

Title	多様性を持つエージェントによる人工市場モデルの構築
Author(s)	松井, 宏樹
Citation	
Issue Date	2002-03
Type	Thesis or Dissertation
Text version	author
URL	http://hdl.handle.net/10119/1534
Rights	
Description	Supervisor: 東条 敏, 情報科学研究科, 修士

修 士 論 文

多様性を持つエージェントによる人工市場モデルの構築

指導教官 東条敏 教授

北陸先端科学技術大学院大学
情報科学研究科情報処理学専攻

松井 宏樹

2002年2月15日

要 旨

近年，株式市場や外国為替市場では，人間の心理の効果が注目されている．しかし，合理的な人間のみが存在する今までの伝統的な経済理論は，市場参加者の個人特性の違いや心理的側面を軽視していた．このような現状から近年，より現実的な市場のモデルを目指した人工市場 (artificial market) 研究が行われている．

和泉らは，エージェント群に為替レートの変動要因となる市場条件（景気，物価，金利など）を入力し，それぞれの売買行動から為替レートの推移を得る人工市場モデル AGEDASI TOF を作成した．

しかし，AGEDASI TOF ではエージェント間の情報交換においてレートの予測に成功したエージェントの重みづけをすべてコピーしたり，レート予測の成功失敗が決まった段階で対等に重みづけを交換すると言った非現実的な方法が用いられていた．また，AGEDASI TOF ではエージェントは一様であるが，現実には多様な市場参加者が存在する．

本研究では，エージェントの情報交換・学習の仕組みの改良，エージェントの多様化という２点について AGEDASI TOF を改良・拡張した人工市場モデルを作成した．情報交換・学習の仕組みの改良については，レート予測に関する重みづけだけコピーするというより現実的な方法を提案し，このモデルで AGEDASI TOF よりもモデルの予測精度を高めることができた．一方，エージェントの多様化では典型的なレート予測方法をとるディーラーであるファンダメンタリスト，チャートリストを実装し，それぞれが存在する市場の特性を調べた．また，現実の政府・中央銀行にあたる介入エージェントを実装し，動的な介入政策の分析を可能にした上で，介入量が小さいときの介入のポートフォリオ・バランス効果，シグナル効果を調べ，シグナル効果によるレートへの影響が大きいことを示した．

目次

1	はじめに	1
1.1	本研究の背景と目的	1
1.2	本論文の構成	2
2	人工市場	3
2.1	人工市場研究	3
2.1.1	人工市場研究とは	3
2.1.2	様々な人工市場モデル	4
2.2	人工市場モデル AGEDASI TOF	6
2.2.1	概要	6
2.2.2	各ステップの詳細	7
2.2.3	シミュレーション方法	13
2.2.4	AGEDASI TOF の問題点	14
3	提案モデル: AGEDASI TOF の改良・拡張	16
3.1	情報交換・学習の仕組みの改良	16
3.1.1	情報交換の仕組みの改良	16
3.1.2	自己修正・自己学習	19
3.2	多様なエージェントの実装	19
3.2.1	介入エージェント	19
3.2.2	ファンダメンタリスト, チャーティスト	22
4	提案モデルの検証	
	(実験結果と解析)	23

4.1	基礎モデルの実装	23
4.1.1	基礎実験	23
4.1.2	モデルの検証	26
4.2	情報交換の改良	27
4.2.1	基礎実験	27
4.2.2	実験結果	31
4.3	自己学習の導入	33
4.4	自己学習の導入	33
4.5	多様なエージェントの実装に関する結果	35
4.5.1	ファンダメンタリスト, チャーティストの実装	35
4.5.2	介入エージェントの実装	40
5	おわりに	45
5.1	まとめ	45
5.2	今後の課題	46

第 1 章

はじめに

1.1 本研究の背景と目的

近年，株式市場や外国為替市場では，人間の心理の効果が注目されている．しかし，合理的な人間のみが存在する今までの伝統的な経済理論は，市場参加者の個人特性の違いや心理的側面を軽視していた．このような現状から近年，より現実的な市場のモデルを目指した人工市場 (artificial market) 研究が行われている．

人工市場とは人間や市場参加者の役目をする多数のコンピュータプログラムが集まって，自由に取引をするコンピュータ上の仮想的な市場のことである．

人工市場研究は目的によって分類されるが，代表的なものとしてバブルなど金融市場に見られる経済現象や市場メカニズムの解析，従来の経済理論の検証を目的とする市場分析が最も盛んに研究されている．また，モデル構築の方法として統計物理学の手法や相転移とのアナロジーを用いる経済物理アプローチ [8] と遺伝的アルゴリズムなどを用いる進化的学習アプローチ，コンピュータプログラムだけでなく人間も参加する仮想市場 [9] がある．

和泉らは，エージェント群に為替レートの変動要因となる市場条件（景気，物価，金利など）を入力し，それぞれの売買行動から為替レートの推移を得る人工市場モデル AGEDASI TOF (A GEnetic-algorithmic Double Auction SImulation in TOkyo Foreign exchange market) を作成した [3]．本研究では人工市場研究の目的を達成するためには，様々な状況を再現できるより現実的なモデルが必要であるという考えをもとに，和泉らのモデルを拡張し多様なエージェントによるマルチエージェント人工市場モデルの構築

を行う．

1.2 本論文の構成

本論文では，2章において人工市場研究とは何か，様々な人工市場研究モデルの紹介を行う．また，本研究の基礎モデルとした人工市場モデル AGEDASI TOF について詳細に説明し，その問題点を述べる．

3章では本研究で提案する AGEDASI TOF の改良・拡張点について述べる．すなわち，情報交換・学習の仕組みの改良と多様なエージェントの実装である．

4章で提案モデルの実装と実験結果，それに対する考察を行い，最後に本論文のまとめ，今後の課題を5章で示す．

第 2 章

人工市場

2.1 人工市場研究

近年，市場に起こったバブルなどの予期せぬ激しい変動は，伝統的な経済理論では的確に解析することができなかった．これは過度に理想的で非現実的な市場が仮定されており，市場参加者の個人の特性や心理的側面を軽視していたためと考えられる．

このような現状からより現実的な市場モデルを目指した人工市場 (artificial market) 研究と呼ばれるアプローチが現れた．本節では人工市場研究の紹介と，様々な研究手法について説明する．なお，この節をまとめるにあたって人工市場入門 [5] を参考にした．

2.1.1 人工市場研究とは

人工市場とは，市場参加者の役目をする多数のコンピュータプログラムが集まって，自由に取引をするコンピュータ上の仮想的な市場のことである．人工市場研究の目的はそれぞれ個性を持ったコンピュータプログラムが市場に参加することによってより現実的な，人間臭い市場を作ることである．

多くの人工市場モデルの市場参加者は先に述べたように一人一人の市場参加者の役目をする多数のコンピュータプログラムである．つまり，人工市場モデルはエージェントが市場参加者であるマルチエージェントモデルと言える．人間の被験者を用いた経済実験を行えば人間心理に左右される市場を構築できるが，大規模になればなるほど物理的な面で限界があった．この点もコンピュータプログラムを用いた人工市場モデルなら解

消することができる．

経済学の歴史の観点から見れば，人工市場研究は「計算科学的方法」または「シミュレーション的方法」と呼ばれる方法であり，文学的方法，数学的方法に次ぐ第3の方法と言える．その登場は経済学にとって，数学の導入に匹敵する学問用具の革命であり，今後，経済学にもたらすであろう影響は大きいと考えられる [11]．

人工市場研究の対象とする問題で中心となるのはミクロ-マクロ問題である．ミクロ-マクロ問題とは，例えば金融市場のバブル現象のような現実の市場で見られるマクロな現象は，個々の市場参加者の行動や意思決定といったミクロなレベルとどのように関係しているのかといった問題である．特にミクロな個々の市場参加者が意図して行動しているわけではないのに，マクロな市場全体のレベルで現れる金融価格の変動などの動的なパターンのことを創発的現象と呼ぶ．これらのミクロ-マクロ問題や創発的現象のメカニズムは，今までの経済学の金融市場モデルではうまく解析することができなかった課題の一つである．人工市場研究では，現実的な市場モデルの構築によりこの問題の解明，また従来の経済理論の検証を目指している．

