

# 生体情報のマイニングによる投資意思決定モデルの精緻化

荒山 泰佑<sup>†</sup> 下川 哲矢<sup>‡</sup>

東京理科大学大学院 経営学研究科<sup>†</sup>

東京理科大学 経営学部 経営学科<sup>‡</sup>

## 1. はじめに

近年, Neuroeconomics の進展に伴い, 特定部位の脳活動が将来のリスクや期待報酬に関する有益な情報を持つことが明らかになってきている. 金融市場における意思決定において, 一般に, 優秀なトレーダーはそうでないトレーダーに比べて, 市場に対する危機意識の持ち方が適切であると考えられる. たとえば Lo and Rapin (2002) は経験を積んだトレーダーとそうでないトレーダーの間に, 市場環境への生理的な反応の差異が存在すること, 移動平均からの乖離やトレンドの変化におけるトレーダーの生体反応の変化を報告している. また, Shimokawa et al. (2009) では, 事後的な分析ではあるものの, 投資家の脳情報 (背外側前頭前野および内側, 外側眼窩前頭皮質における脳血中ヘモグロビン濃度変化) を用いて投資行動モデルを作成している.

投資行動予測精度は, 上記の脳情報をファクターとして採用することで大幅に向上する可能性がある. 脳科学の発展を受けて, 本稿では投資行動予測の脳情報による改善の可能性を探るとともに, 事後的な分析ではなく, 精度向上と実用化を視野に入れたリアルタイムの逐次処理による投資行動の予測を行う.

## 2. 実験デザイン・システム概要

実験のシステム概要は図1に示され, 脳機能測定部・刺激提示部・行動予測モデル逐次学習部の3つから構成される.

### 2.1. 脳機能測定

脳情報の測定には functional Near-infrared Spectroscopy (fNIRS)を用いる. fNIRS は, 装置が小型で被験者の拘束性が少なく, さらに光を用いるため非侵襲的であり, 時間分解能も良い

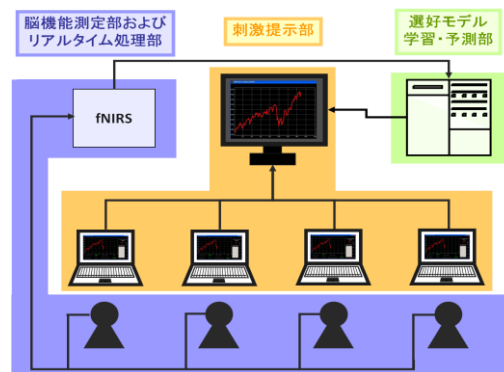


図1 システム概要

(数十ミリ秒のオーダー) という利点を持つ. このことは, 単に実務への応用において大きなメリットとなるだけではなく, 本稿における目的に適している. すなわち, 機材が小型であるため複数のトレーダーのリアルタイムの同時計測が可能となる. 脳情報は, 先行研究を踏まえて, 報酬系の活動をより反映すると考えられる前頭前野内側部, 恐怖や危険に反応する眼窩野の2箇所注目する. また, 解析に先立ち, 生体特有の周期的なゆらぎを除去するために, Savitzky-Golay フィルタを用いてスムージング処理を行っている.

### 2.2. 刺激提示部

Lorentz et al. (2007) の実験を参考に, 以下のような株式投資実験を行った. 被験者 (市場参加者) は各 session において4人で, 18歳から24歳までの健康な男女である. 被験者には, 価格のチャート, 現在の投資比率, 現在値, 保有株数, 保有株総価値, 総利益が表示される. 使用した価格列データは S&P500 及び NASDAQ の日次データである. 価格列2本を1セッションとして, 最終的に41セッション分有効なデータが得られた.

