

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

宮川 和夫^{1*} 下川 哲矢²
Miyagawa Kazuhiro¹ Shimokawa Tetsuya²

¹ 一橋大学大学院経済学研究科

¹ Graduate School of Economics, Hitotsubashi University

² 東京理科大学経営学部

² The School of Management, Tokyo University of Science

Abstract: 本研究で報告するマーケットメイカー型 Brain Computer Interface (BCI) は、複数人の被験者が同時に市場に参加し投資を行い、その際全員の脳反応を同時計測、リアルタイムに投資行動モデルの学習と予測を行うというものである。この BCI では、これまで行動経済学的な分析によって得られた意思決定に関する知見と計測された生体データを基に、市場参加者の投資行動を予測し、それに従ってマーケットメイクするようなコンピュータエージェントを導入する。これによって市場システム自体が自律的に市場に流動性を与え、かつ市場を安定化させることが可能になると期待される。また、より現実的な環境における投資行動分析のプラットフォームとして利用できる。ここでは、これらの目的のための精度向上の試みを報告する。

1 はじめに

神経経済学 ([Camerer 05, Sanfey 06]) の発展を受けて、これまでに我々は、実用化を視野に入れて、投資意思決定やその行動学習モデルを開発・精緻化してきた ([Shimokawa 09b])。今回、これまで得られたこれらの知見を基に、更により現実的な環境における投資意思決定問題を分析すべく、ある Brain Computer Interface (以下では BCI と書く) を開発した。本論文では、この BCI の設計と評価を報告する¹。

本論文で報告する人工市場型 BCI は、複数人の被験者が同時に市場に参加し投資を行い、その際全員の脳反応を同時計測、リアルタイムにフィルタリングおよび投資行動モデルの学習を逐次行うというものである。ここでは、[Lohrenz 07] や [Shimokawa 09b] のように、市場価格は外生的に与えられるのではなく、市場参加者全員の意思決定に基づいて内生的に決定される。この人工市場型 BCI を行動学習分析のプラットフォームに採用することによって、より現実に近い環境において、行動学習モデルの精緻化を行うことが可能になると期待される。

また、市場参加者の投資行動をより正確に予想することによって、自律的に市場を安定化させるような市場システムを構築できる可能性がある (我々は Smart Market, あるいは Intelligent Market と呼ぶ)。すなわち市場参加者の投資行動を逐次的に予想して、市場を安定化させるために市場に介入する Computer Trader Agent (CTA) を考える。本研究発表では、この Smart Market のコンセプトを中心に我々の研究を紹介する。

2 システム構成

2.1 概要

我々の作成した人工市場型 BCI は、大きく、人工市場部、脳機能測定及びリアルタイム処理部、そして投資行動予測モデルの逐次学習部からなる。このうち、人工市場部は、さらにシステムのサーバ部分と、クライアント部分 (各被験者に 1 台の PC) に分かれる。

2.2 人工市場部

人工市場部は、システムのサーバ部分と、クライアント部分に分かれる。クライアント部分は各被験者の前に置かれた PC である。クライアント部分では、各被験者の投資意思決定が入力され、その情報がサーバ部

*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、鈴木他「Brain Computer Interface を用いた投資行動分析」人工知能学会論文誌 (2010.1) [鈴木 01] に基づくものです。




図 1: システム概要 .

分に送られる．入力される情報は，売買（buy or sell）とその指値（limit order price）である．

サーバ部分では，各被験者の投資意思決定情報を基に，今期の市場価格および取引が決定される．被験者のほか，市場参加者には，後述の予測を基に行動する CTA1 名と，まったくランダムに行動するノイズトレーダ 1 名が含まれる．市場価格の決定および取引はダブルオークション方式で行われる．

さらに，株価系列や保有資産額等の表示される指標の他に，サーバ部分において，表 1 に列挙されているような投資行動モデルのファクター候補となる様々なマーケットインデックスが計算され，投資行動予測部に逐次送られる．

