

エージェントアプローチによる人工市場の構築と評価

辻岡 卓・山本 耕司

Construction and Evaluation of an Artificial Market by Agent Approach

Suguru TSUJIOKA, Kohji YAMAMOTO

ABSTRACT

In recent years, market structure is changing quickly and intricately. It is recognized as man's psychology and actions being indispensable to arbitration of a price. Therefore, in a traditional economic theory, it is extremely ideal and sufficient prediction has not been completed.

In this paper, vegetable and fruit markets are simulated as an artificial model, and multi-agents predicted market prices with genetic algorithms. Since this system predicted the wholesale price with sufficient accuracy, it is fully practical and can secure a market participant's profits.

KEYWORDS: Agent Based Model, Artificial market, Genetic algorithm, Complicated market, Computer simulation

1. 背景

従来の経済理論において市場動向をシミュレートする際に主流となっている手法は、対象とする市場動向を数種類の説明変数の連関により構成される方程式で表現し、これらは一般に Equation Based Model (通称 EBM) と呼ばれている¹⁾。方程式の表現対象が、明らかに個別行動を主体とした相互行動の結果によるものであっても、EBM ではそれらを考慮することはない。それはこの背景に合理的期待仮説²⁾があるからである。合理的期待仮説の定義では「全ての市場参加者の情報、認知モデル、効用関数が同じであること (期待の合理性)」と「全ての市場参加者の期待が合理的であることを全ての市場参加者が知っていること (共有知)」の2つが軸になっている³⁾。

しかし、近年合理的期待仮説による市場モデルに対し、理論や実証の双方からさまざまな問題点が指摘されている³⁾。これらの問題点は、合理的期待仮説がその定義の1に則り、全ての市場参加者の期待を本質的に同一であると仮定しているた

め、市場参加者各々の本来異なるべき適応行動を考慮していないことから生じている。

また、EBM を用いずに市場動向をコンピュータで模擬する場合、従来は市場動向を左右する個々の要因について、「こうなればああする」式のプロダクショナルルールに基づいたモデルが用いられてきた。しかし、実際の市場ではこれらの決定要因以外の偶発的現象が、価格決定に大きく影響することもしばしばあるのが現実である。

これらに代表される従来の経済理論と現実市場の乖離を埋める一つの解答として、人工市場アプローチが注目されている。これは経済学・工学など、さまざまな分野から、またこれらが有機的に結びついた学問境界領域から努力的な研究が進められつつある。

本研究ではマルチエージェントを用い、青果物卸売市場を模擬した人工市場モデルを構築した。現在、青果物卸売市場に出荷する生産者のほとんどが市場における青果物価格の正確な予測を強く望んでいる。本論文はこのような生産者利益を追求する実益と、市場動向のモデリングと予測とい

受理日：平成13年10月12日

う複雑系を扱った数理的経済学的基础概念の確立という2つの目的を実現する手段として、最も有効なシミュレーション手法の研究・開発について述べたものである。

2. 人工市場の概要と本研究分野の現況

人工市場はその名のとおりに、コンピュータ上に構築された仮想の市場であり、学習能力を持った自立的なエージェントたちにより売買が行なわれる。この仮想の市場関係者であるエージェントはローカルな情報のみにより学習を行ない、その予測システムを刻一刻と変化させる。また、各エージェントは何かしらの情報を入力として受取り、自分なりの予測システムに基づいて行動決定を行い、売買行動などを出力する。

人工市場は経済的な市場構造のモデルである。つまりエージェントの市場行動の結果、価格(レート)が決定されるようなメカニズムを持っている。価格決定のメカニズムとしては主に、実際の市場のように売り手と買い手が出会って個別に売買が成立していく「相対型」と、市場全体の需要と供給をいったん全て集めて需給が釣り合うところに価格(レート)が決定される「均衡型」の2種類に分かれる。前者を「ざら場」式、後者を「板寄せ」式と呼ぶこともある。⁴⁾

このような研究の目的は、シミュレーション結果の解析を行い、金融市場のマクロ的な特徴の分析、ミクロな行動とマクロ現象との関係の解明等を目的とするグループと、より実践的に予測精度をどれだけ上げられるかを求めるグループの2者に分かれている。前者のグループでは分析対象として、バブル現象をはじめとする創発現象の解明や、合理的期待仮説をはじめとする従来の経済理論で言われてきたいくつかの市場に関する仮説の検証を目指している。また、後者のグループではヘッジファンド等の予測にみるように、大きい変動は逃さないというレベルまで実際に実現しており、現在は予測精度の向上がどの程度まで可能なかが分析対象として挙げられている。⁵⁾

