

Title	予測株価を用いた投資行動の最適化手法に関する研究
Author(s)	山田, 幸治
Citation	
Issue Date	2014-09
Type	Thesis or Dissertation
Text version	author
URL	http://hdl.handle.net/10119/12271
Rights	
Description	Supervisor: 池田 心, 情報科学研究科, 修士

修 士 論 文

予測株価を用いた投資行動の
最適化手法に関する研究

北陸先端科学技術大学院大学
情報科学研究科 情報科学専攻

山田 幸治

2014年9月

修士論文

予測株価を用いた投資行動の
最適化手法に関する研究

指導教員 池田 心 准教授

審査委員主査 池田 心 准教授

審査委員 飯田 弘之 教授

審査委員 白井 清昭 准教授

北陸先端科学技術大学院大学
情報科学研究科 情報科学専攻

1110955 山田 幸治

提出年月: 2014年8月

概要

我々は生活の中で日々意思決定を行っている。意思決定の良し悪しでその選択から得られる報酬も変わることから、意志決定は常に我々の関心事であり、昔から様々な研究がなされてきている。

金融市場もその一つで、市場のデータを分析し、投資判断に役立てる研究が様々な形で行われてきた。ファイナンスの分野では1960年代に William Forsyth Sharpe が CAPM (Capital Asset Pricing Model:資本資産評価モデル) を作り上げた。また、1976年には Stephen Ross によって提案されたマルチファクターモデルと APT (Arbitrage Pricing Theory:裁定価格理論) などがある。

一方、エンジニアリングの分野でもコンピュータ技術の進展に伴い大容量で高速なデータ処理が可能になったことから、市場のデータをそれらの技術を利用してデータ分析に役立つアルゴリズムの開発などがされてきた。

本研究では、金融市場における意思決定（取引）を対象として、意思決定に必要な状況判断では人工知能分野のデータ分析技能を用いて未来の予測する。意思決定では、従来から知られている幾つかの方法と、効用を使った人間の心の満足度のモデル（近年行動経済学で解明されてきている人間の非合理的な判断基準に基づく意思決定モデル）を組み入れた取引エージェントを提案し、人間の非合理的な振る舞いを再現し、その振る舞いの解明とそれに基づく取引結果の検証（分析）を試みる。

具体的には、株価を機械学習（k近傍法）の手法を使い確率的に未来を予測する。その予測結果に基づきエージェントの取引（意思決定）を3つの最適化手法（平均値方式、投票方式、効用最適化方式）を使って最適化する。検証方法としては、過去のマーケットのデータを使うことで実際の市場に近い状況下で検証及び性能評価を行う。またその過程で、性能を上げるためのパラメータの調整方法や具体的な設定値なども整理する。

目次

第1章 研究の背景と目的	1
第2章 関連研究	3
2.1 市場シミュレーション	3
2.2 人工知能を利用した株価分析	3
2.3 意思決定理論	4
第3章 アプローチ	5
第4章 株価の確率分布予測	7
4.1 k近傍法 (k-Nearest Neighbor)	7
4.1.1 特徴量	8
4.1.2 本研究で使用する特徴量	9
4.1.3 特徴量空間での距離	11
4.1.4 特徴量空間で距離を使った株価変化率予測	12
4.1.5 株価予測の計算例	13
4.2 確率分布予測 (多クラス)	16
第5章 確率分布を用いた取引戦略	17
5.1 予測確率平均値方式 (Average)	17
5.2 投票方式 (Voting)	18
5.3 効用最適化方式 (Utility Optimization)	19
5.3.1 プロスペクト理論の価値関数	19
5.3.2 プロスペクト理論の確率加重平均	20
5.3.3 プロスペクト理論を用いた取引戦略	22
5.4 効用のパラメータの最適化	24
5.4.1 先行研究	24
5.4.2 アンケートによるパラメータ推定	25
5.4.3 具体的なパラメータ推定	27
第6章 評価実験	32
6.1 検証データ (学習データ, 評価データ)	32
6.1.1 検証データ	32
6.1.2 株価予測手法	33
6.1.3 取引戦略	34
6.2 交差検定 (Cross-validation)	35

6.3 評価	36
6.3.1 結果の概要	36
6.3.2 予測確率平均値方式の詳細	38
6.3.3 投票方式の詳細	40
6.3.4 効用最適化方式の詳細	41
第7章 考察と今後の展開	45
謝辞	46
参考文献	47

目次

図 3-1 システム概要	5
図 4-1 k 近傍法の一般的な使用方法	7
図 4-2 株価変化率	8
図 4-3 株価の時系列データ	9
図 4-4 本研究で使用する 3 期間の特徴量	10
図 4-5 特徴量空間に分布する特徴量	10
図 4-6 学習データと評価データの距離 (3 期間モデル)	12
図 4-7 最近傍法の学習データによる評価データの株価変化率予測	13
図 4-8 株価変化率の確率分布予測	16
図 5-1 k=5 の平均値の計算例	17
図 5-2 投票方式での意思決定	18
図 5-3 価値関数のグラフ	20
図 5-4 確率加重関数	21
図 5-5 k=5 におけるプロスペクト効用 (PV) のグラフ	23
図 5-6 価値関数 ($\alpha=\beta=0.88, \lambda=2.25$)	24
図 5-7 効用を推測する質問の例	25
図 5-8 選択 1 と選択 2 のプロスペクト効用値	26
図 5-9 パラメータ α と β の分布 ($\lambda=1.80$)	30
図 5-10 本研究で推定した価値関数 ($\alpha=0.72, \beta=0.74, \lambda=1.80$)	31
図 6-1 株価の時系列データ (2001 年~2010 年)	33
図 6-2 予測確率平均値方式での損益分布のグラフ	38
図 6-3 k 毎の予測確率平均値方式による取引の平均利益	38
図 6-4 平均方式の取引における利益の推移	39
図 6-5 投票方式での損益分布のグラフ	40
図 6-6 k 毎の投票方式による取引の平均利益	40
図 6-7 効用最適化方式での損益分布のグラフ	42
図 6-8 k 毎の効用最適化方式による取引の平均利益	42
図 6-9 効用最適化方式での取引における利益の推移	43

表 目次

表 4-1 学習データ (f)	13
表 4-2 評価データ (g)	14
表 4-3 学習データの計算結果.....	15
表 4-4 k 近傍解 (k=1)	15
表 5-1 プロスペクト効用の計算用データ	22
表 5-2 α を推定するための質問票.....	27
表 5-3 β を推定するための質問票.....	28
表 5-4 λ を推定するための質問票.....	29
表 5-5 パラメータの最適値	30
表 6-1 交差検定のデータパターン	35
表 6-2 予測確率平均値方式と投票方式の取引結果.....	36
表 6-3 予測確率平均値方式と投票方式の取引結果詳細	36
表 6-4 効用最適化方式の取引結果	37
表 6-5 効用最適化方式の取引結果詳細.....	37
表 6-6 投資戦略における各取引結果の効用の平均値 (k=20)	44

第1章 研究の背景と目的

近年、人工知能分野のデータ分析手法をそれ以外の分野に応用する研究が数多く行われている。分野の融合、或いはある分野で高度に開発された技術や研究成果を他の分野で利用することは、単独の分野の研究では成し得なかった より良い大きな成果を生み出すことにとっても役立つ。

コンピュータ技術の進展に伴い大容量・高速な処理が可能となった技術的背景から、コンピュータに人間のような知性や認識力を実装しようとする人工知能と呼ばれる分野の研究が 1950 年代頃から行われてきた。アラン・チューリングによって行われたチューリングテスト（『計算する機械と知性』（Computing Machinery and Intelligence））は機械が知性を持てるかどうかを検証しようとしたものであり、コンピュータに高度な知性を持たせようとする様々な試みが行われ始めてきたことを象徴している。その様な中、クラスタリング分析やアソシエーション分析などの分析手法、木構造を模した決定木や脳の神経回路を模倣したニューラルネットワークなどのモデル、識別性能の高いサポートベクタマシン（SVM）や自らの行動のフィードバックから学習を行える強化学習という様々な手法が開発されてきた。

一方経済学の分野では、近年人間の非合理的な特性から人間の行動を解明しようとする研究が盛んに行われている。それらの研究分野は行動経済学と呼ばれ、従来からの人間は合理的に行動・意思決定すると仮定されてきた経済理論・意思決定理論とは対峙するもの、もしくはそれらを補完するものとして研究が行われている。行動経済学の代表的な理論はダニエル・カーネマンとエイモス・トベルスキーによって提唱されたプロスペクト理論であり、人間の認知バイアス（偏見・先入観）による人間の非合理的な行動が理論的に説明されている点が従来の理論には無かった新しい視点である。NHK の白熱教室で放送されている「お金と感情と意思決定の白熱教室 ～楽しい行動経済学の世界～」のダン・アリエリー教授（デューク大学）も行動経済学の第一人者であり、人間の非合理的な行動の数々を様々なユニークな実験を通して解明している。 [30][31][32] それらの研究成果は我々の行動・意思決定において今までには無かった数多くの視点や示唆を与えてくれている。

意思決定はどこでも必要とされる人間活動の一つであるが、よく取り挙げられる場面としてゲームや金融市場がある。金融市場における意思決定及びそれを支援するためのデータ分析技術は従来から人々の関心の的であった。分析手法の代表的なものとしてテクニカル分析やファンダメンタルズ分析といったものがある。テクニカル分析では株価の時系列の変動パターンをもとに移動平均、トレンドラ

イン、相対力指数 (RSI)、騰落レシオ、サイコロジカルライン、一目均衡表、ボリンジャーバンドといった方法で株価の分析を行う。一方ファンダメンタルズ分析では、景気の動向 (各種経済指標) や企業の業績 (財務諸表、損益計算書) などから PER (株価収益率) や PBR (株価純資産倍率) などを算出し、企業の成長性や割安株などを分析する。先物取引発祥の地として知られる大阪堂島の米会所でも 300 年近く前からローソク足チャートと呼ばれる株価分析手法が使われていた。最近では外国為替証拠金取引 (FX) で市場の分析及び売買取引までを自動/半自動で行う売買プログラムなども各証券会社から提供されている。

高度なコンピュータ技術、人工知能分野におけるデータ分析技術や機械学習などの予測技術を利用した金融市場の分析・シミュレーションの研究は大学研究所や産業界でもとても関心が高く、世界中で競って研究が行われている。例えば、ビジネススクールで世界最高位に位置付けられているロンドンビジネススクールやカーネギーメロン大のテッパースクールでも複数の外資系大手金融機関と組んでトレーディング・コンペティションを開催している。日本では、東京工業大学等らを中心に U-mart (Unreal Market as an Artificial Research Testbed) プロジェクトとして人工 (仮想) 市場の研究が行われており、毎年サマースクールや U-Mart 実験システムの公開実験が行われ、市場や投資戦略の分析・シミュレーションといったものに活用されている。 [1, 2]

しかし、現状では基本的な統計学の手法や従来からのファイナンス理論に人工知能分野のデータ分析手法を応用した研究は多くなされてきているが、行動経済学や神経経済学などの比較的新しい経済・ファイナンス分野の研究成果と高度なコンピュータ技術・人工知能分野のデータ分析技術とを結び付けた研究成果はまだそれほど多くなされてきていない。本研究では、機械学習の技術と意思決定技術であるプロスペクト理論を使い人間の非合理的な行動パターンを実装した取引エージェント (プログラム) を作成する。機械学習の手法としては k 近傍法を用いて株価変化率を確率的に予測する。その結果を 3 つの手法 (平均値方式、投票方式、効用最適化方式) を使い投資行動の最適化を試みる。検証では TOPIX の過去データを用いて交差検定を行う。内容は取引における最終損益のみならず、取引全体を通しての利益や取引量の推移、効用 (満足度) の平均値、最適化方式の違いによる結果や振る舞いの違いも観察する。データ分析手法 (k 近傍法) のパラメータや意思決定モデルであるプロスペクト理論のパラメータの最適化なども一部行い、多角的な観点から投資行動の評価を行う。これにより、従来の合理的にのみ取引すると想定されて作られてきた取引エージェントには無い、人間の非合理的な判断基準に基づく行動・意思決定による取引の成果や振る舞いの新しい知見が数多く得られることが期待できる。

この様な各分野の最新成果をまたがる もしくは融合した研究内容は、今後益々重要になってくるものであり、同様に今後最も有益な研究手法の一つでもある。

第2章 関連研究

本章では，本論文に関連する先行研究を紹介する．

2.1 市場シミュレーション

市場シミュレーションの研究は日本では U-mart (Unreal Market as an Artificial Research Testbed) プロジェクトとして行われており，工学・経済の両面から様々な研究が行われている[1, 2]. U-mart 以外にも株式の自動取引エージェント作成に関するシステムの提案がなされている[20]. 取引エージェントに関する研究では合理的に振る舞うエージェントを前提にファンダメンタル情報を使ったもの[17]やファジールール抽出を使ったもの[19]などがある．

2.2 人工知能を利用した株価分析

人工知能の技術を使った株価分析は， k 近傍法を使った株価予測の研究では特徴量として「始値」「終値」「高値」「安値」「リターン」を使用し，ロジスティック回帰との性能を比較した研究がある．この研究で k 近傍法はロジスティック回帰と比べて予測の正解率や κ 係数 (kappa statistic) などで優れていることが示されている[6]. ベイジアンネットワークを使った株価動向の分析ではベイジアンネットワークとサイコロジカルライン分析，一目均衡表を用いたトレンド分析，二項モデルとの比較が行われ，次の日の株価指数の上昇/下降の予測においてベイジアンネットワークが精度良く上下予測を行えることが示された[8]. サポートベクタマシン (SVM) を使った研究では，経済時系データの値動きに着目した分析が行われサポートベクタマシンがインデックス運用の値動きの上下一致の予測に有用であることが示された．短期 (1 日後) の予測で最高で 68% の値動き方向一致率，一年間の疑似トレーディングで最高約 7% の利益，中期 (2 週間後) の予測で最高で 71% の値動き方向一致率，一年間の疑似トレーディングで最高約 8% の利益であった[7]. 進化計算を使った研究では遺伝計算手法を使ったテクニカル指標の最適化や組み合わせ最適化が行われ，年率 3~9% の利益であった[11]. 強化学習を使った研究では強化学習タスクの設計方法とオンライン型 profit sharing (OnPS) の実装方法が提案

され、その評価が行われた。結果は学習しないエージェントが年率 4.9%であり、学習したエージェントが年率 7.8%であった[14, 15].

2.3 意思決定理論

意思決定では期待効用理論で合理的な経済人を想定した多くの研究がされてきているが、近年合理的な意思決定モデルでは説明できない人間の数々の行動を人間の非合理性の特性という観点から解明しようとする研究が行われている[28][29][30][31]. 『不確実性下の選択』では不確実性下の意思決定理論の研究の経緯がまとめられている[23]. 合理性に基づく意思決定と非合理性の意思決定との対比の研究も行われている[26]. 投資家の行動が株価へ与える影響を調べた研究では、期待効用理論に基づく合理的な投資家とプロスペクト理論での非合理性をもった投資家の行動がどのように株価の変動に影響を及ぼすかについても研究が行われており、合理的な投資家だけの人工市場よりも非合理的な投資家が参加する市場の方がより現実の市場に近いことを示されている[32].

