

人工知能は相場操縦という不正な取引を勝手に行うか？ — 遺伝的アルゴリズムが人工市場シミュレーションで学習する場合 —

Does an artificial intelligence perform market manipulation with its own discretion?
— A genetic algorithm learns in an artificial market simulation —

水田孝信*1

Takanobu Mizuta

*1 スパークス・アセット・マネジメント株式会社

SPARX Asset Management Co., Ltd.

人工知能が相場操縦を行った場合の責任の所在が議論されている。そこで本研究では、遺伝的アルゴリズムを用いた人工知能が人工市場シミュレーションを用いて学習するモデルを構築し、人工知能の作成者が相場操縦という取引戦略を全く意図していなかったにも関わらず、人工知能が学習を通じて相場操縦という取引戦略を発見するのか調べた。その結果、人工知能は相場操縦に他ならない取引を最適な取引として見つけ出した。この結果は、株式取引を行う人工知能の作成者には、人工知能が相場操縦を行わないようにする義務を負わせるなどの規制の必要性を示唆している。

1. はじめに

人工知能が事故を起こしたり不正行為を行った場合の責任の所在はどうあるべきか、多くの分野で議論されている。株式市場においては、人工知能が相場操縦を行った場合の責任の所在が議論されている。相場操縦とは市場価格などの相場を自分に有利になるように動かし利益を得ようとする取引戦略であり、本来の価格形成を阻害する不正な行為であるとして多くの市場で禁止されている*1*2。

日本では、日本銀行金融研究所が設置した“アルゴリズム・AIの利用を巡る法律問題研究会”が、“投資判断におけるアルゴリズム・AIの利用と法的責任”という報告書を公表している[アル18]*3。この報告書によると、株式取引を行う人工知能の作成者が相場操縦をする意図をもって人工知能を作成し、実際に人工知能が相場操縦を行った場合は作成者に責任があるとしている。一方で、作成者が相場操縦をする意図が全くなかったにも関わらず、人工知能が勝手に相場操縦を行った場合、責任が問えないケースがあると指摘している*4。このことは、実際に相場操縦が行われているにも関わらず誰も責任が問われない場合があることを示しており、市場の質の維持を妨げる問題である。

この報告書では、“人工知能が自分の取引が市場価格に与える影響を継続的に学習・分析して、作成者が知らないところで相場操縦という取引戦略を発見し、実行することも考えられる”，という重要な指摘をしている。多くの場合、人工知能が学習中の取引戦略を評価するときは、実データを用いて“もし取引していたらどうなっていたか”を分析する、いわゆるバックテストという手法をとる。しかしながらバックテストでは、

連絡先: mizutata@gmail.com

<https://mizutatakanobu.com>

当日の発表スライドは以下にある。

<https://mizutatakanobu.com/2020SIGFIN.pdf>

*1 相場操縦の詳しい定義は、<https://www.jpx.co.jp/regulation/preventing/manipulation/>

*2 日本においても証券取引等監視委員会が相場操縦などの不正取引の検挙事例を多くあげている。

<https://www.fsa.go.jp/sesc/jirei/index.htm>

*3 解説記事として[水田20]

*4 人工知能の作成者がどのような者かによる。証券会社や資産運用会社、高速取引業者など規制対象の者は何かしら責任を問えるが、金融機関でない法人や個人の場合は、責任を問うのが難しいとされる。分かりやすい解説として[水田19a]がある。

自身の取引が市場価格に与える影響を考慮できないため、この報告書が指摘するような、“自分の取引が市場価格に与える影響を継続的に学習・分析する”ことはできない。そのため、人工知能がバックテストで学習している限りは、人工知能が勝手に相場操縦をする心配はない。そういうこともあり、この報告書が懸念しているようなことが本当に人工知能にできるのかどうかは調べられていない。

一方で、コンピュータ上に仮想的に市場を作り出し分析する人工市場(金融市場のエージェントベースドモデル)を用いたシミュレーション[水田19b,高安20,Mizuta19c]*5であれば“自分の取引が市場価格に与える影響を継続的に学習・分析する”ことが可能である。

そこで本研究では図1のように、遺伝的アルゴリズム*6を用いた人工知能が人工市場シミュレーションを用いて学習するモデルを構築し、人工知能の作成者が相場操縦という取引戦略を全く意図していなかったにも関わらず、人工知能が学習を通じて相場操縦という取引戦略を発見し、実行に移すのか調べる。