3. 本研究に関連する他の研究例

既存の研究の中から本研究に特に関連深いものを、以下に示す。

「人工市場アプローチによる為替レートの分析」³⁾

和泉らは為替市場をターゲットとして人工市場を構築し、予測力と説明力の評価を行なっている。その結果、1988年から1991年の為替バブルの成長と崩壊の原因を「市場参加者の予想の同調と完全な一致による」として説明することに成功している。

この研究では、各エージェントの予想システムが予想材料の重要度をパラメータとした線型式で表現されている点において本研究と共通している。しかし、和泉らのモデルでは買い手と売り手が具体的ではないのに対し、本研究では青果物市場を扱っているため、買い手と売り手をはっきりしている。このため基本的なフレームワークは異なっている。

「U-Mart Project」⁶⁾

ここでは共通テストベッドとしての人工市場を準備し、コンテスト形式で様々なエージェントや人間のトレーダーを混在参加させるプロジェクトであり、株価指数を取引する仮想先物市場をターゲットとしている。予測システム、入力情報、学習システムの異なる多様なエージェントやトレーダーを参加させることにより、発生する創発現象を観察する。また、全てのデータは各研究者により収集されるというものである。

本研究でも多様なエージェントの参加を予定しており、遺伝アルゴリズムを学習システムに採用した個性的なエージェント100個を用いて予測力を確認しようと考えている。

“Designing economic agents that Act Like Human Agents: A Behavioral Approach to Bounded Rationality”⁷⁾

ここでは複数のIF-THEN式の集合で表されるルールを持ったエージェントによる人工株式市場を構築し、人工株式市場でシミュレートされた価

格と、従来の経済学の合理的期待仮説が成立した場合の価格とを比較検証している。シミュレーションの結果、各エージェントの持つ予測ルールの複雑性は時とともに上昇し、市場全体での多様性も増加することを証明している。

学習行動には各予測ルールをビット列で表現して遺伝的アルゴリズムを用いて変更していく方法をとっているが、本研究でもこれと同様に遺伝的アルゴリズムを用いている。しかし、本研究においてはビット列による遺伝子型を用いていない点において独自性がある。

“Volatility Clustering in Financial Markets : A Micro Simulation of Interacting Agents”⁸⁾

ファンダメンタリストとチャートリストの2種類が存在する人工株式市場で、実際の市場で見られる価格の時系列的特徴の再現と解析を行なっている。

ファンダメンタルズ要因をエージェントの予想ルールへ組み込んでいる点において本研究と共通する。

4. 本研究で用いた人工市場の仕組み

本研究で構築した人工市場は市場エージェント (Market Agent) 100個、消費エージェント (Consumption Agent) 100個からなる。これらはそれぞれ現実の市場の卸売業者、小売業者に対応しており、また扱う対象が青果物卸売市場であることから市場エージェントは売却、消費エージェントは購入のみの取引を行なう。

それら合計200個のエージェントが、1回あたりの単位処理時間を現実の1日に対応させ、この1つの単位時間 (Time Unit) 毎に、知覚 (Consciousness Step)、予想形成 (Anticipation Step)、取引 (Dealing Step)、学習 (Study Step) の4つのステップを行い、再び知覚ステップ、予想ステップを繰り返すループ構造になっている (図1)。以下に各ステップについて説明する。

4.1 知覚ステップ

各Time Unit (以後 t_u と記載する)の最初に各エージェントは、その t_u が始まるまでに入ってきた様々な予想要因を知覚する。予想要因は気温や風速、降水量などそれぞれが異なる単位をもつ物理量であるため、これらを異なるスケールのまま比較対照することができない。そこで本研究ではまず、それぞれの予想要因を次に示す独特の換算手法によって日本円に換算した。式1に示す換算値 F の持つ意味は、シミュレーション期間全体を通じての予想要因それぞれの最大値、平均値、最小値が、現実市場の平均取引価格のそれらと等値にすることである。

$$D \geq \bar{D} \text{ のとき} \\ F = \frac{\bar{P}}{\bar{D}} D + \frac{P_{\max} - \bar{P}}{D_{\max} - \bar{D}} (D - \bar{D}) \dots \text{ (式1)}$$

$$D < \bar{D} \text{ のとき} \\ F = \frac{\bar{P}}{\bar{D}} D + \frac{\bar{P} - P_{\min}}{\bar{D} - D_{\min}} (\bar{D} - D) \dots \text{ (式1)}$$

