

IMES DISCUSSION PAPER SERIES

フィードバック効果を考慮した動的な
マクロ・ストレステスト

清水季子

Discussion Paper No. 98-J-1

IMES

INSTITUTE FOR MONETARY AND ECONOMIC STUDIES
BANK OF JAPAN

日本銀行金融研究所

〒100-8630 東京都中央郵便局私書箱 203 号

フィードバック効果を考慮した動的なマクロ・ストレステスト

清水季子*

要 旨

本論文の目的は、市場全体が抱えるマクロのリスクを調べるための有効な手法を静的な視点のみからでなく動的な視点も踏まえて示すことにある。論文では、主に市場におけるストレスによって発生するフィードバック効果に注目し、こうした効果を勘案したマクロ・ストレステストを行うために考えられる分析の枠組みを提示することを試みる。ストレスに対する市場参加者の行動を予測するために2つの手法を採用することによって、どのようにフィードバック効果を勘案することが出来るか検討する。一つの手法は、入手可能な情報に基づいて各参加者の典型的なポートフォリオ調整行動を想定するものであり、ここでは参加者の取引戦略やロスカットルール等が勘案される。今一つの手法は、ニューラルネットワークを用いて各参加者のポートフォリオ構成に関するヒストリカルデータ、例えばリスクファクターに対する感応度情報等、から参加者のポートフォリオ調整行動のパターンを抽出するものである。こうしたフィードバック効果を考慮した動的なストレステストを行うことにより、ストレス下における市場全体のマクロのリスク状況について、一段と有用かつ鮮明な情報を入手することが可能になる。

キーワード：フィードバック効果、ストレステスト、ニューラルネットワーク

* 日本銀行金融研究所 (E-mail: tokiko.shimizu@boj.or.jp)

本論文はBISユーロカレンシー・スタンディング委員会の下で行われた日・米・英中央銀行による共同研究の一環として作成されたものである。本論文と同様な幾つかの他の論文の内容を集約して作成された報告書 *THE MEASUREMENT OF AGGREGATE MARKET RISK* および本論文を含む個別論文の英語版は1997年12月にBISより公表されており、これらについては、BISのWorld Wide Web サイト (<http://www.bis.org>) でアクセス可能である。また、報告書の邦訳については、日本銀行月報 1997年12月号に掲載されており、日本銀行ホームページ (<http://www.boj.or.jp>) にも掲載されている。論文中のシミュレーション用データの作成に当たっては、日本銀行金融研究所の吉藤氏(当時出向者として在籍、現在東京三菱銀行)に協力を頂いた。なお、論文中の意見は著者個人に属し、必ずしも日本銀行、金融研究所、もしくはBISユーロカレンシー・スタンディング委員会の見解を示すものではない。

目 次

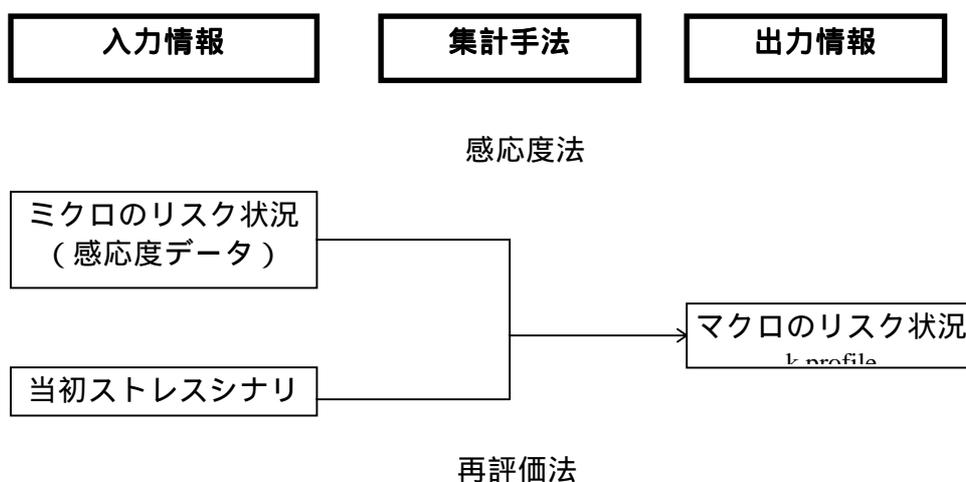
1 . はじめに.....	1
1.1. マクロ・ストレステストの枠組み.....	1
1.2. 動態的ストレステストを行うに当たって考慮すべき課題.....	2
2 . 分析の枠組み.....	3
2.1. 静態的枠組みの拡張.....	3
2.2. 多期間モデルの構築.....	4
2.3. 市場参加者の多様性の考慮.....	6
3 . 動態的なストレステストを行うことの意味.....	19
3.1. ストレステストに必要と考えられる情報.....	19
3.2. テスト結果の活用可能性.....	20
補論.....	22
参考文献.....	24

1. はじめに

1.1. マクロ・ストレステストの枠組み

マクロ・ストレステストは、市場参加者にとって市場全体のリスク・プロファイルを把握するためのツールとなるものであり、入力情報としては、中央銀行等が用意するストレスシナリオと金融機関のポートフォリオの感応度情報が挙げられる（図1）。出力情報は金融機関全体をカバーする合算されたリスク量となる。ミクロのリスク情報をマクロのリスク量に合算する方法としては、具体的に2つのアプローチが考えられる。一つの方法は「再評価法」と呼ばれ、与えられたシナリオ下で各金融機関が算出したミクロのリスク量を合算する方法である。もう一つの方法は「感応度法」と呼ばれ、金融機関毎のマーケットリスクファクターに対する感応度データを用いてマクロのリスク量を計算する方法である。

図1 ストレステストの枠組み



本研究の目的は、市場全体のリスクを調べるための有効な手法を静態的な視点のみからでなく動態的な視点も踏まえて示すことにある。論文では、主に市場におけるストレスによって発生するフィードバック効果に注目し、こうした効果を勘案したマクロストレステストを行うために考えられる分析の枠組みを提示することを試みる。以下では基本的にリスク集計手法として自由度の高い「感応度法」を用いてフィードバック効果を織り込む方法を検討する。しかしながら、当初用意されたストレスシナリオによって発生するフィードバック効果を織り込んだ結果として得られる実現ストレスシナリオを用意することにより、「再評価法」においてもフィードバック効果を取り込むことが可能となると考えられる。

1.2. 動態的ストレステストを行うに当たって考慮すべき課題

ミクロのリスク情報をマクロのリスク量に集計する際には、多くの考慮すべき要因が存在する。とくにマクロ・ストレステストを実施する際には、個別金融機関における静態的なリスク状況のみでなく、当初のストレスに対するこれらの金融機関の反応によって発生する動態的な効果も考慮する必要がある。とくに、フィードバック効果と流動性効果が鍵となる課題である。

静態的な世界においては、あるストレスシナリオ下でのI銀行の予想損失額を R_i とすれば、マクロのリスク量は $\sum R_i$ となると考えられる。しかしながら、ストレスが発生すると各金融機関のトレーダーは将来の損失を最小限に抑えるため、彼らのポートフォリオを変更したり、ポジションをヘッジしたりする。こうした反応により、当初のストレスシナリオはより拍車がかけられたり、抑制されたりすることになる。フィードバック効果とは、市場価格の変動に対するトレーダーの取引行動が市場価格に与える影響と定義され、トレーダーの取引戦略やポートフォリオ変更ニーズの結果として顕現化する。ストレス下におけるマクロのリスクの動態的な姿を把握するためには、ポジション流動化行動の市場への影響を含む流動性効果も、検討すべきもう一つの重要な課題である。

以下の章では、主としてフィードバック効果に注目し、考えられる分析の枠組みを提示するとともに、フィードバック効果を考慮した動的なマクロ・ストレステストの意味を検討する。

2. 分析の枠組み

2.1. 静態的枠組みの拡張

フィードバック効果を考慮するためには、静態的な枠組みを2つの方向に拡張する必要がある。第1の方向は時間軸である。すなわち、動的なストレステストを行うために多期間にわたる分析の枠組みを導入する。本研究の目的はミクロのリスク量の静態的集計値を求めることにあらず、多期間にわたって発生する金融機関の反応によって影響を受けるマクロのリスクプロファイルの変動を把握できるモデルを構築することにある。Glosten and Milgrom (1985) は、多期間モデルを導入することにより、マーケットインパクトの動的な特徴を分析した。

さらに、第2の拡張の方向性は、市場参加者の多様性への対応である。各市場参加者の行動は、各自のポートフォリオ構成や取引戦略により多様である。Glosten and Milgrom は、マーケットメーカー、情報トレーダー、非情報トレーダーの3種類のトレーダーを想定して、市場における価格発見機能をモデル化し、マーケットメーカーの価格決定プロセスを分析した。Genottee and Leland (1990) が提示したモデルは、市場参加者の行動の多様性を取り込んだもう一つの例である。ここでは、ポートフォリオ・インシュアランス戦略を採用しているヘッジトレーダーによる需給が考慮されている。このモデルにより、ブラックマンデーの際に起こった大規模なヘッジ行動による市場の崩壊メカニズムを再現することが可能となった。

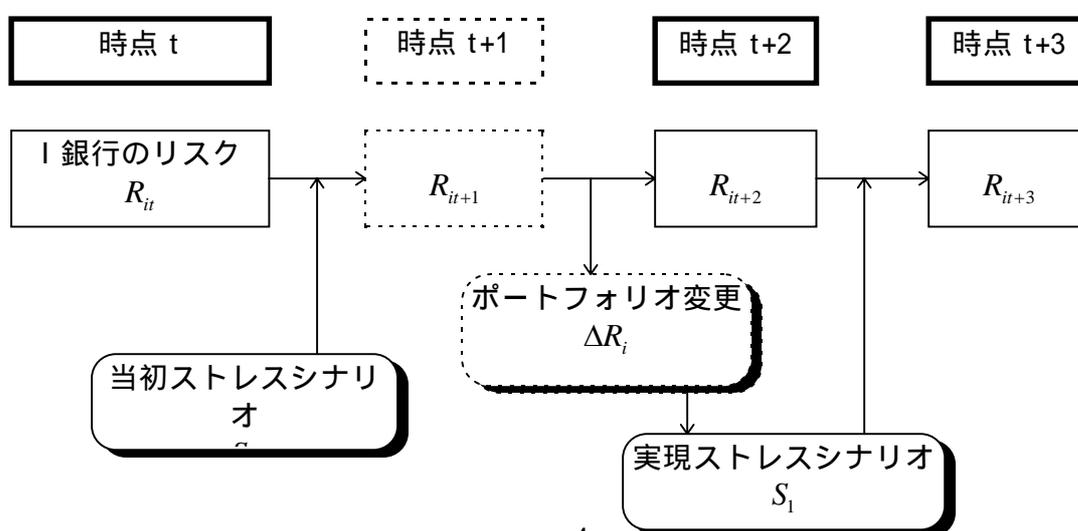
以下の章では、市場参加者の多様な行動を推定するための2つの手法を検討

する。一つの手法は、各参加者が典型的な取引戦略を採用していると仮定するものである。もう一つの手法は、市場変動と参加者のポートフォリオ・プロファイルの変化に関するヒストリカルデータから、各参加者の取引パターンを抽出するものである。