第3章 アプローチ

本研究では、機械学習を用いた将来の株価の確率分布で予測を行い、その予測確率分布と効用を用いて取引の最適化を行う方法を提案する。図 3-1 に本研究で使用するシステムの概要を示す。まず、過去の値動きデータを用いて k 近傍法で学習（株価の遷移確率を予測）する (①)。次に検証用データ（シナリオ）を入力として、学習データした予測遷移確率と 3 つの意思決定モデル（予測確率平均値方式、投票方式、効用最適化方式）を用いて取引を行い (②)、取引結果を出力（検証）する (③)。

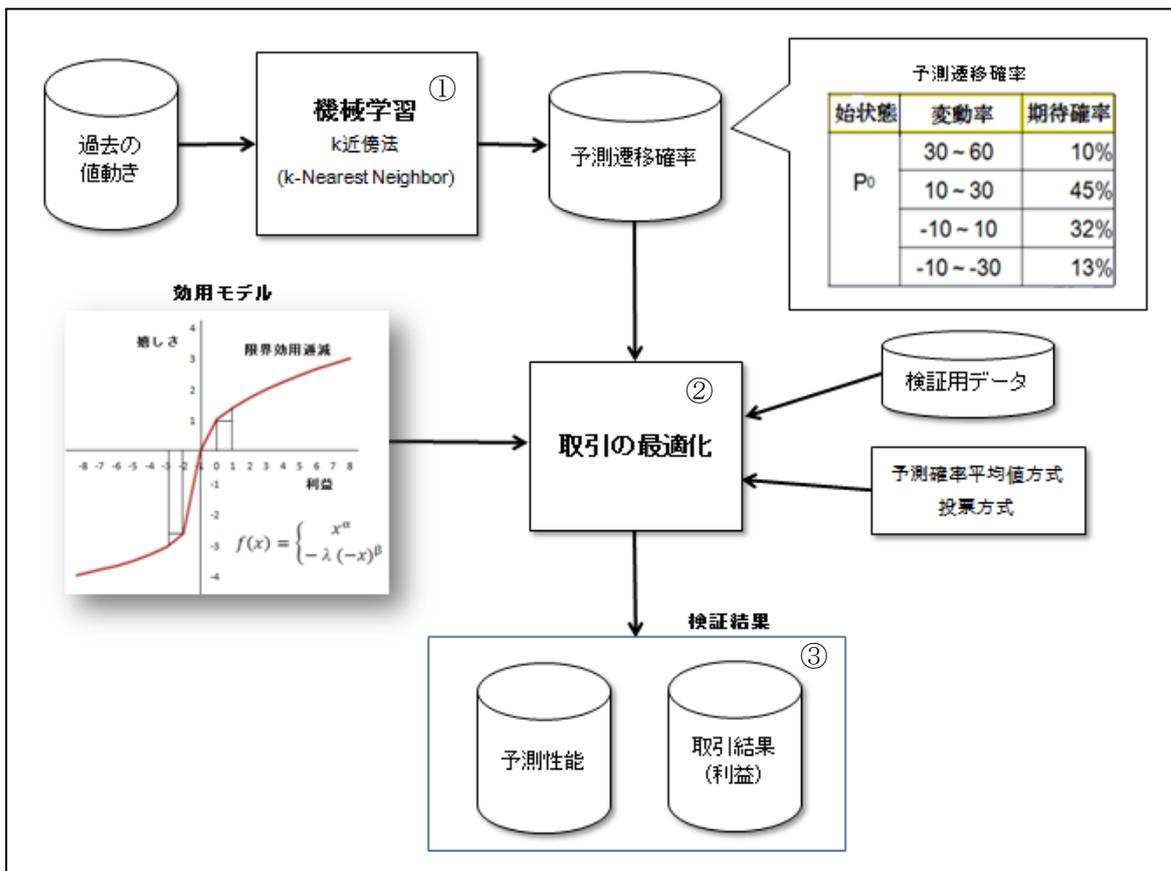


図 3-1 システム概要

この方法では、単一の株価を予測するのではなく、確率分布で予測することで、「大きなリスクを回避」といった行動が取れるようになる。また、効用を用いて最適化することで投資家の嗜好（満足度）に合った行動も取れるようになる。

k 近傍法は新しい手法ではないが、特徴量として株価の変化率を使用する手法や k 近傍法を確率分布に用い、その結果を平均値方式や投票方式で意思決定するやり方は調べた限りでは学術研究にはない。また、プロスペクト理論も既にある意思決定モデルであり、それを使った経済現象の分析などは既に行われているが、上記の機械学習の手法と組合せ、エージェントの行動を最適化する研究は調べた限りでは学術研究にはない。

第4章 株価の確率分布予測

まず初めに、既存のデータからそのデータに存在する規則性を見つけ、それを手掛かりに未知のデータのクラス分類をすることで今後のデータの振る舞いを予測する機械学習の手法を紹介する。今回紹介する手法はk近傍法と呼ばれているものである。

4.1 k近傍法(k-Nearest Neighbor)

k近傍法とは、機械学習のアルゴリズムの1つである。比較的容易に実装ができる割に、データが十分に整えば比較的良い性能が期待できるという特徴をもち、多くの応用例がある。(画像認識、文字認識 など, [3])

k近傍法では、まず特徴(量)空間を定義し、学習データと評価データの特徴量を特徴空間内にマッピングする。次に特徴量空間における両者間の距離を計測することで両者の類似性を測定する。評価データと学習データの距離に応じてランク付けし、距離が近い(類似性がある)順にk個の(近傍)サンプルをとる。その中で最も一般的(多数派)なクラスをその評価データのクラスに割り当てるという手法をとる。図4-1にk=3の近傍法の例を示す。

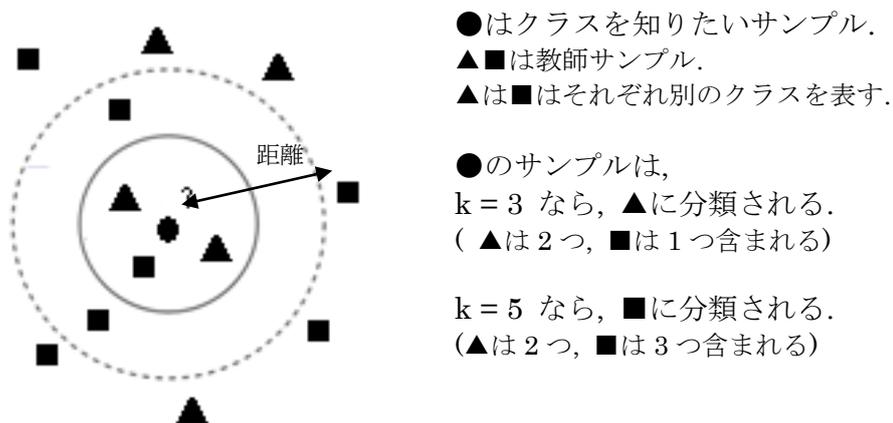


図 4-1 k 近傍法の一般的な使用方法

本研究では、評価データに1つのクラスを割り当てる従来の目的ではなく、k近傍法を用いて株価変動を確率分布で求める手法を使う。詳細は4.2節で述べる。

4.1.1 特徴量

状態を含め物事を評価(比較)するためには何か基準(指標)が必要である。天気を例にとると温度、湿度や降水確率などを使って我々は天気の状態を把握する。ある指標を使うことで2つ以上のもの、例えば昨日の天気と今日の天気、地域Aの天気と地域Bの天気を比較することができる。このようにあるものを特徴付ける基準を特徴量と定義する。

本研究では、株式市場の特徴量として株価の変化率を使用する。株価そのものを用いず変化率を用いる理由は、銘柄ごとに平均的な価格には大きな違いがある一方で変化率にはさほどの違いがない場合が多いためである。またこの株価変化率が今回使用する株価分析手法のk近傍法の入力空間の成分となる。

図4-2に株価変化率の例を示す。時刻Tでの株価が800円であり、時刻T+1での株価が820円であった場合、時刻Tでの株価変化率は2.5%になる。

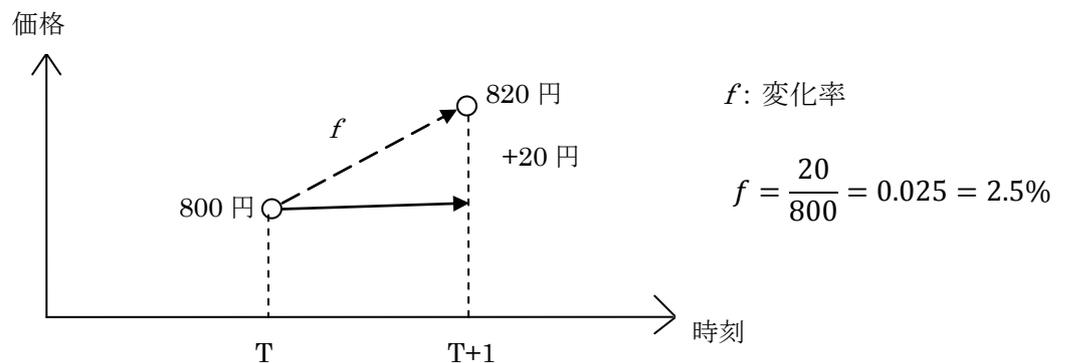


図4-2 株価変化率

また、本研究では変化率を1期間分だけ見るのでは予測には不十分であるため、数期間の株価変化率を特徴量として用いる。

図4-3は3期間の株価をグラフで示した例であり、時刻T+3の時点で次の株価の変化率を予測するために、時刻T~T+1, T+1~T+2, T+2~T+3の3次元の特徴量、変化率(1.67%, -2.73%, 3.37%)を入力としてk近傍法を用いる。

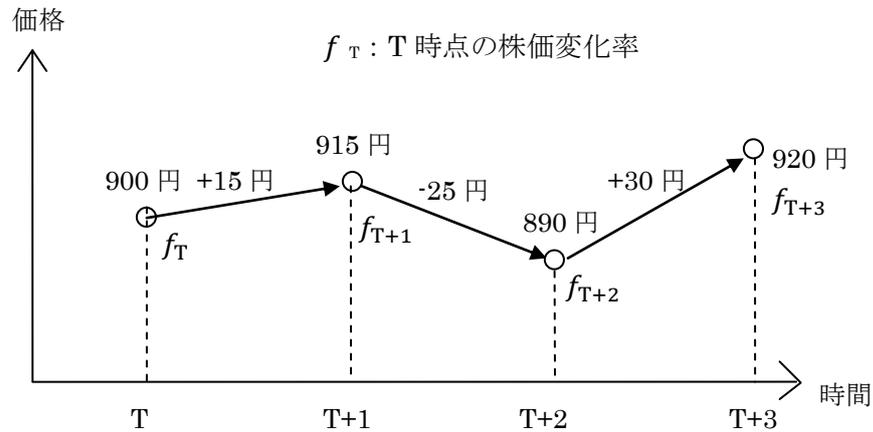


図 4-3 株価の時系列データ

$$\begin{aligned}
 f_T &= +15/900 = 0.01666 \doteq 1.67\% \\
 f_{T+1} &= -25/915 = -0.02732 \doteq -2.73\% \\
 f_{T+2} &= +30/890 = 0.03370 \doteq 3.37\%
 \end{aligned}$$

4.1.2 本研究で使用する特徴量

本研究では単に異なる 3 時点における変化率を使用するのではなく、予測したい時点 (基準点) からの距離に応じたスケーリングをした変化率を使用する。これは基準点の近傍ではより短期的な変化率、遠方ではより長期的な株価変化率が予測に有効に働くと考えるからである。本研究では、3 時点 (1 期間目, 2 期間目, 3 期間目) に対して以下の日付データを使用する。

- 1 期間目 : 9 日前→4 日前 の株価変化率
- 2 期間目 : 4 日前→1 日前 の株価変化率
- 3 期間目 : 1 日前→当日 の株価変化率

以下の株価の時系列データをグラフにすると図 4-4 になる。

9 日前	8 日前	7 日前	6 日前	5 日前	4 日前	3 日前	2 日前	1 日前	当日
734	739	737	730	732	733	726	730	725	727

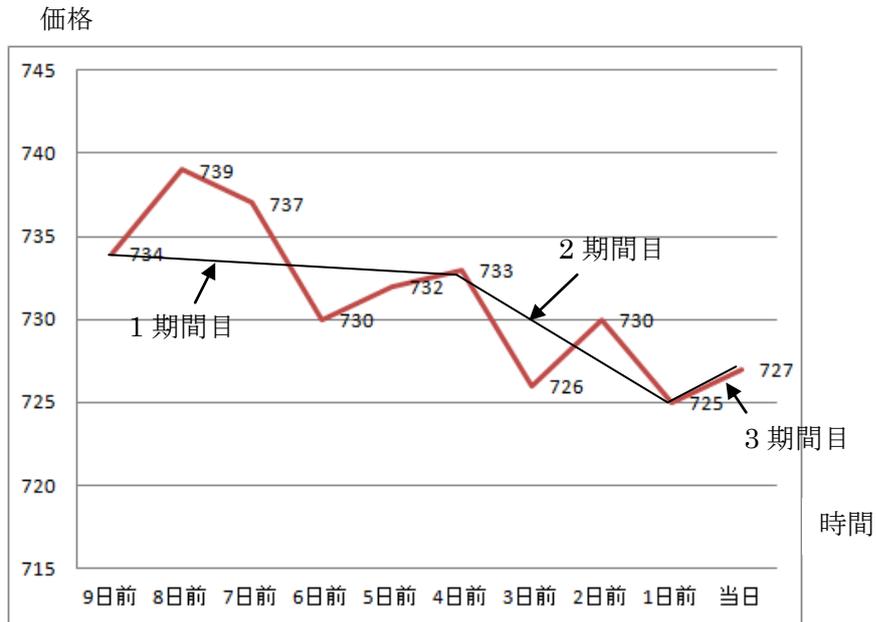


図 4-4 本研究で使用する 3 期間の特徴量

- 1 期間目 : 9 日前→4 日前の株価変化率 = $(727-725) / 734 \cong 0.27\%$
- 2 期間目 : 4 日前→1 日前の株価変化率 = $(727-733) / 733 \cong -0.82\%$
- 3 期間目 : 1 日前→当日 の株価変化率 = $(733-734) / 725 \cong -0.14\%$

図 4-5 に特徴量（株価変化率）の 3 次元特徴量空間での分布を示す。

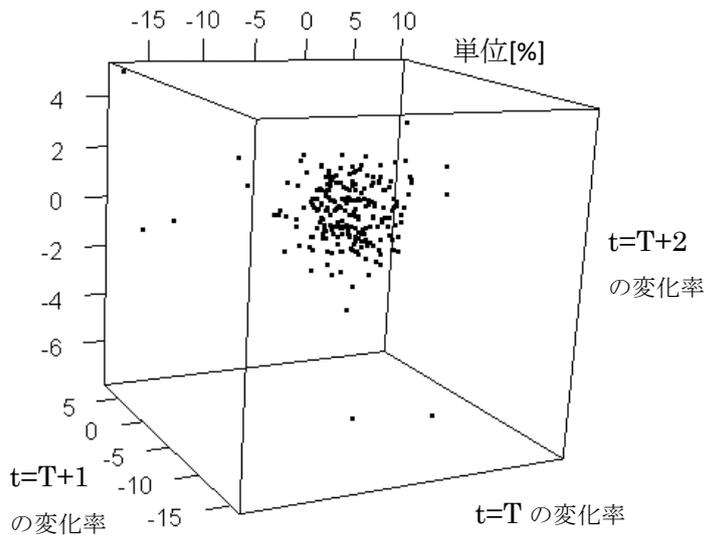


図 4-5 特徴量空間に分布する特徴量

特徴量の分布が 原点の周りに集まっていることから、3 期間の変化量がそれ程大きくなく、かつ平均化していることがわかる。このことから各成分間のスケーリングはそれ程悪くはないと言える。また同時に特に各成分間の相関が高い訳ではないので、株価の変化率の予測においてもそれ程容易ではない問題であることが図 4-5 から予測できる。