- D : 予想要因の値
- \bar{D} : 予想要因の平均値
- D_{\max} : 予想要因の最大値
- D_{\min} : 予想要因の最小値
- \bar{P} : 平均取引価格の平均値
- P_{\max} : 平均取引価格の最大値
- P_{\min} : 平均取引価格の最小値

更に価格換算した要因の時間的変動が、換算後、現実の市場平均取引価格と比較して最も相関が高



(図1) 本人工市場モデルの基本的なワークフロー

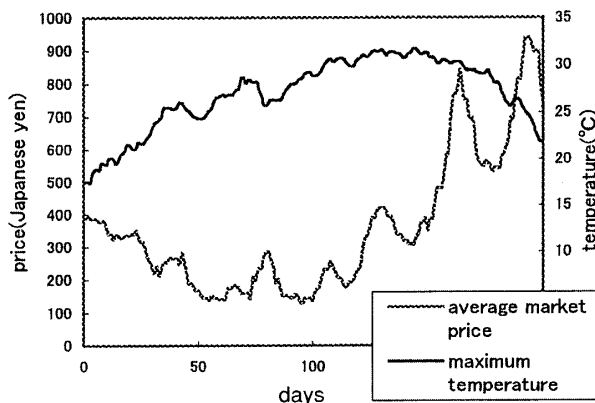
くなるようシフトして日数を求め、このときの換算値を要因値とした。こうして季節変動や要因そのもののもつ青果物価格とのタイムラグによるバランスをとることに成功した。

最適シフト日数算出方法は平均取引価格の推移曲線と予想要因の価格換算値の推移曲線の絶対差の時間積分値を δ 値として算出することとした。この δ 値が小さいほど相関が高いといえる。そこで予想要因の推移曲線の値を1日ずつシフトしていきながら、 δ 値をプロットし、シフト日数に対する δ 値のグラフが最小となる日数を確認し、以後この日数だけシフトした予想要因値を対象とすることとした。

例としてトマトの平均取引価格と最高気温の価格換算値の推移を示す。本例においてはシフト前の δ 値は13114.07であるのに対し(図2-1), 1日ずつ最高気温の価格換算値を右にシフトした結果, シフト日数75日で δ 値が最小の4937.08を示した(図2-2)ため, これをシフト日数として用いることとする。

4.2 予想形成ステップ

各エージェントは予想要因に対して各自異なる重要度の組み合わせ(以下, 予測システム)を持っている。仮に予想要因が n 個あるとすると, t 期の予想要因 i の価格換算値に対するエージェント A の重要度係数を $I_i^A(t)$ (ただし $i=1, 2, 3, \dots, n$) とすると, 予想平均取引価格 $P_A(t)$ は(式2)で算出される。



(図2-1) トマトの平均取引価格と最高気温の推移(シフト前)

$$P_A(t) = I_1^A F_1(t) + I_2^A F_2(t) + I_3^A F_3(t) + \dots + I_n^A F_n(t) \quad (式2)$$

ここで $F_i(t)$ は予想要因 i の価格換算値

4.3 取引ステップ

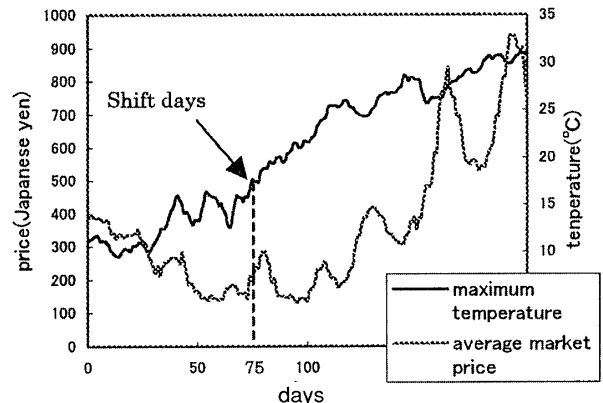
全エージェントの売買戦略を市場全体で集積して, 需要と供給が均衡するように市場エージェントと消費エージェントを組み合わせる。