2.2. 多期間モデルの構築

本章では、フィードバック効果を取り込んだストレステストを行うために必要な多期間モデルを構築する。時点 t を初期状態として、用意されたストレスシナリオに対する I 銀行の潜在的損失額が R_t である時点 $t+1$ とする。そのショックに対して各先が反応する時点 $t+2$ 、さらに当初のストレスシナリオによって誘発されたフィードバック効果を反映したマクロリスク集計値が決定される時点 $t+3$ と考える（図 2）。感応度法を採用した場合には、 $t+2$ 時点で発生するミクロの行動に関して何らかの前提をおき、予め入手していた感応度データにこの影響を加味したうえで、 $t+3$ 時点で実現されるリスク集計値を推定することが可能となる。一方、再評価法を採用した場合には、実際に用意するシナリオを t 時点で想定したものでなく、 $t+2$ 時点で実現される市場変化を織り込んだものとするにより、フィードバック効果を考慮することが可能となる。

図 2 多期間モデルの構造



2.2.1. 多期間モデルの枠組み

まず、 t 時点の I 銀行のポートフォリオ価値を F_{it} とする。 F_{it} は t 時点のポートフォリオ構成 f_{it} とリスクファクター価格 x_t によって決定される。ここにおいて、リスクファクター価格のみならず、ポートフォリオ構成の経時的変化も考慮する必要がある。

$$F_{it} = f_{it}(x_t)$$

当初ストレスシナリオ (S_0) が与えられた場合に、 $t+1$ 時点における I 銀行のポートフォリオ価値は以下ようになる。以下では簡単のためポートフォリオを構成するリスクファクターは 1 つ (x) と考える。ただし、 t 時点から $t+1$ 時点にかけて f_{it} は一定とする。

$$S_0 = dx$$

$$F_{it+1} = f_{it+1}(x_{t+1}) = f_{it}(x_t + dx)$$

この場合の静態的リスク集計値 R_s は、以下のように表される。

$$R_s = \sum R_i = \sum dF_i = \sum \frac{\partial f_i}{\partial x} dx$$

次に、I 銀行がポートフォリオの変更を行う ($f_{it+1} \rightarrow f_{it+2}$) ことを考える。その場合、 $t+2$ 時点におけるポートフォリオ価値は以下ようになる。

$$F_{it+2} = f_{it+2}(x_t + dx)$$

さらに、当初ストレスシナリオに対するポートフォリオの変更を n 個の銀行がそれぞれに行った場合を考える。川原 (1996) は、市場参加者の取引行動がリスクファクター価格に及ぼす影響は市場全体の取引の不均衡、すなわちネットの需給の関数として表現されることを示した。

$$dx' = G \left(\sum_{i=1}^n \frac{dF_i}{x} \right)$$

最終的に得られる実現ストレスシナリオ (S_1) は、

$$S_1 = dx + dx' = dX$$

となり、フィードバック効果を考慮した動態的リスク集計値 R_d は以下のようになる。

$$\begin{aligned} R_d &= \sum (F_{it+2} - F_{it}) \\ &= \sum (f_{it+2}(x_t + dX) - f_{it}(x_t)) \quad (1) \\ &= \sum \left(\frac{\partial f_i}{\partial x} (dx + dx') + \frac{\partial f_i}{\partial t} dt \right) \end{aligned}$$

2.3. 市場参加者の多様性の考慮

2.2.で検討した多期間モデルでは、当初ストレスシナリオによって誘発される市場参加者のポートフォリオ変更行動は、各自の t 時点でのポートフォリオ構成および取引戦略等により異なる。こうした市場参加者の多様性を考慮するため、参加者のタイプに応じて上式(1)中の $\frac{\partial f_i}{\partial t} dt$ の与え方を工夫する。本章では、具体的に以下の2つの手法を検討する。

取引戦略やロスカットルール等に関する情報に基づいて各参加者の典型的なポートフォリオ変更行動を想定する手法

各参加者のリスクファクター価格の変動に対するポートフォリオ・プロファイルの変化に関するヒストリカルデータから変更行動のパターンを抽出する手法

2.3.1. 特定のポートフォリオ変更行動を想定する手法

以下では、フィードバック効果を考慮した R_t を得る簡単な事例を示す。市場には3人(種類)の参加者が存在し、それぞれ t 時点において以下のポートフォリオを保有しているとする。

エージェント1：リスクファクター x を a_t 単位保有。ただし、 $a_t = a$ (constant)

エージェント2：リスクファクター x を b_t 単位保有。ただし、 $db_t = b / x_t$ 、 b は constant。

エージェント3：リスクファクター x を c_t 単位保有。ただし、 $dc_t = c \times dx_t$ 。

ここで想定している各参加者の取引戦略はそれぞれ以下のものであるとする。

エージェント1：市場環境の変化によらず取引を行わない。

エージェント2：日々一定額 (b) の x を購入する(小口投資家向けに推奨されるいわゆる“ドルコスト平均法”と呼ばれる戦略)。

エージェント3：リスクファクター価格が上昇した翌日に上昇幅に比例してこれを買増し、下落した翌日には下落幅に比例してこれを売却(いわゆる順張り)。ポートフォリオ中にオプション取引を有し、ダイナミック・ヘッジングによるポートフォリオ・インシュアランスを行っている場合にも、外部からみるとこの戦略と同様なポートフォリオ変更行動が観測される。

以下では上記3者が存在する場合に、上で構築した多期間モデルを用いてどのように動態的リスク集計値が算出されるかを示す。 t 時点において全ての参加者は100単位の x を保有しているとする。

$$x_t = 100, \sigma_x = 0.2$$

$$S_0 = 5\sigma_x = -6.5$$

$$x_{t+1} = 93.5$$

$$F_{it} = f_{it}(x_t) = 100 \times x_t = 100 \times 100 = 10000$$

$$F_{it+1} = f_{it+1}(x_{t+1}) = 100 \times x_{t+1} = 100 \times 93.5 = 9350$$

この場合の静態的リスク集計値 R_s は以下のように表される。

$$R_s = \sum R_i = \sum dF_i = 1950$$

次に当初ストレスシナリオで想定されるリスクファクター価格の変動に対する3者の行動を考える。

$$F_{2t} = f_{2t}(x_t) = 100 \times x_t = 100 \times 100 = 10000$$

$$F_{2t+1} = f_{2t+1}(x_{t+1}) = (100 + b / x_{t+1}) \times x_{t+1} = (100 + 2000 / 93.5) \times 93.5 = 11350$$

このとき、エージェント2は予め設定した戦略に従い、 $\frac{dF_2}{x_{t+1}} = +21$ 単位の買

い取引を行うことが想定される。

$$F_{3t} = f_{3t}(x_t) = 100 \times x_t = 100 \times 100 = 10000$$

$$F_{3t+1} = f_{3t+1}(x_{t+1}) = (100 + c \times dx) \times x_{t+1} = \{100 + 5 \times (-6.5)\} \times 93.5 = 6311$$

このとき、エージェント3は戦略に従い $\frac{dF_3}{x_{t+1}} = -32.5$ 単位の売り取引を行う

ことが想定される。

こうした市場参加者の取引行動がもたらす市場価格への影響が市場全体の需給不均衡の線形関数として表されると仮定した場合、最終的に以下のような実現ストレスシナリオが得られる。

$$\begin{aligned} \frac{dx'}{x} &= G \left(\sum_{i=1}^n dF_i \right) \\ &= k(21 - 32.5) \\ &= -11.5k \end{aligned}$$

$k=0.2$ とすると、

$$S_1 = dx + dx' = -6.5 - 2.3 = -8.8$$

この場合、動的なリスク集計値 R_d は以下のようになる。

$$\begin{aligned} R_d &= \sum (F_{it+2} - F_{it}) \\ &\cong \sum F_{it+2} \left(1 - \frac{x_t}{x_{t+2}} \right) \\ &= |-880 - 1065 - 544| \\ &= 2539 \end{aligned}$$

動的なリスク集計値は静的なリスク集計値の 1.3 倍となった。この間に、市場では当初ストレスシナリオで与えられた価格下落をさらに下押し売りが観測されるだろう。こうした動的なストレステストによって得られる情報は、静的なものによって得られる情報と比較して有用性が高いといえる。ただし、得られた結果の実現可能性については十分留意する必要がある。とくに市場参加者の行動に関する前提を置く際の参考となる情報の質が重要な問題であり、この点については今後さらに研究を深める必要がある。

2.3.2. 各市場参加者のポートフォリオ変更行動のパターンを抽出する手法

本章では市場参加者の行動に関する想定をより現実的なものとするもう一つの方法を示す。ニューラルネットワーク・システムを用いることにより、ヒストリカルなリスクファクター価格のデータとそれに対応した市場参加者のポートフォリオ・プロファイルの変動に関する情報から、各主体の行動パターンを抽出することが可能となると考えられる（詳しくは補論参照）。

まず最初に、ニューラルネットワーク・システムへの入力情報および出力情報を決定する必要がある。ここでの目的はリスクファクター価格の変動に対して市場参加者が取りうる行動を予想することであるため、トレーダーの行動を決定する要因が入力情報に、また行動を示唆する指標が出力情報になる。入力情報の候補としては、以下のものが挙げられる。

t 時点における参加者のポートフォリオ構成

足許（過去一定期間）の収益動向等、参加者の経営環境を示すもの

リスクファクター価格の変動

予想しようとするポートフォリオ変更行動は、参加者のポートフォリオ構成の変化によって表される。われわれが各参加者のポートフォリオ構成のヒストリカルデータを収拾することは不可能と考えられるため、主要なリスクファクター価格の変化に対するポートフォリオの感応度の変動もしくは実現損益値をポートフォリオ変更行動の代理変数とみなさざるを得ず、これらをニューラルネットワークを用いた分析の出力変数として選択する。

ニューラルネットワークへの入力情報はニューラルネットワーク・システムの柔軟性を反映し、多様であり得る。現段階では、リスクファクター価格の変動とニュースを分析のための入力データとする。このほかの金融経済指標も入力情報の候補となると考えられ、今後とも継続してより適切な入力情報および出力情報を調べる必要がある。

特定の時期の市場データおよびトレーディング・データを用いてシミュレーションを行う。用いたトレーディングデータは、市中金融機関で債券トレーディングの経験を9年間積んだ研究所のメンバーが、ヒストリカルデータの組を見ながら擬似的に日々のトレーディングを行い、その結果を用いた。以下では、シミュレーションの詳細を説明する。

リスクファクター

シミュレーション上のリスクファクターとしては、3年物、5年物、10年物の円スワップ金利を選んだ。

シミュレーション期間

ニューラルネットワークがストレス時におけるエージェントの行動を予測することを可能にするためには、ネットワークに学習させるためのデータにストレスの起こった期間を含めることが重要である。ここでは、ストレス時を含む

期間として、1993年10月から94年3月までの期間を採用した。図3に示したように、94年の初めには円金利が急騰する局面があった。93年末にかけて円金利が大きく下落した後、94年1月14日の運用部の債券売却をきっかけにJGBの現物および先物市場は急激な売り圧力に晒された。なお、94年4月から9月までの市場およびトレーディングデータを用いた外挿シミュレーションもあわせて行った。

エージェントの特徴

シミュレーションには3人のエージェントが登場する。彼らは3年、5年、10年物JGBの取引を行う。彼らは取引量および取引の方向を彼らの取引戦略、リスクファクターに対する感応度、およびわれわれが入手可能であると想定される損益状況を基に決定する。各エージェントの取引パターンを表1に示した。そこでわれわれは、日々の金利変動、金融経済に関するニュース、彼らの実現損益、リスクファクターに対する感応度を観測する。報告される感応度データは10年物JGBのポジション相当額に変換される。各エージェントには、それぞれ独自の収益目標、ポジションリミット、およびロスカットルールが与えられている。仮に累計損失額が収益目標に達した場合には、そのエージェントはポジションを直ちにクローズしなければならないこととする。