2.1.2 様々な人工市場モデル

人工市場研究で最も盛んに研究されている分野はバブルなど金融市場に見られる経済現象や市場メカニズムの解析，従来の経済理論の検証を目的とする市場分析である．

モデル構築の方法としては統計物理学の手法や相転移とのアナロジーを用いる経済物理アプローチと遺伝的アルゴリズムなどを用いる進化的学習アプローチなどがある．また，コンピュータプログラムだけでなく人間も参加する実験ツールとしての人工市場モデルがある．

A Synergetic Approach to Speculative Price Volatility [8]

海蔵寺は物理学の相転移モデルとのアナロジーを用いて市場で見られる価格の時系列的特徴の再現と解析を行った．

海蔵寺の用いたモデルは3つの有価証券（株，債権，外貨）市場にファンダメンタリストとチャーティストと呼ばれる2種類の投資家が存在するモデルである．この2種類

の投資家では大きく価格予想の方法が異なる．すなわちファンダメンタリストとは様々な経済指標などから金融価格の本質価値（ファンダメンタルズ）を求める分析手法を用いるディーラーであり，チャーティストとは過去の価格チャートの動きから現在の値を予測する分析手法を用いるディーラーのことである．

この２種類の投機家の性質，つまりファンダメンタリストの鞘取りの性質とチャーティストのフィードバックトレーディングの性質の違いに重点をおき，それぞれが投機ダイナミクスにどのような影響をもたらすかを解析している．結果は以下の通りである．

- 全投機家がファンダメンタリストの場合，系が均衡点に収束し価格は安定する．
- 全投機家がチャーティストの場合，投機ダイナミクスの不安定性が増幅され，投機バブルと投機カオスが引き起こされる．
- 市場に２種類の投機家がともに存在する場合
 - － 鞘取り効果が強い場合は系に準周期性からカオスへの移行が起こり，価格はファンダメンタル価格のまわりで無秩序に変動する
 - － 鞘取り効果が弱い場合は強いフィードバックトレーディングの効果によって投機バブルが起こり，価格は大きく騰貴，下落を繰り返す

以上から市場に現れる投機バブル，投機カオスはファンダメンタリストの鞘取りの性質とチャーティストのフィードバックトレーディングの性質，両方に依存することを示した．これらの結果は現在の金融危機に有用な分析の基礎を与えると思われる．

U-Mart [9]

U-Mart は仮想取引実験のために株価指数を取引する仮想先物市場シミュレータである．取引や予測に関する戦略を実装した様々なコンピュータプログラムを競わせるコンテスト形式をとっている．

構造などの制約がないので，市場参加者として様々なタイプのコンピュータプログラムや人間のトレーダーがエージェントとして混在が可能である．各エージェントは仮想市場であるインターネット上のサーバーと TCP/IP 上の SVMP (Simple Virtual Market

Protocol) と呼ばれるプロトコルにしたがって、株価指数先物の注文や過去の値動きに関する紹介を行う。

開発者の違うエージェントが参加することでエージェントの個性が生まれ、また、インターネットを用いることで大規模な実験を容易にしている。

2.2 人工市場モデル AGEDASI TOF

本節では和泉らの作成した、エージェント群に為替レートの変動要因となる市場条件（景気、物価、金利など）を入力し、それぞれの売買行動から為替レートの推移を得る人工市場モデル AGEDASI TOF (A GEnetic-algorithmic Double Auction SImulation in TOkyo Foreign exchange market) [3] について説明する。

2.2.1 概要

AGEDASI TOF は、マルチエージェントシステムを用いた円、ドルを扱う人工外国為替市場モデルである。主な特徴としては以下の 4 つがあげられる。

- 為替レートやその変動要因である市場条件に現実のデータを用いている
- 各エージェントの個性は、どの変動要因を重視すべきかという市場に対する重みづけで表される
- 各エージェントは市場の認識を遺伝的アルゴリズムをもとにした情報交換、学習によって変化させる
- 現実のディーラーへのインタビューをもとにエージェントの実装、結果の解析行っている

特に 4 つめの現実のディーラーへのインタビューをモデルの構築、評価に用いている点は他に類をみない。AGEDASI TOF を用いたシミュレーションでは従来の市場研究モデルよりも為替レートの予測精度が高く、バブルの解析 [6] や為替政策の意思決定支援システムの構築でも成果を上げている [4]。

AGEDASI TOF では 100 人のエージェントが参加し，レート決定が 1 回行われる 1 期間は以下の 5 つのステップからなる．また，1 期間は現実世界の 1 週間に対応する．

- 知覚ステップ
- 予想形成ステップ
- 戦略決定ステップ
- レート決定ステップ
- 学習ステップ




図 2.1 AGEDASI TOF のフレームワーク

2.2.2 各ステップの詳細

知覚ステップ

知覚ステップでは各エージェントが為替レートの変動要因である予想材料を知覚する．入力される変動要因は表 2.1 の 17 項目である．

ファンダメンタルズ材料 (1-14) は，変化の度合いに応じて $-3, -2, -1, 0, +1, +2, +3$ の 7 段階にコーディングした値を代入する．トレンド材料 (15-17) は，為替レートの

予想材料	もともになる生データ
1 景気	[米][日] GDP etc.
2 物価	[米][日] 消費者物価指数 etc.
3 金利	[米][日] 公定歩合，長期金利
4 マネーサプライ	[米][日] マネーサプライ
5 貿易収支	[米][日] 貿易収支
6 雇用	[米] 失業率 etc.
7 個人消費	[米] 小売売上，個人所得
8 介入	[米][日] 介入
9 要人発言	[米][日] 中銀総裁の発言 etc.
10 マルク	ドル/マルク，円/マルク
11 石油	石油価格
12 政治	政情，国際的な事件
13 株	[米][日] 株価
14 債券	[米][日] 債券価格
15 短期トレンド 1	先週の変動値 ($\Delta S(t-1)$)
16 短期トレンド 2	変動の変動値 ($\Delta S(t-1) - \Delta S(t-2)$)
17 長期トレンド	5週間の変動 ($S(t-1) - S(t-6)$)

表 2.1 予想材料

チャートから計算した値を同じく 7 段階にコーディングし代入する．AGEDASI TOF では全エージェントの知覚は同じである．

予想形成ステップ

予想形成は，各エージェントがレート（対数）の変動値 $\Delta S(t)$ に対する予測 $E_i[\Delta S(t)]$ を求めることで行われる．各エージェントはそれぞれ独自の市場観を持っており，それは表 2.1 の 17 種類の予想材料に対する重みづけで表される．各エージェントの予測レート変動値は，各予想材料とその予想材料に対する重みづけの積の和として定義される．

$$E_i[\Delta S(t)] \equiv \alpha \left(\sum_{k=1}^n w_i^k(t) x^k(t) \right) \quad (2.1)$$

$$\left(\begin{array}{l} S(t): \text{ 期間 } t \text{ の為替レート（対数）} \\ \Delta S(t) = S(t) - S(t-1) \\ E_i[\Delta S(t)]: \text{ エージェント } i \text{ の } \Delta S(t) \text{ 予測値} \\ x^k(t): \text{ 期間 } t \text{ の変動要因 } k \text{ の値} \\ w_i^k(t): \text{ エージェント } i \text{ の変動要因 } k \text{ に対する重みづけ} \\ \quad (\pm 3, \pm 1, \pm 0.5, \pm 0.1, 0 \text{ の 9 段階}) \\ \alpha: \text{ スケール係数} \end{array} \right)$$

また，この予想の確信度を表す予想の分散度 $\text{Var}_i[\Delta S(t)]$ が以下の式で定義される．

$$(\text{Var}_i[\Delta S(t)])^{-1} \equiv \sqrt{|(wx_+)^2 - (wx_-)^2|} \quad (2.2)$$

$$\left(\begin{array}{l} wx_+: w_i^k(t) x^k(t) (> 0) \text{ の和} \\ wx_-: w_i^k(t) x^k(t) (< 0) \text{ の和} \end{array} \right)$$

wx_+ または wx_- に予想材料が片寄れば分散度 $\text{Var}_i[\Delta S(t)]$ が小さくなり，その予測に対して確信が強いと言える．

戦略決定ステップ

戦略決定ステップでは各エージェントが各自の予想に基づき期待収益を最大にする最適ドル資産保有高を計算し、ドルの売買要求量を決定する。このステップで用いられている方法は計量経済学における典型的なポートフォリオ均衡モデルに共通するものである。