各市場エージェントは予想形成ステップにおいて決定した予想平均取引価格を各エージェント自身の希望取引価格とし, それに近い希望取引価格を示した消費エージェントと取引を行なう。各消費エージェントも同様の手順を踏み, 取引を行なう。具体的には市場エージェントと消費エージェントのそれぞれを希望取引価格の低い順にソートし, 同じ順位同士のエージェント間で取引を行わせた。また, その取引価格は両エージェントの希望取引価格の平均値とした。ここで全取引価格の平均値を算出しておき, これを当該 t_u の平均取引価格として記憶しておく。

4.4 学習ステップ

各エージェントは各々の t_u 毎に, 前 t_u において発生した平均取引価格と予想値との差をもとに, 自身の予測システムの精度を上げるため学習を行なう。

現実市場における市場参加者も, 常に, その時の市場が注目している予想要因を探り, それを自分が予想形成の際に価格予想の材料にしようとしている。この適応行動には自明であるいくつかの



(図2-2) トマトの平均取引価格と最高気温の推移(シフト後)

特徴が存在する。これらを以下に列挙する。

- ・ 予測力の低い予測システムを保持する市場参加者は市場から撤退するか、予測システムを変更する。このため十分に時間が経ったときは、市場はある程度予測力の高い予測システムを持った市場参加者が大多数を占めるようになる。
- ・ ある市場参加者の持つ予測システムが、ある程度の正確さをもって他の市場参加者に伝播する。
- ・ 市場参加者間の相互作用や、ある市場参加者の独自の発案により、常に様々な予測システムが発生する。

4.5 遺伝アルゴリズムの適用

市場における適応行動に見られるこれらの特徴は、生物の遺伝システムに例えることができる。このことから人工市場におけるエージェントの学習行動には遺伝アルゴリズムを用いた例がある。本研究の前段階で行なわれたシミュレーションによる同市場価格の予測過程を検証した結果、本研究でもこの遺伝アルゴリズムを適用することがシミュレーション精度を明らかに高めると判断した。

通常、遺伝アルゴリズムにより確率的探索・学習・最適化を行う際には各個体（本研究におけるエージェントに対応）の遺伝子型をビット列等で表わす。和泉ら³⁾の研究もこれに倣っている。しかし、ビット列で遺伝子型を表現する場合、予想要因の重要度係数を表すのに、遺伝子型とその表現型の2つのパラメータが必要となるため煩雑となる。また、遺伝子型の変化が、ある一定の形を示さないと表現型には影響を及ぼさないため、どうしても適応が緩やかになるという難点もある。特に本研究では現実世界の1日を1 t_u としているため、前日の平均取引価格をもとに有効な学習を行なわせることを前提とした場合に都合が悪い。そこで、各予想要因の重要度係数の値とその組み合わせを、直接的に遺伝子型及び表現型に用いることとした。

基本的なアルゴリズムはGoldberg⁹⁾を参照し、オペレータには選択、交叉、変異を採用した。以下、各オペレータについて具体的に述べる。

a. 選択

まず、前 t_u の各エージェントの予想平均取引価格と平均取引価格を比較し、適応度を算出する。適応度とは各予測システムの最適解への距離を表す指標であり、 t 期におけるエージェント A の適応度 $g_A(t)$ は(式3)で表現した。

当該 t_u における各エージェントは、自分自身を含めた全てのエージェントの予測システムの中から適応度の高いものを選択しようとする。具体的には適応度に比例した確率でその予測システムを選択する。 t 期におけるエージェント A の予測システムが各エージェントに選択される確率 $Pb_A(t)$ は(式4)のルーレット法で表現した。

$$g_A(t) = \frac{1}{|P_A(t) - M(t)| + 1} \quad (\text{式3})$$

ただし、 $M(t)$: t 期における平均取引価格

$$Pb_A(t) = \frac{g_A(t)}{G(t)} \quad (\text{式4})$$

ただし、 $G(t) = \sum_{k=1}^N g_k(t)$ ($k=1, 2, 3, \dots, N$)

適応度の高い予測システムは各期において選択されやすく、適応度の低い予測システムは淘汰される。したがって、各エージェントはこの適応度を高めることを指針に各期において学習を行なう。しかし、選択だけでは初期に設定した予測システムの優越を測るに留まってしまうため、選択の後に交叉を、交叉の後に変異を用いることとした。

b. 交叉

一定のごく低い確率で選ばれたエージェントの予想材料に対する重要度係数(式5)を、1箇所だけ他のエージェントとランダムに交換する(式6)。この交叉によって初期設定にはない新しい重要度係数の組み合わせが発生することとなる。ただし、現実の市場参加者はローカルな情報をもとに行動することが多い。そのため、これを表現する方法として各エージェントに通し番号をわりふり、この番号が隣接するエージェント同士でのみ交叉が行なわれることとした。