表1 エージェントの特徴

エージェント	取引決定上 鍵となる情報	順張り/ 逆張り	その他の特徴	目標収益 ポジションリミット
1	市場変動に関するチャート情報	順張り	収益状況と取引量の間 に正の相関	30億円/半年 デルタ枠: ±1000億円
2	市場変動に関するチャート情報	逆張り	オプション取引に積極 的	30億円/半年 デルタ枠: ±1000億円
3	ファンダメンタルズに 関する情報	-	ポートフォリオ保有期 間が相対的に長い(投 資家型トレーダー)	20億円/半年 デルタ枠: ±700億円

取引対象資産：3年物、5年物、10年物日本国債

各エージェントは日々の市場変動およびニュースに反応して取引を行う。

取引は各自の収益目標およびポジションリミット、ロスカットルールの制約を受ける。

学習のための入力情報

ニューラルネットワークの予測能力の向上を図るため、以下のステップで学習するための入力情報の調整を行った。

まず、リスクファクターの日々の変化率と金利のボラティリティの組を入力情報とした。この場合、エージェント1のトレーディング・パターンを学習したニューラルネットワークの予測の正確性は71.67%の水準に止まった(図4-1参照)。

次に、各エージェントのリスクテイク意欲は累積損益額の制約を受けるため、実現損益データを学習情報に加えた。この場合のニューラルネットワークの予測力は76.67%に向上した(図4-2参照)。しかしながら、実際のトレーディング・データが示す急激な変動性を十分には追えないことも示された。

最後に、直近3日間の市場変動と金融経済関係のニュースの有無を入力情報に含めて一段の予測力の向上を図った(図4-3、図5参照)。市場変動とニュースに関するデータについてはとくに足元のデータにより高いウェイトがかかるように加工した。この調整により、ニューラルネットワークの予測力は85.42%にまで向上した。なおエージェント3については、他のエージェントよりも長い期間の市場変動を狙ってトレーディングを行っているため、さらにニューラルネットワークの予測力を向上させるためには、より長期の市場データを入力情報として加える必要がある(図6)。表2は各エージェントに関する入力情報の調整に伴うニューラルネットワークの予測力向上過程を示したものである。

表2 入力情報調整過程

入力情報	エージェント1	エージェント2	エージェント3
A: 市場データ	71.67%	82.08%	80.00%
B: A + 累積損益額	76.67	82.08	82.92
C: B + 直近の市場変動 + ニュース	85.42	87.92 (図5)	87.92
D: C + 長期トレンド			90.83 (図6)

表中の数値は事前に設定された一定のスコアと比較して予想値と実現値の差が小さいケースの比率を示す。

ある期間のエージェントの行動パターンを学習したニューラルネットワークを用いて外挿シミュレーションを行った。シミュレーション結果をみると、エージェント1およびエージェント2に関しては、サンプル外の期間でもトレーディング・パターンを追うのは比較的容易であることがわかる(図7-1、図7-2)。しかしながら、エージェント3については、ニューラルネットワークはあまりよくトレーディング傾向を追えていない(図7-3)。エージェント3についてこのような結果となった理由としては、ディーラー型のエージェントと投資家型のエージェントの間の違いが指摘できる。すなわち、最初に与えたデータ期間においては、市場のトレンドが金利の連続的な低下を示していたことから、エージェント3はほとんど全期間にわたり債券の買い方にポジションを固定していた。しかしながら、後で与えたデータ期間に入って市場のトレンドが急激に変化したため、一方向のデータでしか学習を行っていないニューラルネットワークには、トレンドが変化した期間における買い方から売り方へのポジション変更の取引を予測することが難しかったことが指摘できる。

ストレスシナリオ

対象期間中、各リスクファクターが最大の日次変化率を示した日のデータを上下両方向ともに抽出し、これらを組み合わせてストレスシナリオを作成した。図3には各リスクファクターについてストレスシナリオの構成要素に選ばれた時点を示した。3年物および10年物スワップレートについては、両方向ともに最大の変動を示したのは94年の3月であった。93年11月から翌年1月にかけての期間は、5年物スワップレートについてのストレス期間であった。

上記の変動率の大きさは図8-1から図8-3、および表3に示した。各図に示したx軸を挟む一組の平行線は期間中の標準偏差の2倍の水準の変化率を示している。

これらの数字を組み合わせて、4種類のストレスシナリオを策定した。イールドカーブの平行移動、短期ゾーンでのストレス発生、中期ゾーンでのストレス、長期ゾーンでのストレスである。各シナリオは上下両方向のものを想定した。

この結果、8通りのストレスシナリオが用意された(表4)。金利のボラティリティについては、各シナリオにおいて常に期間中の最大の変化率に相当する水準を想定した。

表3 最大変動率の大きさ

	上昇方向への変化	下降方向への変化
3年物スワップ金利	3.01	-3.43
5年物スワップ金利	2.96	-2.59
10年物スワップ金利	3.46	-2.54

: 期間中の標準偏差

表4 ストレスシナリオ

	%		
	3年物金利	5年物金利	10年物金利
t時点	3.33	3.98	4.49
シナリオ1	3.59	4.22	4.72
シナリオ2	3.05	3.78	4.33
シナリオ3	3.59	3.98	4.49
シナリオ4	3.05	3.98	4.49
シナリオ5	3.33	4.22	4.49
シナリオ6	3.33	3.78	4.49
シナリオ7	3.33	3.98	4.72
シナリオ8	3.33	3.98	4.33

フィードバック効果

シミュレーション結果をみると(表5)、イールドカーブの上昇よりも下降方向のストレスに対して、エージェントのポジションはより大きく変動していることがわかる(シナリオ2, 4, 8)。短期ゾーンへのストレス時と長期ゾーンへのストレス時では、市場全体の需給の方向は異なる。短期ゾーンに対する下向きのストレスが発生したときには、大量のJGBの売りが発生し、これは当初のストレスを相殺する方向でのフィードバック効果をもたらすといえる。

一方、長期ゾーンに対する下向きのストレスは、市場に大量の買い需要を生むため、当初のストレスを増幅させるポジティブフィードバック効果をもたらす。

フィードバック効果の大きさを決めるため、各エージェントのデルタポジションの変化を市場の総需給の変化を示す指標として認識する。期間中の日々の総需給の平均は2億円であり、その標準偏差は120億円に達する(図9)。

表5 各シナリオ下でのエージェントのデルタ変化額

	エージェント1	エージェント2	エージェント3	需給合計
シナリオ1	-80	260	-60	120
シナリオ2	-150	-90	-100	-340
シナリオ3	-30	330	-60	200
シナリオ4	-430	-30	90	-370
シナリオ5	-420	270	300	-150
シナリオ6	40	10	-40	10
シナリオ7	-40	140	-40	60
シナリオ8	210	200	310	720
標準偏差				120

平行移動シナリオ(シナリオ1, 2)

シナリオ下におけるフィードバック効果の方向については、2つのシナリオはともにネガティブフィードバックすなわち当初ストレスを相殺する方向のリアクションを発生させることが示された。イールドカーブの上昇は、エージェント2をそのポジションに比して大規模な260億円の買い行動に向かわせる。市場の総供給は、このときほぼ期間中の標準偏差に等しい120億円に過ぎず、フィードバック効果はネガティブなものになることが示された。下降方向の平行移動は大量のJGBの売りをもたらすものの、これも当初シナリオを相殺する方向でのフィードバック効果を発生させる。これらの結果は、イールドカーブの平行移動をもたらすストレスは市場全体のフィードバックの観点からみて、大きな問題はもたらさない可能性を示していると解釈できる。

短期ゾーンのシナリオ（シナリオ3、4）

シミュレーション結果をみると、イールドカーブの短期ゾーンの上昇ストレスは大量の JGB に対する買い需要を発生させる。一方、下落ストレスは逆にかなりの規模の売りを惹起する。平行移動のシナリオと同様に、短期ゾーンにおけるストレスもネガティブ・フィードバックを発生させることが示された。

中期ゾーンのシナリオ（シナリオ5、6）

他のシナリオと比較して、中期ゾーンのストレスシナリオによる影響は小さい。しかしながら、上昇ストレスに伴うフィードバック効果の方向は、ストレスを拍車するポジティブなものである。すなわち、仮に中期ゾーンのイールドカーブの上昇ストレスに直面した場合には、長期金利（10年物 JGB の価格）は、ストレスの結果さらに上昇する（下落する）と予想される。

長期ゾーンのシナリオ（シナリオ7、8）

下落方向のストレスの方が、上昇方向のそれよりも深刻な影響をおよぼす。長期金利の下落は大量の JGB に対する買い需要を惹起し、これはシナリオに対するポジティブ・フィードバックの発生を意味している。

エージェントのリスク状況

JGB 価格に対するフィードバック効果の影響の大きさは、ストレスに対するエージェントの反応によって顕現化する市場全体の需給によって決まると仮定する。仮に以下に示すように市場価格の変化率が総需給量の線形関数で表わされるとすると、フィードバック効果によって各エージェントが被る損失額を推計することが可能となる。各エージェントのリスク状況を推計したものが表6である。エージェントの損失規模は、フィードバック効果による追加的な市場価格の変動とフィードバック取引直後のデルタポジションによって決定される。フィードバック効果によって生ずる推計損失額の決定方法に関しては、今後の

更なる検討が必要と考えられ、とくにフィードバック取引を行ったことに伴う潜在的な損益を考慮するかどうかという点は問題となろう。

$$\Delta P = \alpha \sigma_p \cdot \beta$$

ΔP : JGB 価格の変化率

α : 市場全体の需給/期間中の市場全体の需給の標準偏差

σ_p : 期間中の JGB 価格の変化の標準偏差

β : 市場の需給状況による価格変化率 (シミュレーションでは 1 と仮定)

表 6 エージェントのリスク状況

	億円			
	エージェント 1	エージェント 2	エージェント 3	合計
シナリオ 1	2.0	0.9	-0.3	2.6
シナリオ 2	-5.1	1.8	1.3	-2.8
シナリオ 3	4.5	2.5	-0.5	6.5
シナリオ 4	-1.6	1.0	-1.2	-1.8
シナリオ 5	0.8	1.3	1.8	3.9
シナリオ 6	0.4	-0.0	-0.0	0.3
シナリオ 7	1.1	0.2	-0.1	1.3
シナリオ 8	19.8	4.0	8.0	31.8
VaR (t)	5.8	0.5	2.2*	

* エージェント 3 の t 時点のポジションは 0 のため、VaR 値は t-1 時点もの。

8つのシナリオのうちシナリオ 2、下方向への平行移動型のストレスは、マクロ的なリスク水準との関係では最も深刻なフィードバック効果を生じさせる。シミュレーション結果によれば、ストレスの直前すなわち t 時点において、各エージェントはすべてバリュー・アット・リスクを超えるようなリスクに直面していないため、どのシナリオも深刻なフィードバック効果をもたらす可能性は低いといえる。本章で示したように、シミュレーション結果を分析することにより、どのような種類のストレスが深刻なフィードバック効果をもたらすか、またその中でこういったタイプのエージェントが重要な役割を果たすかという問題を調べるのが可能となる。