2.3 脳機能測定およびリアルタイム処理部

脳機能測定及びリアルタイム処理部では，投資意思決定を行っている最中の被験者の脳機能を，全員同時に測定し，そのデータをリアルタイムでシステムに転送，さらにノイズを消去するためのフィルタリング処理を逐次行なっている．

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部の背外側部 ([Hikosaka 00])，内側眼窩部，および外側眼窩部 ([O'Doherty 01]) に注目する．[Shimokawa 09b] では，fNIRS を用い，これ

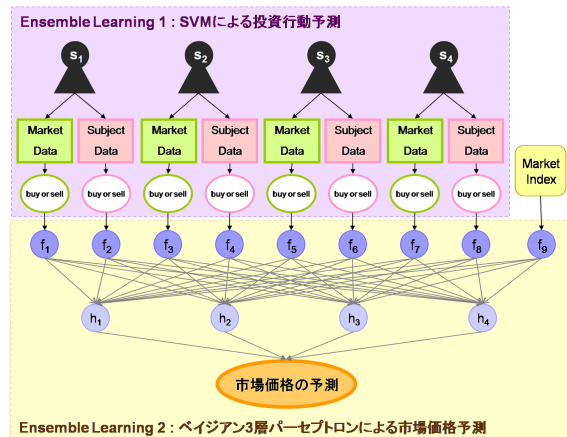


図 2: アンサンブル学習 .

らの部位の脳情報により，投資行動予測が，赤池のベイズ情報量基準 (ABIC) や平均 2 乗予測誤差 (MSD) で改善することが示されている．本 BCI においても，この知見を利用し，市場参加者の脳情報測定部位を，背外側部，内側眼窩部，および外側眼窩部とした．

2.4 投資行動予測モデルの構築及び逐次学習部

2.4.1 予測ファクター

投資行動予測モデルの構築及び逐次学習部では，人工市場部で決定された市場価格および実現利益や未実現利益など，投資行動に影響すると思われるいくつかのマーケットインデックスと，脳機能測定部において測定されたノイズ除去の処理をされた脳血中ヘモグロビン濃度に関するデータを用い，各被験者の投資行動およびその結果としての市場価格を予測している．表 1 に，今回加味した行動予測ファクターの候補が示されている．これらのファクターは，行動ファイナンス分野や資産価格の予測可能性分野において，しばしば注目されるものである ([Lo 02],[Shimokawa 09a],[Kinoshita 10]) ．

2.4.2 アンサンブル学習 1： SVM による投資行動予測

本人工市場型 BCI で採用される予測モデルは，脳血中ヘモグロビン濃度変化のデータとマーケットインデックスから各被験者の次期投資行動を予測する SVM と，その各被験者の予測された投資行動を統合し市場価格を予測するベイジアン 3 層パーセプトロンの 2 段階からなる．すなわち，ある種のアンサンブル学習を行っている．このような 2 段階学習を行う理由は，第一に，各市場参加者の投資行動予測モデルと市場価格予測モ

デルを分けて推定することで、将来、投資行動や市場価格形成メカニズムを解明する際の利便が期待できること、第二に、統計基準を用いて適切なファクター選択が可能になるといいうベジアンニューラルネットワークの利点を保持しつつ、逐次学習のための計算量を減らすことが可能になることによる。実験の間、システムは次々に得られる情報を取り込んで、モデルパラメータの逐次学習を行わなくてはならないため、このような計算量を抑える工夫が必要になる。SVMのカーネルには線形関数、2次関数、およびガウス型基底関数を検討後、ガウス型基底関数を採用した。