なお、これと同様に選択においてもルーレット法の範囲を狭めることにより、ローカル性の再現が可能ではあるが、最適解探索までの時間が長くなるため、本研究ではこの方法は採用していない。

$$\left. \begin{aligned} P_A(t) &= I_1^A(t)F_1(t) + I_2^A(t)F_2(t) + \dots \\ P_{A+1}(t) &= I_1^{A+1}(t)F_1(t) + I_2^{A+1}(t)F_2(t) + \dots \end{aligned} \right\} \quad (\text{式 5})$$

↓

$$\left. \begin{aligned} P_A(t) &= I_1^A(t)F_1(t) + I_2^{A+1}(t)F_2(t) + \dots \\ P_{A+1}(t) &= I_1^{A+1}(t)F_1(t) + I_2^A(t)F_2(t) + \dots \end{aligned} \right\} \quad (\text{式 6})$$

c. 変異

交叉よりもなお低い確率で選ばれたエージェントの重要度係数(式7)を、新たに乱数で決定した値に変更する(式8)。この変異により新しい重要度係数をもった予測システムが発生することになる。

$$P_A(t) = I_1^A(t)F_1(t) + I_2^A(t)F_2(t) + \dots \quad (\text{式 7})$$

↓

$$P_A(t) = I_1^A(t)F_1(t) + R(t)F_2(t) + \dots \quad (\text{式 8})$$

ただし $R(t)$: ランダムに決定した重要度係数

交叉・変異により、初期設定には存在しない新しい予測システムを持ったエージェントが市場に出現することになる。このことは、予測システムの多様性、及び解空間の拡大というメリットを得ることにつながる。しかし、限りなく最適解に近い理想的な予測システムに対しても、これら交叉・変異は同様に適用されるため、最適解への収束がどうしても遅くなってしまふという欠点も存在する。

このため、本研究では適応度の高いエージェントの予測システムを次期に継承させるため、最も適応度の高い予測システムに対しては交叉・突然変異を行わないというエリート戦略を採用した。このエリート戦略を用いることは、ある戦略が市場に急速に広がる可能性が高いため局所解に陥りやすいという欠点はあるが、本研究では各期毎にエリート戦略の採用を行なうかどうかをランダムに裁決することによってこれを解決することとし

た。このことにより、交叉・変異率を下げることなく、優秀な予想システムを次期に継承することが可能となった。

以上で述べた遺伝アルゴリズムを用いた学習によって、新たな予想システムを得たエージェントは、次期の知覚ステップへと進む。この一連の作業をシミュレーション期間として設定した日数分繰り返すことで本研究の人工市場は運用されている。

5. シミュレーションの方法

具体的にシミュレーションを行なうにあたり、まず、青果物市場の関係者へインタビューを行ない、14個の予想要因を得た。トマトを例に表1にこれら予想要因を列挙する。これらは4章で述べたとおり、データクレンジングを行ない、円価格に換算する。更に δ 値が最も小さくなるよう日数をシフトしている。シフト前後の δ 値とシフト日数を同様に表1に挙げる。

シミュレーション期間は現実の200日に対応する $200t_u$ とした。そして、その前半 $100t_u$ を学習シーン、後半 $100t_u$ を実践シーンと定義した(図3)。学習シーン、実践シーンともに知覚ステップにおいて、表1の予想要因すべてを入力データとして与え、それを基に各エージェントは予想形成ステップを行なう。

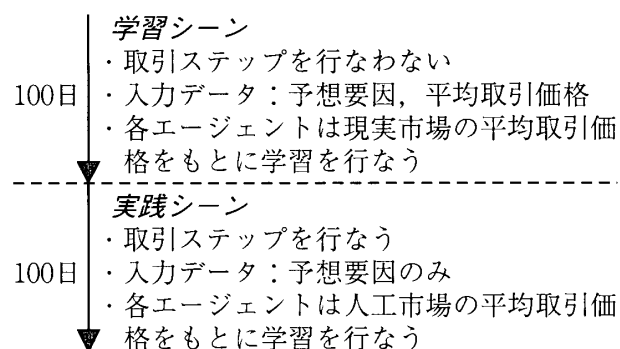
ここで、学習シーンにおいては取引ステップは行なわない。各エージェントは現実市場の平均取引価格と自分自身の予想平均取引価格を基に適応度を算出し、学習ステップにおいて予想システムの変更を行なう。このようにして、現実市場のダイナミズムを学習させる。