2. モデル

人工知能を用いた取引を行う場合、人工知能はどのような取引戦略が利益を獲得するか学習し戦略の構築を行う。本研究では、人工知能の作成者が相場操縦という取引戦略を全く意図していなかったにも関わらず*7、人工知能が学習を通じて相

*5 人工市場シミュレーションはバブルや金融危機の発生メカニズムの解明に貢献したことはもちろん、現実の金融市場の規制や制度、ルールの変更の議論に貢献し始めている[水田19b,高安20,Mizuta19c]。

*6 遺伝的アルゴリズムとは生物の進化から着想を得た最適解を近似的に求める計算手法であり、入力値を遺伝子に見立て適応度(出力値)が高い遺伝子が生き残っていくことによって、最大の適応度(出力値)を持つ遺伝子(入力値)を探す手法である。優れた解説書として[Goldberg89]がある。

*7 実際には作成者がいかなる投資戦略も意図せずに人工知能を作ることには難しい。しかし本研究では、いかなる投資戦略も意図しないことが明確なモデルであることが重要であるため、あえて売買戦略のモデル化を行わず、ある人工市場環境で最適なすべての取引を直接探し出すモデルとした。売買戦略がモデル化されていないため、学習していない環境での売買を出力できず、アウトサンプルでの検証はできない。しかし、本研究の目的はあくまでも相場操縦という戦略を人工知能が学習時点で見つけ出せるかどうか注目しており、実際にモデルを稼働させることは目的としないため、アウトサン

