

Neuroデータのマイニングによる投資意思決定モデルの精緻化

下川 哲矢^{1*} 木下 寛大²

宮川 和太³

Shimokawa Tetsuya¹

Kinoshita Kanta²

Miyagawa Kazuhiro³

¹ 東京理科大学経営学部

¹ The School of Management, Tokyo University of Science

² 早稲田大学経済学研究科

² Graduate School of Economics, Waseda University

³ 一橋大学大学院経済学研究科

³ Graduate School of Economics, Hitotsubashi University

Abstract: 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。本研究では、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する。

1 背景および本研究の位置付け

近年の神経科学の発展は、これまで経済学において使われてきたような、公理的に定義された合理性の仮定に基づくリスク下での意思決定モデルに修正を迫り、より現実に近い新たな限定合理的な意思決定モデルの構築を促している ([Lo 02],[Camerer 05],[Sanfey 06])。

たとえば [Lo 02] では、現実の為替データ(週次)を用いて、トレード時におけるマーケットイベントと生体情報との関係を統計的に検証している。皮膚電導反応(SCR)、血容量(BVP)、心拍(HR)、筋電図(EMG)、体温(Temp.)が測定され、マーケットイベントとしては価格、リターン、スプレッドにおける平均からの乖離、トレンドの変化、ボラティリティの変化が用いられた。t検定の結果、多くのイベントにおいてBVP、SCR、Temp.が有意に異なる反応を示すことが明らかにされた。彼らが用いた生体データは自律神経系のものがほとんどなので、この結果は、トレードはイベント時にある異常なストレスにさらされている、と解釈するのが妥当であろう。彼らは、また、投資経験の多寡による反応の違いを明らかにしている。興味深いのは、投資により習熟したトレーダーは、スプレッドとボラティリティにのみ有意な反応をする点である。投

資の習熟という点で、この結果はある有益な示唆を与えていると思われる。

また、[Lohrenz 07]や[Chiu 08]は、fMRIを用いた投資実験を行っている。彼らは通常良く用いられる強化学習項(単なる近々のリターンとQ学習におけるTD項がここでは用いられている)に加えて、fictive errorに注目した。fictive error自体は行動学的な研究において頻繁に用いられる意思決定要因項である。彼らの新規性は、それと脳情報の関係を明らかにした点であろう。彼らは尾状核や尾状核被殻といった、いわゆる報酬系と、fictive errorとの関係を明らかにしている。

このような流れの中で、我々も脳情報を用いた経済意思決定の精緻化を試みてきた([Shimokawa 09, 鈴木 01, Shimokawa 08, Misawa 10])。本研究発表ではこれらの研究をベースとして投資意思決定における脳情報の有効性および実用への可能性を検討する¹。脳情報を用いた先行研究と比較して、我々の貢献は以下のようになる。

- (1) 実用的な観点からfNIRSを用いた意思決定モデル化を行っている。
- (2) マッピングに留まらず、行動ファイナンスの知見を利用して投資意思決定のモデル化を行っている。
- (3) さらに、統計的パターン認識理論を用いて学習モデルの高度化をはかっている。

*連絡先：東京理科大学経営学部
〒346-8512 埼玉県久喜市下清久 500
E-mail: simokawa@ms.kuki.tus.ac.jp

¹本研究発表は主として [Shimokawa 09] を基にしています。




図 1: Screen used in the SIT experiment

2 実験

2.1 Task

我々の行った投資実験 (Sequential Investment Task) の設定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 回である (これを 1task とする)。図 1 が実験画面である。実験用アプリケーションを起動すると、まず 225 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。

被験者は健康な 18 歳から 30 歳までの 15 名である。報酬は参加料として 7000 円を支払い、出来高に応じて ±5000 円の増減をインセティブとして与えた。

2.2 NIRS measurement and preprocessing for data analysis

今回の実験では、島津製作所の fNIRStation を使い、課題遂行中の酸素化ヘモグロビン (oxyHb) と脱酸素化ヘモグロビン (deoxyHb) の濃度変化を測定した。図 2 は NIRS のプローブ装着位置である。今回の実験では前頭前野に注目するため、図のように前頭部分に装着する。装着には 10-20 法を用いた。図 2 中の数字は、fNIRS の観測チャンネル番号である。以下の分析では、報酬系の活動をより反映すると考えられる前頭