これに対し、実践シーンでは取引ステップにおいて各エージェントの希望取引価格を基に取引を行ない、それにより得られた人工市場内での平均取引価格を基に適応度を算出する。実践シーンの前に学習シーンを設けることにより、実践シーン開始時の予想システムが、ある程度現実に即したものとなることを狙った。

なお、学習シーン開始時点では各エージェントの持つ予想材料に対する重要度及びその組み合わせをランダムに与え、遺伝アルゴリズム中の交叉率は5%、変異率は1%、エリート保存戦略適用率は30%とした。これらのオペレータ、及び戦略の適用率はシミュレート期間100期で予想平均取引価格の誤差が25%以内になることを目標に設定した。

(表1) トマトの価格と各予想要因の相関

予 想 要 因	δ 値		シフト 日 数
	シフト前	シフト後	
最高気温	13114.07	4937.08	75
平均気温	12291.61	4785.47	69
最低気温	12439.00	4999.01	72
平均湿度	14222.06	7736.28	84
最低湿度	10880.03	4637.03	40
日照時間	14678.04	14427.21	9
降 水 量	18157.31	18157.31	0
平均風速	14050.31	12217.45	24
最大風速	12468.59	11246.93	17
平均株価	19460.12	5880.30	89
為 替	12842.35	9222.00	45
国内卸売物価指数			
・(農産物)	15402.19	7670.42	72
・(総平均)	15402.19	7141.75	89
出 荷 量	16435.54	6877.16	89




(図3) シミュレーション期間のシーン構成

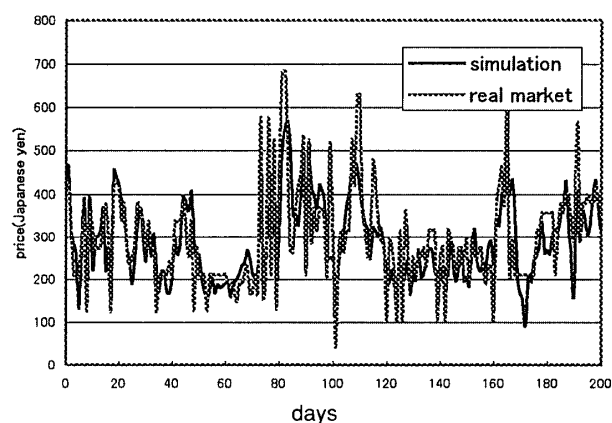
6. シミュレーション結果

図4-1及び図4-2にシミュレーションによる平均取引価格と現実市場の平均取引価格を示す。横軸中央の100日目を境に左側が学習シーン、右側が実践シーンである。前述のように実践シーンにおいては各エージェントは現実市場の平均取引価格には無関係に価格が予測されている。しかしこれにも関わらず、いずれの図からも見て取れるように、学習シーンだけでなく、実践シーンにおいても現実の市場のダイナミズムをうまく再現できることが確認できた。これはトマト、レンコンといった品目に関わらず、一様に成立している成果である。

ただし、シミュレーションの全期間を通じて、



(図4-1) トマトの平均取引価格比較



(図4-2) レンコンの平均取引価格比較

現実市場に比べ、厳密にはシミュレーション結果の変動が緩やかとなった。これは人工市場のエージェント群が前日の予想システムを基盤として各期の予想システムを構築しているのに比べ、現実の市場参加者は過去（特に前日）の経験への依存度が少ないことが理由として挙げられる。それ以外にも現実市場では市場参加者が一定ではないことも理由の一つであると考えられる。これは解りやすく言いかえると、前日の市場参加者が当日に参加するとは限らず、また前日の参加者以外の参加者が当日に参加し、その参加者数も一定ではないということである。