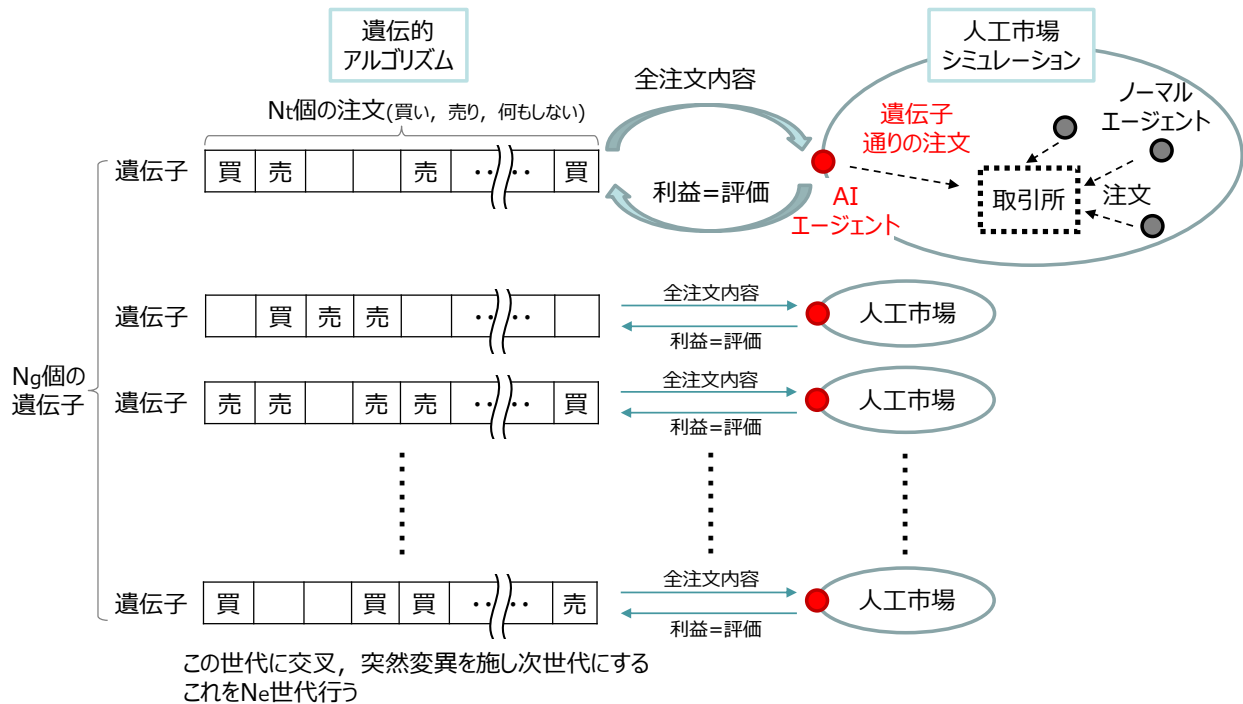


図 1: モデルの概要

場操縦という取引戦略を発見し、実行に移すのみに注目する。

図 1 は、本研究のモデルの概要である。作成者がいかなる投資戦略も意図しない人工知能として、すべての取引行動を 1 つの遺伝子とした遺伝的アルゴリズムを用いる。各遺伝子は人工市場を用いたシミュレーションで評価を行う。人工市場内には遺伝子通りの取引を行う AI エージェントを投入する。そして、この AI エージェントの利益をこの遺伝子の評価とし、遺伝的アルゴリズムによって高い評価の遺伝子を探し出す。この探し出す行為が人工知能の学習に相当する。

なお、各人工市場のノーマルエージェントのパラメータセットは、各時刻ごとに変化する乱数も含め、すべて同じものを用いる。そのため、仮に AI エージェントの売買が同じであれば、ノーマルエージェントの売買も同じとなる。

また、人工市場内での AI エージェントの取引は市場価格に影響を与えるが、比較のため、市場価格に影響を与えない場合(バックテスト)も分析する。

以下ではまず、各遺伝子の評価を行う人工市場シミュレーションについて説明し、その後、優れた遺伝子を探す遺伝的アルゴリズムの説明を行う。

2.1 人工市場シミュレーション

本研究の人工市場モデルは [水田 19b, Mizuta 19c] のモデルを用いる。

本モデルでは 1 つの株式を取引対象とする。価格決定メカニズムは、ザラバ方式 (continuous double auction) *8 とし、独立して価格の決定・売買が行われる。注文できる価格の変化幅の最小単位 (呼値の刻み) は δP とし、注文価格のそれより小さい端数は、買い注文の場合は切り捨て、売り注文の場合は

切り上げる。

n 体のノーマルエージェントと、1 体の AI エージェントが存在する。各エージェントは保有する株数に制限はなく (キャッシュが無制限)、マイナスの保有数量 (空売り) にも制限はない。また、時刻は 1 体のエージェントが注文を出すたびに 1 増える、いわゆるティック時刻とする。

2.1.1 ノーマルエージェント

n 体のノーマルエージェントが売買に参加する。エージェント番号 $j = 1$ から順番に $j = 2, 3, 4, \dots$ と注文を出す。 $j = n$ が注文を出すと、次のティック時刻にはまた $j = 1$ から注文を出し繰り返される。注文数量は常に 1 株と一定とする。

注文価格 $P_{o,j}^t$ 、売り買いの別を以下のように決める。ティック時刻 t にエージェント j が予想する株価の変化率 (予想リターン) $r_{e,j}^t$ は、

$$r_{e,j}^t = (w_{1,j} \log \frac{P_f}{P^{t-1}} + w_{2,j} \log \frac{P^{t-1}}{P^{t-\tau_j-1}} + w_{3,j} \epsilon_j^t) / \sum_i^3 w_{i,j} \quad (1)$$

とする。ここで、 $w_{i,j}$ はエージェント j の i 項目の重みであり、シミュレーション開始時に、それぞれ 0 から $w_{i,max}$ まで一様乱数で決める。 \log は自然対数である。 P_f は時間によらず一定のファンダメンタル価格、 P^t はティック時刻 t のすでに出されている注文のうち最も高い買い注文価格と最も安い売り注文価格の平均 (仲値)、 ϵ_j^t はティック時刻 t 、エージェント j の乱数項であり、平均 0、標準偏差 σ_ϵ の正規分布乱数である。 τ_j はシミュレーション開始時に 1 から τ_{max} までの一様乱数でエージェントごとに決める *9。

式 (1) の第 1 項目はファンダメンタル価格と比較して安ければプラスの予想リターンを高めればマイナスの予想リターンを示す、ファンダメンタル価値を参照して投資判断を行うファ