さらに、ニューラルネットワークの出力値をデルタの変化の大きさおよび方向性に分解することにより、予測力の改善を行った。エージェントがデルタを増加させるのか減少させるのかという点に関する予測は、フィードバック効果の方向を推定する際に重要である。また、取引量に関する予想もフィードバック効果のマグニチュードを把握する際に不可欠である。出力情報を分解することにより、フィードバック効果に関するより正確な近似が可能となる。現時点における暫定的なシミュレーションによれば、こうした改善により各エージェントの取引方向や量について予測力が向上するという結果が得られている。図 10 - 1 は取引の方向に関する予測結果を示している。ここではエージェントがデルタを増加（減少）させるとパラメータは 0.5（-0.5）を示す。ニューラルネットワークは 120 データのうち 2 回だけエージェントの取引方向を予測できなかった。図 10 - 2 は取引量に関する予測結果を示している。図 10 - 3 は出力値を分解しない、すなわちデルタ値そのものを予測させた場合の結果を示しており、これと比較すると分解した場合の予測誤差は 78 から 44 に減少している。

また、ストレスシナリオを変化させた場合の効果についても調べた。本章で示したように、ここで用意したストレスシナリオはマクロのリスク状況に深刻な影響は及ぼさないことがわかった。そこで、イールドカーブの変化だけではなくニュースの有無も含んだストレスを想定したストレス・シミュレーションを実施した。暫定的な結論としては、エージェントがストレスに直面した際に、これを増幅させるようなニュースも併せて受け取った場合には、ニュースが存在しない場合と比べてフィードバック効果が拡大するとの結果が得られている。

3. 動的なストレステストから得られるインプリケーション

3.1. ストレステストに必要と考えられる情報

再評価法を採用する場合には、各金融機関は用意されたシナリオに対する予想損失額を報告する。一方、感応度法を採用する場合には、各金融機関はリスクファクターに対する感応度情報を報告する。

しかしながら、本稿で検討したような動的なマクロストレステストを行うためには、いずれの方法を採用するにしても、各参加者の感応度情報を入手する必要がある。再評価法においても、最終的に実現するシナリオを構築するためには、参加者の当初ストレスに対するリアクションを予想するための情報が必要となるためである。

さらに、2.3.2.で指摘したように、ヒストリカル・データから市場参加者のポートフォリオ変更行動を予測する手法を採用する場合には、ニューラルネットワークに学習させるためのヒストリカルなリスクプロファイル情報を入手することが必要となる。より効果的に彼らの取引行動を予測させるためにどのような入力情報が候補となるかという点については、今後とも検討を行うことが求められる。例えば感応度情報よりも入手しやすいと考えられる実現損益に関するヒストリカルデータをシミュレーションの出力情報とすることもあり得よう。

ここで挙げたデータ群、例えば日々の感応度や実現損益に関するデータの入手可能性については、現時点で広範囲の市場参加者から徴求することは難しいと言わざるを得ない。しかしながら、これらの情報は金融機関の内部リスク管理上の基礎的情報であるため、近い将来においては、市場業務を活発に行う金融機関においては日常的なリスク管理のツールとしてより頻繁に活用されることが期待される。

3.2. テスト結果の活用可能性

ストレステストの結果として得られる情報は、各段階において採用したアプローチ、すなわち再評価法か感応度法か、ニューラルネットワークを用いるかどうかにより異なる。静態的なテストと動態的なテストを行った場合に得られる情報は、以下のように整理されると考えられる。

静態的ストレステスト：当初ストレスシナリオと静態的なリスク集計値

動態的ストレステスト：当初ストレスシナリオ、静態的リスク集計値、各金融機関の当初ストレスに対する反応、最終的に実現するストレスシナリオ、動態的リスク集計値

再評価法と感応度法の違いは、リスク集計値を計算する場合に用いるシナリオに関する自由度にある。また、エージェントの行動を予測する手法として何を採用するかは、テスト結果の情報の内容に影響を及ぼす。本稿で示した2つの方法を比較した場合、人工知能を用いて各参加者の行動パターンをヒストリカルデータから学習し予測する手法の方がより現実的なテスト結果を与えられとされる。

ストレステストの結果がどのように使われるかという点には重大な注意を払う必要がある。フィードバック効果を考慮した動態的なストレステストは、ストレス下におけるマクロのリスク状況についてより有用かつ具体的な情報を与えられとされる。上述したような情報がストレステストの結果として得られた場合には、ストレスに対してより効率的かつ効果的な対応を準備することが可能となる。当初のストレスへの反応としてほとんどの金融機関から売りがでることが予想されるという情報が得られた場合には、市場の反応について全く情報がない場合に比べて確実な対応が可能とされる。例えば、本稿のシミュレーション結果でも示したように、仮にイールドカーブの上昇方向の平行移動はポジティブ・フィードバックを惹起する確率が非常に高く、他のシナリオに比してシステミックリスクのトリガーとなる可能性が高い場合には、日々市場をモニタリングする際にこうした方向へのイールドカーブの変化によ

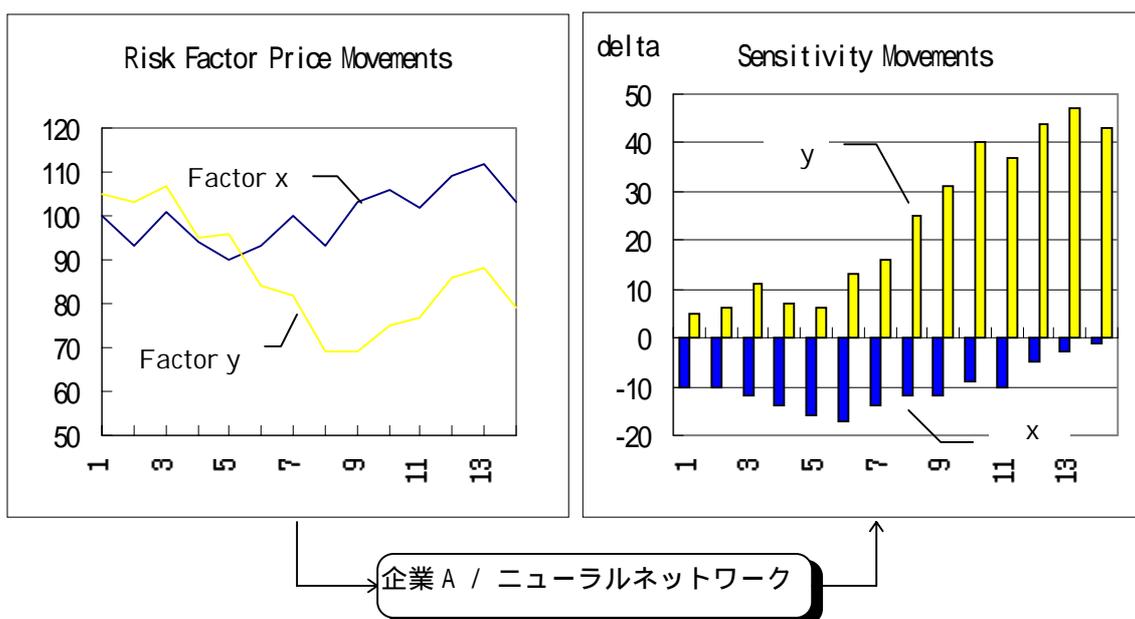
り注意を払うことが求められよう。一方で、短期ゾーンにおけるストレスに伴うネガティブ・フィードバックの発生可能性は、短期金利にクラッシュが発生した場合に、われわれが市場への流動性供給等の必要な対策を講ずるための政策決定を行う際に、相対的に余裕を与えてくれることになるといえる。

さらに、本稿で示したストレステストの時点を拡張することにより、金融システムおよび取引システムの枠組みを検討する上で有用なインプリケーションが得られる。例えば、システミックリスクの観点からみて、どのような状況においてサーキットブレーカー・システムがうまく機能するのかどうかといった点についての検討を行うことができる。本稿で用いたモデルは、これを用いて均衡価格が消滅してしまうケースを調べたり、時点の拡張を行うことにより、市場におけるシステミックな市場崩壊を再現するツールとなると期待される。

補論

ニューラルネットワークを用いたマクロダイナミックシミュレーション

1. 企業の行動パターンに関する情報の生成



$$X_t = (x_t, y_t)$$

t 時点における企業のポートフォリオ価値

$$f_t(X_t) \quad \text{Sensitivity data at } t : \frac{\partial f_t(X_t)}{\partial x}, \frac{\partial f_t(X_t)}{\partial y}, \dots$$

t+1 時点における企業のポートフォリオ価値

$$f_{t+1}(X_{t+1}) \quad \frac{\partial f_{t+1}(X_{t+1})}{\partial x}, \frac{\partial f_{t+1}(X_{t+1})}{\partial y}, \dots$$

仮に日次の企業の感応度情報とリスクファクター価格の変動情報を持っていれば、各企業が市場変動に対応してどのようなポートフォリオの変更を行うか推定することができる。日々の企業の感応度情報の変化は以下の要因で発生する。

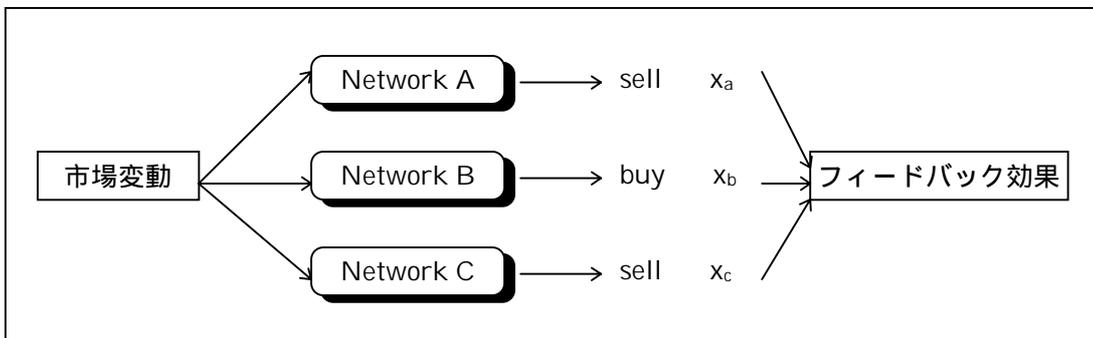
$$\text{a) リスクファクター価格の変動} \quad \frac{\partial f_t(X_t)}{\partial x} \quad \frac{\partial f_t(X_{t+1})}{\partial x}$$

$$\text{b) ポートフォリオの変更} \quad \frac{\partial f_t(X_{t+1})}{\partial x} \quad \frac{\partial f_{t+1}(X_{t+1})}{\partial x}$$

感応度情報の変化からリスクファクター価格の変動要因を除去することができれば、企業のポートフォリオ変更に関する情報を入手することが可能になる。 f_t f_{t+1}

ニューラルネットワークは非線形的な変動パターンを学習することができるため、これを用いることにより、疑似企業を作ることができる。具体的には日次の企業の感応度情報とリスクファクター価格の変動情報を基に対応する企業のポートフォリオ変更行動をネットワークに学習させる。

2. 企業のポートフォリオ変更行動に伴うフィードバック効果のシミュレーション



各企業のポートフォリオ変更行動のパターンを学習したニューラルネットワークは、シミュレーションにおいて疑似企業としての役割を果たす。すなわち、リスクファクターの変動に関する初期値を与えてやると、ネットワークは対象資産をどれだけ売るのか買うのかという判断を学習したパターンに従って判断する。彼らの取引注文が集約され、疑似市場において新たな均衡価格が発見される。仮に新しい均衡価格と初期値との変動率が与えた初期変動を下回る / 上回る場合には、市場でネガティブ / ポジティブフィードバックが生じたと認識可能。さらに、これら疑似市場モデルを使うことにより、企業に報告負担を課すことなくフィードバック効果を考慮した価格変動を再現することが可能となる。

参考文献

川原淳次、「市場価格の信頼性と価格インパクト」、日本金融学会

Camargo, F. A., “Learning Algorithms in neural Networks,” *Working Paper*, the DOC Laboratory, Computer Science Department, Columbia University, 1990.