図 2: fNIRS probe placement and photo of a subject

前野内側部、恐怖や危険に反応する眼窩野の 2 点に注目するが、これは後述の統計基準に基づく有効な情報を持つ部位の選択に依る。これらの部位が選択されたことは、fMRI をもちいた先行研究とも整合的である ([Hampton 07], [Knutson 05], [Kuhnen 05])。サンプリング期間は 110msec とした。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。

3 結果

3.1 Representative sample

図 3 および図 4 は、観測データのサンプルパスである。図は 1 段目左列が被験者の見た株価の時系列、右列が被験者の投資率である。2 段目および 3 段目が、投資課題遂行時における脳各部位の血中酸化ヘモグロビン濃度変化である。2 段目左列が Channel11(DLPFC)、右列が Channel29(OFC)、3 段目左列が Channel23(MPFC)、右列が Channel30(OFC) の時系列変化にそれぞれ対応している。

Channel11 と 23 の血中酸化ヘモグロビン濃度変化と被験者の投資率とを比較すると、正の相関が観察できる。先行研究から報酬予測は前頭前野内側部を活性化させることが知られている ([Hampton 07], [Knutson 05], [Kuhnen 05])。ここで観測された血流量はこのような内側部の活性化か、あるいは、この部位の血流量が Bayes 推定量と比較的強い相関を持っていることより、合理的な報酬予測による背外側部の賦活のどちらかであると推測される。このような血流量と投資率とのパラレルな変動は、他の被験者においても、かなり頑強に観察された。次に、Channel29 と 30 の血中酸化ヘモグロビン濃度変化は、一転して、投資率とおおむね逆に相関していることが見て取れる。特に、投資率を急激に低下させ危険回避的な行動をとる場合、この部分の血流量が上昇していることがわかる。これらの部位は眼窩野に対応して

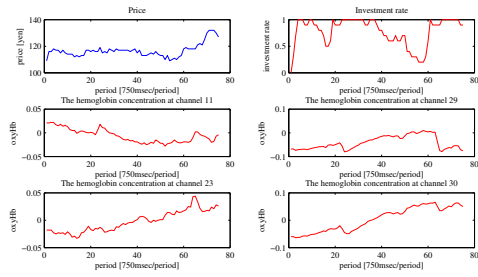


図 3: Series of stock prices, investment rate, and the hemoglobin concentration in blood at each site in a sample path.

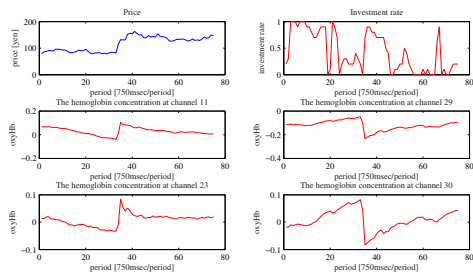


図 4: Series of stock prices, investment rate, and the hemoglobin concentration in blood at each site in a sample path.

おり、危険予測あるいは精神的なストレスをあらわしているものと推定される ([Camille 04], [Coricelli 05], [Kim 06], [Kringelbach 04], [O'Doherty 01])。しかしながらこの部分については、観測が難しいためか、観測できた被験者とできない被験者がいた。

図 5 は、投資率と血中酸化ヘモグロビン濃度の時系列相関を示している。横軸はタイムラグである。この図から、投資率と Channel 11 は正に有意に相関していること、反対に Channel 29 は負に有意に相関していることが見て取れる。青い線は、信頼区間である（時系列変数が無相関のガウス分布に従った場合の 5% 区間）。

通常ファイナンスでよく用いられる投資指標や代表的な時系列統計量と、これらの部位の血中酸化ヘモグロビン濃度変化の、タイムラグを含んだ相関分析も全ての観測データについておこなった (図 6)。その結果、注目した脳部位の血中酸化ヘモグロビン濃度変化ともっとも相関が高かったのは「価格の平均からの乖離率」であった。また、報酬系に対応する血流については、「ナイーブな Bayes 予測値」との強い正の相関が観測された。これらの観測結果は、従来言われてきたような、投資行動における「平均回帰バイアス」の存在や「適応的な期待形成」を示唆するものとして興味深い。また、血中酸化ヘモグロビン濃度変化と投資行動との時間的な大きなラグは観察されていない。




図 5: Sample cross-correlation function between the time series of investment rate and the time series of hemoglobin concentration at each channel. The blue lines indicate the upper and lower confidence bounds (5%) assuming the input series are completely uncorrelated.