エージェントの効用関数を負の指数関数であると仮定すると期間 t , エージェント i の最適ドル資産保有高 $q_i^*(t)$ は以下の式で求められる [7] 。

$$q_i^*(t) = \frac{1}{a} \frac{E_i[\Delta S(t)]}{\text{Var}_i[\Delta S(t)]} \quad (2.3)$$

つまり、ドル高になると予想したらドル資産を増やし、ドル安になると予想したら減らす。その量はレートの予想変動値だけではなく、予想の確信に比例する。

期間 t のエージェント i の売買要求は

$$\begin{aligned} \text{レート} \quad \text{order rate} &= E_i[\Delta S(t)] \\ \text{要求量} \quad \text{order quantity} &= \Delta q_i^*(t) \equiv q_i^*(t) - q_i(t-1) \end{aligned}$$

となる。ここで $q_i(t)$ は期間 t におけるエージェント i のドル資産保有高である。

各エージェントの売買戦略は、期間 t における最適ドル資産保有高が期間 $t-1$ のドル資産保有高よりも大きく（小さく）、かつレートが自分の予想したレートよりも安く（高く）有利な場合には、その差の分だけドルを買って（売って）保有高を最適値に近づけようとする。

レート決定ステップ

各エージェントの売買戦略を市場全体で集積して、需要と供給が均衡するような値にモデルの今期のレートを決定する。

レート決定後、エージェントのドル資産 $q_i(t)$ は以下のようになる。

$$q_i(t) = \begin{cases} q_i^*(t) & \text{買いで } E_i[\Delta S(t)] > \Delta S(t) \text{ or 売りで } E_i[\Delta S(t)] < \Delta S(t) \\ q_i(t-1) & \text{その他} \end{cases}$$

すなわち、取引が行えたエージェントはドル資産 $q_i(t)$ を最適ドル資産保有高に更新し、取引が行えなかったエージェントはドル資産を更新することができない。




図 2.2 レートの決定

学習ステップ

学習ステップではsimple GA [1] をもとにした遺伝的アルゴリズムを用いて各エージェントは情報交換，学習を行い，予想材料に対する重みづけの列 $W_i(t) = (w_i^1(t), \dots, w_i^{17}(t))$ を変化させる．学習ステップで行われるオペレーションは淘汰，交叉，突然変異の3つである．

淘汰 まず，エージェント i の期間 t における適応度¹ $F_i(t)$ を以下のようにレートの予測と実際のレートのずれをもとに定義する．

$$\begin{aligned} F_i(t) &= -|E_i[\Delta S(t)] - \Delta S(t)| \\ &= -\left| \alpha \left(\sum_{k=1}^n w_i^k(t) x^k(t) \right) - \Delta S(t) \right| \end{aligned} \quad (2.4)$$

確率 G (Generation Gap) で選ばれたエージェント i (全エージェント数 $N \times G$ 人) は，適応度 $F_j(t)$ に比例する確率で選ばれた相手 j から重みづけの列をコピーする．

$$W_i(t+1) = W_j(t) \quad (2.5)$$

$$\begin{pmatrix} i: \text{確率 } G \text{ で選ばれたエージェント} \\ j: \text{適応度 } F_j(t) \text{ に比例する確率で選ばれた (適応度の高い) エージェント} \end{pmatrix}$$

¹厳密には，エージェント i の期間 t にとった予想方式（予想材料に対する重みづけの列 $W_{i,t}$ ）の適応度




図 2.3 淘汰

つまり，各エージェントは自分の予想が正確であれば変更せず，予想が不正確であれば他のエージェントが持つ適応度の高い重みづけの列に入れ替えるのである．

これは予測に失敗したディーラーが成功したディーラーと情報交換を行うことによって自らの予想方式を変更することにあたる．

交叉 ランダムに全エージェントをペアにし，それぞれのペアの重みづけの列に対し，確率 P_{cross} で一点交叉を行う．




図 2.4 交叉

$$\begin{aligned} \mathbf{W}_i(t+1) &= (w_i^1(t), \dots, w_i^k(t), w_j^{k+1}(t), \dots, w_j^{17}(t)) \\ \mathbf{W}_j(t+1) &= (w_j^1(t), \dots, w_j^k(t), w_i^{k+1}(t), \dots, w_i^{17}(t)) \end{aligned} \quad (2.6)$$

$$\left(\begin{array}{l} i, j: \text{ 確率 } P_{cross} \text{ で選ばれたエージェントのペアに属するエージェント} \\ k: \{1, \dots, 17\} \text{ からランダムに選ばれた数} \end{array} \right)$$

これはディーラー間のコミュニケーションによりお互いの意見を交換しあい，その結果予測方針を変更することにあたる．

突然変異 エージェント i がある重みづけ w_i^k を，確率 $P_{mutation}$ でランダムに変化させる．




図 2.5 突然変異

$$w_i^k(t+1) = \text{random}(\{\pm 3, \pm 1, \pm 0.5, \pm 0.1, 0\}) \quad (2.7)$$

$$\left(\begin{array}{l} i: \text{確率 } P_{mutation} \text{ で選ばれたエージェント} \\ k: \{1, \dots, 17\} \text{ からランダムに選ばれた数} \\ \text{random}(A): \text{集合 } A \text{ からランダムに要素を返す関数} \end{array} \right)$$

これはディーラーがある変動要因に対して，思いつきで新たな価値を設定することにあたる．

2.2.3 シミュレーション方法

シミュレーションは対象とする期間について複数回シミュレーションを行い，シミュレーションパスを複数生成する．1回のシミュレーションは以下の3つの段階から構成される．

1. 初期化
2. トレーニング期間
3. シミュレーション期間

初期化

エージェントの初期状態における予想材料に対する重みづけはランダムに決定する．

$$w_i^k(0) = \text{random}(\{\pm 3, \pm 1, \pm 0.5, \pm 0.1, 0\})$$

また，エージェントの初期ドル資産保有高は 0，すなわちドルのポジションはスクエアとする．

$$q_i(t) = 0$$

トレーニング期間

シミュレーションの対象とする直前の期間の現実の予想材料（表 2.1 の 17 項目）と現実の為替レートを用いてエージェントのトレーニングを複数回繰り返し行う．トレーニング期間ではレート決定ステップを行わず，適応度は式 (2.4) の代わりに以下の式を用いる．ここで $\Delta S(\tau)$ は，現実のレートの変動値である．

$$F_i(t) = - \sum_{\tau=0}^t |E_i[\Delta S(\tau)] - \Delta S(\tau)| \quad (2.8)$$

つまり，エージェントのレートの予測と現実のレートの差を期間 t まで積算したものである．

シミュレーション期間

シミュレーション期間ではレート決定ステップで決まったレートを市場のレートとしてシミュレーションを行っていく．

この期間では外部から入力されるのは現実のファンダメンタルズ予想材料（表 2.1 の 1-14）のみである．トレンド予想材料（表 2.1 の 15-17）についてはレート決定ステップで決まったレートをもとに計算する．適応度については式 (2.4) を用い， $\Delta S(t)$ はレート決定ステップで決定したレートの変動値である．

2.2.4 AGEDASI TOF の問題点

情報交換・学習における問題点

AGEDASI TOF では，遺伝的アルゴリズムに基づいたディーラー間での情報交換，学習を行っている．しかし，この仕組みには非現実的な部分があると考えられる．またこの仕組みでは情報交換に依存しない学習は不可能である．以降にそれぞれの問題点をあげる．

淘汰 AGEDASI TOF で用いられている遺伝的アルゴリズムにおける淘汰の操作は適応度は式 (2.4) のように、その期間での為替レートの予測誤差を基準に決定し、適応度の低いエージェントが適応度の高いエージェントの予想材料に対する重みづけをすべてコピーするというものである。

しかし、重みづけをすべてコピーするとレートの予測（すなわち適応度）に無関係であった予想材料、すなわち $x^k(t)$ が 0 である予想材料に対する重みづけもコピーしてしまう。適応度を高める（予測を誤った原因を修正する）為に情報交換するのであれば、適応度に関係ない重みづけをコピーするのは不自然である。また、適応度に関係ない重みづけをむやみにコピーすることは各エージェントが個性を失うことにつながる。