Glosten, L., and P. Milgrom, “Bid, Ask, and Transaction Prices in a Specialist Market with Heterogeneously Informed Traders,” *Journal of Financial Economics*, 13, 1985, pp.71-100.

Gennottee, G., and H. Leland, “Market Liquidity, Hedges and Crashes,” *American Economic Review*, 80, 1990, pp.999-1021.

O’hara, M., *Market Microstructure Theory*, Blackwell Publishers.

Shimizu, Tokiko, and Tsukasa Yamashita, “Dynamic Micro and Macro Stress Simulation,” *Discussion Paper Series*, 96-E-4, IMES, Bank of Japan

Figure 3

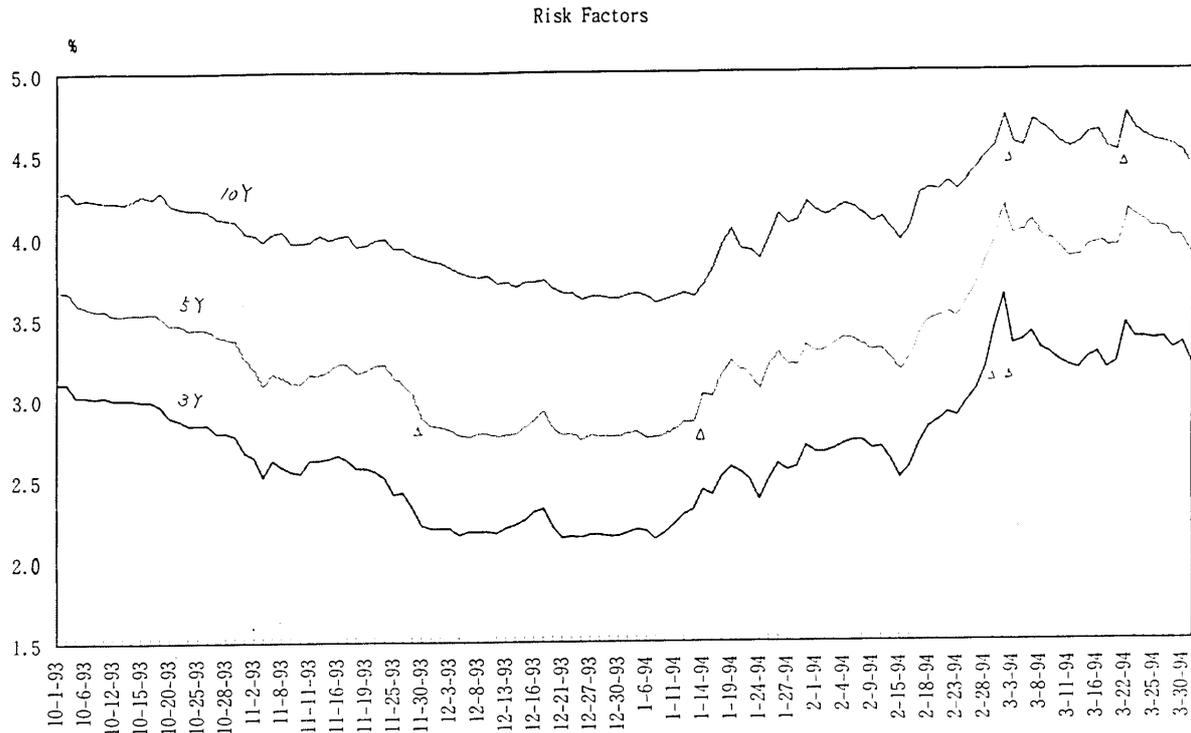


Figure 4-1

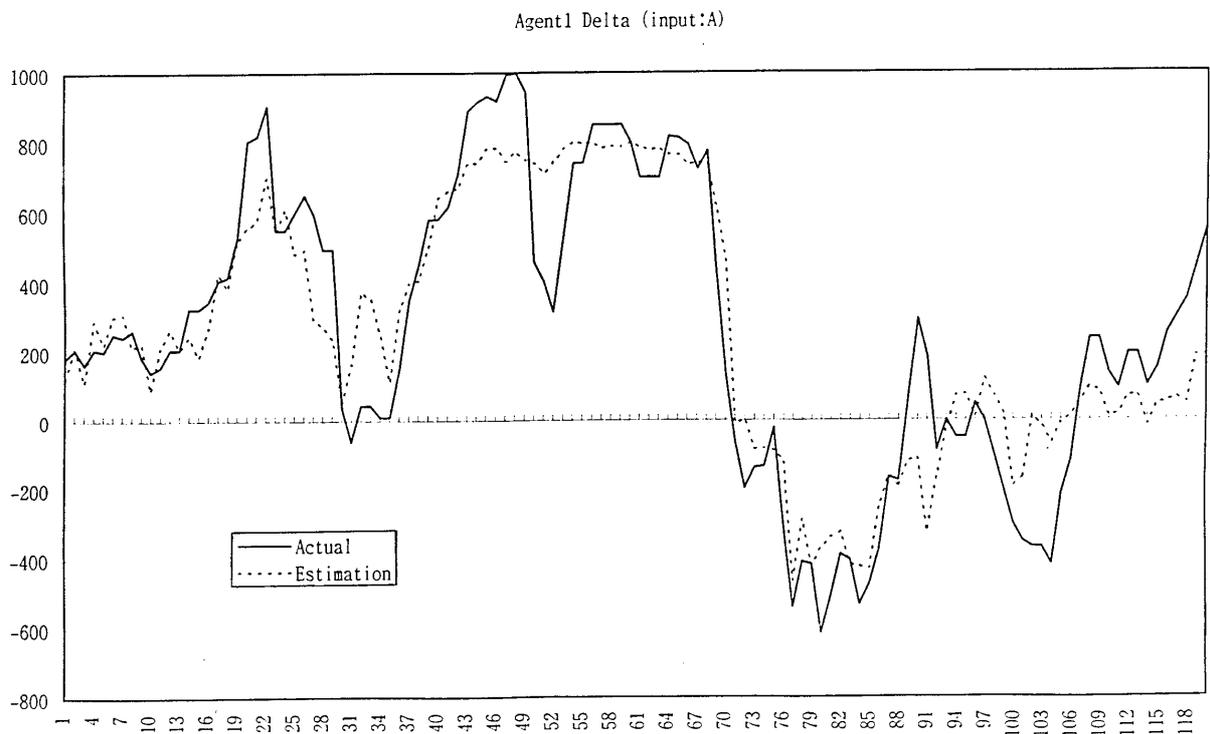


Figure 4-2

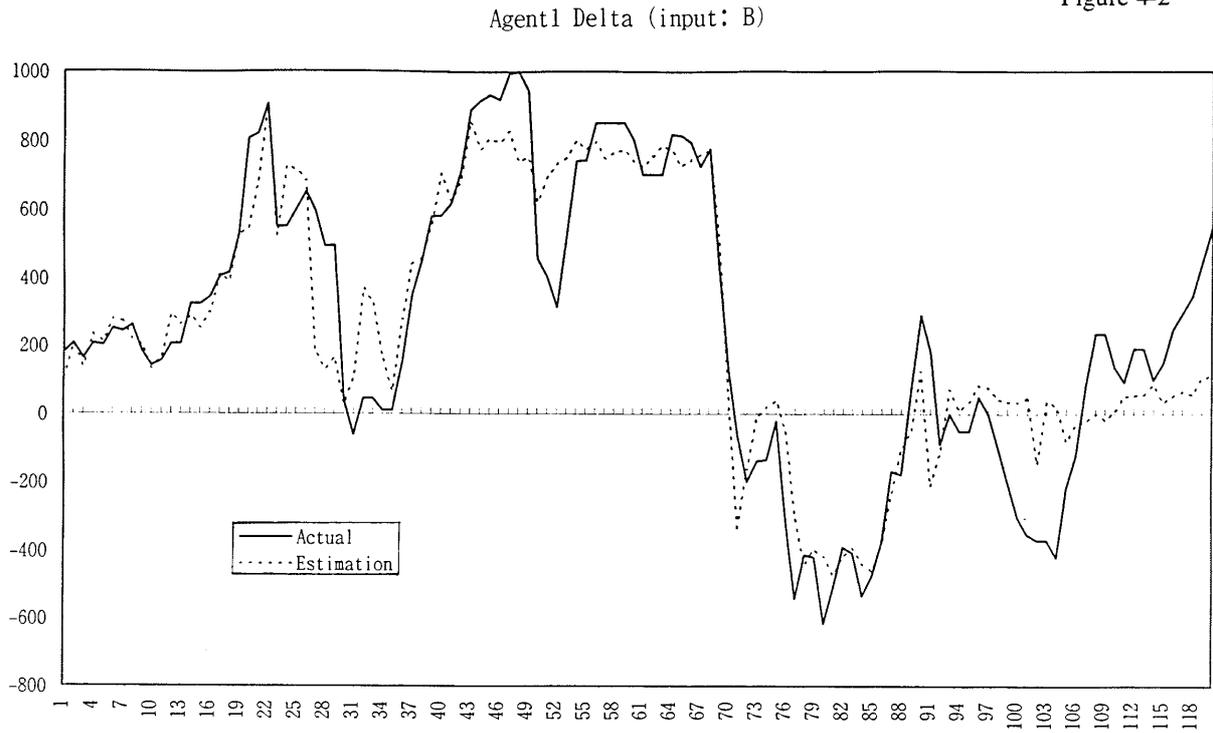


Figure 4-3

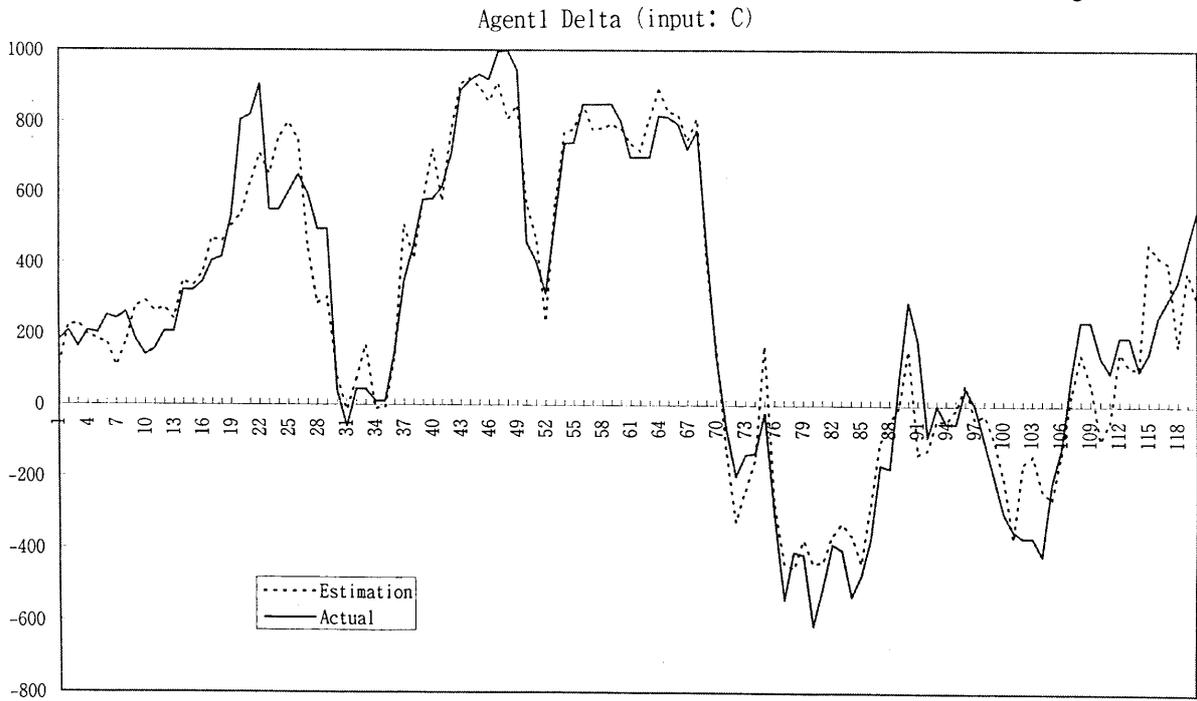


Figure 5

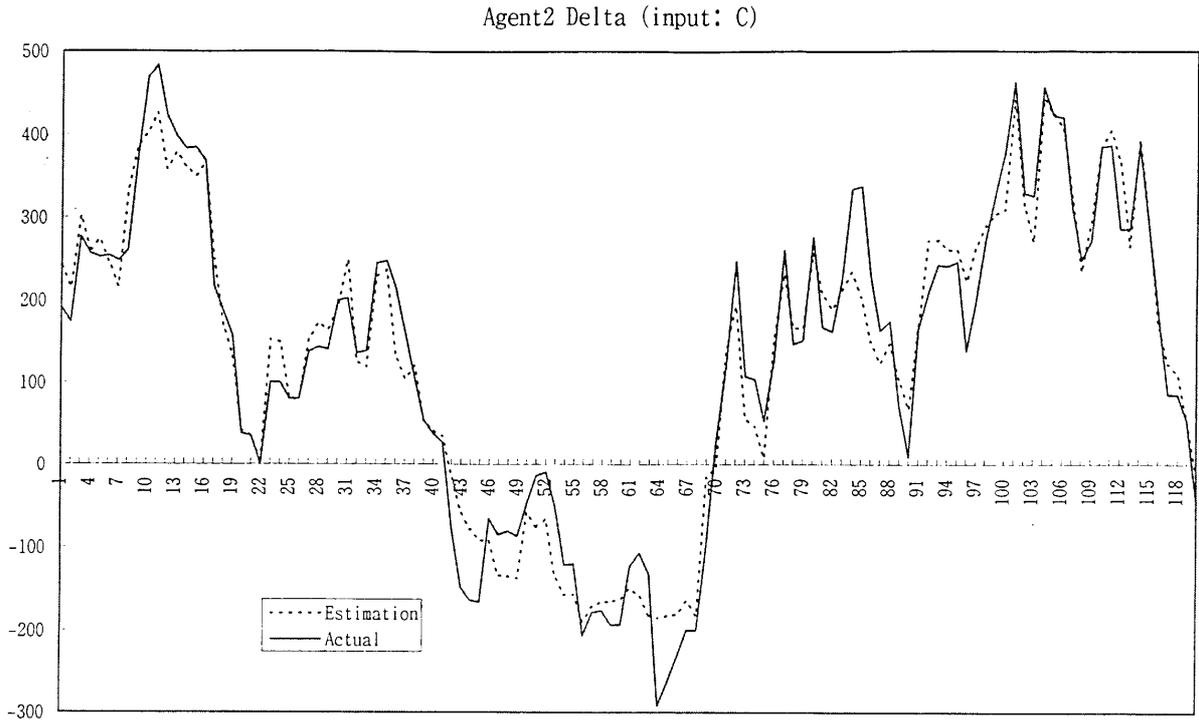


Figure 6

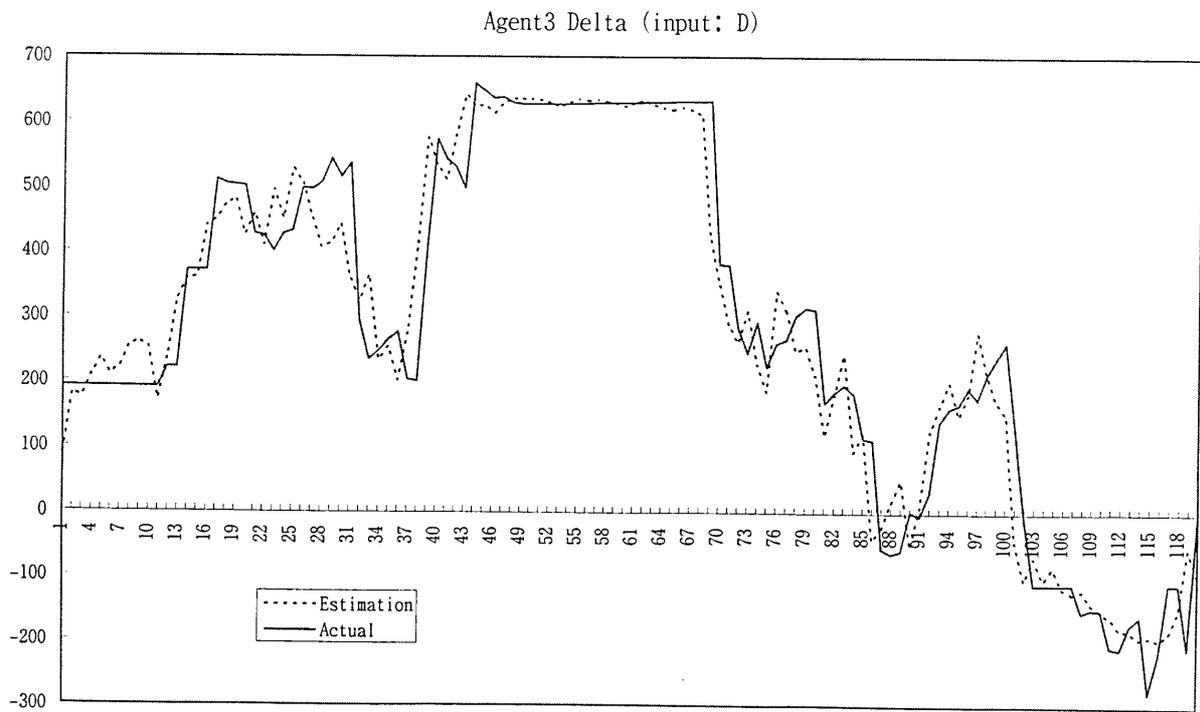


Figure 7-1

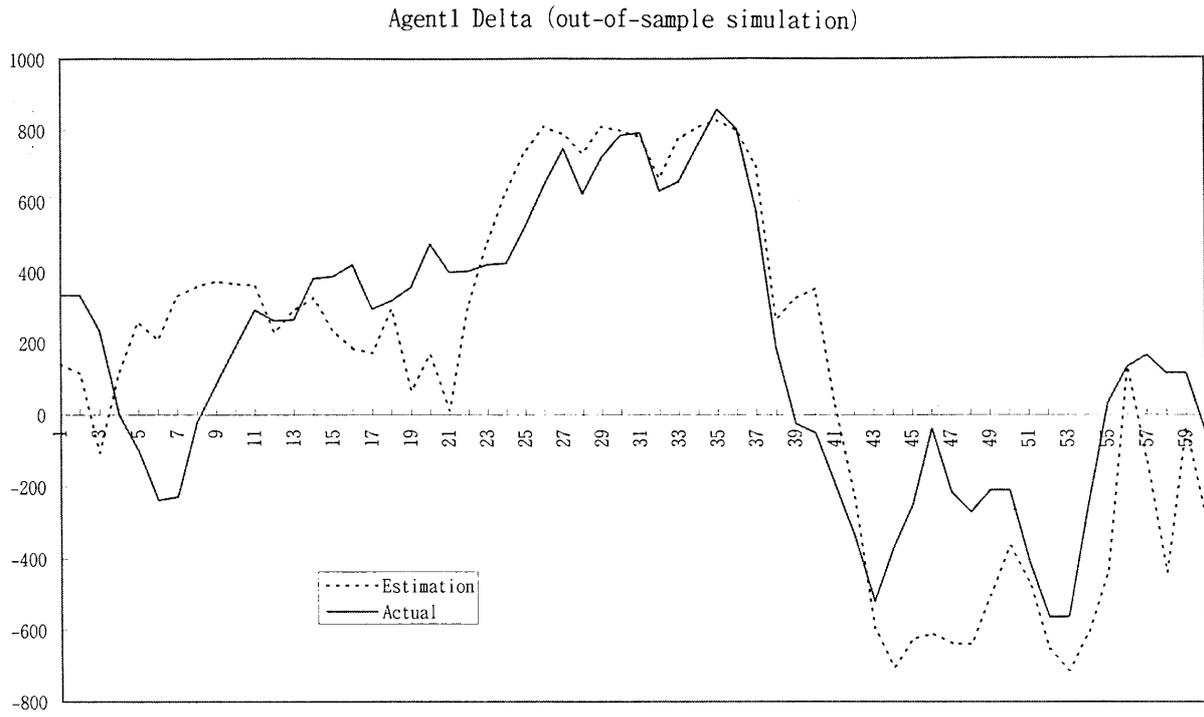


Figure 7-2

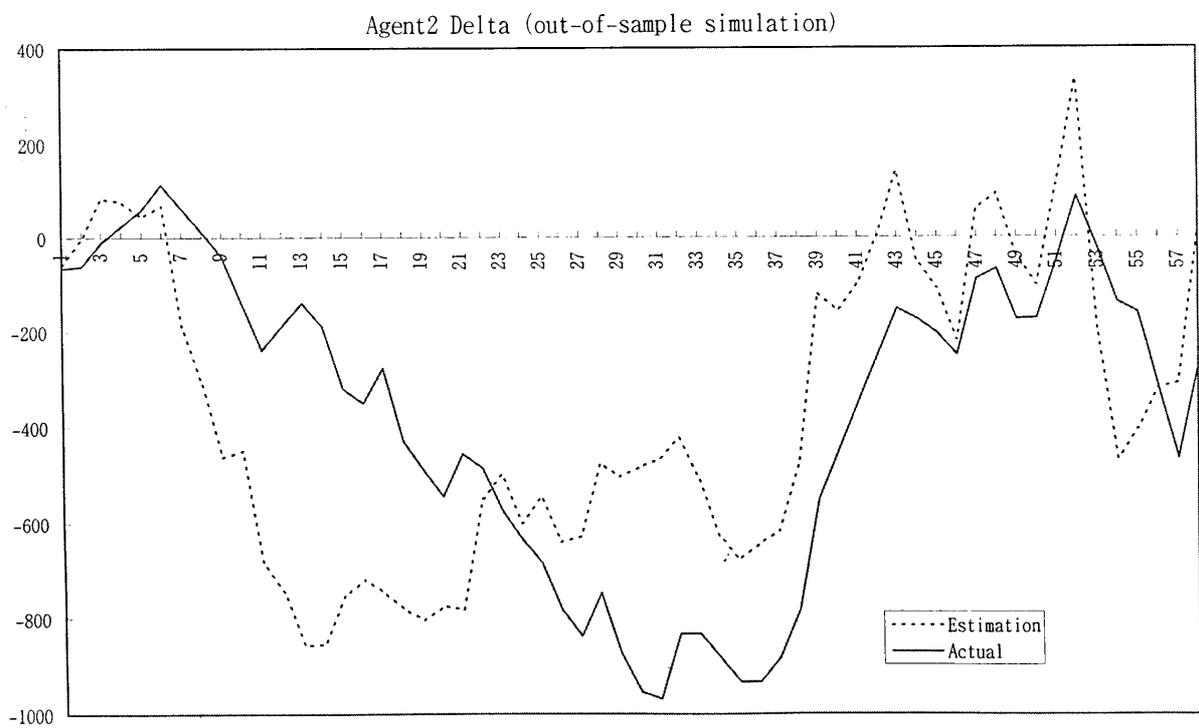
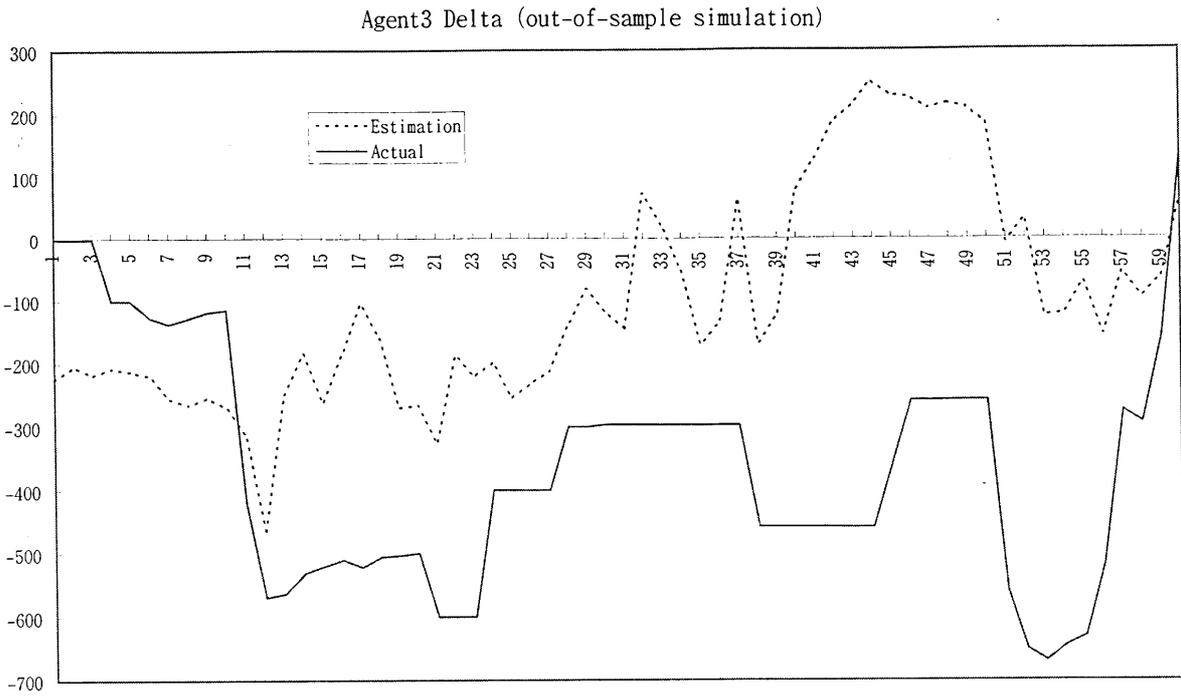