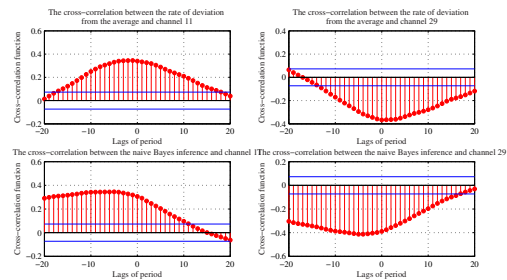


図 6: Sample cross-correlation function between the time series of the rate of deviation in price from the average / the naive Bayes inference and the time series of hemoglobin concentration at each channel. The blue lines indicate the upper and lower confidence bounds (5%) assuming the input series are completely uncorrelated.




図 7: Activation of the area near the medial prefrontal cortex corresponding to reward prediction. The units on the heat map is a normalized value of the observed relative concentration changes in oxy-Hb. Here, the range of the observed relative concentration changes, $(-0.1, 0.1)$, is normalized to the range, $(0, 1)$.




図 8: Activation of the area near the orbital cortex corresponding to risk prediction and stress. The units on the heat map is a normalized value of the observed relative concentration changes in oxy-Hb. Here, the range of the observed relative concentration changes, $(-0.1, 0.1)$, is normalized to the range, $(0, 1)$.

3.2 A Bayesian Neural Network Model

上記の fNIRS による観測データの有効性を統計的に検証するために、観測された血流量をファクターとする投資行動予測モデルを構築した。各被験者について、株価列 8 本分の実験データを使い、予測モデルのパラメータを学習させ、残りの株価 2 本分についての投資率を予測した。予測モデルには 3 層パーセプトロンを用い、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) によるベイズ推定を行っている ([MacKay 92b], [MacKay 92a], [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を用いた。予測ファクターとしては、前期の投資率の他に、前述の前頭前野内側部や眼窩野に対応する部分の血中酸化ヘモグロビン濃度を用いた。

表 1: Results of model selection using hyperparameter marginal likelihood for each subject. HML means the hyperparameter marginal likelihood and MSD represents the mean squared deviation. Factor set 1 means that explaining variables are composed of the investment rate 1 period prior. Factor set 2 means that explaining variables are composed of the oxyHb concentration in blood in channel 11 in addition to the investment rate 1 period prior. Factor set 3 means that explaining variables are composed of the oxyHb concentration in blood in channel 11 and 29, in addition to the investment rate 1 period prior. Factor set 4 means that explaining variables are composed of the oxyHb concentration in blood in channel 11, 29, and 23, in addition to the investment rate 1 period prior.

no	f.set	h. unit	HML	imp.ratio	MSD
1	4	5	281.9594	0.1478	0.0098
2	3	3	171.5305	0.1381	0.0399
3	4	5	299.4448	0.0410	0.0181
4	3	5	181.6080	0.1182	0.0408
5	4	5	188.0448	0.0926	0.0369
6	2	4	256.1265	0.1256	0.0236
7	4	5	255.3679	0.0536	0.0249
8	2	4	181.9051	0.1018	0.0338
9	4	3	246.8542	0.0804	0.0123
10	1	5	255.4749	0.0019	0.0195
11	3	5	210.4210	0.1157	0.0360
12	4	5	224.1684	0.1407	0.0341
13	4	4	263.5017	0.1415	0.0248
14	4	4	187.8198	0.0775	0.0150
15	4	4	255.9968	0.0257	0.0268

予測モデルとそのベイズ学習の詳細は以下のとおりである。非線形システムの基底関数として、ファクター n 個、中間子 h 個の 3 層パーセプトロンを採用する。すなわち t 期における投資率 $i(t)$ を被説明変数、同じく t 期における説明変数 (あるいは学習ファクター) のベクトルを $x(t)$ として、投資意思決定モデルを以下のよ

うに定式化する .

$$i(t) = f(x(t); \theta) + \varepsilon \quad \forall t$$

where

$$\varepsilon \sim N(0, 1/\beta),$$

$$f(x; \theta) = \sum_{k=1}^h a_k \cdot \sigma \left(\sum_{i=1}^n b_{ki} x_i + c_k \right) + d,$$

$$\sigma(u) \equiv \frac{1}{1 + \exp(-u)} \text{ (the sigmoidal function),}$$

$$\theta \equiv (a, b, c) \text{ (set of parameters).}$$

モデルの複雑化は、説明力をより増大させる利点を持つが、その一方で overfitting による延長可能性の低下をもたらす恐れが大きい。この問題に対処するために、階層ベイズの枠組みにおいて、ハイパーパラメータの周辺尤度をもちいたモデルの選択手法がある。我々もこの基準を用いて、ハイパーパラメータの周辺尤度

$$P(\{i(t), x(t)\}_t | \alpha, \beta) = \int P(\{i(t), x(t)\}_t | \theta, \beta) P(\theta | \alpha) d\theta \quad (1)$$

