

脳情報のマイニングによる経済意思決定モデルの精緻化

Refining economic decision-makings by applying data mining techniques to decode brain information.

下川 哲矢*¹ 木下 寛大*² 宮川 和夫*³ 参沢 匡将*⁴
Shimokawa Tetsuya Kanta Kinoshita Miyagawa Kazuhiro Misawa Tadanobu

*¹東京理科大学経営学部

The School of Management, Tokyo University of Science

*²楽天株式会社

Rakuten, Inc.

*³一橋大学大学院経済学研究科

Graduate School of Economics, Hitotsubashi University

*⁴富山大学大学院理工学研究部

Graduate School of Science and Engineering, University of Toyama

Recent advancements in neuro-economics have revealed that specific sites of brain activity provide beneficial information regarding human's future decision-makings. In light of these findings, this study explored whether or not the predictability of economic decision-making under risk and strategic situations be improved dramatically by applying data mining techniques to brain information and other biological reactions. Especially, considerations of ensemble learning, individual variation, and huge factor set are focused upon in this study.

1. はじめに

近年の脳神経科学の発展は、これまで経済学において使われてきたような意思決定モデルに修正を迫り、より現実に近い新たな意思決定モデルの構築を促している。このような流れを受けて、本研究では脳情報をはじめとする生体データにより、従来の行動ファイナンス理論に基づく投資モデルがどのように改善されるのかを分析する。脳情報は一般にノイズが大きく要因が複雑に交錯しているため、その解釈には一定の訓練を要し、それが実用化の障害にもなっている。我々はこれまで、このような問題意識のもと、統計的パターン認識技術をベースにしたマイニングにより投資意思決定の予測の精度を大幅に向上させる可能性を追求してきた ([Shimokawa 09, 鈴木 10, Shimokawa 08])。本研究では、さらなる精緻化と実用への可能性を検討する。

2. Sequential Investment Task

投資実験 (Sequential Investment Task) の概要は以下の通りである。被験者は初期に総資産として 100 万円を保有しており、株式投資比率を決定する。株式投資比率は実験中いつでも変更することができ、決定された株式投資比率に応じた金額が株式に投資され、残った資産は預金に回される。預金に回された資産に対する利率は 0% である。株式への投資額は株価の変動に応じて変化する。株価は 750 msec. 毎に自動的に更新され、1 銘柄の株価時系列につき、株価の総更新回数は 75-150 回である (実験により異なる)。図 1 が実験画面である。株価は実際の東証株価を用いている。実験用アプリケーションを起動すると、まず数期間分の価格データの推移が表示され、その表示が終わると被験者の意思決定が行われる。被験者には参加料と出来高に応じた報酬をインセンティブとして与えている。

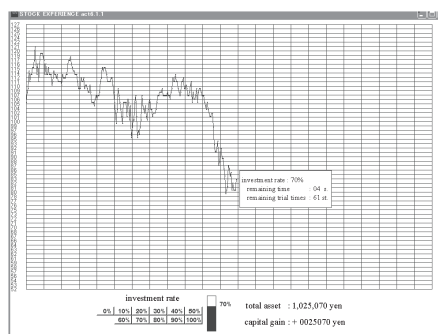


図 1: 連続投資実験画面

3. A Bayesian Neural Network Model

[Shimokawa 09] では、従来の行動学習モデルを、脳情報を加味することおよび非線形性に対応させることを目的として、ある意思決定予測モデルを検討した。このモデルでは、予測器として 3 層パーセプトロンが用いられ、パラメータやハイパーパラメータはマルコフ連鎖モンテカルロ法 (MCMC 法) によるベイズ推定によって推定されている ([MacKay 92], [Neal 96])。中間層や予測ファクターの選択には、ハイパーパラメータ周辺尤度が用いられ、予測に必要なファクターはハイパーパラメータ周辺尤度から決定された。各被験者についてモデルの選択と評価を行った結果、中間層の数としては 3 から 5、予測ファクターとしては、1 期前の投資率のほかに、前頭前野背外側部と眼窩部の血中酸化ヘモグロビン濃度が有意なファクターとして採用されることが多いことを確認した。被験者により偏りがあるものの、1 次の自己回帰型 [AR(1)] 予測モデルと比較して、ハイパーパラメータ周辺尤度で 0.2%-14.8%、平均 2 乗予測誤差で 0.0098-0.0399 程度の改善が見られ、血中酸化ヘモグロビン濃度によって大幅に投資行動の説明力が増した。

4. 予測精度向上のためのいくつかの試み

[Shimokawa 09] では、投資行動モデル化に関して、非線形性の導入などある程度の結果は得られたと思われるが、モデル

連絡先: 下川哲矢, 東京理科大学, 埼玉県久喜市下清久 500, simokawa@ms.kuki.tus.ac.jp

の精緻化の面でいくつか不十分な点も課題として残った。そこで我々のその後の研究では、実務応用に向け更なる精度向上を追求した。予測精度向上のために新たに検討したのは以下の点である。