交叉 AGEDASI TOF で用いられている遺伝的アルゴリズムにおける交叉の操作は、ランダムに全エージェントをペアにしそれぞれのペアの重みづけの列に対し、ある確率で一点交叉を行うというものであった。

交叉は、エージェントがお互いの意見を交換しあい予測方針を変更することと意味付けされている。しかし交叉が行われるときにはすでに適応度の優劣がついており、その状態でディーラーが重みづけを対等に交換するとは考えにくい。また、重みづけの列の順序に意味がなければ、一点交叉であることも現実的ではないと思われる。

自己学習 実際の外国為替市場ではディーラーが各種情報（AGEDASI TOF では主に 17 種類の予想材料）をもとに、自分で各予想材料に対する重みづけを変更することも考えられる。しかし、AGEDASI TOF ではディーラー間での情報交換に依存せずに、自分の持っている情報をもとに自ら重みづけを変更することはできない。

エージェントについて

AGEDASI TOF では各エージェントの個性は、どの予想材料を重視すべきかという重みづけで表される。しかしエージェントの目的は各期間の利益を最大にするというものであり、レートの予想方法は全予想材料を同等に評価し予想を行うものとそれぞれ一様である。しかし、現実には様々な予想方法や目的を持ったディーラーが存在すると考えられ、これを AGEDASI TOF で実現することはできない。

第 3 章

提案モデル: AGEDASI TOF の改良・拡張

本研究では AGEDASI TOF に以下の 2 つの点で改良，拡張を行う．

1. 情報交換・学習の仕組みの改良
2. エージェントの多様化

3.1 情報交換・学習の仕組みの改良

3.1.1 情報交換の仕組みの改良

前章で述べた点で AGEDASI TOF で用いられている遺伝的アルゴリズムをもとにした仕組みには非現実的な部分があると考え、そこで本研究では以下のように情報交換，学習の仕組みを提案する．

交叉

AGEDASI TOF の交叉にあたるものは行わない．すでに予測の成功，失敗が決まっている段階で，ディーラーが同等に重みづけを交換することは考えにくいからである．

予想材料	$x^k(t)$	1	-3	0	...	2	0	
エージェント i	$w_i^k(t)$	3	-0.1	0.5	...	0	-3	適応度:高
エージェント j	$w_j^k(t)$	0	1	3	...	1	0.5	適応度:低

⇓

予想材料	$x^k(t)$	1	-3	0	...	2	0	
エージェント i	$w_i^k(t+1)$	3	-0.1	0.5	...	0	-3	適応度:高
エージェント j	$w_j^k(t+1)$	3	-0.1	3	...	0	0.5	適応度:低

表 3.1 コピーする対象を限定した淘汰の例

淘汰

次に淘汰に関してであるが AGEDASI TOF における淘汰の操作は適応度の低いエージェントが適応度の高いエージェントの予想材料に対する重みづけをすべてコピーするというものであった．適応度を高める（予測を誤った原因を修正する）為に情報交換するのであれば，適応度に関係ない重みづけをコピーするのは不自然である．そこで本研究では，入力データ $x^k(t) = 0$ に対する重みづけ $w_i^k(t)$ は，適応度に関係ないことに着目し，すべての重みづけをコピーするのではなく $x^k(t) (\neq 0)$ に対する重みづけだけ（間違った原因だけ）コピーの対象とする．

表 3.1 には，適応度の低いエージェント j が適応度の高いエージェント i から重みづけをコピーする例を示す．しかし，3 つめの予想材料と最後の予想材料は 0 でありレート予想に関係するため，エージェント j はそれらに対する重みづけに関してはコピーを行わず，自分の認識を変えていない．この操作では，適応度に関係ない重みづけをむやみにコピーしないことで各エージェントが個性を失うことを防いでいるとも言える．

本研究のモデルで実際にこの情報交換（コピーする対象を限定した淘汰）を行う際には，まずエージェント N 人を適応度によってソートする．さらに割合 R_h によってエージェントを 2 つに分ける．すなわち適応度上位グループ（ $R_h \times N$ 人）と適応度下位グループ（ $(1 - R_h) \times N$ 人）である．下位グループのエージェントは，確率 P_s で上位グループのエージェントから予想材料 $x^k(t) (\neq 0)$ に対する重みづけだけコピーを行う．その際，コピーする相手は上位グループのエージェントから適応度に応じた比例選択に




図 3.1 コピーする対象を制限した淘汰

によって決定する．

この仕組みは AGEDASI TOF が用いている遺伝的アルゴリズムによる仕組みよりもエージェントの状態変化を追いやしく，ミクロレベルでの分析がより行いやすくなる．

適応度

AGEDASI TOF では適応度の計算方法がトレーニング期間では積算され，シミュレーション期間ではその期間の予測誤差がそのまま適応度になっていた（式 2.4）．本研究では，トレーニング期間，シミュレーション期間ともに学習率を設定した以下の式で適応度を定義する．

$$\mathbf{F}_i(t) = \gamma \mathbf{F}_i(t-1) - (1-\gamma) |\mathbf{E}_i[\Delta S(t)] - \Delta S(t)| \quad (3.1)$$

$$\left(\begin{array}{l} S(t): \text{ 期間 } t \text{ の為替レート (対数)} \\ \Delta S(t) = S(t) - S(t-1) \\ \mathbf{E}_i[\Delta S(t)]: \text{ エージェント } i \text{ の } \Delta S(t) \text{ 予測値} \\ \gamma: \text{ 学習率} \end{array} \right)$$

AGEDASI TOF では現在のドル資産以外には過去の状態を反映するものがなかったが，適応度に学習率を設定することで前の期間で予測に成功していたかどうか適応度にあられ，1 エージェントに注目した状態変化の追跡に意味が増すと考えられる．

突然変異

突然変異については AGEDASI TOF と同様に行う．

3.1.2 自己修正・自己学習

前章で述べた理由から，予想要因 $x^k(t)$ ($\neq 0$) に対する重みづけだけに対象を絞り，その値を適応度 $F_i(t)$ が高くなるように変更する方法を用いる．

本研究では，各エージェントが確率 P_l で以下のことを行う．

1. まず予想要因 $x^k(t)$ ($\neq 0$) に対する重みづけそれぞれに対し，その他の重みづけを固定した上でその重みづけを 1 段階ずつ上下に変化させた重みづけ列を生成する．
 $x^k(t)$ ($\neq 0$) が n 個あるなら $2n$ の重みづけ列が生成される．
2. 次に元々の重みづけ列と新たに生成された重みづけ列それぞれに対し，期間 t での予測誤差を計算する．
3. エージェントの重みづけ列を，最も予測誤差が小さかった重みづけ列に変更する．

3.2 多様なエージェントの実装

AGEDASI TOF ではエージェントの目的，レート予想方法が一様である．そこで本研究では目的，予想形成のそれぞれについて以下のようなディーラーを新たに提案する．

3.2.1 介入エージェント

AGEDASI TOF では利益をあげることを目的としたさや取りエージェントのみが存在する．本研究ではレートの安定を目指す介入エージェントを新たに考える．これは現実世界では政府，中央銀行に相当するものである．

本研究で実装した介入エージェントとは，シミュレーションで決定されたレートに基づき動的に介入を行うものである．具体的なモデルは [10] で分析に用いられている目標為替相場仮説を採用する．すなわち，介入エージェントは期間 t に目標為替レート $T(t)$

	k	1	2	3	...	16	17
予想材料	$x^k(t)$	3	0	0	...	-2	0
エージェント i	$\mathbf{W}_i(t)$	0	-0.1	0.5	...	1	3