4.1.3 特徴量空間での距離

4.1.1 節で特徴量を使う意義を述べた。本節では特徴量が定義（分布）されている特徴量空間での特徴量間の距離（類似性）を計算する方法を紹介する。距離の測定にはユークリッド距離、マンハッタン距離、マハラノビス距離などの測定方法がある。ユークリッド距離では、サンプルデータ値の間の差の 2 乗和を計算する。マンハッタン距離では、データ値の間の差の絶対値の合計を計算し距離とする。マハラノビス距離では、多変数間の相関に基づき平均や共分散行列を用いて距離を計算する。

本研究では特徴空間の距離の計算に k 近傍法で一般的に使われているユークリッド距離を使用する。ここで d は各特徴量間の距離を表す。

1 次元空間での距離

$$d = |f - g| \quad (1)$$

多次元空間における距離

$$d = \sqrt{\sum_i (f_i - g_i)^2} \quad \begin{cases} f: \text{学習データの特徴量} \\ g: \text{評価データの特徴量} \end{cases} \quad (2)$$

i は n 次元空間の i 次元目の成分である。 n 次元空間内での距離 d は各特徴量の i 次元目の成分の差分を二乗して $1 \sim n$ まで足し合わせて、平方根 d をとった値となる。図 4-6 に多次元空間（3 期間モデル）における距離の計算例を示す。

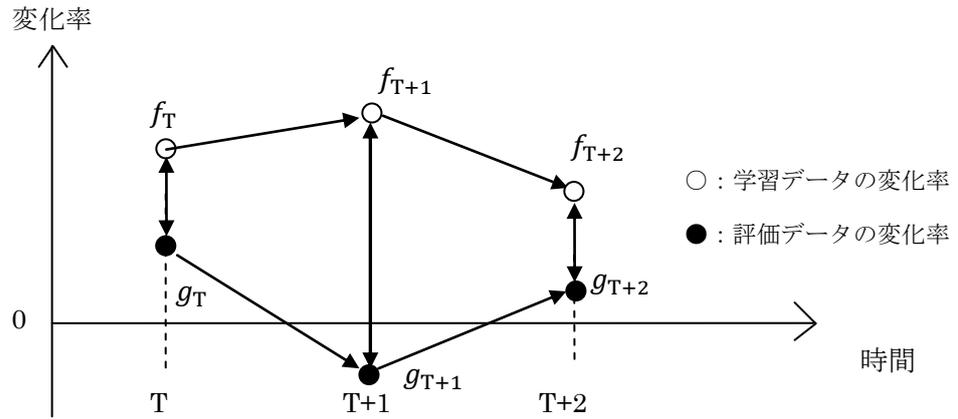


図 4-6 学習データと評価データの距離 (3 期間モデル)

図 4-6 の例で実際に 3 期間で計算される距離 d は,

$$d = \sqrt{(f_T - g_T)^2 + (f_{T+1} - g_{T+1})^2 + (f_{T+2} - g_{T+2})^2} \quad (3)$$

となる。

4.1.4 特徴量空間で距離を使った株価変化率予測

本研究では、先に述べたように 3 期間分の特徴量 ($f_T \sim f_{T+2}$) を使い学習データと評価データとの距離を計算する。計算結果をもとに評価データに最も近い学習データを見つける。学習データは評価データに特徴が近い (類似している) ことから、評価データはこの学習データに変化率が類似したものになると期待する。図 4-7 に最近傍法による株価変化率予測の概念図を示す。T ~ T+2 の間の特徴量 $f_T \sim f_{T+2}$ で学習データと評価データの類似性を調べ、最も評価データに類似している学習データを 1 つ抽出する。そのデータの f_{T+3} の変化率を見る。評価データの T+3 における株価変化率は、学習データの株価変化率 f_{T+3} と類似したものになると期待する。

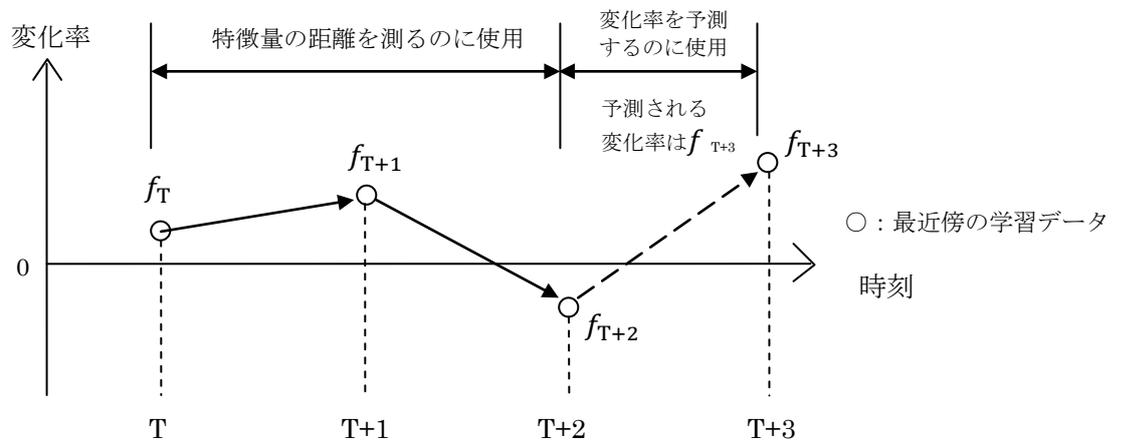


図 4-7 最近傍法の学習データによる評価データの株価変化率予測

4.1.5 株価予測の計算例

続いて、10 個の学習データを用いて $k=1$ すなわち最近傍法を使い株価の変化率を予測する例を示す。学習データは表 4-1 の通りである。

表 4-1 学習データ (f)

No	f_t	f_{t+1}	f_{t+2}	f_{t+3}
1	-2.0%	1.2%	0.2%	-0.12%
2	-2.1%	1.6%	0.5%	0.85%
3	-1.2%	1.4%	-0.1%	1.97%
4	-1.2%	1.0%	0.5%	0.54%
5	-1.2%	1.8%	0.3%	0.42%
6	-1.1%	1.1%	0.3%	0.59%
7	-1.3%	1.4%	0.6%	0.25%
8	-1.3%	2.0%	0.6%	0.25%
9	-1.1%	1.7%	-0.1%	1.63%
10	-1.4%	1.8%	0.3%	-0.36%

f_t は時刻 t における株価変化率、 f_{t+1} は時刻 $t+1$ における株価変化率を表す。学習データ 1 では時刻 t における株価変化率は-2.0%、 $t+1$ では 1.2%、 $t+2$ では 0.2%、 $t+3$ では-0.12%とする。

次に評価データ（未知のサンプル）として表 4-2 を用意する。

評価データは時刻 t における株価変化率は-1.47%， $t+1$ では 1.55%， $t+2$ では 0.35%と仮定する。この評価データの $t+3$ における株価変化率を知りたい。

表 4-2 評価データ (g)

f_T	f_{T+1}	f_{T+2}	f_{T+3}
-1.47%	1.55%	0.35%	(予測したい値)

計算式 (3) を使い学習データ 1 と評価データとの距離 d を計算すると

$$d = \sqrt{(-2.00 - (-1.47))^2 + (1.20 - 1.55)^2 + (0.20 - 0.35)^2} \quad (4)$$

$$= \sqrt{(-0.53)^2 + (-0.35)^2 + (-0.15)^2} \quad (5)$$

$$= \sqrt{0.4259} \quad (6)$$

$$= 0.6526101 \quad (7)$$

となる。

同じ方法でその他の学習データと評価データとの距離 d を計算し、 d の値の昇順でデータをソートすると、表 4-3 の学習データの計算結果が得られる。この表から距離の小さい方(近傍)からサンプル 1 個を見つけると太線の値となる。これらが予測される株価変化率の候補となる。

表 4-3 学習データの計算結果

				(1)	(2)	(3)	d^2	単位 [%]
f_T	f_{T+1}	f_{T+2}	f_{T+3}	$(f_1-g_1)^2$	$(f_2-g_2)^2$	$(f_3-g_3)^2$	$(1)+(2)+(3)$	近傍
-1.40	1.80	0.30	-0.36	0.0049	0.0625	0.0025	0.0699	1
-1.30	1.40	0.60	0.25	0.0289	0.0225	0.0625	0.1139	2
-1.20	1.80	0.30	0.42	0.0729	0.0625	0.0025	0.1379	3
-1.30	2.00	0.60	0.25	0.0289	0.2025	0.0625	0.2939	4
-1.20	1.40	-0.10	1.97	0.0729	0.0225	0.2025	0.2979	5
-1.10	1.10	0.30	0.59	0.1369	0.2025	0.0025	0.3419	6
-1.10	1.70	-0.10	1.63	0.1369	0.0225	0.2025	0.3619	7
-1.20	1.00	0.50	0.54	0.0729	0.3025	0.0225	0.3979	8
-2.10	1.60	0.50	0.85	0.3969	0.0025	0.0225	0.4219	9
-2.00	1.20	0.20	-0.12	0.2809	0.1225	0.0225	0.4259	10

k 近傍法では表 4-4 のように近傍解から予測変化率を計算できる。

表 4-4 k 近傍解 (k=1)

k	予測値変化率	
1	-0.36%	←最近傍解
2	0.25%	
3	0.42%	
4	0.25%	
5	1.63%	

候補で最近傍は f_{T+3} における変化率は-0.36%となることから、予測される変化率は-0.36%となる。

4.2 確率分布予測（多クラス）

本研究では、 k 近傍法で得られた k 個のサンプルに対して通常の使い方のような多数派のサンプルの 1 つのクラスを評価データに割り当てるのではなく、 k 個のサンプルのそれぞれを評価データに対する候補のクラスと考え、 k 個のクラスを標本データに割り当てる。 k 個の候補にそれぞれの割り当てられたクラスは k 個のクラスの中の存在確率（分布）として評価される。候補に確率的な幅を持たせることで、1 クラスで評価した場合に見落とされていたかも知れない候補に近かった 2 番目以降のクラスも 1 番目のクラスと同様に評価することができる利点がある。図 4-8 に株価変化率と確率分布予測の例を示す。

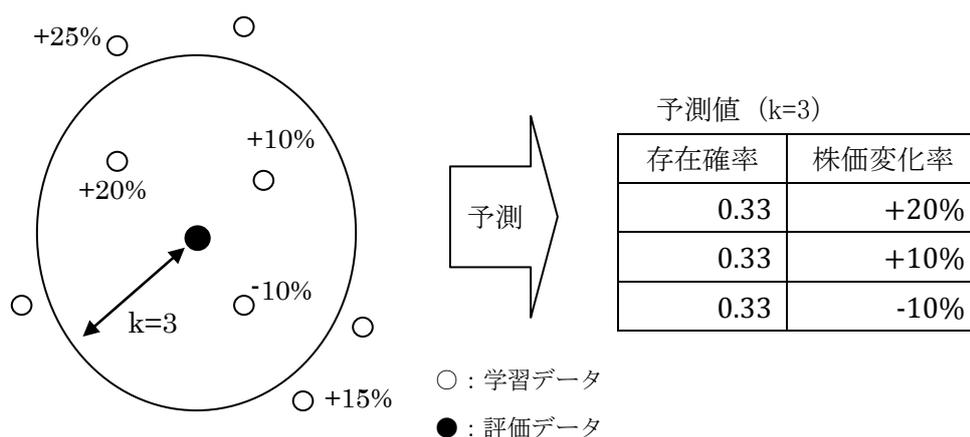


図 4-8 株価変化率の確率分布予測

左上の図では $k=3$ で近傍解を見つける例である。評価データから距離の近い順に 3 つのサンプル(+20%, +10%, -10%)を類似データの候補として採用する。右上の表では k 近傍法を使って確率的に評価データの株価変化率をクラス分けした内容を示してある。それぞれの候補データは同一の存在確率 ($1/3=33.3\%=0.333$) で評価される。本論文では実験していませんが、存在確率を均等にすることはなく、距離や距離ランクで重み付けをすることが可能である。

第5章 確率分布を用いた取引戦略

第4章では株価データを機械学習の手法を使うことにより確率的に予測する手法について述べてきた。第5章では第4章の手法で求めた予測値を使い取引エージェントが行う意思決定の手法について述べる。先ず、5.1節と5.2節で比較的シンプルな株価の予測値からそのまま意思決定を導く2つの手法を紹介する。次に、5.3節では人間の満足度を示す数理モデルである効用関数を使い、欲求や満足度といった人間が意思決定に深く関連する心のメカニズムを考慮した手法を紹介する。

5.1 予測確率平均値方式 (Average)

予測確率平均値方式では、予測した変化率の確率的な平均値を計算し、その平均値を意思決定の重要な要素として意思決定（行動の選択）を行う。手順は以下の通りである。kとnはパラメータである。

- (1) k近傍法により、存在確率と予測変化率の組 (p_i, a_i) をk個取得する。
- (2) 予測変化率の平均値 $av = \sum(p_i \times a_i)$ を計算する。
- (3) $av > 0$ ならばn株買い、翌営業日にn株売る。
- (4) $av < 0$ ならばn株売り、翌営業日にn株買う。

図5-1に平均値方式での計算例を示す。

存在確率	予測変化率
0.20	0.65%
0.20	0.39%
0.20	-0.06%
0.20	-0.15%
0.20	-0.69%

平均値の計算
 $0.2 \times 0.65\% + 0.2 \times 0.39\% - 0.2 \times 0.06\%$
 $- 20\% \times 0.15\% - 20\% \times 0.69\% = \underline{0.028\%}$

図5-1 k=5 の平均値の計算例

予測確率平均値から株価が 0.028%上昇すると予測して、買いの行動をとる。本研究では、取引で株を“買う”もしくは“売る”の行為をした場合は必ず翌営業日に前日の取引の反対売買を行うことで利益（あるいは損益）を確定していく。予測確率平均値方式では予測結果の数値にのみ依存して取引を行ってしまうため投資家の嗜好や満足度に合った投資ができないといったデメリットがある。

5.2 投票方式 (Voting)

投票方式では、候補の中から多数を占めるものを重要な要素として意思決定（行動の選択）を行う。ここで、多数決関数を“入力成分（関数の入力引数）の中から多数派を占める要素を 1 つ選び、戻り値として出力する”と定義する。

$$\text{投票結果} = \text{多数決関数}(C_1, C_2, C_3, \dots, C_k) \quad (8)$$

- (1) k 近傍法により、存在確率と予測変化率の組 (p_i, a_i) を k 個取得する。
- (2) 上昇下降の予測 $\text{vote} = \text{多数決関数}(C_1, \dots, C_k)$ を計算する。ここでの入力 C_i は、特徴量の変動パターンを表す“上昇”もしくは“下降”とする。
- (3) $\text{vote} = \text{上昇}$ ならば n 株買い、翌営業日に n 株売る。
- (4) $\text{vote} = \text{下降}$ ならば n 株売り、翌営業日に n 株買う。

図 5-2 に投票方式での意思決定の例を示す。

存在確率	予測変化率
0.20	0.65%
0.20	0.39%
0.20	-0.06%
0.20	-0.15%
0.20	-0.69%

左の内訳は
 株価上昇（変化率プラス） - 2 票（少数派）
 株価下降（変化率マイナス） - 3 票（多数派）

図 5-2 投票方式での意思決定

左図は株価予測変化率とその存在確率を表している。株価が上昇するとの予測が 2 票、株価が下降すると予測するのが 3 票となっている。多数決の結果、全体では多数派を占める“株価下降”を予測の最有力候補と考え、売りの行動をとる。ここで注意しなければならないことは、投票方式では単純に多数決（支持する候補者の数

が多い) のみに依存して意思決定を行う為, 各クラスが持っているその他の要素や特徴の重要な部分 (例えば少数派であるが株価変動が多数派よりも非常に大きい場合) を見過してしまふ可能性がある.