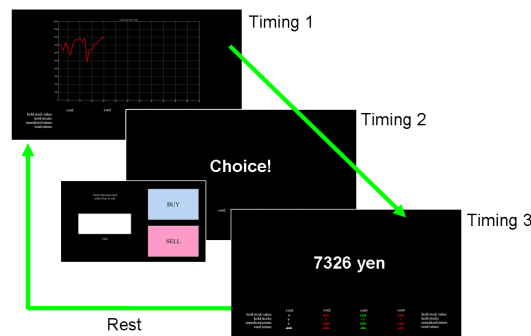


図 3: 実験手続き。

2.4.3 アンサンブル学習 2: ベジアン 3 層パーセプトロンによる市場価格予測

今期の市場価格と各被験者の投資行動に関する SVM の結果を予測ファクターとし、次期の市場価格を予測するために、予測モデルの基底関数として 3 層パーセプトロンを採用した。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) による階層ベイズ推定を、逐次オンラインで行っている。統計的学習法を用いることにより、生体データのようなノイズの多いデータにもある程度対応することができ、さらにオーバーフィッティングの問題も考慮して統計的な基準を用いたモデルの選択が可能になるという大きな利点がある。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 ([MacKay 92, Neal 96])。経済分野における、[Shimokawa 08, Shimokawa 09a] といった研究においても、投資行動や商品選択行動に応用され有用性が示唆されている²。

3 評価

3.1 実験の手続き

我々の行った投資実験における各セッションは以下の通りである。被験者 (市場参加者) は各セッションにおいて 4 人で、19 歳から 39 歳までの健康な男女である。すべてのセッションにおける参加者は 24 人 (延べ) であった。各セッションは 60 期行われた。各期における手続きを図 3 に示す。

3.2 投資行動分析

まず、当該システムによる投資行動予測の精度を見る。表 2 と表 3 には、SVM による投資行動予測と実際の投資行動が一致した割合 (以下、正答率) を示す。な

お、予測は 20 期以降、逐次的に行った。すなわち SVM による予測と実際の投資行動が一致した割合が示してある。ただし、売買に参加しない場合は正答率のカウントから外してある。

表 2 では、今回、CTA による予測に用いたファクターの組み合わせを用いた場合の、各セッションの各被験者についての結果がまとめてある。この表から、第一に比較的高い精度で予測できていることが見て取れる。これは、ファクターによる予測可能性のほか、一般に投資行動は自己相関が高い傾向があるからであると考えられる³。第二に、上表と下表の比較から、多くの場合、脳情報を加えることで投資予測は改善しうることが確認できる。5 つのケースにおいてのみ正答率は低下している。

表 3 には、各セッションの各被験者についての正答率の平均値が、様々なファクターセットの候補について示されている。1 列目はファクターセットの候補を表し、2 列目は正答率の平均値 (すべてのセッションにおけるすべての被験者に関する)、3 列目は当該ファクターセットの中から脳情報を除いた場合からの正答率の改善分がまとめられている。

ここでファクターセット候補には、投資意思決定との時系列相関が大きなものを選んである。まず、「1 期前の収益率」は典型的な強化学習モデルにおいて重要なファクターであり、今回の投資決定との時系列相関係数 (ラグ 1 期) は約 0.12 であった。また「価格のファンダメンタル価値からの乖離率」や「平均値からの乖離率」は、意思決定においてほぼ同様の情報を持つと思われるが、これらの時系列相関は軒並み高く、それぞれ -0.24 と -0.23 であった。すなわち、投資行動は顕著な平均回帰傾向を持つと考えられる。さらに興味深いのは、「未実現利益 (含み損益)」の投資決定への影響である。時系列相関係数 (ラグ 1 期) の分布を見てみると、平均値こそほぼ 0 であるが、ピークが 2 つあり、

³高い自己相関は、今回のように売り買いの離散的な意思決定においてだけでなく、投資量を連続的に変化させていく場合にもあてはまる。また、正答率のカウントには投資に参加しない場合は除かれていることにも注意されたい。

²ベジアン 3 層パーセプトロンの詳細は、上記論文が本研究会における下川発表分 [下川 11] を参照。

2つのタイプの投資家がいることが観測された。片方のタイプは、保有している資産の価値が低下すると売れなくなり、反対に上昇するとすぐに売ってしまう傾向を持つ（有名な資産効果バイアス）、すなわちマイナスの相関をもつグループであり、もう片方は、反対に、順張り傾向を持つプラスの相関があるグループである。もし仮に価格に予測可能性がなく、かつ被験者が合理的であれば、これらの傾向は観測されないはずである。これらのファクターが意思決定予測に重要な役割を果たすと考え、ファクター候補として採用している。

