

人工市場における人間の投資意思決定モデルの精緻化 ～脳情報ならび視覚情報を用いて～

今川 裕貴[†] 下川 哲矢[‡]

一橋大学 経済学研究科[†] 東京理科大学 経営学部ビジネスエコノミクス学科[‡]

1. はじめに

リスク環境下において、人間はどのように予想を形成するのであろうか。この問いに関して、90年代以降、行動経済学的なアプローチを用いた分析が盛んにおこなわれている。動学的なリスク環境下においては、これまで、一般に学習モデルと言われる行動モデルがいくつか提案されている。しかしながら、未だドミナントモデルと言えるような、精度の優れたモデルは提案されていない。

近年、人間の期待形成は、統計的な手法を用いているのではなく、なんらかのベンチマークを用いて行われるのではないかという仮説に従ったモデルがいくつか提案されている。これらは、Simon(1959)らによって提唱された限定合理性の現代版と言え、数理モデル化が進んでいる(Matejka and McKay(2015))。

本研究はこのような研究の流れを前提として、不確実性下における動学的意思決定モデルの精緻化に貢献しようとするものである。本研究では、人間の期待形成に用いられると予想されるベンチマークを、これまでの金融論的な前提知識や単純な観察的手法ではなく、Deep Neural Networkを用いた特徴抽出によって求める。さらにこのようにして抽出した特徴が、本当に人間の意思決定においてベンチマークとして機能しているか否かを、視線解析や脳情報を用いて検証する。

2. 実験の概要

実験はコンピュータベースの刺激提示で行われた(図1)。実験の内容は基本的に Lohrenz et al. (2007)などの連続投資実験である。ただし被験者には、先行研究を参考に、価格列のほか、保有株式数、実現利益、未実現利益の情報も与えている。価格列は0.8秒ごとに更新され、被験者は随時、投資率を決定する。投資率は-100%から100%までの範囲で、10%ごとに選択可能

である。価格データとしては S&P500 インデックスの日次データを6種類用意し、ランダムに提示した(図2)。

本実験では、被験者の行動(投資率決定)と同時に、視線情報と脳情報も合わせて取得した。脳情報としては、脳波計(EEG)により測定される脳波とfNIRSによって測定される背外側前頭前野と眼窩野における血中酸化ヘモグロビンの濃度変化を得ている。また、被験者は東京理科大学の学生を中心とした65名である。




図1：提示刺激の例

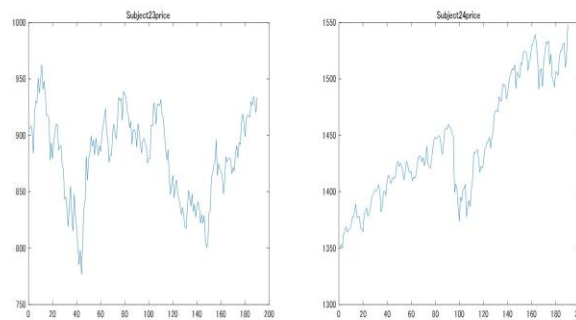


図2：価格列の例

3. 分析手法

まず、このようにして求めた行動と価格列との関係を、Deep Neural Networkを用いて解析する。ここでは、入力を過去40期間の価格の系列とし、隠れユニットが40、30、20の3層型で、出力層がソフトマックス関数となっている積層型 Neural Networkを用いた。ファイナンス理論の観点からは、価格列ではなく収益率を用いる方が理論と整合的であるが、人間の意思決定では価格変化のある種のイメージとして処理して

Modeling investment decision makings: A refinement with multi-model bio-data

[†]Yuki Imagawa · Graduates School of Economics, Hitotsubashi University

[‡]Tetsuya Shimokawa · School of Management, Tokyo University of Science

いる可能性があるため、ここでは価格列を解析の対象としている。出力は被験者の入力した投資率であり、21次元(カテゴリ数)の2値データである。学習は自己符号化学習による事前学習ののち、確率的勾配降下法による学習を行った。自己符号化器はスパース自己符号化器を採用している。

このように学習した積層 Neural Network における最も高次の層における隠れユニットを、人間の投資意思決定においてベンチマークとなる価格の特徴的な動きであるとし、それらの値が何を意味しているのか、さらには脳情報や視線解析結果とどういった関係性を持つかを比較検討した。