6.1 個々のエージェントの動き

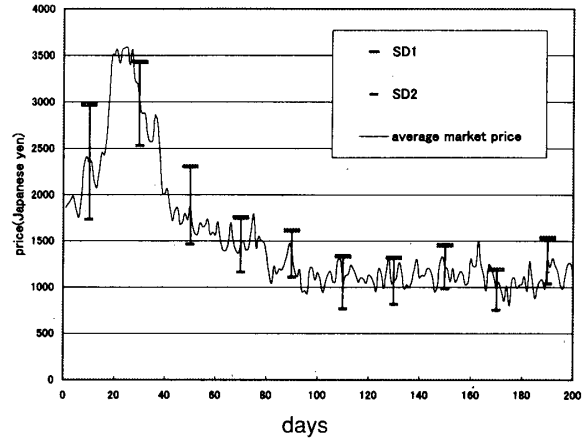
次にエージェントの動きを俯瞰的に観察することを目的として、シミュレーションにより得られた予想価格の実際価格とのズレを示す指標として、ある t_n 毎の偏差を算出した。これは、各取引価格の平均値の上部・下部において、平均値からのズレの確率密度の累積値が ± 0.3413 である価格値をそれぞれ SD1, SD2 として算出したものである。シミュレーション結果として、平均取引価格を中心に SD1, SD2 を20日間隔で図5に示す。

仮に各々の取引価格が十分に多く存在し、これらが正規分布をしていると仮定すると、SD1, SD2は


$$\int_{-\infty}^{SD1} e^{-\frac{1}{2}x^2} dx = \int_{SD2}^{0} e^{-\frac{1}{2}x^2} dx \quad (\text{ただし } x \text{ は取引価格を表す})$$

なる関係を示す、いわゆる標準偏差にあたる量であり、平均取引値からのSD1, SD2に示す拡がりがあり、予測精度をある意味では表現していると言える。

SD1, SD2の拡がり（両者の間隔）はシミュレーション開始後、トマトでは約90日、レンコンでは約50日までは減少し、その後は小幅ながら増減を繰り返している。これはシミュレーション開始からその時点までは各エージェントの学習が進み、これに応じて予想システムの均質化が進むが、その後も変異・交叉オペレータにより新しい予想システムが発生しており、その均質化と新たな予



(図5-1) シミュレーション結果
：トマトの平均取引価格と標準偏差



(図5-2) シミュレーション結果
：レンコンの平均取引価格と標準偏差

想システムの発生がある程度つりあった時点で、偏りの減少がストップすると考えると納得できる。図6に挙げる平均適応度とSD ($|SD1| \approx |SD2| = SD$)の動きからも同じことが言える。

6.2 既存の手法との比較

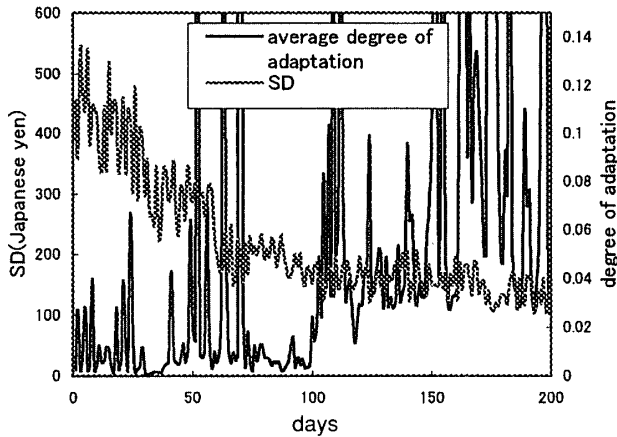
次に既存の手法との比較を行なうため、重回帰分析により得られた近似曲線との比較を行なった。回帰式には(式7)を用いた。対象品目はトマトとし、予想要因、及び分析期間に関しては本研究の人工市場モデルと同様とした。

$$P(t) = I_1 F_1(t) + I_2 F_2(t) + I_3 F_3(t) + \dots + I_{14} F_{14}(t) \quad (\text{式7})$$