ルでの検証は不要と考える。

*8 ザラバ方式は、売り手と買い手の双方が価格を提示し、売り手と買い手の提示価格が合致するとその価格で直ちに取引が成立する方式である。

*9 ただし、 $t < \tau_j$ のときは、式 (1) の第 2 項目を 0 とした。

ンダメンタル投資家の成分である。第2項目は過去の価格推移から投資判断を行うテクニカル投資家の成分であり、過去のリターンがプラス(マイナス)ならプラス(マイナス)の予想リターンを示す。第3項目はノイズを示す。

予想リターン $r_{e,j}^t$ より予想価格 $P_{e,j}^t$ は、 $P_{e,j}^t = P^{t-1} \exp(r_{e,j}^t)$ で求まる。注文価格 $P_{o,j}^t$ は $P_{e,j}^t - P_d$ から $P_{e,j}^t + P_d$ の一様乱数で決める。ここで、 P_d は定数である。そして、売り買いの別は予想価格 $P_{e,j}^t$ と注文価格 $P_{o,j}^t$ の大小関係で決める。すなわち、

$$\begin{aligned} P_{e,j}^t > P_{o,j}^t &\text{なら1株の買い} \\ P_{e,j}^t < P_{o,j}^t &\text{なら1株の売り} \end{aligned} \quad (2)$$

とする*10。注文を行ってからキャンセル時間 t_c だけ経過した注文はキャンセルする。

2.1.2 AI エージェント

AI エージェントはティック時刻 δt ごとに、1株の買い(注文価格はすでにある最も高い売り価格)または売り(注文価格はすでにある最も安い買い価格)、または何もしないの3通りのいずれかを行う*11。1試行のシミュレーションはティック時刻 t_e まで行うため、AI エージェントは $N_t = (t_e - t_c)/\delta t$ 回行動を選ぶことになる。この行動は次節に述べる遺伝的アルゴリズムによって与えられる。

2.2 遺伝的アルゴリズム

2.2.1 遺伝子情報と人工市場

作成者がいかなる投資戦略も意図しない人工知能として遺伝的アルゴリズムを用いる。図1も参照。 N_g 個の遺伝子を用意する。1つの遺伝子は N_t 個の遺伝子情報を持つ。遺伝子情報は1つの注文に相当し、買い、売り、何もしないの3つどれか1つである。各遺伝子は前節で述べた人工市場シミュレーションを用いて、1体のAI エージェントに遺伝子情報である N_t 個の注文をティック時刻 δt ごとに順番に行わせ利益を算出する。遺伝子の評価はこの利益で行う。最後まで持っていた株式の価格は P_f と評価する。各遺伝子が用いる人工市場内のノーマルエージェントの行動は乱数も含め同じである。そのため、もしAI エージェントの行動が同じであれば、まったく同じ利益が得られる。

2.2.2 世代交代

全遺伝子 N_g 個のうち、利益が高かった上位 N_{ge} 個の遺伝子はそのまま残す。

残り $N_g - N_{ge}$ 個の各遺伝子は確率 R_c で、利益が高かった上位 N_{ge} 個の遺伝子からランダムに選んだ2つの遺伝子 g_0, g_1 を交叉させたものに置き換える。交叉はまず遺伝情報をすべて遺伝子 g_0 のものに置き換え、ランダムで決められた i_0 個目から i_1 個目の遺伝子情報をすべて遺伝子 g_1 のものに置き換える。その後、その $N_g - N_{ge}$ 個の各遺伝子の各遺伝子情報に対して確率 R_m で買い、売り、何もしないをそれぞれ1/3の確率でランダムに書き換える突然変異が行われる。

このようにして次の世代を作成し、これを N_e 世代繰り返す。

なお、初めの世代は、すべての遺伝子のすべての遺伝子情報は買い、売り、何もしないをそれぞれ1/3の確率でランダムに決める。

*10 ただし、 $t < t_c$ のときは十分な板の厚さを確保するため、 $P_f > P_{o,j}^{t-1}$ なら1株の買い、 $P_f < P_{o,j}^{t-1}$ なら1株の売りとする。また、 $P^{t-1} = P_f$ とする。

*11 ただし、初めのティック時刻 t_c までは注文を出さない。シミュレーションを不安定にしないため。初めの t_c までは*10でも述べたように、十分な板の厚さを確保するための期間である。