予測誤差: 0.05

↓

w_i^1 を 1 段階 + に変化させた重みづけ列

k	1	2	3	...	16	17
$w_i^k(t)$	0.1	-0.1	0.5	...	1	3

予測誤差: 0.06

w_i^{16} を 1 段階 + に変化させた重みづけ列

k	1	2	3	...	16	17
$w_i^k(t)$	0	-0.1	0.5	...	3	3

予測誤差: 0.1

w_i^1 を 1 段階 - に変化させた重みづけ列

k	1	2	3	...	16	17
$w_i^k(t)$	-0.1	-0.1	0.5	...	1	3

予測誤差: 0.04

w_i^{16} を 1 段階 - に変化させた重みづけ列

k	1	2	3	...	16	17
$w_i^k(t)$	0	-0.1	0.5	...	0.5	3

予測誤差: 0.07

↓

k	1	2	3	...	16	17
$\mathbf{W}_i(t+1)$	-0.1	-0.1	0.5	...	1	3

図 3.2 本研究における自己学習の例

を持ち，次のような介入政策を実施する．

$$Q_i(t) = \begin{cases} -q_i \Delta S(t-1) & (S(t-1) < T(t-1) \text{ かつ } \Delta S(t) < 0 \\ & \text{or } S(t-1) > T(t-1) \text{ かつ } \Delta S(t) > 0) \\ 0 & (\text{それ以外るとき}) \end{cases} \quad (3.2)$$

$$\left(\begin{array}{l} Q_i: \text{ 介入量} \\ q_i: \text{ 介入の基準量 } (> 0) \\ S(t): \text{ 期間 } t \text{ の為替レート} \\ \Delta S(t) = S(t) - S(t-1) \end{array} \right)$$

現在の為替レートが目標値に比べ円高のときには，円高の進行に対してのみ介入を行い円安の進行は放置する．一方，現在の為替レートが目標値に比べ円安のときには円安の進行に対してのみ介入を行う．つまり，目標値から乖離幅が拡大するような為替相場の動きに対して介入を行うというものである．

シミュレーション期間では予想材料の介入に関する項目 $x^8(t)$ は，このエージェントの行動がフィードバックされる．期間 t に介入エージェントがドル買い介入を行えば $x^8(t+1)$ は正になり，ドル売り介入を行えば $x^8(t+1)$ は負になる．また，その大きさは介入量により決定される．

外国為替市場における中央銀行の介入が為替相場に及ぼす効果については2つのルートの存在が指摘されている．第1のルートは介入が外国通貨の需給に影響を与え，それを反映して為替相場が変化するというものである．例えば，中央銀行が外国通貨を購入した場合にはその分だけ外国通貨に対する需要が増えるため外国通貨高・自国通貨安になる．これはポートフォリオ・バランス効果 (portfolio balance effect) と呼ばれる．第2のルートは，将来の為替相場に関する外国為替市場参加者の予想の変化を通じるものである．外国為替市場参加者は，中央銀行の介入から将来の金融政策に関する中央銀行の意図を読み取り，それに基づいて将来の金融政策に対する予想を改訂するという考えである．将来の金融政策に関する予想の変化は将来の為替相場に関する予想を変化させ，効率的な市場では，これは直ちに足元の為替相場に影響を及ぼす．これはシグナル効果と呼ばれる．

AGEDASI TOF では介入は予想材料の1つにすぎず，市場の需給には何の影響も及

ばさない．これはポートフォリオ・バランス効果を完全に無視していると言える．しかし一方で，現実の介入においてはシグナル効果の重要性が指摘されており，ポートフォリオ・バランス効果はシグナル効果に比べるとかなり小さいという事例も報告されている [2] ．

そこで介入量の基準 q_i は小さく設定した．また，AGEDASI TOF の予想材料の介入の項目は現実の値を系の外から入力しているため，シミュレーションパスが現実のパスと全く違ってても介入が行われる期間は同じである．つまり，系の状態を全く考慮していない介入と言える．本研究では動的な，系の状態に応じた介入を可能にし系の状態と介入の相関をふまえた分析を可能にする．

3.2.2 ファンダメンタリスト，チャーティスト

AGEDASI TOF では様々な予想材料を同等に扱い予想を形成する．本研究ではファンダメンタルズ材料のみからレートの予測を行うファンダメンタリスト，過去のレート変動のみから予想形成するチャーティストを新たに考える．

最も単純なモデルとして以下のように考えることができる．

ファンダメンタリスト $W_i(t) = (w_i^1(t), \dots, w_i^{14}(t), 0, 0, 0)$

チャーティスト $W_j(t) = (0, \dots, 0, w_j^{15}(t), w_j^{16}(t), w_j^{17}(t))$

ここで $w_i^{1, \dots, 14}(t)$ はファンダメンタルズ材料に対する重みづけ， $w_i^{15, \dots, 17}(t)$ はトレンド材料に対する重みづけである．すなわちファンダメンタリストはトレンド材料を無視し，チャーティストはファンダメンタルズ材料を無視する．

第 4 章

提案モデルの検証 (実験結果と解析)

4.1 基礎モデルの実装

本研究の提案モデルの実装を行う前に、まず基礎モデルとして AGEDASI TOF の実装を JAVA で行った。これは提案モデルにおける拡張をはじめ、様々なエージェントなどの拡張を行いやすくするためである。また、提案モデルとの比較にも用いている。実装にあたっては AGEDASI TOF に関する論文 [3] [7]、公開されているプログラムソース¹を参考にした。

4.1.1 基礎実験

まず、トレーニング回数とシミュレーション回数に関する基礎実験を行った。

市場に参加するエージェント数、各種パラメータは AGEDASI TOF で用いられている設定にしたがった。表 4.1 にその設定を示す。

トレーニング回数 様々な期間でトレーニング回数を変えてシミュレーションを行った。その際のトレーニング期間は 2 年間（約 100 週）、トレーニング回数は 1, 5, 10, 20, 30, 50, 75, 100, 200, 300 回である。それぞれのトレーニング回数に対してシミュレーションを 1000 回ずつ行い検証にはその平均を用いた。図 4.1 にその一例の結果を示す。

¹AGEDASI TOF のプログラムソースは <http://www.carc.aist.go.jp/~kiyoshi/> で公開されている

エージェント数	100 人
G (Generation Gap)	0.8
P_{cross}	0.3
$P_{mutation}$	0.003

表 4.1 AGEDASI TOF の設定




図 4.1 様々なトレーニング回数によるシミュレーション (基礎モデル)

トレーニング期間: 1991 年 1 月第 1 週 ~ 1992 年 12 月最終週

シミュレーション期間: 1993 年 1 月第 1 週 ~ 1994 年 12 月最終週

トレーニング回数が1回の場合は，期間によって平均をとっても様々な変動を示した．しかし，トレーニング回数が少しでも増えるとすぐに安定し，それ以上トレーニング回数が増えても特に変化は見られなかった．

以上の結果より，以降の実験ではトレーニング回数は20回とした．

シミュレーション回数 様々な期間でシミュレーション回数を変えてデータの平均をとった．その際のトレーニング期間は2年間（約100週），トレーニング回数は20回とした．図4.2はそれぞれについて，シミュレーション開始後1週間，4週間，13週間，26週間，52週間の予測誤差（現実のレートとの誤差）を計算しグラフにしたものである．




図 4.2 様々なシミュレーション回数の平均データの予測誤差（基礎モデル）

トレーニング期間: 1991 年 1 月第 1 週～1992 年 12 月最終週

シミュレーション期間: 1993 年 1 月第 1 週～1994 年 12 月最終週

それぞれシミュレーション回数 1000 回の誤差を 100%とした．

880 回近くから，安定してきている．シミュレーション回数は 900 回以上あれば十分であると思われる．

4.1.2 モデルの検証

モデルの検証を行うために，1986 年 1 月から 1998 年 12 月までの現実の予想材料とレートのデータを用いた予測誤差の測定を行った．1986 年 1 月から 2 年間のトレーニング期間ののち，トレーニング期間終了後 52 週先までシミュレーションを行う．次にトレーニング期間，シミュレーション期間を 26 週間ずらしシミュレーションを行う．これをデータがなくなるまで繰り返した．その後，各シミュレーションの平均データのシミュレーション開始後 1，4，13，26，52 週先のレートについて現実のレートとの対象期間に対する平均絶対誤差 (MAE)，平均平方誤差 (RMSE) を求め，オリジナルの AGEDASI TOF と比較した．

$$\text{MAE}(k) = \frac{\sum_{s=0}^{N-1} \left| \tilde{S}(t + s \times 26 + k) - S(t + s \times 26 + k) \right|}{N} \quad (4.1)$$

$$\text{RMSE}(k) = \sqrt{\frac{\sum_{s=0}^{N-1} \left[\tilde{S}(t + s \times 26 + k) - S(t + s \times 26 + k) \right]^2}{N}} \quad (4.2)$$

$$\left(\begin{array}{l} S(t): \text{ 期間 } t \text{ の現実の為替レート (対数)} \\ \tilde{S}(t): \text{ 期間 } t \text{ のシミュレーションモデルの為替レート (対数)} \\ k: \text{ 誤差計測対象期間 (1,4,13,26,52)} \\ N: \text{ 全試行回数 (= 21)} \end{array} \right)$$