5.3 効用最適化方式 (Utility Optimization)

本節では, プロスペクト理論 (Prospect Theory) [25] に基づく取引戦略を提案する. プロスペクト理論とは, 1979 年にダニエル・カーネマンとエイモス・トベルスキーにより提案された理論で, ファイナンスにおける不確実性下 (既知の確率) において, 人々がどのように意思決定をするかを明らかにした理論である. 特に, 投資家の短期的に陥りやすい非合理的な感情 (バイアス) にもとづく意思決定の仕組みがモデルに組み込まれているのが特徴である. プロスペクト理論は, 人間の効用を表す価値関数と確率に依存する比重パラメータである確率加重関数の 2 つからなる. またこの理論は実際の短期的な投資行動において投資家の心理をうまく説明しているといわれる.

5.3.1 プロスペクト理論の価値関数

価値関数とは, 人間の満足度を表す効用の数理モデルであり人間の心理的な特性 (参照依存, 損失回避, 効用の非対称性) がモデルに組み込まれている. 参照依存では, 利得の絶対値ではなく, 利得の相対値 (変化量) でその価値を評価する. 損失回避では, 同じ額の利益と損失では, 損失の方を過大に評価する (賭をしない選択をする). 価値関数の計算式を以下に示す.

$$v(x) = \begin{cases} x^\alpha & (x \geq 0) \\ -\lambda(-x)^\beta & (x < 0) \end{cases} \quad \begin{cases} v: \text{効用} \\ x: \text{利得} \end{cases} \quad (9)$$

α : 利得を得た時の感情の変化の度合いを表す.

α が大きいほど同じ利得でもより多く満足度を感じる.

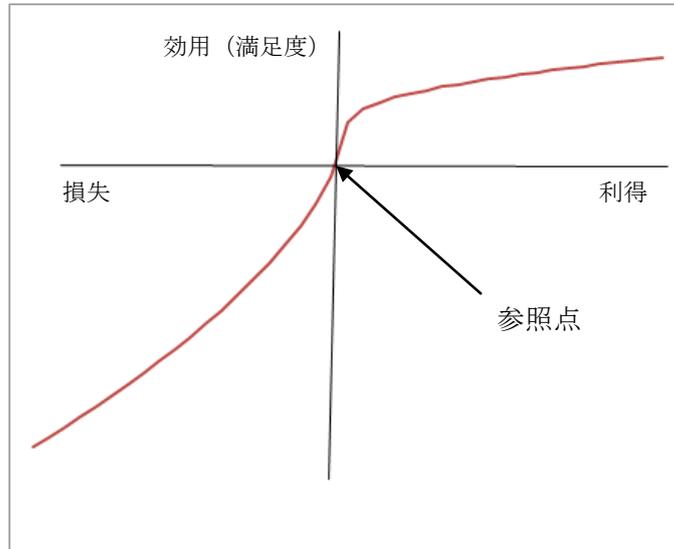
β : 損失を被った時の感情の変化の度合いを表す.

β が大きいほど同じ損失でも悲しさを強く感じる.

λ : 満足度の増し方と悲しさの増し方の比率を表す.

一般に人間は悲しさの増し方が満足度よりも大きい ($\lambda > 1$).

図 5-3 に価値関数の例を示す.



α	0.80
β	0.85
λ	2.50

図 5-3 価値関数のグラフ

参照依存では、効用値は参照点 (Reference Point) からの相対値 (変化量) を用いて計算する。資産が 100 万円だったものが 110 万円になれば $v(10 \text{ 万})$, 80 万円になれば $v(-20 \text{ 万})$ になる。

5.3.2 プロスペクト理論の確率加重平均

確率加重平均とは、人間の確率の主観的な確率と実際の確率との関係を表す。以下に確率加重の計算式を示す。 p は実際の確率, ω^+ は利得がプラス, ω^- は利得がマイナスのときの主観的な確率 (確率加重) を表す。 γ と δ は主観的な確率と実際確率の変換比率を表すパラメータを表す。

$$\omega^+(p) = \frac{p^\gamma}{\{p^\gamma + (1-p)^\gamma\}^{1/\gamma}} \quad (10)$$

$$\omega^-(p) = \frac{p^\delta}{\{p^\delta + (1-p)^\delta\}^{1/\delta}} \quad (11)$$

図 5-4 に確率加重関数の例を示す.

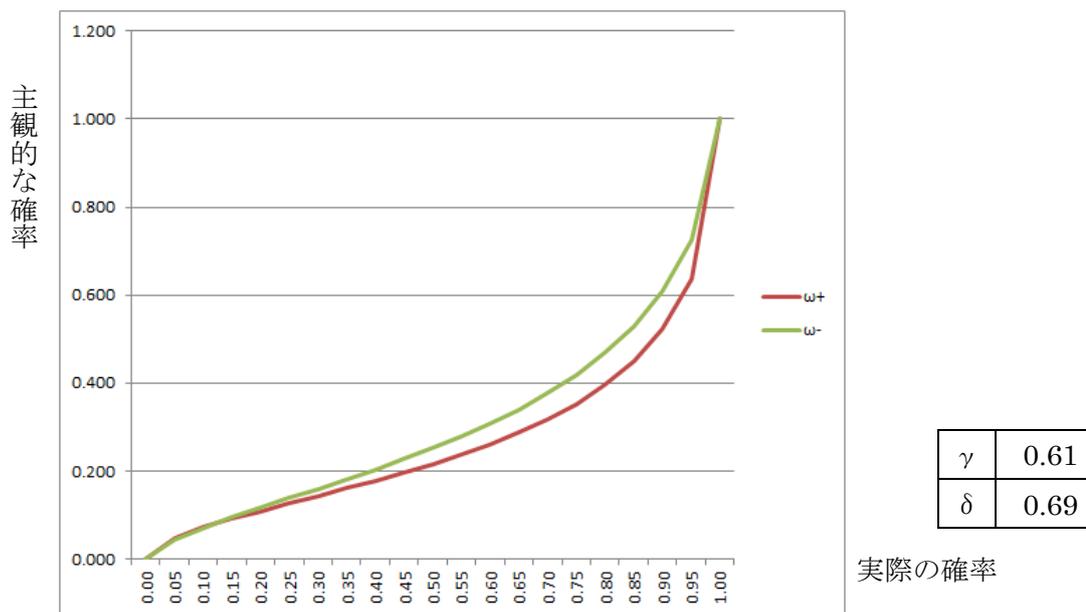


図 5-4 確率加重関数

このグラフは人間が、低い確率を過大評価し、高い確率を過小評価することを表している。例えば、宝くじは当たる確率が理論値として、一般的には1等の当選確率は約1000万分の1と言われている。これを単純に計算すると1枚300円で1等が3億円の場合、期待値は30円なので、宝くじを買いたとは思わない。しかし、確率を50万分の1くらいに誤認すれば、期待値は600円になるので、買う人がいてもおかしくはない。実際は1000万分の1と50万分の1は殆ど違いが感じられないので、こういったことがありうる。人が宝くじを購入するのは、当たる確率が低くてもその確率を実際の確率以上に過大評価している為とも言える。

6.3.3 プロスペクト理論を用いた取引戦略

効用最適化方式では，存在確率と効用からプロスペクト効用（ PV ）を計算しプロスペクト効用が最大となるポイントで意思決定を行う．効用の計算式は以下の通り．プロスペクト効用が最大となる q で取引を行う．

$$PV = \sum_{i=1}^n \omega(p_i)v(x) \quad (12)$$

$$= \sum_{i=1}^n \omega(p_i)v(a_i c q) \quad (13)$$

$$= \sum_{i=1}^n \{\omega^+(p_i)v(a_i c q) + \omega^-(p_i)v(a_i c q)\} \quad (14)$$

$$\begin{cases} p_i : \text{存在確率, } c: \text{株価} \\ a_i : \text{予測変化率} \\ q : \text{取引量} \end{cases}$$

このプロスペクト効用を用いた取引戦略アルゴリズムは以下の通りである．

- (1) k 近傍法により，存在確率と予測変化率の組 (p_i, a_i) を k 個取得する．
- (2) $-1000 \leq q \leq +1000$ の範囲で， $PV(q)$ が最大となる q を求める．
- (3) $q > 0$ ならば q 株買い，翌営業日 q 株売る．
- (4) $q < 0$ ならば $-q$ 株売り，翌営業日 $-q$ 株買う．

実際のデータを用いてこのアルゴリズムの例を示す．表 5-1 に， $k=5$ の場合の存在確率 p_i ，予測変化率 a_i を示す．

表 5-1 プロスペクト効用の計算用データ

存在確率 p_i	予測変化率 a_i
0.20	0.65%
0.20	0.39%
0.20	-0.06%
0.20	-0.15%
0.20	-0.69%

株価 $c=900$ とする。効用のパラメータは $\alpha=0.6$, $\beta=0.7$, $\lambda=1.8$, $\gamma=\delta=1.0$ とする。図 5-5 の横軸は取引量 q , 縦軸は効用の値である。細い 5 本の線は、各予測 $i=1\sim 5$ に対する効用を、太い線はその合計値を表す。細い線はすべて単調増加または単調減少であるが、太い線は単調関数ではなく $q=200$ 付近で極大値を持つ。すなわち $q=200$ 程度で最も期待効用を持つために、200 株の買い取引を行うことになる。

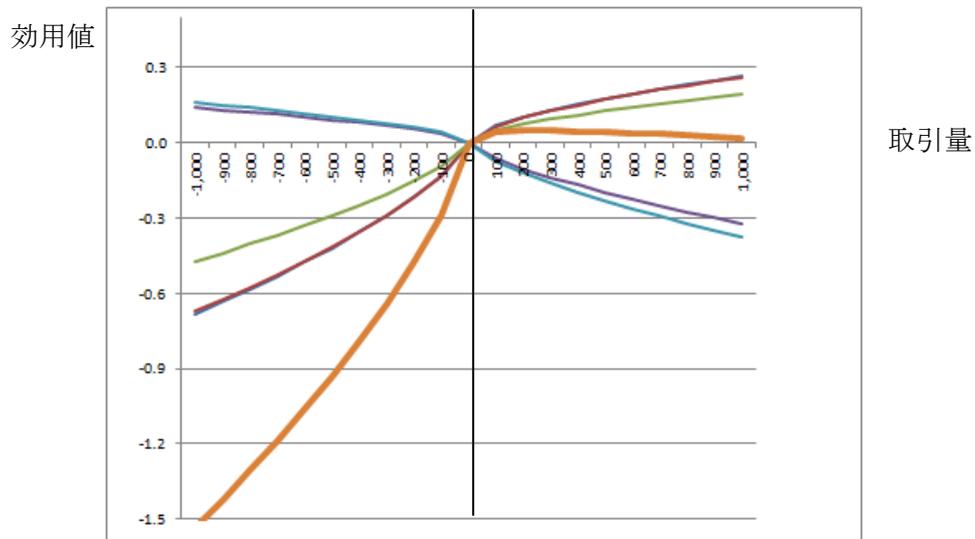


図 5-5 $k=5$ におけるプロスペクト効用 (PV) のグラフ

5.4 効用のパラメータの最適化

効用最適化方式では，人間の満足度を表す指標である効用を使い，効用の最適値（最大値）で意思決定を行う．本研究では，効用の数理モデルとしてプロスペクト理論の価値関数を利用する．その理由は，プロスペクト理論は短期的に人間がとりがちな感情に基づく非合理的な意思決定がモデル化されていて投資家の心理（投資行動）を反映しており，今回の研究に最も適していると考えられるからである．本研究では，価値関数で効用の最適化を行うと同時に価値関数におけるパラメータ α ， β ， λ を実験を行い，最適な値を推定する．

5.4.1 先行研究

効用関数を推定した先行研究を紹介する．これはプロスペクト理論を提唱したプリンストン大学の **Kahneman** と **Tversky** らによってはカリフォルニア大学バークレー校とスタンフォード大学の学生にアンケートをする事で，効用関数を推定した．（ $\alpha = \beta = 0.88$ ， $\lambda = 2.25$ ， $\gamma = 0.61$ ， $\delta = 0.69$ ） [26]

$$V(x) = \begin{cases} x^{0.88} & (x \geq 0) \\ -2.25 \times (-x)^{0.88} & (x < 0) \end{cases}$$

図 5-6 は上記パラメータの価値関数のグラフである．

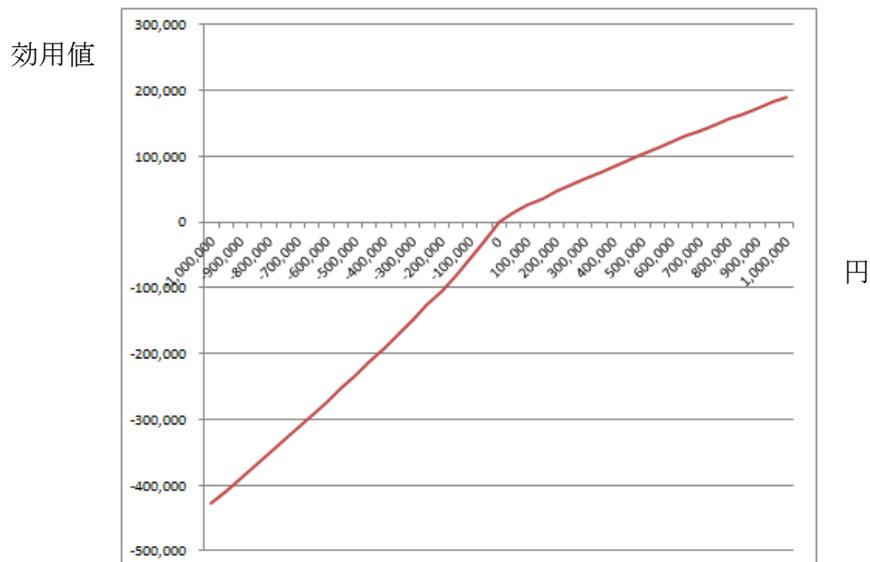


図 5-6 価値関数 ($\alpha = \beta = 0.88$ ， $\lambda = 2.25$)

図 5-4 は上記パラメータを使って確率加重関数を描いたものである。

$$\omega^+(p) = \frac{p^{0.61}}{\{p^{0.61} + (1-p)^{0.61}\}^{1/0.61}} \quad (15)$$

$$\omega^-(p) = \frac{p^{0.69}}{\{p^{0.69} + (1-p)^{0.69}\}^{1/0.69}} \quad (16)$$