表3を見てみると、まず確認できるのは、脳情報の有効性である。2列目と3列目を比較すると、すべてのファクターセット候補において、脳情報は平均正答率の改善をもたらしている。次に、各ファクターの影響を見てみると、やはりとりわけ「価格のファンダメンタル価値からの乖離率」あるいは「平均値からの乖離率」や「未実現利益（含み損益）」が投資行動を説明する上で有効であるようである。ただし、SVMの予測正答率で見ると、後述のCTAに採用したファクターセット（1行目）が望ましいようである。

3.3 CTAの導入

本実験では、次のようなCTAを市場参加者に加えた。このCTAは、上記の予測モデルによる逐次予測に従って投資意思決定する。このCTAは、現実の市場におけるマーケット・メーカーのアナロジーである。したがって、このCTAの目的は、マーケット・メーカーと同様に、市場に流動性を与え、かつ市場を安定化させることである。ただし、市場において生き残るためには損失を出してはならない。CTAの投資ルールは、以下の通りに設定した。

case 1. 市場価格が上昇し、かつこの株式のファンダメンタル価値から上に乖離すると予想
→ 売り注文を出す。指値は予測した市場価格とファンダメンタル価値の中間値。

case 2. 市場価格が下落し、かつこの株式のファンダメンタル価値から下に乖離すると予想
→ 買い注文を出す。指値は予測した市場価格とファンダメンタル価値の中間値。

case 3. その他
→ 取引には参加しない。

すなわち、CTAは被験者の投資行動が一致し、流動性が欠乏し、市場価格がバブルや暴落するといった状況において、流動性を供給しかつ市場を安定化させる役割を持つ。BCIによる市場予想が正しくない場合、この投資ルールに従うCTAは、流動性を供給し市場を安

定化させることができなかつたり、たとえきたとしても損失を被る可能性がある。CTAが損失を出すことなく機能するためには、市場価格が正しく予測されていないとてはならない。

3.4 CTAのパフォーマンス評価

表4に実験における本BCIのパフォーマンス評価を示す。まず、1行目と2行目には、各セッションにおけるCTAが参加することによる安定性の改善が示されている。1行目は価格変動幅（ボラティリティ）の期間平均が、CTAが参加しない期間から、CTAが参加することによりどれだけ改善したかを示しており、2行目はDuffy and Unver [Duffy 03] のバブル指標が、同様にどれだけ改善したかを示している。表からわかるように、両者ともに、すべてのセッションにおいて改善している。3行目は、CTAが取引に参加した割合（CTAが市場に参加する全期間における）を表している。予想が正しくない場合、CTAのオファーによる取引が成立する頻度は少なくなり、CTAの目的の一つである市場への流動性の供給が達成されない。この行からわかるように、CTAは市場流動性の供給に大きく貢献している。4行目は、CTAの利益を表している。先にも述べたように、CTAの投資ルールの定義から確定利益は0以上となる。ここで示したのは、確定利益と未確定利益の和である。一つのセッションを除きCTAの損失は計上されていない。これらの結果から、CTAはその目的をほぼ達成できているといえるだろう。

3.5 市場価格形成予測

最後に、ここで採用されたファクター、特に血中ヘモグロビン濃度変化、の価格列予測に関する有効性を別の観点からも検証してみたい。具体的には、これらのファクターが情報量基準によって有意なファクターとして採用されるか否かを検討する。ただし、上記の市場価格列はCTAの行動（すなわち予測そのもの）を既に含んでしまっているため、市場価格予想に関する精度分析には使えない。そこでここでは、上記のCTA実験に先立って採取したCTAが市場参加者として含まれていない場合のセッションデータ（4本）を用いた。実験そのものは3.1と同様であり、被験者も1セッションに4人である。

表5および表6には、3層パーセプトロンを用いた予測モデルを、いくつかのファクターセットについて作成した場合の結果がまとめてある。3層パーセプトロンは2.4と基本的に同様のものである。事後的な分析のため、逐次予測ではなく、各セッションについて、全データの8割でモデルを学習し、残り2割を予測し