基本モデルの設定はトレーニング回数は各 20 回，シミュレーション回数は各 1000 回，各種パラメータは表 4.1 の通りである．また，AGEDASI TOF の設定は [7] にしたがった．トレーニング回数は各 200 回，シミュレーション回数は各 100 回，各種パラメータは表 4.1 の設定と同じである．

結果 結果を，表 4.2 に示す．

結果に多少の差が見られるが，AGEDDASI TOF をほぼ実装できたといえる．

	MAE ($\times 10^2$)		RMSE ($\times 10^2$)	
	AGEDASI TOF	基礎モデル	AGEDASI TOF	基礎モデル
$k = 1$	1.78	1.03	2.21	1.44
$k = 4$	2.53	1.93	2.85	2.23
$k = 13$	4.96	5.04	6.07	7.00
$k = 26$	5.41	6.25	6.99	7.79
$k = 52$	8.53	8.90	10.46	11.25

表 4.2 基礎モデルの検証

4.2 情報交換の改良

4.2.1 基礎実験

まず，3.1.1 で述べた情報交換の改良モデルに関する実験結果を示す．

エージェント数

様々なエージェント数 (10, 20, 30, 50, 75, 100, 200, 300, 500, 750, 1000 人) でシミュレーションを行った．トレーニング回数は 20 回，シミュレーション回数は 100 回，情報交換・学習に関するパラメータは仮に $R_h = 0.3$ ， $P_s = 0.7$ ， $P_{mutation} = 0.003$ で行った．以下に結果の一例を示す．図 4.3 は各人数で行ったシミュレーションの平均データを示している．100 人を超えたあたりからレートのパスがかなり不規則になっている．

次に，シミュレーション回数に対する平均平方誤差 (RMSE) を考える．

$$\text{RMSE}(k) = \sqrt{\frac{\sum_{n=1}^N [\tilde{S}_n(t+k) - S(t+k)]^2}{N}} \quad (4.3)$$

($\tilde{S}_n(t)$: シミュレーションパス n での期間 t の現実の為替レート (対数))

これは，すなわちシミュレーションパスの平均が現実のレートと仮定したときの分散である．これによって各シミュレーションパスの散らばり具合を見ることができる．この結果を図 4.4 に示す．




図 4.3 様々なエージェント数のシミュレーション平均データ

トレーニング期間: 1991 年 1 月第 1 週 ~ 1992 年 12 月最終週

シミュレーション期間: 1993 年 1 月第 1 週 ~ 1994 年 12 月最終週




図 4.4 シミュレーション回数に対する RMSE (様々なエージェント数)

エージェント数が 100 人くらいまでは比較的安定しているが、200 人を超えるとエージェント数に応じて RMSE の値が大きくなっていく。1 つ 1 つのシミュレーションパスを見ると 100 人以下の場合では見られなかったような、レートが単調増加していくパスやかなり大きな変動を伴うパスが見られる。200 人を超えるとあまりにも系が不安定になるため、以降の実験は 100 人で行うことにする。しかし、現実の市場では市場参加者は 100 人よりもはるかに多いと思われるため、モデルの実装に何らかの不備が考えられる。この点は今後の課題である。

パラメータの決定

情報交換・学習に関するパラメータの最適値を求める実験を行った。 $R_h = \{0.1, 0.3, 0.5\}$, $P_s = \{0.1, 0.4, 0.7\}$, $P_{mutation} = \{0.3, 0.03, 0.003\}$ からいろいろな組合わせで行った。図 4.5 はその一部である。

その結果、最も予測精度の高い組合わせは $R_h = 0.3$, $P_s = 0.7$, 0.003 であった。




図 4.5 様々なパラメータのシミュレーション平均データ

トレーニング期間: 1991 年 1 月第 1 週 ~ 1992 年 12 月最終週

シミュレーション期間: 1993 年 1 月第 1 週 ~ 1994 年 12 月最終週

トレーニング回数: 20 回, シミュレーション回数 1000 回




図 4.6 様々なトレーニング回数によるシミュレーション

トレーニング期間: 1995 年 1 月第 1 週 ~ 1996 年 12 月最終週

シミュレーション期間: 1997 年 1 月第 1 週 ~ 1998 年 12 月最終週

トレーニング回数

様々な期間でトレーニング回数を変えてシミュレーションを行った。その際のトレーニング期間は 2 年間（約 100 週）、トレーニング回数は 1, 5, 10, 20, 30, 50, 75, 100, 200, 300 回である。それぞれのトレーニング回数に対してシミュレーションを 1000 回ずつ行い検証にはその平均を用いた。図 4.6 にその一例の結果を示す。また、そのシミュレーション回数に対する平均平方誤差を表 4.3 に示した。

1 回のトレーニングではシミュレーションパスにかなりのばらつきが見られる。このケースだとトレーニング回数が 5 回以上になればシミュレーションパスの平均、ばらつきも安定し始めている。

この結果から、以下の実験ではトレーニング回数を 20 回とした。

トレーニング回数	1 週間後	4 週間後	13 週間後	26 週間後
1	0.00829074	0.0125271	0.0690361	0.183706
5	0.00860381	0.0301967	0.0840853	0.0620826
10	0.00868609	0.031355	0.0866268	0.0621491
20	0.0087334	0.0308209	0.0864268	0.0585375
30	0.00865971	0.0309082	0.0864268	0.0634746
50	0.00871615	0.0313892	0.0872428	0.0630983
75	0.00865042	0.0312998	0.0861342	0.0604219
100	0.00871957	0.0310781	0.0864714	0.0599548
200	0.00873978	0.0305234	0.0851908	0.0619277
300	0.00872054	0.0308754	0.0856599	0.0590426

表 4.3 シミュレーション回数に対する RMSE (様々なトレーニング回数)

シミュレーション回数

様々な期間でシミュレーション回数を変えてデータの平均をとった．その際のトレーニング期間は 2 年間 (約 100 週) ，トレーニング回数は 20 回とした．図 4.7 はそれぞれについて，シミュレーション開始後 1 週間，4 週間，13 週間，26 週間，52 週間の予測誤差 (現実のレートとの誤差) を計算しグラフにしたものである．

980 回近くから，安定してきている．シミュレーション回数は 1000 回以上あれば十分であると思われる．

4.2.2 実験結果

1986 年 1 月から 1998 年 12 月までの現実の予想材料とレートのデータを用い，基礎モデルの検証と同様の方法を使って，提案モデルの評価を行った．

提案モデルのシミュレーションはエージェント 100 人，トレーニング回数は各 20 回，シミュレーション回数は各 1000 回， $R_h = 0.3$ ， $P_s = 0.7$ ， $P_{mutation} = 0.003$ で行った．




図 4.7 様々なシミュレーション回数の平均データの予測誤差

トレーニング期間: 1991 年 1 月第 1 週 ~ 1992 年 12 月最終週

シミュレーション期間: 1993 年 1 月第 1 週 ~ 1994 年 12 月最終週

それぞれシミュレーション回数 1000 回の誤差を 100%とした。

	MAE ($\times 10^2$)			RMSE ($\times 10^2$)		
	AGEDASI TOF	基礎モデル	提案モデル	AGEDASI TOF	基礎モデル	提案モデル
$k = 1$	1.78	1.03	0.98	2.21	1.44	1.30
$k = 4$	2.53	1.93	1.82	2.85	2.23	2.06
$k = 13$	4.96	5.04	4.27	6.07	7.00	6.08
$k = 26$	5.41	6.25	5.74	6.99	7.79	6.90
$k = 52$	8.53	8.90	8.36	10.46	11.25	10.08

表 4.4 提案モデルの評価

結果

結果を、表 4.4 に示す。

提案モデルは平均絶対誤差 (MAE)、平均平方誤差 (RMSE) とともに、ほとんどの期間で AGEDASI TOF よりも小さかった。これらのことは AGEDASI TOF における情報交換の仕組みよりも直感的にもモデルの精度においてもより現実的な仕組みを実装できたと考えることができる。