Figure 7-3



3y Swap Rate Daily Return

Figure 8-1

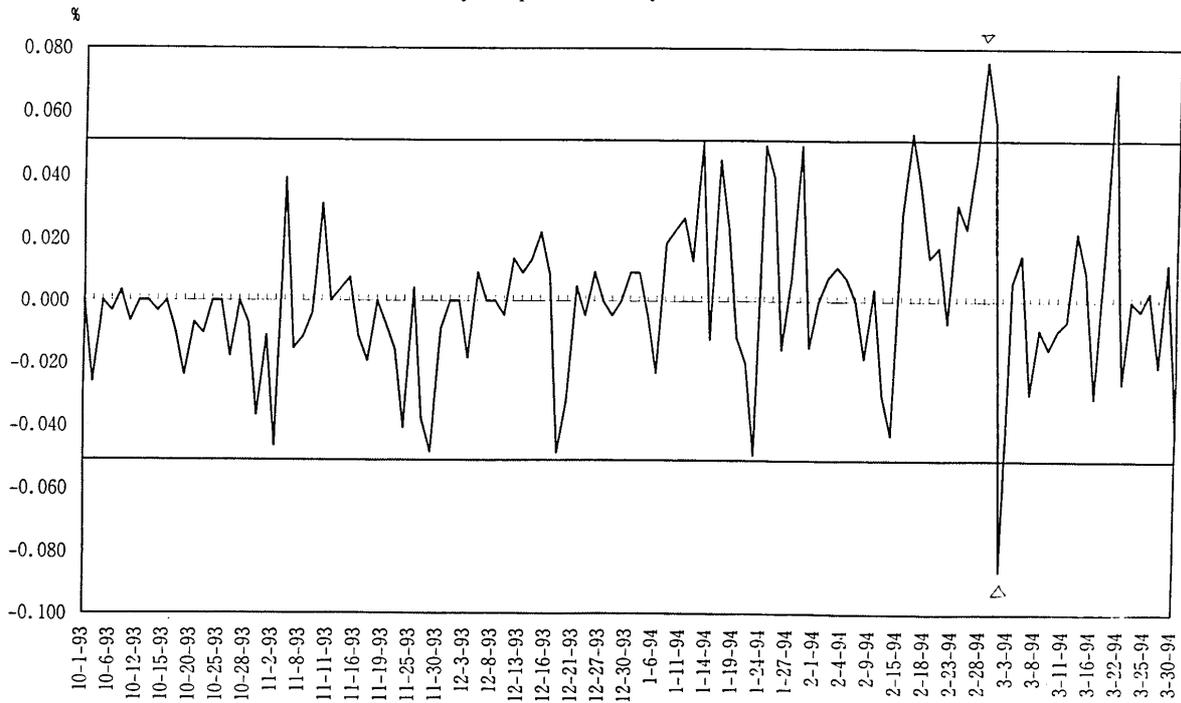


Figure 8-2

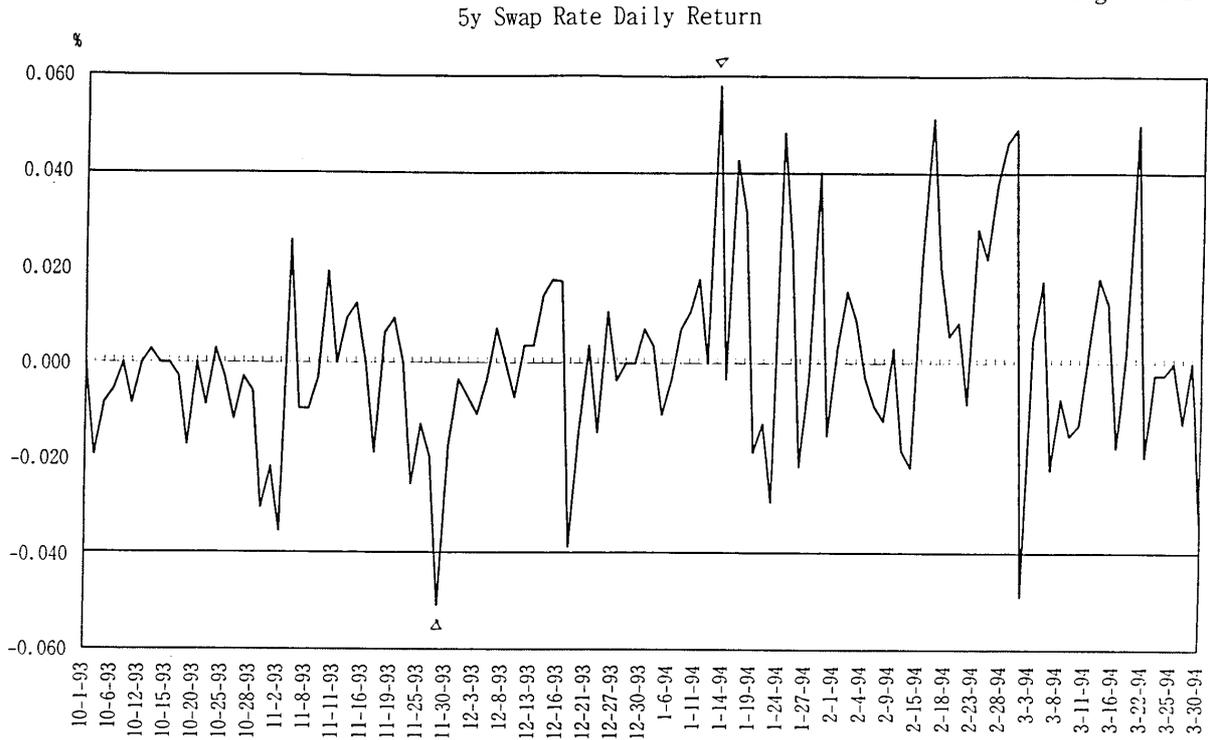


Figure 8-3

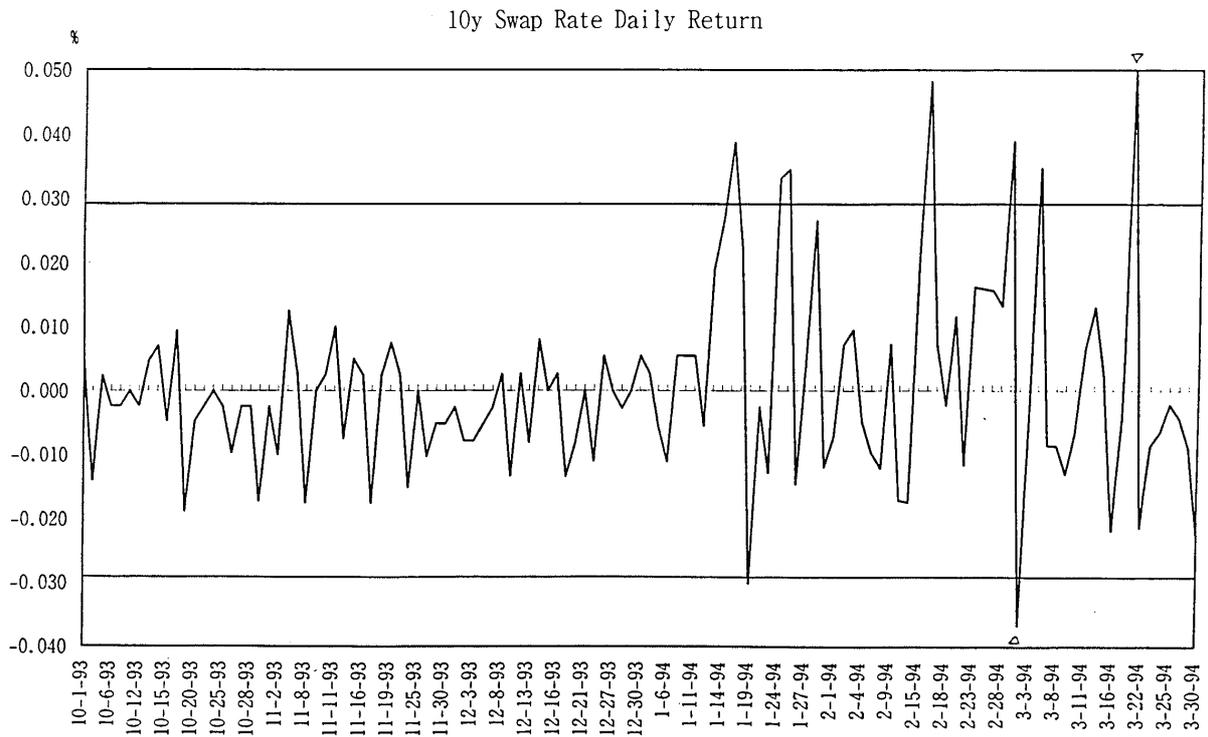


Figure 9

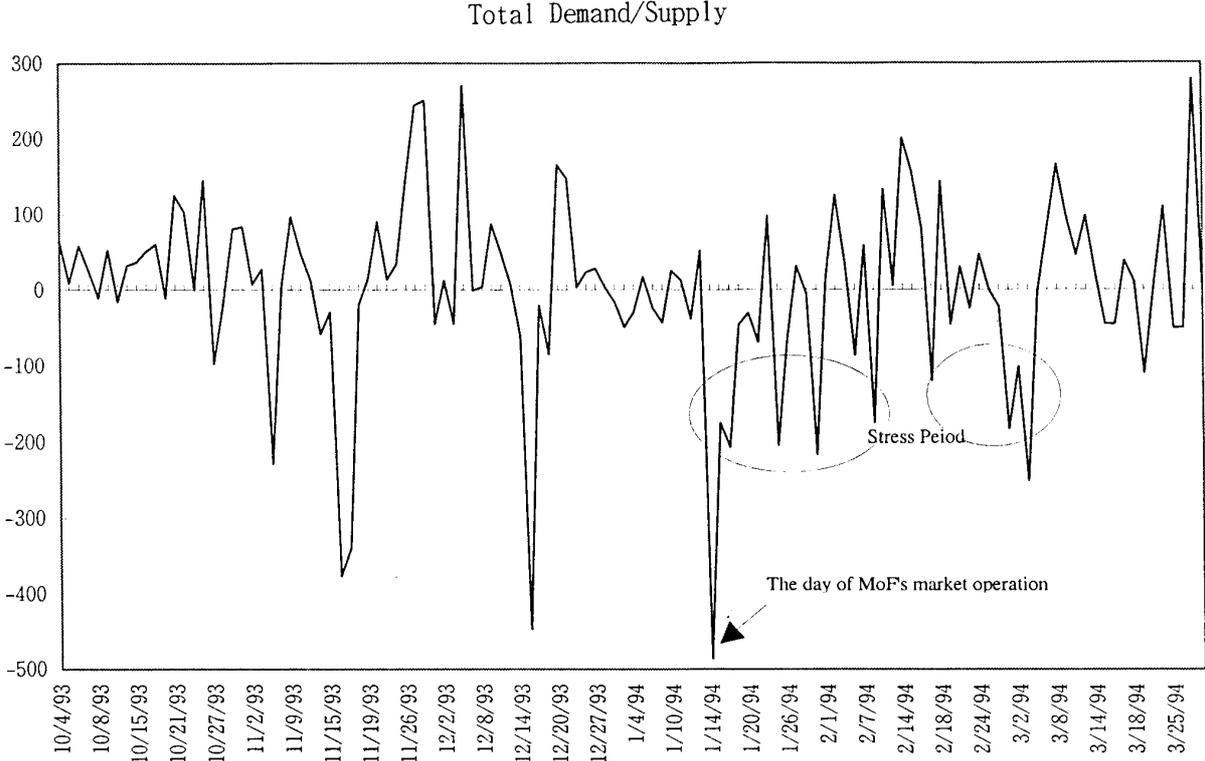


Figure 10-1

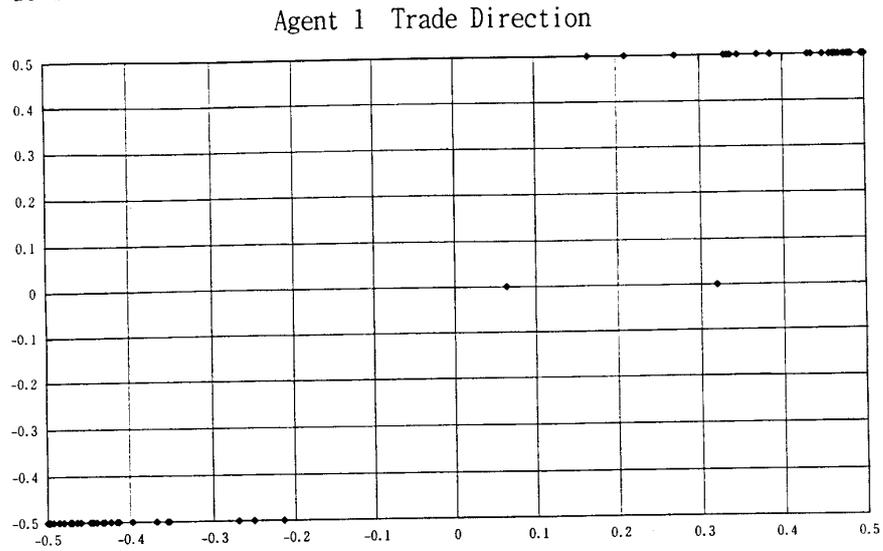


Figure 10-2

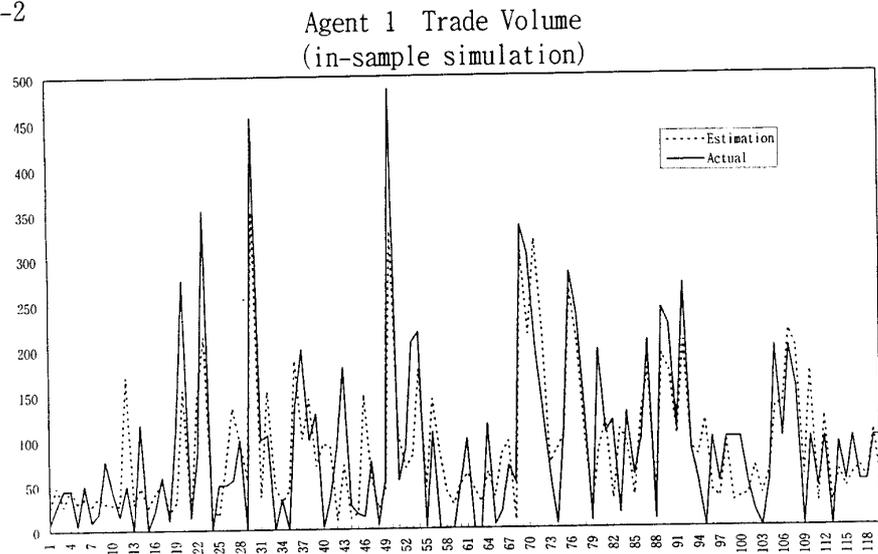


Figure 10-3

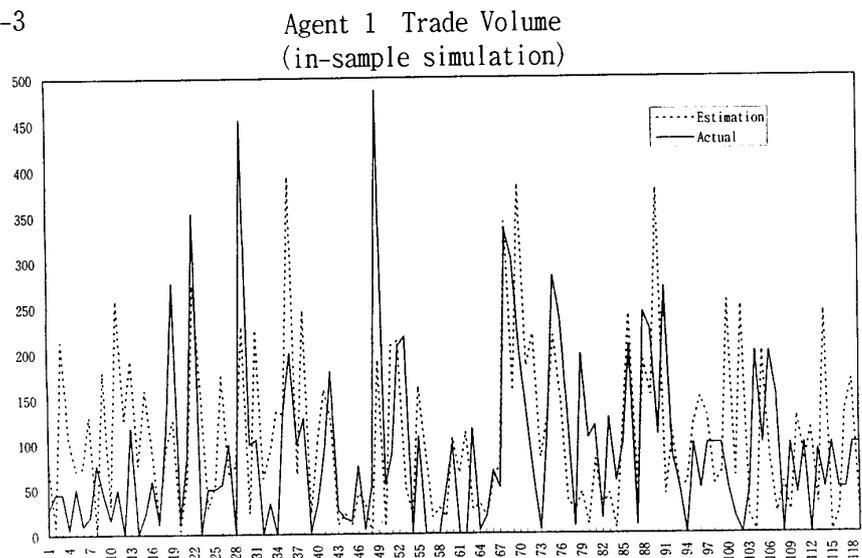


Table 1
Characteristics of the agents

	Key for trading	Fortrend/contrarian	Other characteristics	Targeted profit (loss limit), Position limit
Agent 1	Charts of market movements (chartist)	Fortrend	Positive correlation b/w P/L condition and trading volume	3 billion yen/half year, delta limit:± 100 billion
Agent 2	Charts of market movements (chartist)	Contrarian	Frequent writer of options	3 billion yen/half year, delta limit:± 100 billion
Agent 3	Fundamental events (fundamentalist)		Trading horizon is longer than the others (more an investor-type of trader than a dealer)	2 billion yen/half year, delta limit:± 70 billion

Table 2
Steps for inputs adjustments

Inputs	Agent 1	Agent 2	Agent 3
A: Market data (change on a trading day)	71.67%	82.08%	80.00%
B: A + accumulated P/L	76.67	82.08	82.92
C: B + recent market movements + news	85.42	87.92 (Figure 5)	87.92