### 2.3. 行動予測モデル逐次学習部

Shimokawa et al. (2009) では, 統計的パターン認識手法の Bayesian Three-Layered Perceptron を用いて, モデルの選択を行っている. この手法は, 統計的基準による選択を可能

Adaptive Prediction of Financial Decision Makings by Using Biological Data Mining

<sup>†</sup>Taisuke Arayama · Graduates School of Management, Tokyo University of Science

<sup>‡</sup>Tetsuya Shimokawa · School of Management, Tokyo University of Science

にするが、その一方において計算量が膨大になるという欠点を持つ。本稿では、実用を視野に入れつつ、よりリアルタイム性を重視した逐次的な学習効果を検証する。予測器としては Support Vector Machine (SVM) を採用し、予測ファクターには市場情報、投資行動・資産情報、脳情報の組み合わせを用いる。

### 3. 分析結果

#### 3.1. 更新期間と予測精度の関係

逐次学習の効果を示すために、更新期間（何期ごとの学習するか）を每期から30期ごとに変化させた。図2はあるセッションの正答率のグラフである。横軸は更新期間、縦軸は正答率を表している。この図から更新期間が減少するとともに正答率も減少し、右下がりの傾向になっていることがわかる。また、全セッションの正答率の平均において、每期学習と30期で学習を比較すると、Radial Basis Function kernel では、改善幅 0.1583, linear kernel では、改善幅 0.0820 と明らかに精度が向上した。従って、逐次的に学習することで投資行動の予測精度を向上させることができるといえる。

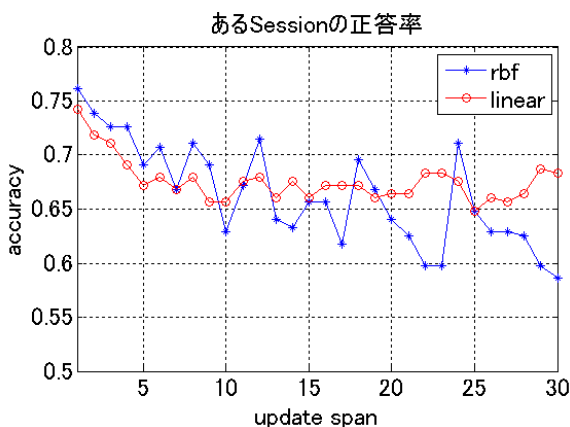


図2 更新頻度と正答率の関係

#### 3.2. ファクター選択

次に、予測ファクターの組み合わせを変えて投資行動を予測し、各ファクターの評価を行った。結果、脳情報が予測に有効であることと伴に、評価の高いファクターが每期変化することが観察できた。これは、每期同じファクターを用いたモデルでは、投資行動を十分に予測することが難しいことを意味している。

#### 3.3. 更新期間とファクター選択の組み合わせ

上記の結果を踏まえ、逐次的に学習し、かつ每期評価の高いファクターを選択するモデルを

用いて予測精度を検証した。図3はあるセッションにおけるモデルごとの正答率を比較したグラフである。1~3は逐次学習を行った場合で、ファクター選択が、それぞれ每期、1回、なしのケース、4は逐次学習しないケースを表している。この図からも逐次的に学習し、さらに每期ファクターを選択したモデルの予測精度が高いことが確認できる。




図3 あるSessionのモデルごとの正答率

### 4. おわりに

以上の結果より、每期ファクターを選択し、それらのファクターを採用した逐次学習 SVM を用いることで、比較的高い精度で、リアルタイムに投資行動を予測できる可能性があることがわかった。その理由は、株価の暴落やバブル、トレンドやボラティリティといった刻々と変化する状況に応じて、投資家の心理状態や投資行動も逐次的に変化しているためであると考えられる。逆にいえば、従来の常に同じファクターを用いたモデルでは、投資行動を十分に説明しきれないといえる。

リアルタイムに投資行動を予測することによって、意思決定の支援など、実務への幅広い応用が今後期待できる。

#### 参考文献

Shimokawa, Suzuki, Misawa, and Miyagawa. Predictability of investment behavior from brain information measured by functional nearinfrared spectroscopy: A bayesian neural network model. *Neuroscience*, 161(2):347-358, 2009.

Lo and Repin. The Psychophysiology of Real-Time Financial Risk Processing. *Journal of Cognitive Neuroscience*, 14(3):323-339, 2002.

Lohrenz, McCabe, Camerer and Montague. Neural signature of fictive learning signals in a sequential investment task. *Proceedings of the National Academy of Sciences*, 104(22):9493-9498, 2007.