4.3 自己学習の導入

4.4 自己学習の導入

前節の提案モデルにさらに自己学習の仕組みを実装した。本研究における自己学習は予想要因 $x^k(t)$ ($\neq 0$) に対する重みづけに対し、その他の重みづけを固定した上でその重みづけを 1 段階ずつ上下に変化させた重みづけ列を生成し、生成された重みづけ列の中で最も予測誤差が小さかった重みづけ列に変更するというものである。

自己学習を行う確率 P_l を変化させて、シミュレーションを行った。結果を図 4.8、4.9 に示す。いずれの結果もトレーニング期間終了から 16 週（約 4 か月）は自己学習をした方が予測誤差が小さくなっている。しかし、長期に見ると自己学習をするモデルは誤差が大きくなっていく。これは自己学習を行うことでより、直前の期間への適応度が高いエージェントが多くなり、市場に存在する重みづけ列の種類が少なくなるためではないかと思われる。トレーニング期間終了からあまり時間が経たないうちは、うまく市場




図 4.8 様々な P_i でのシミュレーション平均データ

トレーニング期間: 1991 年 1 月第 1 週 ~ 1992 年 12 月最終週

シミュレーション期間: 1993 年 1 月第 1 週 ~ 1994 年 12 月最終週




図 4.9 様々な P_i でのシミュレーション平均データ

トレーニング期間: 1993 年 1 月第 1 週 ~ 1994 年 12 月最終週

シミュレーション期間: 1995 年 1 月第 1 週 ~ 1996 年 12 月最終週

の状況を捉えているが、ひとたび大きな変化が起きると、それに適応するエージェント（重みづけ列）が少なく、市場全体に新たな認識がうまく広がらないためではないかと思われる。この点については、学習率を活かした長期に適応度の高い重みづけ列に変化させる学習の仕組みや、情報交換のパラメータとの兼ね合いも考える必要があると思われる。

また、自己学習で値を変化させるエージェントは自己学習を行う確率が P_l のとき、ほぼ $P_l \times N$ 人であったが自己学習を行うかどうかでシミュレーションパスは大きく変化した。そこに P_l の値との関係は見られなかった。この点に関しても検証が必要である。

4.5 多様なエージェントの実装に関する結果

以下の実験では自己学習を行わない提案モデルを用いている。トレーニング回数は 20 回、各パラメータは $R_h = 0.3$ 、 $P_s = 0.7$ 、 $P_{mutation} = 0.003$ である。

4.5.1 ファンダメンタリスト、チャーティストの実装

ファンダメンタリスト、チャーティストの存在する市場の特性

まず、ファンダメンタリストのみが 100 人いる場合とチャーティストのみが 100 人いる場合のシミュレーション結果を図 4.10 に示す。

ファンダメンタリストのみが存在する市場のシミュレーションパスはファンダメンタル材料とトレンド材料を同等に扱う通常のディーラーのみが存在する市場とほぼ同じである。シミュレーションの対象期間によっては通常のディーラーのみの市場よりもパスが安定している。これはレートの変化に基づく予想を行わないためであり、自明である。

一方、チャーティストのみが存在する市場ではシミュレーション期間で全くレートの変動が起こっていない。これは十分な回数のトレーニングを行うと、トレンド材料に対する重みづけがほぼ一様になり、シミュレーション開始直後には取引が行われない。さらにその状態（レートが変化しない状態）がしばらく続くとトレンド材料がすべて 0 になり、例えば重みづけが変化しても予想されるレート変動値が 0 になってしまい、ずっとその状態が続く。




図 4.10 ファンダメンタリスト，チャーティストのみが存在する市場のシミュレーション

トレーニング期間: 1991 年 1 月第 1 週～1992 年 12 月最終週

シミュレーション期間: 1993 年 1 月第 1 週～1994 年 12 月最終週

各シミュレーション 100 回の平均データ

次に、ファンダメンタリストとチャーティストがともに存在するような市場を考える。本研究のモデルでは、チャーティストが少しでもいるとたちまち市場が不安定になった。シミュレーション回数に対する平均平方誤差（シミュレーションパスの平均が現実のレートと仮定したときの分散）を図に示した。

チャーティストが市場参加者に占める割合が増えるにしたがって、シミュレーションパスの不安程度が増すのがわかる。

シミュレーションパスの分析

本研究のチャーティストの存在する市場モデルで図 4.11 で示されているようなパスは典型的なものである。ここでは図 4.11 のパス 1 のような急激な円高がどうして起こるのかということについて分析を試みる。

この解析を行う鍵は、チャーティストの関係するトレンド材料とそれに対する重みづけであると考えられる。図 4.12 に 3 つのトレンド材料とそれに対する各エージェントの重みづけを示した。

各グラフを見ると、予想材料の短期トレンド $1(x^{15})$ 、短期トレンド $2(x^{16})$ に対するエージェントの重みづけはシミュレーション期間では多くのエージェントが 0 である。急激な円高の原因はシミュレーション期間において常に -3 を取り、かつほとんどのエージェントが重みづけを $+3$ に設定している長期トレンド x^{17} であると考えられる。これはトレンドがトレンドを生む、チャーティストによる特徴的なバンドワゴン効果である。ほぼ全エージェントの重みづけが $+3$ になっていることから、実際には予想に使用しないもののファンダメンタリストもチャーティストに引っ張られる形となっている。

全エージェントが市場に対する認識を同じくすると、市場にチャーティストのみが存在している例のように取引が成立せず、そのコンセンサスは本来終わりを迎えるのだがこのケースではトレンドを無視する一部のファンダメンタリストによるドルの需要があるため、取引が成立しさらに円高に進んでいく。

これは投機バブルを生むのはファンダメンタリストとチャーティストの共同作用によるものであるという [8] で示される結果に合致する。




図 4.11 ファンダメンタリストとチャーティストがともに存在する市場
のシミュレーション

トレーニング期間: 1991 年 1 月第 1 週 ~ 1992 年 12 月最終週

シミュレーション期間: 1993 年 1 月第 1 週 ~ 1994 年 12 月最終週

ファンダメンタリスト 90 人, チャーティスト 10 人






図 4.12 シミュレーションパス 1 (図 4.11) におけるトレンド材料に対する重みづけの変化

4.5.2 介入エージェントの実装

[10] で分析に用いられている目標為替相場仮説を採用した介入エージェントを実装し、10 月に 1 週間で 20 円もドル-円レートが下落した 1998 年のシミュレーションを行った。

まず、介入エージェントが存在しない通常のディーラーのみのシミュレーション結果を図 4.13 に示す。




図 4.13 介入エージェントが存在しない市場のシミュレーション

トレーニング期間: 1996 年 1 月第 1 週 ~ 1997 年 12 月最終週

シミュレーション期間: 1998 年 1 月第 1 週 ~ 1998 年 12 月最終週

シミュレーションの結果を時間的変化をもとにグループ分けを行った。8 月末の時点でも 12 月の時点でも 136 円以上であったシミュレーションパスを上昇グループ、8 月には 136 円以上まで上昇した後、116 円から 136 円の間まで下降するかもしれない 1 か月以内に 10 円以上の下落が起こったパスをバブルグループとした。また、常に 116 円から

136 円の間レートがあったパスを安定グループとした．図 4.13 にはその典型的なシミュレーションパスが示されている．すなわちパス 1 が上昇グループ，パス 2 が安定グループ，パス 3 がバブルグループである．介入エージェントが存在しない市場のシミュレーションでは 100 回のシミュレーション中，80%近くが上昇かバブルグループに属し，安定グループに属すパスは 15%程度であった．

そこで，よりレートの安定を保つために介入エージェントを 1 人加えたシミュレーションを行った．介入方法を以下に再掲する．

$$Q_i(t) = \begin{cases} -q_i \Delta S(t-1) & (S(t-1) < T(t-1) \text{ かつ } \Delta S(t) < 0 \\ & \text{or } S(t-1) > T(t-1) \text{ かつ } \Delta S(t) > 0) \\ 0 & (\text{それ以外のとき}) \end{cases}$$

$$\left(\begin{array}{l} T(t): \text{ 期間 } t \text{ の目標為替レート} \\ Q_i: \text{ 介入量} \\ q_i: \text{ 介入の基準量 } (> 0) \\ S(t): \text{ 期間 } t \text{ の為替レート} \\ \Delta S(t) = S(t) - S(t-1) \end{array} \right)$$