5.4.2 アンケートによるパラメータ推定

本研究において、先行研究と同様に独自の効用関数を推定する試みを行う。手法は以下の通りである。まず初めに人間の判断基準を探るために質問票を用意する。質問票では期待確率と利得の組合せた選択肢を幾つか示す。それらの大小関係を比較して、いことで意思決定の基準となっている枠組みを推測していく。続いて、効用関数の数理モデルに当てはめることでその質問の回答内容を数値処理し、数理モデルのパラメータを推定する。図 5-7 に効用を推測する質問の例を示す。

ここに 2 つの選択肢が提示されました、
どちらかを選ぶことができます。

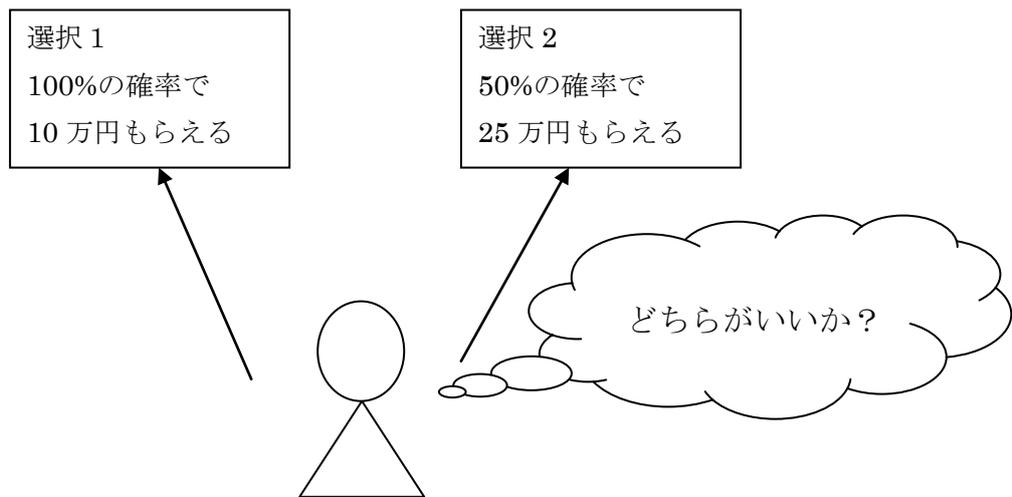


図 5-7 効用を推測する質問の例

例えば、上記の選択で選択肢1を選んだとする。この場合、選択肢間の効用（満足度）の大小関係は『**選択1の効用 > 選択2の効用**』となる。これを数理モデルに当てはめ数値処理を行うと以下になる。

選択肢1の効用値を式(13)を使って計算すると、

$$PV1 = \sum_i^k p_i \times PV(a_i cx) \quad (17)$$

$$PV1 = 1.0 \times (100,000)^\alpha \quad (18)$$

$$= (100,000)^\alpha \quad (19)$$

選択肢2の効用値を式(13)を使って計算すると、

$$PV2 = 0.5 \times (250,000)^\alpha \quad (20)$$

選択肢1が選ばれたのだから、 $PV1 > PV2$ ということである。

$$(100,000)^\alpha > 0.5 \times (250,000)^\alpha \quad (21)$$

図5-8に α の値を横軸に取った場合のPV1,PV2を示す。グラフより、

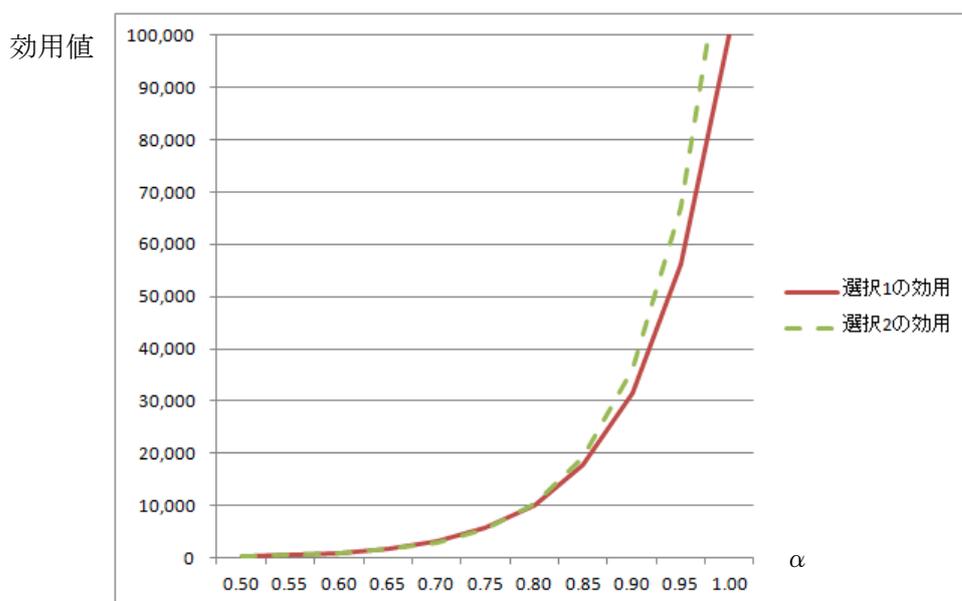


図 5-8 選択1と選択2のプロスペクト効用値

グラフより、選択肢1が選択肢2より高い効用を持つためには、 $\alpha < 0.8$ でなければならないことが分かる。本節では1つの判断のみから α の適切な範囲を求めたが、次節では、複数の判断をできるだけ多く満たすような α 、 β 、 γ の値を求める。

5.4.3 具体的なパラメータ推定

以下の様な質問票を準備する。被験者に2つの選択内容を比較してもらい、どちらがより価値のある選択肢であるかを評価し、評価欄に大小関係を記入してもらう。表5-2に α を推定するための質問票を示す。

表5-2 α を推定するための質問票

No	区分	選択1		評価	選択2	
1	1	100%	10万円もらう	<	90%	13万円もらう
2		100%	10万円もらう	<	80%	15万円もらう
3		100%	10万円もらう	<	65%	20万円もらう
4		100%	10万円もらう	>	50%	25万円もらう
5		100%	10万円もらう	>	35%	35万円もらう
6		100%	10万円もらう	>	20%	70万円もらう
7		100%	10万円もらう	>	10%	100万円もらう
8	2	100%	100万円もらう	>	90%	130万円もらう
9		100%	100万円もらう	<	80%	150万円もらう
10		100%	100万円もらう	>	65%	200万円もらう
11		100%	100万円もらう	>	50%	250万円もらう
12		100%	100万円もらう	<	35%	350万円もらう
13		100%	100万円もらう	>	20%	700万円もらう
14		100%	100万円もらう	<	10%	1000万円もらう
15	3	100%	1000万円もらう	<	90%	1300万円もらう
16		100%	1000万円もらう	>	80%	1500万円もらう
17		100%	1000万円もらう	<	65%	3000万円もらう
18		100%	1000万円もらう	>	50%	5000万円もらう
19		100%	1000万円もらう	>	35%	3500万円もらう
20		100%	1000万円もらう	>	20%	7000万円もらう
21		100%	1000万円もらう	>	10%	1億円もらう

表 5-3 に β を推定するための質問票を示す.

表 5-3 β を推定するための質問票

No	区分	選択 1		評価	選択 2	
1	1	100%	10 万円支払う	>	90%	13 万円支払う
2		100%	10 万円支払う	>	80%	15 万円支払う
3		100%	10 万円支払う	>	65%	20 万円支払う
4		100%	10 万円支払う	<	50%	25 万円支払う
5		100%	10 万円支払う	>	35%	35 万円支払う
6		100%	10 万円支払う	>	20%	70 万円支払う
7		100%	10 万円支払う	>	10%	100 万円支払う
8	2	100%	100 万円支払う	>	90%	130 万円支払う
9		100%	100 万円支払う	<	80%	150 万円支払う
10		100%	100 万円支払う	>	65%	200 万円支払う
11		100%	100 万円支払う	>	50%	250 万円支払う
12		100%	100 万円支払う	>	35%	350 万円支払う
13		100%	100 万円支払う	>	20%	700 万円支払う
14		100%	100 万円支払う	>	10%	1000 万円支払う
15	3	100%	1000 万円支払う	>	90%	1300 万円支払う
16		100%	1000 万円支払う	<	80%	1500 万円支払う
17		100%	1000 万円支払う	>	65%	3000 万円支払う
18		100%	1000 万円支払う	<	50%	5000 万円支払う
19		100%	1000 万円支払う	<	35%	3500 万円支払う
20		100%	1000 万円支払う	<	20%	7000 万円支払う
21		100%	1000 万円支払う	<	10%	1 億円支払う

λ の場合は 2 つの選択肢の効用の符号が逆の為単純に比較できない. よって, 同じ確率で 2 つの選択肢があった場合に賭けを “やる” (プラスとマイナスの効用の絶対値の差がプラス), “やらない” (プラスとマイナスの効用の絶対値の差がマイナス) で判断する. 表 5-4 に λ を推定するための質問票を示す.

表 5-4 λ を推定するための質問票

No	選択 1		評価 (賭けを)	$ v(\text{選択 1}) $ $- v(\text{選択 2}) $	選択 2	
	50%				50%	
1	50%	1000 円もらう	やらない	<	50%	500 円支払う
2	50%	3000 円もらう	やる	>	50%	1000 円支払う
3	50%	1 万円もらう	やらない	<	50%	4000 円支払う
4	50%	2 万円もらう	やらない	<	50%	7000 円支払う
5	50%	3 万円もらう	やる	>	50%	1 万円支払う
6	50%	4 万円もらう	やらない	<	50%	3 万円支払う
7	50%	8 万円もらう	やらない	<	50%	5 万円支払う
8	50%	10 万円もらう	やらない	<	50%	7 万円支払う
9	50%	15 万円もらう	やらない	<	50%	10 万円支払う
10	50%	80 万円もらう	やらない	<	50%	30 万円支払う
11	50%	150 万円もらう	やらない	<	50%	50 万円支払う
12	50%	300 万円もらう	やる	>	50%	70 万円支払う
13	50%	400 万円もらう	やる	>	50%	100 万円支払う
14	50%	500 万円もらう	やらない	<	50%	300 万円支払う
15	50%	800 万円もらう	やらない	<	50%	500 万円支払う
16	50%	2000 万円もらう	やる	>	50%	700 万円支払う
17	50%	3000 万円もらう	やらない	<	50%	1000 万円支払う
18	50%	8000 万円もらう	やらない	>	50%	3000 万円支払う
19	50%	1 億円もらう	やらない	<	50%	6000 万円支払う
20	50%	15 億万円もらう	やらない	<	50%	8000 万円支払う
21	50%	50 億万円もらう	やらない	>	50%	10 億円支払う

これを計算式に代入し解析的に解くことは困難であるため、今回は工学的な手法を用いてパラメータ (α , β , λ) を推定する。具体的な手順は以下の通りである。

(手順 1) 先ず, α , β , λ に対して比較的当てはまりそうな値を設定する。

$$\alpha = \{0.50, 0.52, 0.54, \sim 1.46, 1.48\} - 50 \text{ 通り}$$

$$\beta = \{0.50, 0.52, 0.54, \sim 1.46, 1.48\} - 50 \text{ 通り}$$

$$\lambda = \{0.5, 0.6, \sim 2.3, 2.4\} - 20 \text{ 通り}$$

(手順2) 次のそれらのパラメータの組み合わせを作る.

$$(\alpha, \beta, \lambda) = (0.50, 0.50, 0.5), (0.50, 0.50, 0.6), (0.50, 0.55, 0.5), \\ (0.55, 0.50, 0.5), (0.55, 0.55, 0.6), (0.55, 0.55, 0.7), \dots$$

50 通り × 50 通り × 20 通り = 50,000 通り

(手順3) 組み合わせのパラメータを1つずつ上記のアンケートの回答結果に当てはめ、計 63 通りでの正解率を調査する.

一番正解率の高いものを、一番妥当なパラメータの組み合わせ (回答内容を反映している) とする.

調査結果は表 5-5 の通りで $(\alpha, \beta, \lambda) = (0.66, 0.68, 1.70)$, $(0.72, 0.74, 1.80)$, $(0.72, 0.76, 1.50)$, $(0.82, 0.84, 2.00)$, $(0.82, 0.85, 1.70)$ のときに正解率 71.429% で最高となった. 図 5-9 にパラメータ α と β の分布を示す.

表 5-5 パラメータの最適値

No	α	β	λ	正解率
1	0.66	0.68	1.70	71.429%
2	0.72	0.74	1.80	71.429%
3	0.72	0.76	1.50	71.429%
4	0.82	0.84	2.00	71.429%
5	0.82	0.86	1.70	71.429%

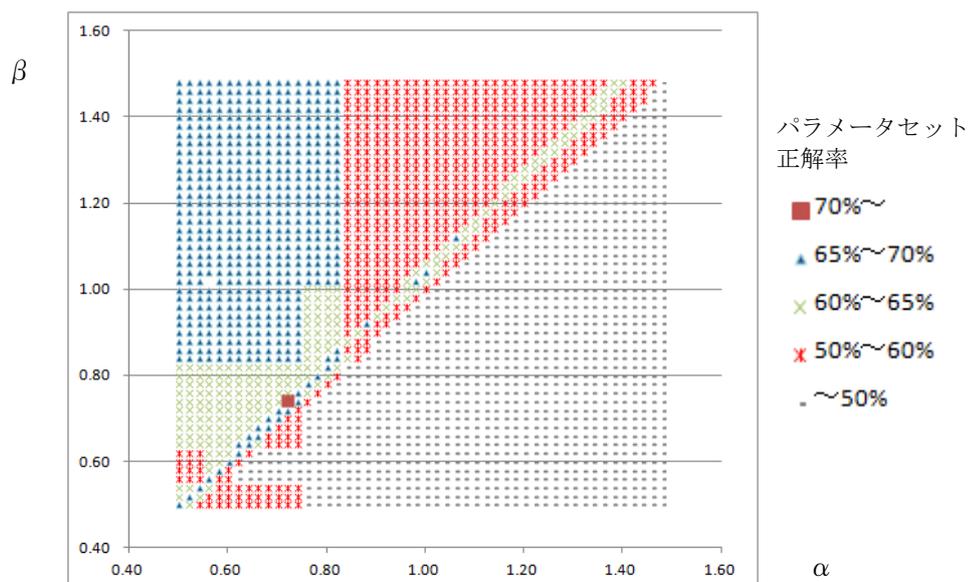


図 5-9 パラメータ α と β の分布 ($\lambda=1.80$)

図 5-10 は本研究で推定した価値関数である。

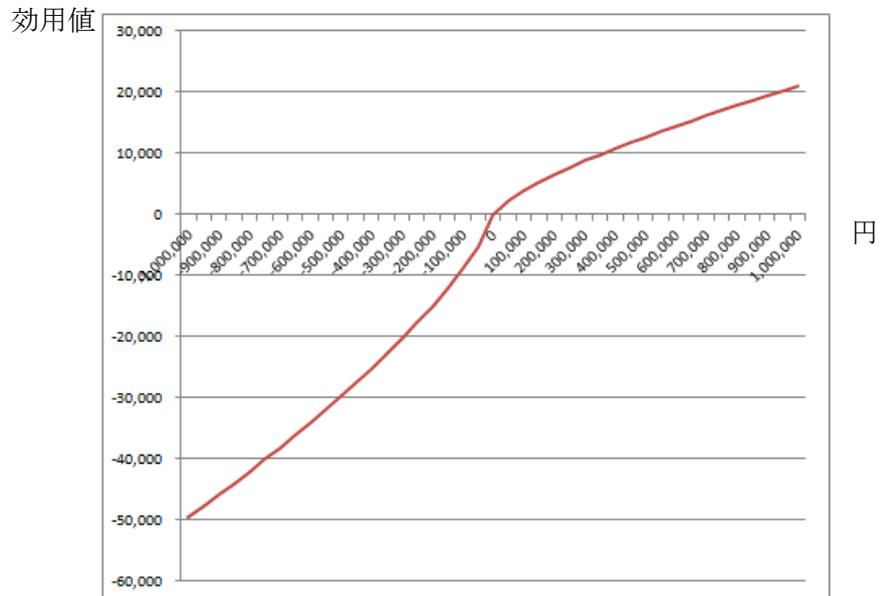


図 5-10 本研究で推定した価値関数 ($\alpha=0.72, \beta=0.74, \lambda=1.80$)