(1) 意思決定要因の多様化：意思決定理論および行動学習理論の分野において知られた経済意思決定に関するバイアス項、さらに資産価格予測分野における重要な変数を中心に、主要な文献で取り上げられている要因をサーベイして徹底を図った ([Lo 02],[Shimokawa 09])。さらに、それぞれの要因に関して、差分、移動平均値も要因として加え、代表的なフィルタリング手法によるバリエーションも検討する候補をした。

(2) 意思決定モデル(予測器)の切り替えあるいはアンサンブル化：行動学習理論において知られている強化学習・仮想行動・EWA、経済統計分野における ARMA・GARCH・EGARCH、さらにパターン認識分野において用いられる ANN (TLP)・SVM を予測器として用い、逐次的な切り替えやアンサンブル学習の可能性を探った。

(3) 個人差への対応：意思決定や生体反応分析では、個人差が大きく、それをいかに加味するかが重要になる。各個人のいくつかの属性ごとに、意思決定モデルや意思決定要因がどのように異なるのかを検討した。また、予測を行う被験者を限定することで精度向上にどのような影響があるかを検討した。

(4) 生体情報計測のマルチモダリティ化：生体情報はノイズが大きく、有効性も被験者において異なるため、多様な生体情報を測定して総合/比較検討することでより精度の高い予測が期待できる。ここでは NIRS の他、EEG (脳波)、ERP (事象関連電位)、皮膚電導反応 (SCR)、血容量 (BVP)、心電 HR)、筋電図 (EMG)、瞬目 (EyeBlink) 等との同時測定による精度向上を検討した。

図 2 は、投資意思決定予測における、ある代表的な被験者の全意思決定要因の重要度を表している。横軸はマルチモダリティ測定を行った場合の全要因、縦軸はその評価値である。この図からも読み取れるように、多くの被験者において以下のような傾向が観測された。(a) 統計モデルによる価格予測(合理性を表すと思われる)や、NIRS・ERPなどの脳情報は投資意思決定モデルの構築に重要な役割を果たす。(b) ただ、行動ファイナンスや行動学習分野において重要とされてきた強化学習項や Fictive error については、少なくとも今回の我々の検証の範囲では、その有効性が確認できなかった。(c) また、被験者ごとに意思決定モデルや要因のばらつきはかなり大きく、これらを丁寧にマイニングすることで精度を大幅に上昇させることができる。このことは被験者ごとの分析、あるいは適切な被験者のグルーピングが必要であることを意味しており、従来のような全ての被験者に共通する要因を特定するというアプローチに再考を迫るものであると思われる。(d) 生体情報に関しては、有効である被験者とそうでない被験者があり、有効である被験者の場合、その他の要因と複合的に関係している。

図 3 はある被験者の意思決定を上記の多様な予測器で予測した結果である。横軸は投資期間、縦軸は予測器の正答率評価をモデル間で分布(比率)にしたものである。正答率の評価は、当該期以前の正答率を割り引いて(割引率は0.8)足し合わせたものを用いている。上図の被験者の場合、75期付近において SVM や TLP の予測精度が急上昇している。このように、何らかの要因によって被験者の意思決定レジームが変化することを、多くの被験者において観察した。予測器ごとの平均では ANN や SVM の正答率が最も高く、行動経済学分野において中心的な EWA を大きく上回った。




図 2: Multi-modality 計測




図 3: モデルの逐次学習とアンサンブル予測

参考文献

- [Lo02] Lo, A. and Repin, D.: The Psychophysiology of Real-Time Financial Risk Processing, *Journal of Cognitive Neuroscience*, Vol. 14, No. 3, pp. 323-339 (2002)
- [MacKay92] MacKay, D.: The evidence framework applied to classification networks, *Neural Computation*, Vol. 4, No. 5, pp. 720-736 (1992)
- [Neal96] Neal, R.: *Bayesian Learning for Neural Networks*, Springer (1996)
- [Shimokawa08] Shimokawa, T., Misawa, T., and Suzuki, K.: Neural Representation of Preference relationships, *NeuroReport*, Vol. 19, No. 16, pp. 1557-1561 (2008)
- [Shimokawa09] Shimokawa, T., Suzuki, K., Misawa, T., and K., M.: Predictability of Investment Behavior from Brain Information Measured by Functional Near-Infrared Spectroscopy: A Bayesian Neural Network-Model, *Neuroscience*, Vol. 161, No. 2, pp. 347-358 (2009)
- [鈴木 10] 鈴木, 木下, 宮川, 塩見, 参沢, 下川: Brain Computer Interface を用いた投資行動分析, *人工知能学会論文誌*, Vol. 15(1), pp. 183-195 (2010.1)