によりモデルを評価する。この値は、ABIC に対応する量であり Evidence ともしばしば呼ばれる。我々の設定において具体的に計算すると、 N を観測されたデータの数として

$$P(\{i(t), x(t)\}_t | \alpha, \beta) = \left(\frac{\beta}{2\pi} \right)^{\frac{N}{2}} \int \exp \left\{ -\frac{\beta \sum_t (i(t) - f(x(t); \theta))^2 + \sum_c \alpha_c \|\theta_c\|^2}{2} \right\} d\theta$$

となる。ここで、 α の推定値が大きいファクターや中間子は、ハイパーパラメータの周辺尤度を大きく低下させることがわかる(したがって有効でない)。すなわち、この基準において、 α はファクターや中間子数に関する罰則として機能する。通常、正則化法を用いた場合、罰則の重みは外生的に規程されることが多いが、階層ベイズの枠組みでは、罰の重み α は内生的に決定することが出来るという利点大きい。

各被験者について、ハイパーパラメータ周辺尤度によるモデルの選択を行った結果が表 1 に示されている。この表から、中間層の数としては 3 から 5、予測ファク

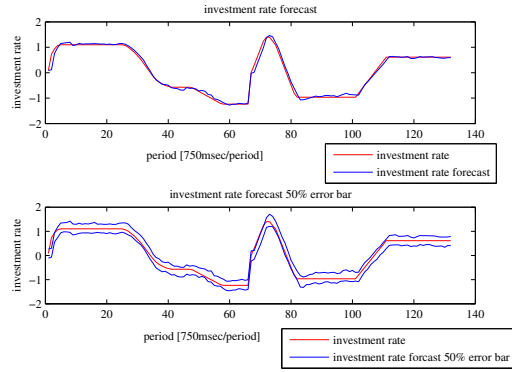


図 9: Results of investment prediction

ターとしては、1 期前の投資率のほかに、Channel11 と Channel29 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確認できる。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 (the mean squared deviations, MSD) で 0.0098-0.0399 程度の改善が見られる。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といえる。

投資行動を予測する際の問題点は、個人の投資行動には、大きなノイズが含まれることである。仮に投資行動にある統計的な傾向があったとしても、このようなノイズの存在は、当該傾向の観測を難しくさせる。個人のノイズを取り除く一つの簡便で有効な方法が、個人間の平均を取ることである。図 9 は、平均化された投資率と血中酸化ヘモグロビン濃度を用いた予測である。ただし fNIRS の血中酸化ヘモグロビン濃度は、あくまで個人の相対変化を表しており、したがって、平均化するには注意が必要である。ここでは各個人のデータを、正規化し、個人間での変動の大きさや平均的なトレンドの差を除く処理をした後で足し合わせ、平均化している。

上図の赤線は被験者による実際の投資率、青線はモデルが予測した投資率をあらわす。両者を見比べると、比較的高い精度で予測できていることが確認できる。モデルの選択の結果、中間層としては 4、予測ファクターとしては前期の投資率に加え、Channel11 と Channel29 の血中酸化ヘモグロビン濃度変化が採用された。これらの血中酸化ヘモグロビン濃度変化データを加えることにより、無い場合と比較して、予測誤差で約 59.8% の改善が可能となった。下の図は予測の 50% 区間 (青線) をあらわす。区間は十分に狭く、またほとんどの期においてこの区間内に実際の投資率 (赤線) が含まれている。

4 まとめ，あるいは現在進行中の研究

本研究では，脳情報の実用化を視野に入れて，ファイナンス市場における意思決定をモデル化した．ここでの結果を精緻化し実用に活かすために，現在，我々は以下の研究を行っている．

(1) より現実的な人工市場型実験環境の構築，および自律的市場システム設計 ([鈴木 01] あるいは本研究会の宮川論文 [宮川 11])