本研究で求めたパラメータ値は先行研究で求められたパラメータ値と誤差があり、且つ正解率もそれ程高くないことが見てとれる。これは、被験者の人数や対象被験者層の違いや本研究では確率加重関数を定数 1 で実験を行っていることによると考えられる。

第6章 評価実験

第5章までに本研究で使用する手法，すなわち機械学習による確率予測や効用による意思決定の方法論について述べてきた．第6章では，実際の株価データを使ってそれらの手法の性能を検証する．

6.1 検証データ(学習データ， 評価データ)

6.1.1 検証データ

検証データとしては TOPIX（東証株価指数：Tokyo Stock Price Index）を使用する．TOPIX データが比較的入手し易いことや日本の経済市場において市場予測に頻繁に引用されている指標であるからである．TOPIX とは市場の全体の動きを表す指標であり，内容は以下の通りである．

構成銘柄	東証市場一部内普通株式全銘柄（約 1,650 銘柄）
基準日	1968 年 1 月 4 日
基準値	100 ポイント
算出方法	時価総額加重型
算出元	東京証券取引所

$$\text{株式指数の値 (ポイント)} = \frac{\text{算出時点の構成銘柄の時価総額の合計}}{\text{ある過去の一定時点 (基準日) の時価総額}} \times \text{基準値} \quad (22)$$

※ 時価総額 = 株価 × 株式数

[東京証券取引所]

図 6-1 に TOPIX の 2001 年から 2010 年までの株価の時系列データを示す。

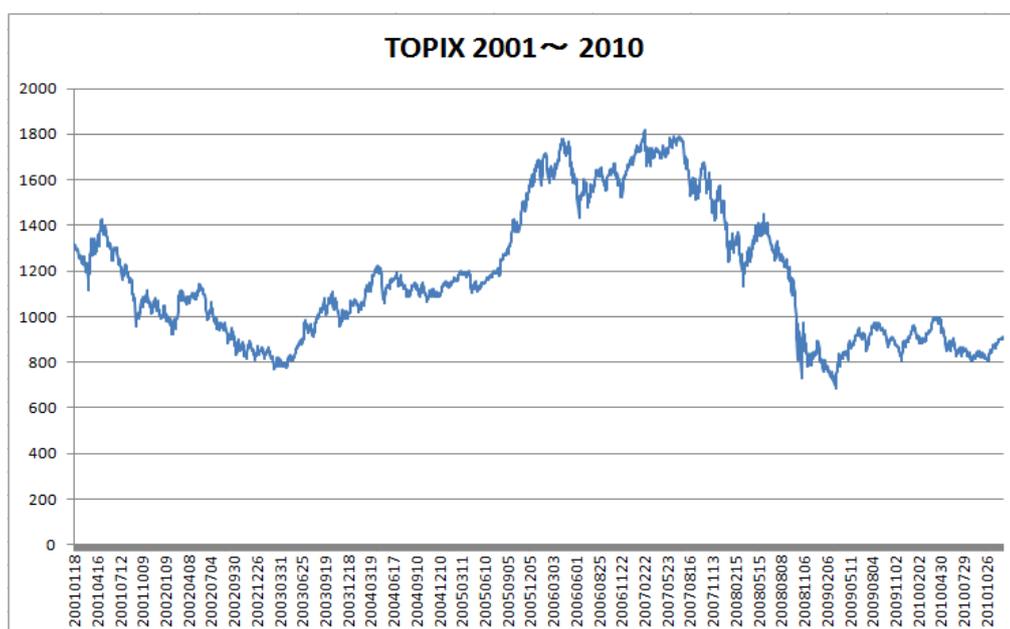


図 6-1 株価の時系列データ (2001 年~2010 年)

本研究では直近の過去 10 年のデータを検証データとして使用する。

6.1.2 株価予測手法

次に本研究での使用する予測手法の条件設定を示す。

(1) k 近傍法 (k-Nearest Neighbor)

k は 5, 20, 40, 80, 160 を使用する。また、今回の実験は学習データが約 1,000 件で特徴量も 3 次元であり、それ程内容が複雑ではないので、k の値は学習データの数%~1 割程度が適当と考える。k が小さすぎると学習サンプル数が不十分で、クラス分けに重要な要素を充分に含むことができずに評価サンプルを正しく評価できない可能性が発生してしまう。一方、k が大きすぎると本来含める必要のない要素までをも含めてしまい、ノイズが含まれ評価性能が落ちる可能性が生じる。

(2) 特徴量 (入力)

過去の株価の期間変化率を使用する。変化率は3期間モデル(3次元)を採用する。1期間目は9日前→4日前の株価変化率, 2期間目は4日前→1日前の株価変化率, 3期間目は1日前→当日の株価変化率を使用する。

(3) 距離 (類似性) の測定

近傍の評価方法はユークリッド距離を使用する。距離の算出は, 学習データと評価データの株価変化率の差の2乗を1~3期間に渡って合計したものの平方根である。

(4) 予測 (出力)

当日→翌日の株価変化率の確率分布である。

6.1.3 取引戦略

次に本研究での使用する取引戦略を示す。

(1) 予測確率平均値方式 (Average)

5.1節のアルゴリズムに基づき取引を行う。

(2) 投票方式 (Voting)

5.2節のアルゴリズムに基づき取引を行う。

(3) 効用最適化方式 (Utility Optimization)

5.3節のアルゴリズムに基づき取引を行う。

パラメータセットは以下の2つを使用する。セット1は5.4.1節の先行研究で求められたパラメータの α β λ のみを参考にしたものであり, セット2は5.4.2節で推定したものである。

パラメータセット1: $\alpha=0.88, \beta=0.88, \lambda=2.25, \gamma=1.0, \delta=1.0$

パラメータセット2: $\alpha=0.80, \beta=0.85, \lambda=1.40, \gamma=1.0, \delta=1.0$

取引は, $-1,000 \leq X \leq 1,000$ の範囲で, 効用が最大の X (取引量)で売買を行う。実際の取引としては, 売った場合には翌営業日に同じ量を買戻し, 買った場合には同じ量を売る。

6.2 交差検定 (Cross-validation)

交差検定とは、標本データを分割し一部を学習データ、それ以外の部分を評価データとして使う。学習データと評価データを部分的に変えることで、限られた標本データを使い精度の良い検証を効率良く行うことができる。

本研究では、検証に交差検定の手法を使用する。表 6-1 に今回使用する 2001 年から 2011 年までのデータ学習データと評価データの構成を示す。4 年分のデータ約 1,000 件を学習データとして使用し、翌年のデータを評価データとして使用し検証を行う。例えば、シリーズ 1 では 2001 年から 2004 年までの株価を使って学習を行い、翌年の 2005 年の株価変化率を予測する。検証では、2005 年の実際の株価変化率データと、機械学習で予測したデータを比較することで予測値の性能を評価する。これを 7 パターン作り、評価を繰り返す。

表 6-1 交差検定のデータパターン

	学習データ	評価データ
シリーズ 1	2001 年 ~ 2004 年 平均 : 1,053 分散 : 20,511	2005 年 平均 : 1,268 分散 : 23,655
シリーズ 2	2002 年 ~ 2005 年 平均 : 1,071 分散 : 28,991	2006 年 平均 : 1,626 分散 : 4,392
シリーズ 3	2003 年 ~ 2006 年 平均 : 1,234 分散 : 76,905	2007 年 平均 : 1,664 分散 : 9,865
シリーズ 4	2004 年 ~ 2007 年 平均 : 1,420 分散 : 63,808	2008 年 平均 : 1,189 分散 : 39,296
シリーズ 5	2005 年 ~ 2008 年 平均 : 1,438 分散 : 63,546	2009 年 平均 : 868 分散 : 4,444
シリーズ 6	2006 年 ~ 2009 年 平均 : 1,339 分散 : 122,325	2010 年 平均 : 884 分散 : 2,679
シリーズ 7	2007 年 ~ 2010 年 平均 : 1,152 分散 : 118,222	2011 年 平均 : 820 分散 : 5,470

上記データでは、平均が劇的に変化していることから変化値でなく変化率を見る本研究の手法の検証に有益なデータであることがわかる。また、分散も劇的に変化していることから挙動は年単位でも大きく変化しており、予測はそれほど容易ではない課題であるともいえる。

6.3 評価

6.3.1 結果の概要

表 6-2 と表 6-3 に予測確率平均値方式と投票方式による取引結果を示す。

表 6-2 予測確率平均値方式と投票方式の取引結果

投資戦略	平均値方式	投票方式
1 パターンでのトレード数	235	235
マイナス	48%	49%
ゼロ	3%	4%
プラス	49%	47%

表 6-3 予測確率平均値方式と投票方式の取引結果詳細

No	投資戦略	K	2005	2006	2007	2008	2009	2010	2011	平均
1	平均値方式	5	-90,000	48,000	899,000	-155,000	-1,206,000	-164,000	26,000	-91,714
2		20	118,000	8,000	855,000	559,000	854,000	208,000	250,000	407,429
3		40	404,000	-26,000	53,000	243,000	856,000	100,000	342,000	281,714
4		80	136,000	264,000	603,000	339,000	-838,000	56,000	134,000	99,143
5		160	378,000	236,000	235,000	-125,000	-1,176,000	60,000	-210,000	-86,000
7	投票方式	5	209,000	81,000	258,000	229,000	-66,000	-119,000	88,000	97,143
8		20	-101,000	-149,000	-132,000	653,000	-34,000	7,000	310,000	79,143
9		40	71,000	165,000	-474,000	7,000	-52,000	-187,000	314,000	-22,286
10		80	-9,000	159,000	128,000	-181,000	128,000	91,000	202,000	74,000
11		160	211,000	69,000	-48,000	-123,000	-206,000	-33,000	76,000	-34,000

表 6-4 と表 6-5 に効用最適化方式による取引結果を示す。

表 6-4 効用最適化方式の取引結果

効用パラメータ	パラメータセット 1	パラメータセット 2
1 パターンでのトレード数	235	228
マイナス	4%	7%
ゼロ	91%	85%
プラス	5%	8%

表 6-5 効用最適化方式の取引結果詳細

No	投資戦略	k	2005 年	2006 年	2007 年	2008 年	2009 年	2010 年	2011 年	平均
1	パラメータ セット 1	5	-17,000	-143,000	-1,448,000	1,155,000	-140,000	-31,000	178,000	-63,714
2		20	-10,000	0	-5,000	-21,000	31,000	13,000	-5,000	429
3		40	0	0	0	0	0	0	0	0
5	パラメータ セット 2	5	-80,400	-210,300	26,400	518,100	-193,900	-114,100	143,300	12,729
6		20	-4,400	8,500	-18,900	208,700	22,800	14,000	46,500	39,600
7		40	-2,000	0	4,000	147,000	-22,000	0	0	18,143

表 6-3 と表 6-5 より取引における利益の年率平均は $k=20$ のときに平均値方式が 40.7%, 投票方式が 9.7%, 効用方式が 4.0% となった。また, 表 6-4 より効用最適化方式の平均取引量はパラメータセット 1 で 9%, パラメータセット 2 で 17% となり取引量が余り大きくない。これは価値関数の λ が大きい場合には予測確率から導かれる効用値の合計 (重ね合わせ) が負になり取引を行わなくなる確率が大きくなるためである。(本研究では効用が負の場合は取引をしない)

6.3.2 予測確率平均値方式の詳細

図 6-2 と図 6-3 に予測確率平均値方式の取引における損益のグラフを示す。

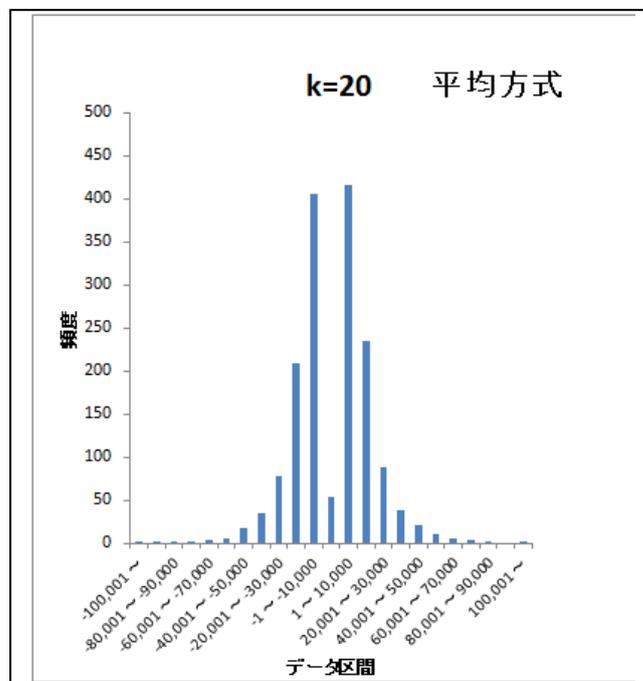


図 6-2 予測確率平均値方式での損益分布のグラフ

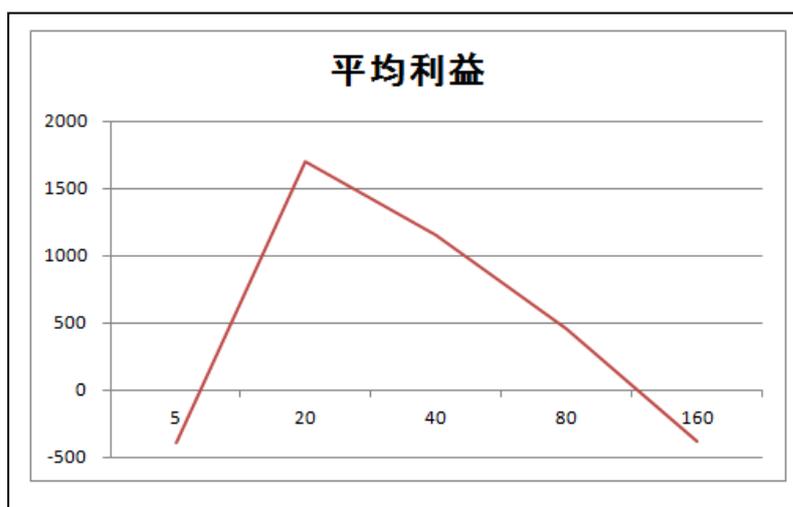


図 6-3 k 毎の予測確率平均値方式による取引の平均利益

このグラフから k 毎の予測平均値方式の平均利益を見ると k が 20 のところでピークになることがわかる。

図 6-4 に平均方式の取引における利益の推移のグラフを示す。

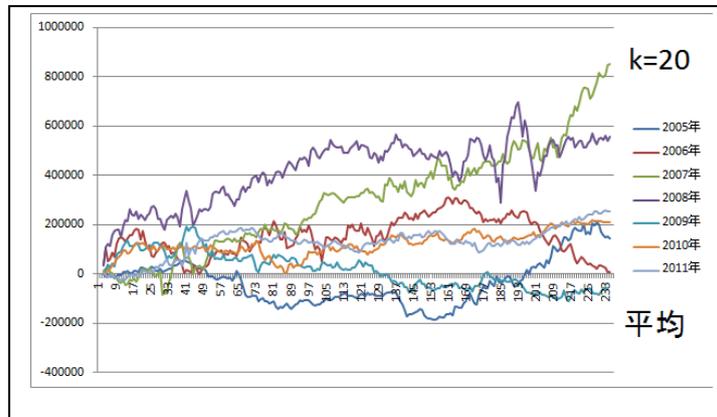


図 6-4 平均方式の取引における利益の推移

6.3.3 投票方式の詳細

図 6-5 と図 6-6 に投票方式の取引における損益のグラフを示す.