D: C + market trend over a longer horizon (Agent 3)			90.83 (Figure 6)

Table 3

The magnitude of largest daily change

	Upward change	Downward change
3-year swap rate	3.01 σ	-3.43 σ
5-year swap rate	2.96 σ	-2.59 σ
10-year swap rate	3.46 σ	-2.54 σ

Table 4

Stress scenarios

	3y	5y	10y
Period t	3.33%	3.98%	4.49%
Scenario 1	3.59%	4.22%	4.72%
Scenario 2	3.05%	3.78%	4.33%
Scenario 3	3.59%	3.98%	4.49%
Scenario 4	3.05%	3.98%	4.49%
Scenario 5	3.33%	4.22%	4.49%
Scenario 6	3.33%	3.78%	4.49%
Scenario 7	3.33%	3.98%	4.72%
Scenario 8	3.33%	3.98%	4.33%

Table 5
Changes of each agent's delta under scenarios
(in billions of yen)

	Agent 1	Agent 2	Agent 3	Total D/S
Scenario 1	-8	26	-6	12
Scenario 2	-15	-9	-10	-34
Scenario 3	-3	33	-6	20
Scenario 4	-43	-3	9	-37
Scenario 5	-42	27	30	-15
Scenario 6	4	1	-4	1
Scenario 7	-4	14	-4	6
Scenario 8	21	20	31	72
Standard deviation				12

Table 6
Risk profiles of each agent
(in billions of yen)

	Agent 1	Agent 2	Agent 3	Total
Scenario 1	0.20	0.09	-0.03	0.26
Scenario 2	-0.51	0.18	0.13	-0.28
Scenario 3	0.45	0.25	-0.05	0.65
Scenario 4	-0.16	0.10	-0.12	-0.18
Scenario 5	0.08	0.13	0.18	0.39
Scenario 6	0.04	-0.00	-0.00	0.03
Scenario 7	0.11	0.02	-0.01	0.13
Scenario 8	1.98	0.40	0.80	3.18
VaR(t)	0.58	0.05	0.22*	

* Agent 3's VaR figure is measured at period t-1, since its position at period t is square.