ここで，目標為替レート $T(t)$ は単純化のために期間によらず常に 130 円とした．また，介入の基準量 q_i は Q_i が通常のディーラー 1 人の売買要求量と同程度になるように調整した．これは介入のポートフォリオ・バランス効果を小さくし，シグナル効果を見るためである．

最初に，介入エージェントが存在し介入を行うがその行動が予想材料の介入の項目 $x^8(t)$ にフィードバックしない場合のシミュレーションを行った．これは介入が行われたという情報が全くディーラーに伝わらない状態であり，介入の影響は完全にポートフォリオ・バランス効果だけに限定される．シミュレーションを 100 回行い，そのシミュレーションパスをグループに分類した結果を表 4.5 に示す．

上昇グループ	バブルグループ	安定グループ	下降グループ
47 %	24 %	16 %	7 %

表 4.5 予想材料にフィードバックされない場合のシミュレーションパスの分類

上昇，バブルグループを合わせたパスの割合は少し減っているものの，安定グループに属すパスの割合は特に増えていない．

次に，介入エージェントの行動が予想材料の介入の項目 $x^8(t)$ にフィードバックされる場合のシミュレーションを行った．予想材料 $x^8(t)$ は，期間 $t - 1$ における介入エージェントの行動によって決定し，その内容はドル売りなら負，ドル買いなら正となりその大きさは介入量に比例する．シミュレーションを 100 回行い，そのシミュレーションパスをグループに分類した結果を表 4.6 に示す．

上昇グループ	バブルグループ	安定グループ	下降グループ
35 %	8 %	29 %	7 %

表 4.6 予想材料にフィードバックする場合のシミュレーションパスの分類

上昇，バブルグループに含まれるパスの割合が明らかに減少し，安定グループに属すパスの割合が大きくなっていることがわかる．

考察

介入エージェントの参加する市場の以上 2 つのシミュレーション結果より，介入量が小さいときにはポートフォリオ・バランス効果は小さいがシグナル効果を勘案すれば介入の効果を期待できるということが示せた．

しかし，予想材料へ介入エージェントの行動がフィードバックする場合のシミュレーションでは図 4.14 のような，レートの下落が進み続けるパスもいくつか見受けられた．

これは，ディーラーのコンセンサスが予想要因の介入 x^8 に対し負の重みづけを取り，トレンド材料に対して正の重みづけを取るというものになっていると考えられる．ほとんどのディーラーがこのような重みづけをした場合，取引が成立せずそのコンセンサスは終わりを迎えるが，この場合はこれ以上の円高を防ごうとする介入エージェントのドル買い介入という需要があるため，コンセンサスが変わらず円高が進行し続ける．介入量がディーラーの供給を圧倒するくらい十分大きく，ポートフォリオ・バランス効果が十分期待できる場合にはこういったことが起こらないので，介入量が小さい場合にのみ起こることである．




図 4.14 レートの下落が続くシミュレーションパスの例

しかし、現実には全ディーラーの売買要求量を完全に圧倒できるような介入量は考えられないため、更なる安定を目指すには介入エージェントに柔軟な対応を行わせる必要があると思われる。

第 5 章

おわりに

5.1 まとめ

本研究では，人工市場モデル AGEDASI TOF を情報交換・学習の改良，ディーラーエージェントの拡張により，より現実的な人工市場モデルを作成した．

AGEDASI TOF ではエージェント間の情報交換においてレート予測に成功したエージェントの重みづけをすべてコピーしたり，レート予測の成功失敗が決まった段階で対等に重みづけを交換すると言った非現実的な方法が用いられていた．そこで本研究では予測に成功したエージェントからレート予測に関する重みづけだけコピーするという方法を提案した．この方法であればレートに予測に関係ない認識まで変更することがなく，エージェントの個性をむやみに失わせることも防ぐことができる．このモデルを使い，AGEDASI TOF よりもモデルの予測精度を高めることができた．また，予測誤差を小さくするように重みづけを自身で変更することで，情報交換を行わずに自己学習を行う方法も提案した．

一方，AGEDASI TOF ではエージェントの目的，レートの予測方法などが同じであり，そういった点でのエージェントの多様性はなかった．しかし，現実には様々な目的，予測方法を持ったディーラーが存在する．そこで本研究ではファンダメンタリストとチャートリストと呼ばれる典型的なレートの予測方法を持ったディーラーの実装を行い，それぞれが存在する市場の特徴を調べた．また，現実の政府・中央銀行にあたる介入エージェントを提案した．AGEDASI TOF でも予想材料の介入のパラメータを操作することで最適な政策の探索を行うことが可能であるが，シミュレーションにおける市場が例えば

ドル売り介入時に急激な円高など予期せぬ方向に動いたとき動的に対応することが不可能であった．本研究では介入を行う中央銀行を1エージェントとして系に組み込むことで動的な介入，分析を可能にした．本研究ではこのモデルの適応例として，介入量が小さいときの介入のレートに対する影響，すなわちポートフォリオ・バランス効果，シグナル効果について調べ，介入量が小さいときにレートの安定をもたらすのはシグナル効果による影響が大きいことがわかった．

5.2 今後の課題

情報交換・学習については本研究では自己学習での重みづけの変更方法は1つのパラメータに対して直前の期間により適応できるように変更するものであった．この発展として自己学習で変更する重みづけの数，また学習率を活かした長期に適応する重みづけへの更新などが考えられる．また，本研究では自己学習を他のエージェントとの情報交換による学習と完全に独立に考えたが，本来お互いに関係し合うものであるのでそれぞれの起こる確率などはともに考慮して検討する必要がある．

また，エージェントの多様化に関しては本研究で提案した目的，予測方式の違うエージェント以外にも戦略の違うエージェントなどが考えられる．予測方式に関しても本研究で提案したものは最も単純なものであり，トレンド材料から複雑に計算して予測を行ったり，ファンダメンタルズ分析とチャート分析を使い分けるなどが考えられる．

本研究では政府・中央銀行にあたる介入エージェントは介入しか行えないが現実の政府は口先介入を行ったり金利を操作したりすることが可能である．単純に介入を行うだけでなく，状況に応じて口先介入や金利操作なども行えるエージェントを作成しシミュレーションを行えば，為替政策全体のシミュレーションを行うことが可能になると考えられる．

これらが今後の課題である．

参考文献

- [1] D.E.Goldberg. *Genetic algorithms in search, optimization, and machine learning*. Addison–Wesley Publishing Company, 1989.
- [2] Katharyn M. Dominguez and Jeffrey Frankel. Does foreign exchange intervention matter? disentangling the portfolio and expectations effects for mark. *American Economic Review*, Vol. 83, No. 5, pp. 1356–1369, 1993. NBER Working Paper # 3299.
- [3] Kiyoshi Izumi. *An Artificial Market Model of a Foreign Exchange Market*. PhD thesis, Department of General Systems Studies, Graduate School of Arts and Sciences, the University of Tokyo, 1998.
- [4] 和泉潔, 植田一博. 人工市場アプローチによる為替シナリオの分析. コンピュータソフトウェア, Vol. 17, No. 5, pp. 47–54, 2000.
- [5] 和泉潔, 植田一博. 人工市場入門. 人工知能学会誌, Vol. 15, No. 6, pp. 941–950, 2000.
- [6] 和泉潔, 植田一博. 金融市場における意図せざる協調現象 — 人工市場アプローチによる分析. 植田一博, 岡田猛 (編), 協同の知を探る, pp. 199–227. 共立出版, 2000.
- [7] Kiyoshi Izumi and Kazuhiro Ueda. Phase transition in a foreign exchange market: Analysis based on an artificial market approach. *IEEE Transactions on Evolutionary Computation*, Vol. 5, No. 5, pp. 456–470, 2001.
- [8] Taisei Kaizoji. A synergetic approach to speculative price volatility. *IEICE Transaction on Fundamentals of Electronics, Communications and Computer Sciences*, Vol. EA82-A, No. 9, pp. 1874–1882, 1999.

- [9] U-mart 研究会 web site. <http://www.u-mart.econ.kyoto-u.ac.jp/>.
- [10] 渡辺努. 市場の予想と経済政策の有効性. 東洋経済新報社, 1994.
- [11] 塩沢由典. 経済学にとっての人工市場. 人工知能学会誌, Vol. 15, No. 6, pp. 951–957, 2000.