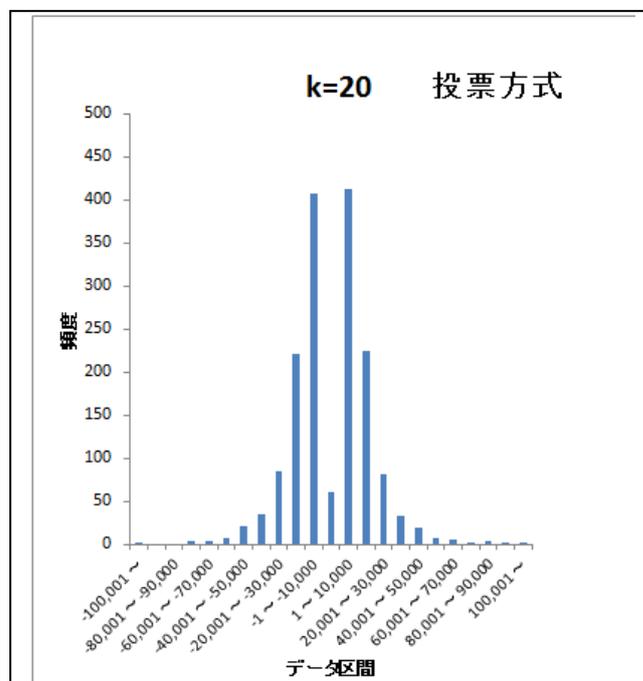


図 6-5 投票方式での損益分布のグラフ

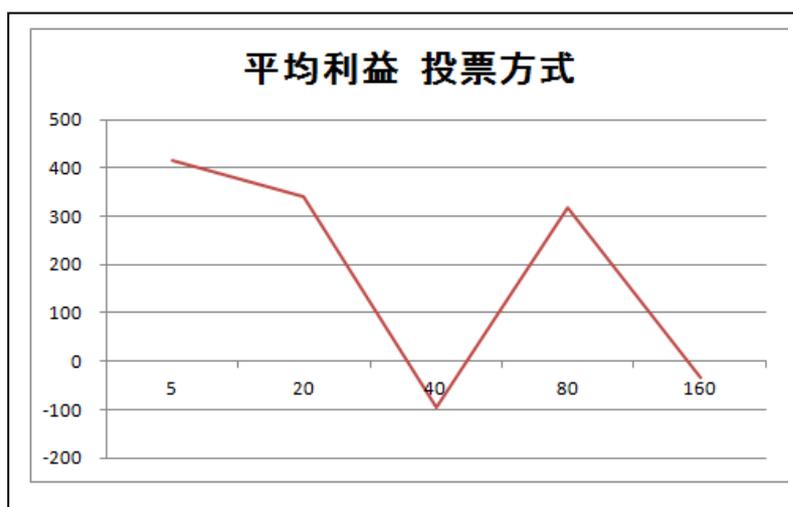


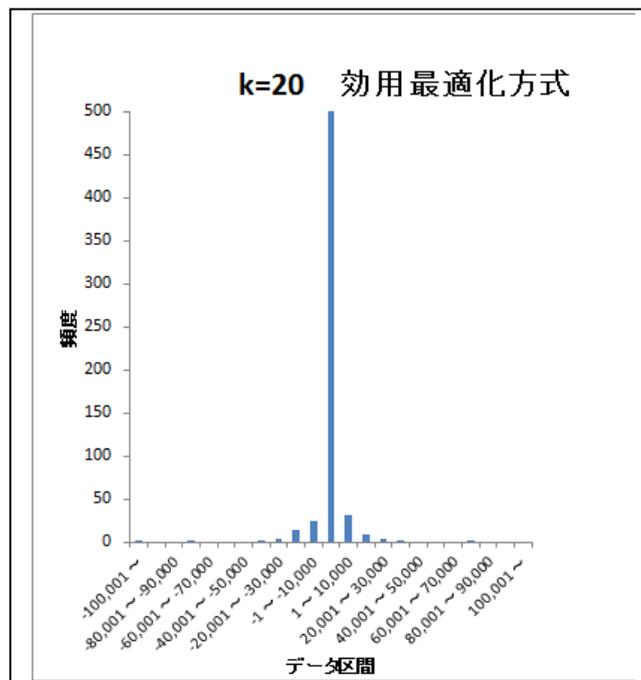
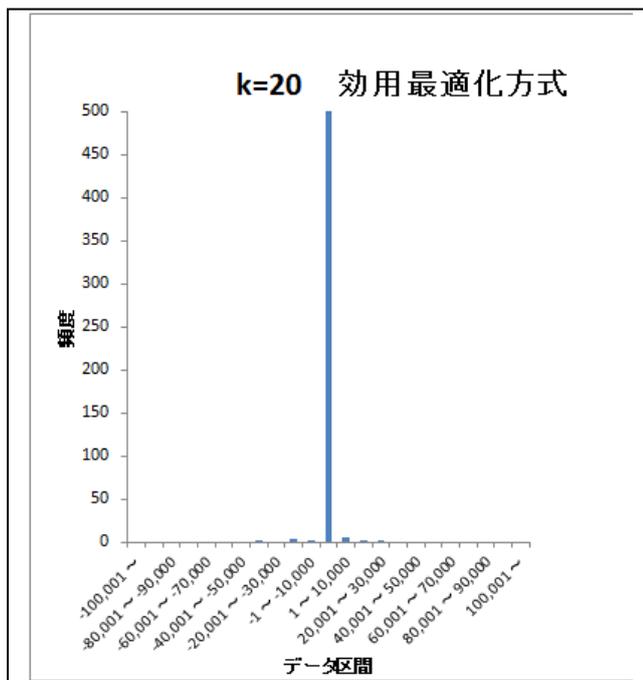
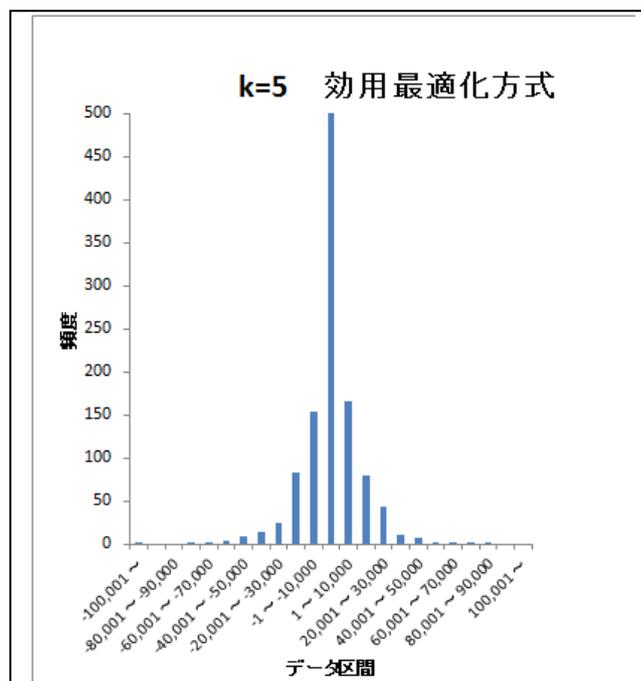
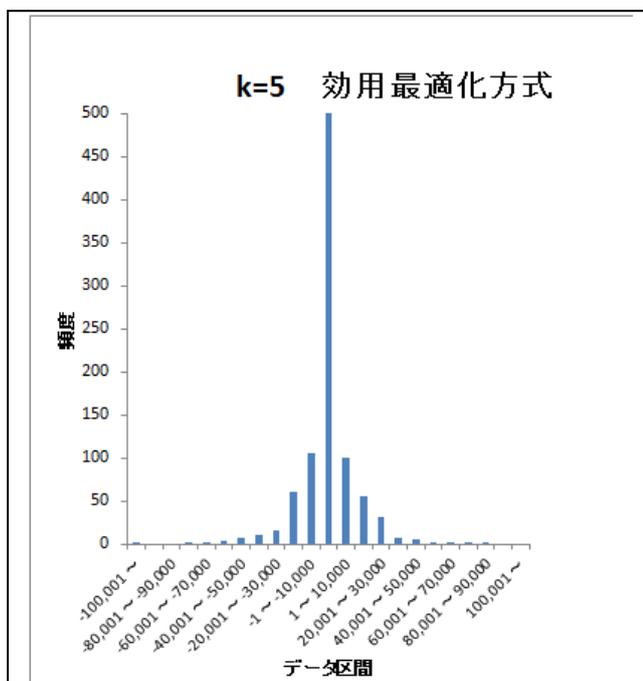
図 6-6 k 毎の投票方式による取引の平均利益

この表から k 毎の投票方式の平均利益を見ると k が 5 のところで最高で、続いて 20 の平均利益が高くなるのがわかる。

6.3.4 効用最適化方式の詳細

図 6-7 と図 6-8 に効用最適化方式の取引における損益のグラフを示す。

(左がパラメータセット 1, 右がパラメータセット 2)



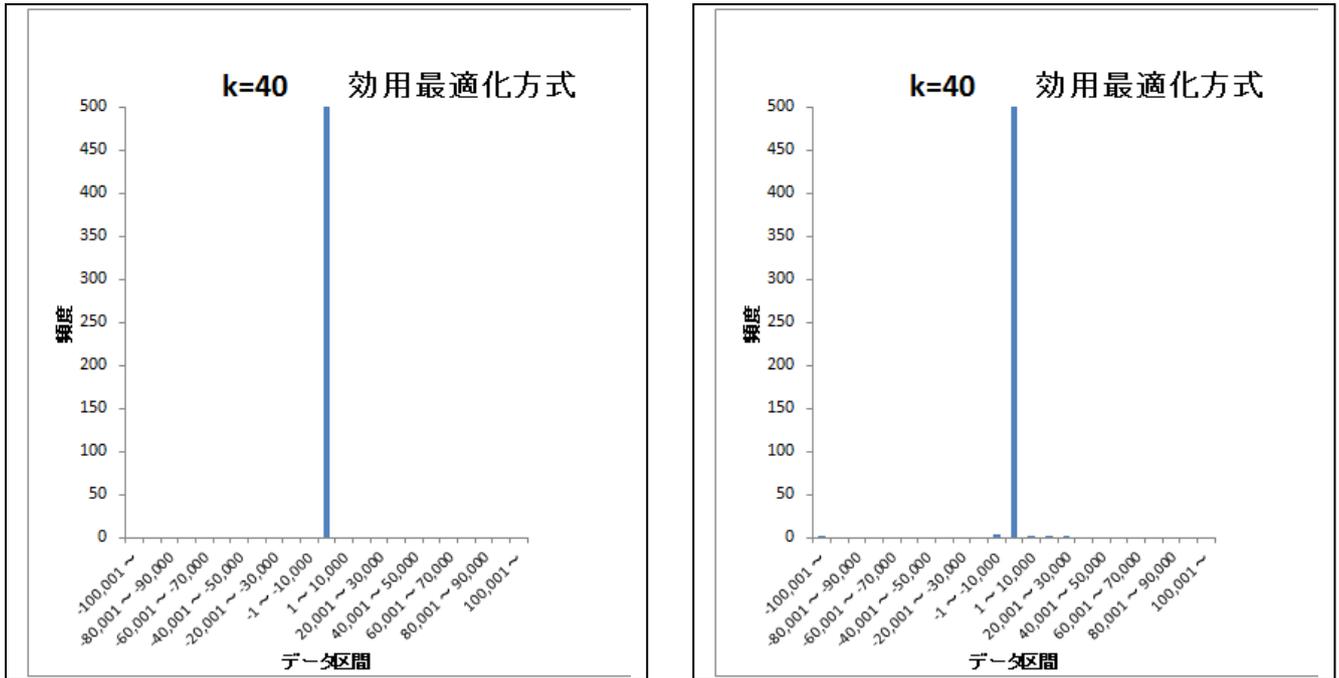


図 6-7 効用最適化方式での損益分布のグラフ

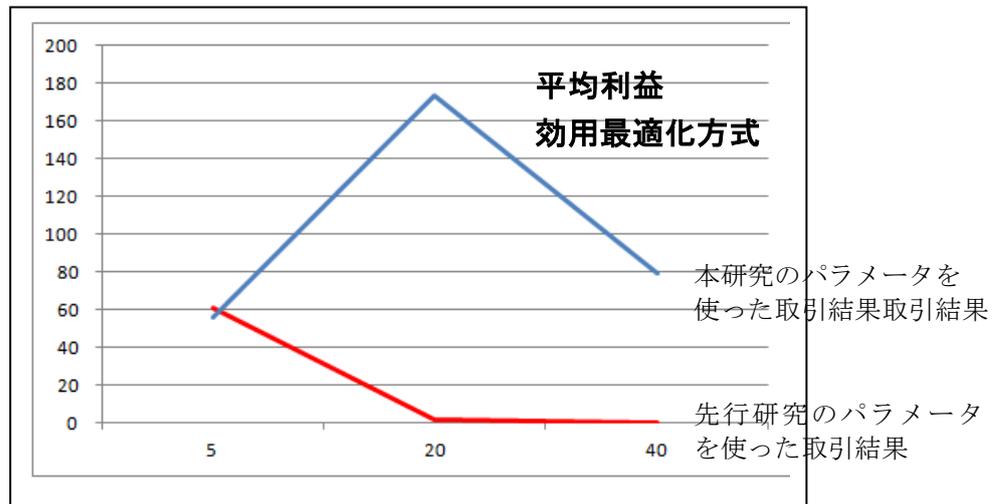


図 6-8 k 毎の効用最適化方式による取引の平均利益

この表から本研究で推定したパラメータで取引した結果は、k 毎の平均利益は k が 20 のところで最高になった。

図 6-9 に効用最適化方式の取引における利益の推移のグラフを示す。
 (左がパラメータセット 1, 右がパラメータセット 2)