た。ABIC は 8 割の学習データについて計算されており，MSD は残り 2 割について計算されている。

また，表 7 には，比較のために各セッションデータを，金融統計学において標準的な ARMA-GARCH モデルにおいて予想した結果が示されてある。この表の 1 列目は赤池の情報量基準によって選択されたモデルを，2 列目はそのモデルによる収益率予想の精度 MSD が示される。この結果と，上記の選択されたモデルの結果（表 6 の 2 行目）を比較してみると，脳情報を加味した我々のモデルは，ARMA-GARCH 型の予測モデルを大きく上回る精度を持つことが確認できる。

4 結論

本論文では，我々が製作した人工市場型 BCI の詳細を報告し，その評価のために行った CTA を含む市場実験の結果を述べた。実験の結果は，BCI による被験者の投資行動予測に基づいて行動する CTA が市場の安定化と流動性の供給という目標を達成しており，この人工市場型 BCI が投資行動分析に有用であることを示している。この分析プラットフォームは，計算量を抑えつつ多くの意思決定要因を考慮するためのアンサンブル学習モデルパラメータの逐次統計学習といった機能を持っており，市場環境と脳反応との相互作用や，投資パフォーマンスと脳反応との関係の解明に，有効な分析環境を提供するものであった。今後は，この人工市場型 BCI を用いて，市場システムの設計や投資行動の解明を進めていく。

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)
- [Duffy 03] Duffy, J. and Utku Unver, M.: Asset price bubbles and crashes with near-zerointelligence traders, towards an understanding of laboratory findings (2003)
- [Hikosaka 00] Hikosaka, K. and Watanabe, M.: Delay Activity of Orbital and Lateral Prefrontal Neurons of the Monkey Varying with Different Rewards, *Cerebral Cortex*, Vol. 10, No. 3, pp. 263–271 (2000)
- [Kinoshita 10] Kinoshita, K., Suzuki, K., and Shimokawa, T.: Evolutionary Foundation on Bounded Rationality in a Financial Market, *The IEEE Transactions on Evolutionary Computation (forthcoming)*. (2010)
- [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, pp. 9493–9498 (2007)

- [MacKay 92] MacKay, D.: A practical Bayesian framework for backpropagation networks, *Neural Computation*, Vol. 4, No. 3, pp. 448–472 (1992)
- [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 09a] Shimokawa, T., Suzuki, K., and Misawa, T.: Augmented Reinforcement Learning and Investment Decision Making, *Neurocomputing*, Vol. 72, No. 16–18, pp. 3447–3461 (2009)
- [Shimokawa 09b] 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)
- [下川 11] 下川, 木下, 宮川: 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, 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)

表 1: 投資行動予測モデルのファクター候補一覧。ファクターの ID (M, Hb, S) は以下の分析において用いられる。

Factor ID	Factor name
M1	1 期前の収益率
M2	2 期前の収益率
M3	3 期前の収益率
M4	ファンダメンタル価値からの乖離率
M5	平均値価値からの乖離率
M6	10 期間移動平均からの乖離率
M7	トレンドリバーサル指標
M8	被験者全体での未実現損益
M9	被験者全体での保有株式数
S1	未実現損益
S2	保有株式数
Hb1	背外側部 timing 1
Hb2	背外側部 timing 2
Hb3	内側眼窩部 timing 1
Hb4	内側眼窩部 timing 2
Hb5	外側眼窩部 timing 1
Hb6	外側眼窩部 timing 2

表 2: サポートベクターマシンによる投資行動予測可能性。上表は正答率，下表は脳情報を考慮しない場合からの正答率の改善分を表す。ファクターセットは表 1 の M1-9, S1,2, Hb1,2,5,6 を用いた場合。