4. 分析結果

意思決定の個人差を考慮して、学習は個人ごとのデータで行った。当該 Neural Network による分類精度は、ほとんどの被験者において95%以上であり、十分な学習が行われていると言っよいと思われる。

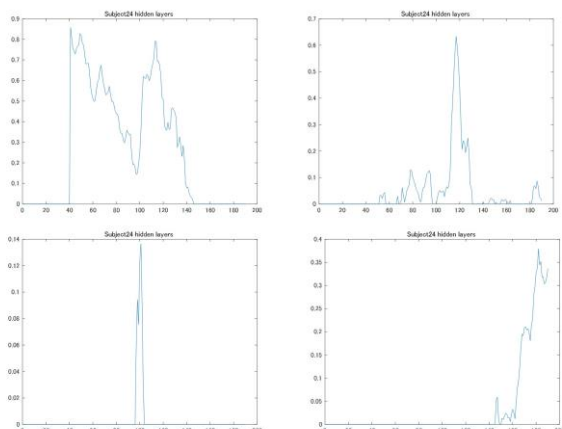


図3：高次層における隠れユニットの値の時系列変化(上段左から①②、下段ともに③の例)

図3は高次層における隠れユニットの値の時系列変化の代表例をプロットしたものである。この被験者には図2右側の価格列が刺激提示されている。多くの被験者において、高次ユニットにおいて抽出された特徴量は、①価格トレンドに対応しているもの(トレンド指標)、②分散の大きさの変化に対応しているもの(ボラティリティ変化指標)、③収益の急激な変化に対応するもの(スパイク型指標)、およびそれらの混合指標となっていた。このうち①の指標は、トレンドの追従というモーメンタム効果や中心への回帰というよく知られた投資意思決定の性質に対応していると考えられる。また②も投資家のリスク回避性を前提とした金融理論と整合的なものであると言える。③は特徴的で、リタ

ーンリバーサルや株価の暴落を機に、投資家の心理的模式が変化する(情動が優位になる)効果と考えることもできる。

これらの抽出された特徴量が意思決定において、本当にベンチマークとして機能するのか否かを確かめるために、視線解析や生体情報を用いた分析を行った。図4は投資意思決定中の投資家の視線の動きと停留時間の長さを示したものである。上記の①②③に注目が集まっていることが確認できる。また、脳反応の面からも、特に③のスパイクが生じたときに、事象関連電位や血中酸化ヘモグロビン濃度に大きな片が生じることが確認できた。これらの事実は、価格と投資行動の関係から抽出された特徴量が、実際の意思決定においても重要な役割を果たしていると推測する根拠になると考える。

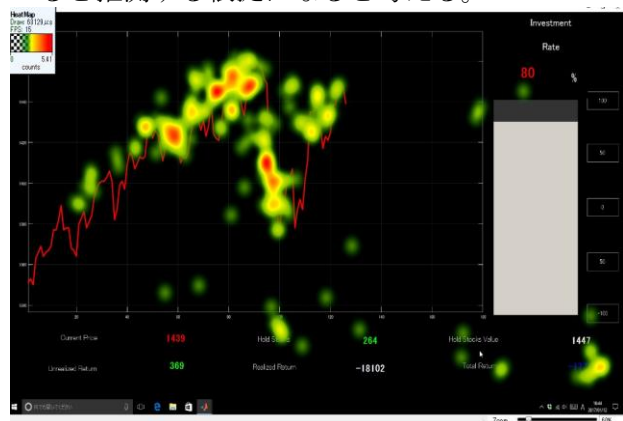


図4：投資意思決定中の視線の動き

5. まとめ

本研究では Deep Neural Network を用いて人間の投資意思決定においてベンチマークとなる特徴量の抽出を行い、さらに、それらのベンチマークと生体情報の関係性を分析した。本研究でモデル化した Deep Neural Network は被験者行動に関する高い記述能力をもち、かつこれまでの研究で経験的分析によって明らかにされてきたいくつかの効果の説明するものであった。

[主要参考文献]

[1]Simon, Herbert 1959, American Economic Review 49 (3): 253–83.

Filip Matejka and Alisdair McKay, 2015, American Economic Review 2015, 105(1): 272–298.

[2]Lohrenz, McCabe, Camerer and Montague, 2007, Proceedings of the National Academy of Sciences, Vol. 104, No. 22, pp. 9493–9498.