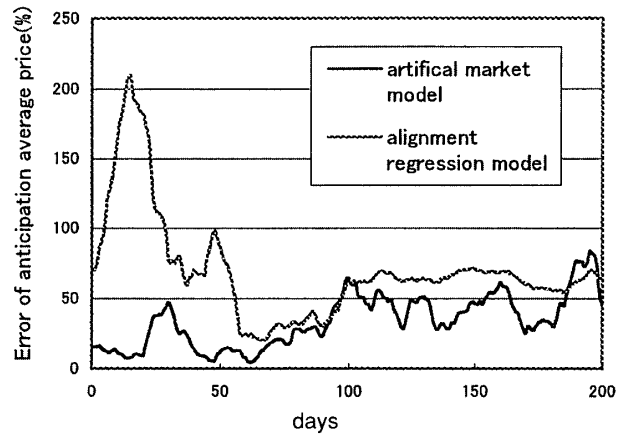
ただし、 $P(t)$ ：平均取引価格

I_n ：予想要因 n に対する重要度

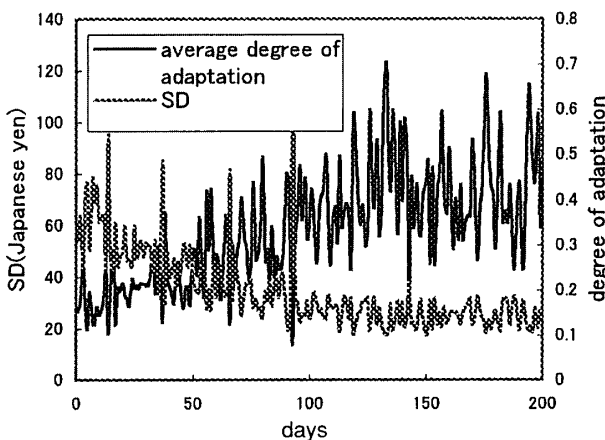
F_n ：予想要因 n の価格換算値



(図 6-1) トマト市場の平均適応度と平均取引価格の標準偏差



(図 7) 重回帰分析との比較



(図 6-2) レンコン市場の平均適応度と平均取引価格の標準偏差

分析の結果得られた回帰係数を以下に示す。

$$\begin{aligned}
 I_1 &= 0.052, & I_2 &= 0.055, & I_3 &= 0.048, \\
 I_4 &= 0.041, & I_5 &= 0.018, & I_6 &= 0.069, \\
 I_7 &= 0.001, & I_8 &= 0.090, & I_9 &= 0.087, \\
 I_{10} &= 0.094, & I_{11} &= 0.102, & I_{12} &= 0.124, \\
 I_{13} &= 0.073, & I_{14} &= 0.141
 \end{aligned}$$

ここで現実市場の平均取引価格と各モデルにより出力された予想平均価格の誤差を算出し、その予測力を比較した。予想平均価格の誤差を図 7 に示す。今回実行したエージェントによるシミュレーションは重回帰分析を行なうよりも誤差が 50% 以上小さいという成果が得られた。

7. 考察とまとめ

本研究は、青果物卸売市場をもとに人工市場モデルを構築し、価格を決定する要因に与えるウェイトを遺伝アルゴリズムによって更改していくマルチエージェントを用い、価格裁定のシミュレーションを行なった。その結果、このシミュレーション手法が十分妥当であることを検証した。そして本システムを用いることにより、現実の卸売価格の予測を既存の手法を上回る精度で行なえることが評価できた。このことから青果物生産者の利益を確保するに足りる十分に信頼性の高い実用的なシステムへと発展できる可能性を確認した。

今後は更にシミュレーション期間を拡大しても高い精度で予測可能なようにプログラムに改善を加えていくと共に、他の市場においても本手法の有効性を評価していきたいと考えている。

参 考 文 献

- 1) 高階知己, 秋永利明, 渡辺成良, “エージェント・レベルでの妥当性評価：株式市場シミュレーションによるケーススタディ”, シミュレーション, vol19-1, pp. 58-66 (2000)
- 2) J. F. Muth, “Rational expectations and the theory of price movements”, Econometrica, vol29-3, pp. 315-335 (1961)
- 3) 和泉潔, 大勝孝司, “人工市場アプローチによる為替レートの分析”, 人工知能, vol. 102-2, pp. 7-

- 12 (1995)
- 4) 和泉潔, 植田一博, “人工市場入門”, http://www.carc.aist.go.jp/~kiyoshi/paper/intro_html/intro_html.html
 - 5) 出口弘, 和泉潔, 塩沢由典, 高安秀樹, 寺野隆雄, 佐藤浩, 喜多一, “座談会：人工市場を研究する社会のおよび学問的意義”, 人工知能学会誌, vol. 15-6, pp. 982-989 (2000)
 - 6) U-Mart 研究会, “U-Mart 研究会 Web Site”, <http://www.u-mart.econ.Kyoto-u.ac.jp/>
 - 7) Arthur, W, “Designing economic agents that Act Like Human Agents Behavioral Approach to Bounded Rationality”, The American Economic Review, vol. 81-2, pp. 353-359 (2000)
 - 8) Lax. T, Marchesi, M, “Volatility Clustering in Financial Markets :A Micro-Simulation of Interacting Agents”, Technical Report B-437, University of Bonn (1998)
 - 9) David E. Goldberg, “Genetic Algorithms in Search, Optimization, and Machine Learning” (1999)