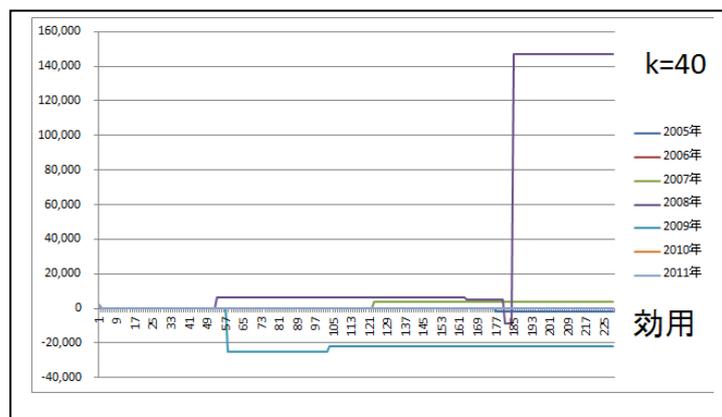
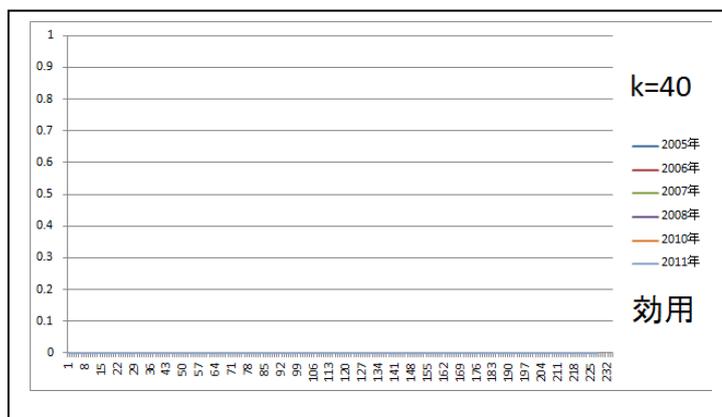
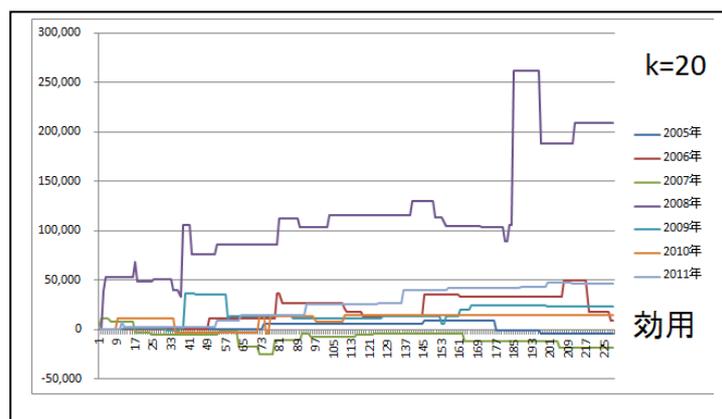
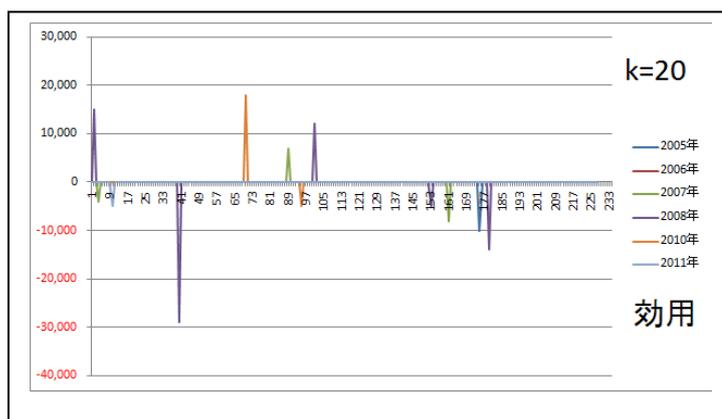
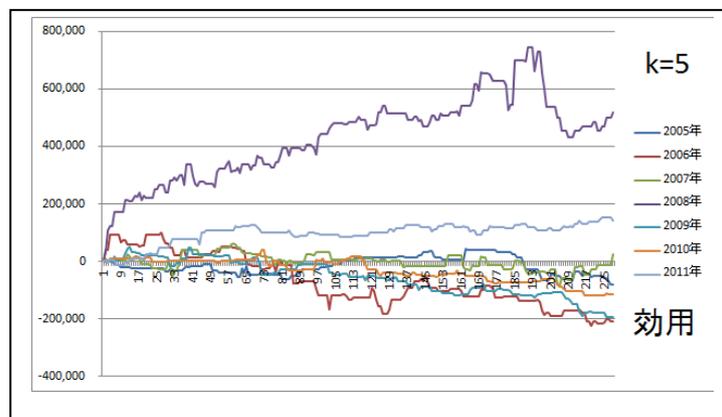
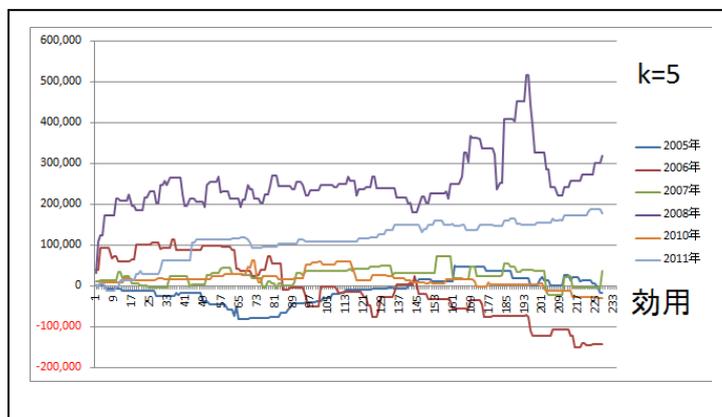


図 6-9 効用最適化方式での取引における利益の推移

表 6-6 に投資戦略における各取引結果の効用の平均値を示す。これは、取引の最終結果から効用の平均値を求めたのではなく、取引を行う毎にその損益に対して効用値を求め、取引全体で平均したものである。

表 6-6 投資戦略における各取引結果の効用の平均値 (k=20)

平均値方式	-184 (取引量 : 100)	-1,030 (取引量 : 1,000)
投票方式	-212 (取引量 : 100)	-1,184 (取引量 : 1,000)
効用最適化方式	-44 (取引量 : Max 1,000)	

この表で効用の平均値がマイナスになっているのは効用関数の形状 (損を大きく見る) によるものである。また、平均値方式と投票方式において取引量を 100 にして計算してあるのは平均利益が効用最適化方式の平均利益と同程度にすることで、利益に対しての平均効用値を比較し易くする為のものである。この結果から 3 方式の取引において、効用最適化方式での取引の効用値 (満足度) は他の既存手法 (平均値方式や投票方式) に比べて高くなることが確認できた。つまり、効用最適化方式は、平均値方式や投票方式よりも平均利益では劣ることがあるが、同じくらいの利益を見込んだ場合には、より小さいリスクで取引が行えているといえる。

第7章 考察と今後の展開

今回の試みでは機械学習（ k 近傍法）の手法を使い、過去のデータから株価の変化率を確率（分布）的に予測し、そのデータをもとに3種類の方法（予測確率平均値方式、投票方式、効用最適化方式）で投資行動を最適化する試みを行った。予測確率平均値方式、投票方式では、今回データは限定的であったが今回の手法である一定の利益を出せることを確認できた。最適化方式では価値関数を使うことで投資家の嗜好に合った取引を行う試みも行った。こちらについても限られた条件設定ではあるが投資家の嗜好に合った形で取引を行い、取引結果も価値関数のパラメータ値から予測される結果に概ね一致した取引内容になっていることも確認できた。また、今回の結果では、3方式を通じて $k=20$ の近傍で取引の利益が最大値（最適値）になることや効用最適化方式は、平均値方式や投票方式よりも小さいリスクで取引が行えることを確認できた。

今後は、データの範囲（銘柄、対象期間）を拡張することで、手法の一般的な有用性（汎化性能）を確認していくことや、今回できなかった多クラス SVM（サポートベクタマシン）を株価予測に使う試みや、強化学習、遺伝アルゴリズム（GA）等を使った最適化にもチャレンジしてみたい。

今回は時間的な制約からプロスペクト理論の確率加重平均のパラメータ（ γ , δ ）を定数1で検証を行った。今後は確率に対する人間のバイアスについても考慮したより総合的（一般的）なエージェントの挙動を確認していくことや、パラメータの設定値がどのように意思決定に影響が及ぶのか？その意思決定がもたらす結果がどのように市場に影響を及ぼすのか？についても詳細に観察することが必要である。

また、本研究では効用関数にプロスペクト理論のみを用いて、人間の非合理性に焦点を当てた投資行動の挙動や最適化を調べてきた。しかし、人間の意思決定に用いられ効用は、その状況により割合は変化するかもしれないが、本来は理性（合理性）に依存する部分と感情（非合理性）に依存する部分とが共存し、相互作用しながら意思決定に影響を及ぼしている筈である。人間の合理性と非合理性を同時に兼ね備えた意思決定（投資行動）モデルの解明や最適化という課題も残されている。

非合理的な振る舞いは社会規範や市場規範といった枠組みで説明されることがある。また最近では、行動経済学の更なる発展として神経経済学の分野の研究（脳の神経科学からのアプローチで人間の意思決定を解明しようとする試み）が盛んに行われている。新たな意思決定の枠組みや様々な最新の研究成果を取り込んでいくことでより広い知見やより深い洞察が得られることが今後期待できる。

謝辞

本研究を進めるにあたって、主指導教官の池田心准教授には日頃より懇切丁寧な御指導，たくさんの御助言を頂きました。ここに深く感謝の意を表し，御礼を申し上げます。

参考文献

- [1] 喜多一,森直樹,小野功,佐藤浩,小山友介,秋元圭人 著,人工市場で学ぶマーケットメカニズム-U-Mart 工学編-,共立出版,2009
- [2] 塩沢由典,松井啓之,谷口和久,中島義裕,小山友介 著,人工市場で学ぶマーケットメカニズム-U-Mart 経済編-,共立出版,2006
- [3] Christopher M.Bishop, Pattern Recognition and Machine Learning (Information Science and Statistics) , Springer ,2006
- [4] 元田浩,津本周作,山口高平,沼尾正行,データマイニングの基礎,オーム社,平成 18 年
- [5] Khalid Alkhatib, Hassan Najadat, Ismail Hmeidi, Mohammed K. Ali Shatnawi ,Stock Price Prediction Using K -Nearest Neighbor (k NN) Algorithm, International Journal of Business, Humanities and Technology Vol. 3 No. 3, pp.32-44; March 2013
- [6] M.V.Subaha,S.Thirupparkadal Nambi,Classification of Stock Index movement using k -Nearest Neighbours (k -NN) algorithm, Wseas Transactions on Information Science and Applications, Issue 9, Volume 9, pp.261-270, September 2012
- [7] 中田貴之,対象の値動きの方向性に着目した経済時系列予測へのサポートベクターマシンの応用に関する研究,東京大学 (修士論文) ,平成 20 年 2 月 4 日
- [8] ベイジアンネットワークの株価動向分析への応用, 人工知能学会研究会資料 SIG-FIN-004-07,pp.40-45,2010
- [9] 神原悠祐,ニューラルネットを用いることによる株価予測への有効性について,立命館大学 (卒業論文) ,平成 20 年 2 月 18 日
- [10] 上山薫,左毅,上島康孝,北栄輔,進化計算による tick 価格変動のトレンド予測,徳岡聖二, 田中美栄子, Vol. 48 No. SIG19 (TOM19) 情報処理学会論文誌 : 数理モデル化と応用 pp.68-74, Dec. 2007
- [11] 藤原健太, 伊庭斉志,進化計算手法に基づく外国為替の自動取引, 人工知能学会, 人工知能学会研究会資料 SIG-FIN-003-12,pp.89-96, 2010
- [12] Franklin Allen and Risto Karjalainen, Using Genetic Algorithms to Find Technical Trading Rules, Journal of Financial Economics 51 (1999) ,pp.245-271, October 9, 1995
- [13] Harish Subramanian, Subramanian Ramamoorthy, Peter Stone, Benjamin

- J. Kuipers, Designing safe, profitable automated stock trading agents using evolutionary algorithms, In Proceedings of the Genetic and Evolutionary Computation Conference, pp.1777-1784, July 2006.
- [14] 松井藤五郎,大和田勇人,株式取引エージェントへの強化学習の応用, The 19th Annual Conference of the Japanese Society for Artificial Intelligence, 2005
- [15] 松井藤五郎,大和田勇人,強化学習を用いた株式取引エージェントの評価, The 20th Annual Conference of the Japanese Society for Artificial Intelligence,2006
- [16] 松本光弘,福井健一,森山甲一,栗原聡,沼尾正行,U-Mart におけるQ学習エージェントの設計と評価, The 20th Annual Conference of the Japanese Society for Artificial Intelligence, 2006
- [17] 青嶋憲太郎,ファンドメンタル情報を用いる合理的取引エージェント, 東京工業大学 (修士論文) ,平成 13 年
- [18] 山重真紀夫,エージェントベース市場モデルにおける合理的取引エージェント,東京工業大学 (修士論文) ,平成 13 年
- [19] 北埜裕子, 中島智晴, 石淵久生,ファジールール抽出による先物取引エージェントの行動理解, 21st Fuzzy System Symposium Chofu, Sept.7-9,pp.201-204, 2005
- [20] 鳥海不二夫, 西村啓, 浅野千尋, 石井健一郎,株式自動取引エージェント作成支援システムの開発, 社団法人情報処理学会 研究報告 2007-ICS-147 (10) 2007/3/15,pp.67-74
- [21] Yi Feng, Ronggang Yu, Peter Stone,Two Stock-Trading Agents:Making and Technical Analysis, Agent Mediated Electronic Commerce V: Designing Mechanisms and Systems, Lecture Notes in Artificial Intelligence, pp. 18–36, Springer Verlag, 2004.
- [22] Phichhang Ou, Hengshan Wang, Prediction of Stock Market Index Movement by Ten Data Mining Technique, Modern Applied Science ISSN 1913-1844 (Print) ISSN 1913-1852 (Online), December 2009
- [23] 依田高典, 行動経済学—感情に揺れる経済心理,中公新書,2010
- [24] Kahneman, Daniel, and Amos Tversky (1979) “Prospect Theory: An Analysis of Decision under Risk”, *Econometrica*, XLVII (1979) ,pp.263-291.
- [25] 打越允哉, プロスペクト理論とポートフォリオ理論, cfee 研究発表会,2012年10月16日
- [26] 仲澤幸壽, 生産性リスク下におけるプロスペクト理論と期待効用理論の比較分析, 西南学院大学経済学論集,pp.1-23, 2009年11月
- [27] Yang-Yu Liu, Jose C. Nacher, Tomoshiro Ochiai, Mauro Martino, Yaniv Altshuler, Prospect Theory for Online Financial Trading, 26 Feb 2014
- [28] ダニエル・カーネマン,ファスト&スロー: あなたの意思はどのように決まるか?,

早川書房,2012

[29] ダン アリエリー,予想どおりに不合理:行動経済学が明かす「あなたがそれを選ぶわけ」,早川書房,2008

[30] ダン アリエリー,不合理だからすべてがうまくいく—行動経済学で「人を動かす」,早川書房,2010

[31] ダン アリエリー,ずる—嘘とごまかしの行動経済学,早川書房,2012

[32] 並河悠介,瞿菲,沈侃,北栄輔,行動ファイナンス理論に従うエージェントの市場取引への影響について, *Information Processing Society of Japan (IPSJ)*

Vol. 48No. SIG6 (TOM17) 情報処理学会論文誌:数理モデル化と応用 Mar. 2007

[33] ポール・W. グリムシャー, 神経経済学入門—不確実な状況で脳はどう意思決定するのか,生産性出版,2008

[34] 竹村和久,井出野尚,大久保重孝,松井博史,神経経済学と前頭葉,分子精神医学,Vol.8 No2,pp.35-40, 2008