(2) 意思決定モデルの精緻化 1 : 統計的パターン認識手法の高度化

(3) 意思決定モデルの精緻化 2 : 測定デバイスの Multimodality 化

(4) 教育利用を視野に入れた Bio-FeedBack System の構築

現時点において，脳情報の実用化はマーケティング分野が主であるが，今後はファイナンス分野をはじめとした多くの経済分野において実用化が進展すると期待される．

参考文献

- [Camerer 05] Camerer, C., Loewenstein, G., and Prelec, D.: Neuroeconomics: How neuroscience can inform economics, *Journal of Economic Literature*, Vol. 43, No. 1, pp. 9–64 (2005)
- [Camille 04] Camille, N., Coricelli, G., Sallet, J., Pradat-Diehl, P., Duhamel, J., and Sirigu, A.: The Involvement of the Orbitofrontal Cortex in the Experience of Regret, *Science*, Vol. 304, No. 5674, pp. 1167–1170 (2004)
- [Chiu 08] Chiu, P., Lohrenz, T., and Montague, P.: Smokers' brains compute, but ignore, a fictive error signal in a sequential investment task, *Nature neuroscience*, Vol. 11, No. 4, p. 514 (2008)
- [Coricelli 05] Coricelli, G., Critchley, H., Joffily, M., O'Doherty, J., Sirigu, A., and Dolan, R.: Regret and its avoidance: a neuroimaging study of choice behavior, *Nature neuroscience*, Vol. 8, No. 9, p. 1255 (2005)
- [Hampton 07] Hampton, A. and O'Doherty, J.: Decoding the neural substrates of reward-related decision making with functional MRI, *Proceedings of the National Academy of Sciences*, Vol. 104, No. 4, p. 1377 (2007)
- [Kim 06] Kim, H., Shimojo, S., and O'Doherty, J.: Is avoiding an aversive outcome rewarding? Neural substrates of avoidance learning in the human brain, *PLoS Biol*, Vol. 4, No. 8, p. e233 (2006)
- [Knutson 05] Knutson, B. and Peterson, R.: Neurally reconstructing expected utility, *Games and Economic Behavior*, Vol. 52, No. 2, pp. 305–315 (2005)
- [Kringelbach 04] Kringelbach, M. and Rolls, E.: The functional neuroanatomy of the human orbitofrontal cortex: evidence from neuroimaging and neuropsychology, *Progress in Neurobiology*, Vol. 72, No. 5, pp. 341–372 (2004)
- [Kuhnen 05] Kuhnen, C. and Knutson, B.: The Neural Basis of Financial Risk Taking, *Neuron*, Vol. 47, No. 5, pp. 763–770 (2005)
- [Lo 02] 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)
- [Lohrenz 07] Lohrenz, T., McCabe, K., Camerer, C., and Montague, P.: Neural signature of fictive learning signals in a sequential investment task, *Proceedings of the National Academy of Sciences*, Vol. 104, No. 22, p. 9493 (2007)
- [MacKay 92a] MacKay, D.: A practical Bayesian framework for backpropagation networks, *Neural Computation*, Vol. 4, No. 3, pp. 448–472 (1992)
- [MacKay 92b] MacKay, D.: The evidence framework applied to classification networks, *Neural Computation*, Vol. 4, No. 5, pp. 720–736 (1992)
- [Misawa 10] Misawa, T., Shioimi, S., Suzuki, K., and Shimokawa, T.: A Brain-computer Interface for Purchase Decision-making, *International Journal of Computational Science*, Vol. 4(2), pp. 173–185 (2010)
- [Neal 96] Neal, R.: *Bayesian Learning for Neural Networks*, Springer (1996)
- [O'Doherty 01] O'Doherty, J., Kringelbach, M., Rolls, E., Hornak, J., and Andrews, C.: Abstract reward and punishment representations in the human orbitofrontal cortex, *Nature neuroscience*, Vol. 4, pp. 95–102 (2001)
- [Sanfey 06] Sanfey, A., Loewenstein, G., McClure, S., and Cohen, J.: Neuroeconomics: cross-currents in research on decision-making, *Trends in Cognitive Sciences*, Vol. 10, No. 3, pp. 108–116 (2006)
- [Shimokawa 08] Shimokawa, T., Misawa, T., and Suzuki, K.: Neural Representation of Preference relationships, *NeuroReport*, Vol. 19, No. 16, pp. 1557–1561 (2008)
- [Shimokawa 09] 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)
- [宮川 11] 宮川, 下川 : Smart Market : NeuroFinance の知見を応用したマーケットメイカー型 Brain Computer Interface の作成と評価, 人工知能学会 SIG-Fin 研究会資料 (2011.1)
- [鈴木 01] 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)