は2)

Regression results (n = 5)

	coeff	標準誤差
Intercept	-0.58195	0.21758
Slope	0.64996	0.041201

推定されたハースト指数 = 0.649958
推定されるフラクタル次元 = 1.350042

参考文献

- Abhijit V. Banerjee (1992), 'A Simple Model of Herd Behavior', The Quarterly Journal of Economics, Vol. 107, No. 3, (Aug., 1992), pp. 797-817
- Andrea Beltratti, Sergio Margarita and Pietro Terna, "Neural Networks for Economic and Financial Modelling.", International Thomson Computer Press, c1996

- Ellison, Glenn, and Drew Fudenberg. 1993. Rules of thumb for social learning. *Journal of Political Economy* 101, no. 4: 612-643.
- John H. Holland; John H. Miller(1991), 'Artificial Adaptive Agents in Economic Theory', "The American Economic Review, Vol. 81, No. 2", *Papers and Proceedings of the Hundred and Third Annual Meeting of the American Economic Association*. (May, 1991), pp. 365-370.
- K.Fukase & H.Morimoto(2004), 'An investigation into the relationship between Japanese stock prices and the behavior patterns of various investment subject', 『大阪経済法科大学科学技術研究所紀要』、第 9 卷第 1 号、pp.85-100
- 田代 純 (2002)、『日本の株式市場と外国人投資家』、東洋経済新報社
- ウォルター・円ダース著・新谷元嗣・藪知良訳 (2019) 『実証分析のための計量時系列分析』 有斐閣
- エドガー・ピーターズ著・新田功訳 (1994) 『カオスと資本市場－資本市場分析の新視点』 白桃書房
- 内海正郎 (2014)、 「仮想先物市場を用いた個人投資家の同調行動の検証」、 『京都経済短期大学論集』、京都経済短期大学、経営・情報学会 pp127-138
- 北島孝博 (2011)、 「データ・スヌーピングを考慮したテクニカル分析の有効性の時系列的推移」、 『経営財務研究』 第 31 卷第 2 号, pp. 93-111
- 桑井淳子 (1998)、 「資本市場における人工エージェントと経済モデルの発展」、 『大阪市大論集第 92 号』、pp.67-89
- 深瀬 澄 (1999) 「経済統計学におけるニューラルネットワークの導入 (1) - 複雑系・生命系の経済現象を想定して -」、大阪経済法科大『経済学論集』 第 22 卷 2 号
- 深瀬 澄 (1999) 「経済統計学におけるニューラルネットワークの導入 (2) - 複雑系・生命系の経済現象を想定して -」、大阪経済法科大『経済学論集』 第 22 卷 3 号

閲覧サイト

- 松崎隆司 PRESIDENT ONLINE 「AI は野村証券の働き方を激変させるのか－業務の自動化が付加価値を生む」, <https://president.jp/articles/-/25184> 2021 年 2 月 25 日閲覧