Session	被験者 1	被験者 2	被験者 3	被験者 4	平均
1	0.522	0.600	0.714	0.706	0.635
2	0.692	1.000	0.714	1.000	0.852
3	0.677	1.000	0.633	0.875	0.796
4	0.647	0.765	1.000	0.647	0.765
5	0.600	0.833	0.556	0.880	0.717
6	1.000	0.833	0.667	1.000	0.875

Session	被験者 1	被験者 2	被験者 3	被験者 4	平均
1	-0.043	-0.055	0.029	0.000	-0.018
2	0.056	0.333	-0.013	0.333	0.177
3	0.000	0.400	0.047	0.000	0.112
4	0.000	0.000	0.000	0.047	0.012
5	-0.050	0.146	0.056	0.005	0.039
6	0.167	0.056	0.167	0.000	0.097

表 3: サポートベクターマシンによる投資行動予測可能性。1 列目は利用したファクターセット，2 列目は正答率，3 列目は脳情報を考慮しない場合からの正答率の改善分を表す。全てのセッションにおけるすべての被験者の平均値である。ファクターセットは表 1 のものを用いた。

Factor set	正答率	正答率の改善分
M1-9, S1,2, Hb1,2,5,6	0.773	0.070
M1, Hb1,2,5,6	0.697	0.104
M4, Hb1,2,5,6	0.734	0.051
M5, Hb1,2,5,6	0.738	0.056
M7, Hb1,2,5,6	0.705	0.107
S1, Hb1,2,5,6	0.757	0.046
S2, Hb1,2,5,6	0.677	0.074
M1,4, Hb1,2,5,6	0.727	0.049
M1,5, Hb1,2,5,6	0.734	0.020
M1,7, Hb1,2,5,6	0.708	0.113
M1, S1, Hb1,2,5,6	0.734	0.059
M1, S2, Hb1,2,5,6	0.677	0.074

表 4: パフォーマンス指標。

指標	S 1	S 2	S 3	S 4	S 5	S 6
価格改善率	0.640	0.271	0.099	0.221	0.408	0.125
パブル改善率	0.778	0.698	0.548	0.285	0.6502	0.124
取引成功率	0.225	0.324	0.158	0.227	0.139	0.100
総利益	5842	3056	5536	-9191	8482	2310

表 5: ベイジアン 3 層パーセプトロンによる市場収益率の予測可能性 (赤池のベイジアン情報量基準)。ファクターセットは表 1 のものを用いた。

Factor set	Session 1	Session 2	Session 3	Session 4
M1-9, S1,2, Hb1,2,5,6	24.449	19.854	7.832	15.236
M1,4, S1,2, Hb1,5	30.236	27.051	10.636	19.290
M1,4, S1,2, Hb1	29.100	20.258	9.689	18.732
M1,4,8,9, Hb1,5	28.567	14.527	3.994	4.923
M1-9, S1,2	23.474	18.565	7.916	14.887
M1,4, S1,2	28.959	15.233	7.769	0.697
M1,4,8,9	8.791	12.532	0.070	6.599

表 6: ベイジアン 3 層パーセプトロンによる市場収益率の予測可能性 (平均 2 乗誤差)。ファクターセットは表 1 のものを用いた。

Factor set	Session 1	Session 2	Session 3	Session 4
M1-9, S1,2, Hb1,2,5,6	0.000776	0.002290	0.001594	0.000302
M1,4, S1,2, Hb1,5	0.000242	0.000652	0.003501	0.000270
M1,4, S1,2, Hb1	0.000995	0.005002	0.003367	0.001129
M1,4,8,9, Hb1,5	0.001182	1.007400	0.069385	0.005456
M1-9, S1,2	0.000393	0.002074	0.003258	0.000113
M1,4, S1,2	0.001037	0.004956	0.004059	3.461200
M1,4,8,9	0.004643	1.090200	0.003494	0.022014

表 7: ARMA+GARCH モデルによる市場収益率の予測可能性 (平均二乗誤差)。

Session	選択された Model	MSD
1	ARMA(1,1) - GARCH(1,1)	0.0015
2	ARMA(1,1)	0.0048
3	ARMA(0,1) - GARCH(1,1)	0.0048
4	ARMA(1,1)	0.0029