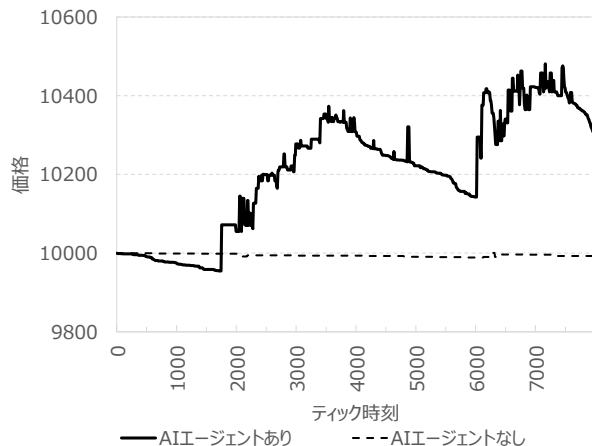


図2: AI エージェントありの場合となしの場合の市場価格(仲値)の時系列




図3: AI エージェントありの場合の市場価格と200ティック時間ごとに集計したAI エージェントの売買数量(買いがプラス、売りがマイナス)

3. シミュレーション結果

人工市場に関するパラメータは、 $n = 900, w_{1,max} = 1, w_{2,max} = 100, w_{3,max} = 1, \tau_{max} = 1000, \sigma_\epsilon = 0.03, P_d = 1000, t_c = 2000, \delta P = 0.01, P_f = 10000, \delta t = 10$ とした。またシミュレーションは時刻 $t = t_e = 10000$ まで行った。遺伝的アルゴリズムに関するパラメータは、 $N_t = (t_e - t_c)/\delta t = 800, N_g = 10000, N_{ge} = 400, R_c = 0.65, R_m = 0.2, N_e = 1500$ とした。そのため、 $N_g \times N_e = 1.5 \times 10^7$ 回(1千5百万回)という膨大な回数の人工市場シミュレーションを行ったことになる。そして以下では、遺伝的アルゴリズムの最終世代で最も利益が高かった遺伝子情報(全注文内容)を用いる。

3.1 最初の試行の結果

図2は、AI エージェントがいる場合(AI エージェントあり)と、AI エージェントがいない場合(AI エージェントなし)の市場価格(仲値)の時系列である。AI エージェントによって、市場価格が変動が大きくなっていることがわかる。

図3は、AI エージェントありの場合の市場価格と200ティック時間ごとに集計したAI エージェントの売買数量(買いがプ

表 1: さらに 10 試行を行った結果

シミュレーション						
試行	$P_{min}/P_f - 1$	$P_{max}/P_f - 1$	$(P_{max} - P_{min})/P_f$	AI エージェントの売買数量	結果タイプ	
2	-0.59%	4.12%	4.7%	518	相場操縦 (買い上げ)	
3	-0.63%	4.49%	5.1%	506	相場操縦 (買い上げ)	
4	-0.77%	5.37%	6.1%	496	相場操縦 (買い上げ)	
5	-4.33%	0.00%	4.3%	414	相場操縦 (空売り下げ)	
6	-0.14%	0.00%	0.1%	0	売買せず	
7	-3.67%	0.03%	3.7%	489	相場操縦 (空売り下げ)	
8	-0.77%	5.02%	5.8%	511	相場操縦 (買い上げ)	
9	-0.61%	4.96%	5.6%	507	相場操縦 (買い上げ)	
10	-3.68%	-0.01%	3.7%	491	相場操縦 (空売り下げ)	
11	0.00%	0.17%	0.2%	0	売買せず	

バックテスト						
試行	$P_{min}/P_f - 1$	$P_{max}/P_f - 1$	$(P_{max} - P_{min})/P_f$	AI エージェントの売買数量	結果タイプ	
2	-0.04%	0.13%	0.2%	221	ファンダメンタル戦略	
3	-0.08%	0.21%	0.3%	230	ファンダメンタル戦略	
4	-0.10%	-0.03%	0.1%	0	売買せず	
5	-0.10%	0.01%	0.1%	0	売買せず	
6	-0.14%	0.00%	0.1%	413	ファンダメンタル戦略	
7	-0.05%	-0.01%	0.0%	0	売買せず	
8	-0.05%	0.23%	0.3%	482	ファンダメンタル戦略	
9	-0.04%	0.11%	0.2%	529	ファンダメンタル戦略	
10	-0.01%	0.13%	0.1%	567	ファンダメンタル戦略	
11	0.00%	0.17%	0.2%	484	ファンダメンタル戦略	

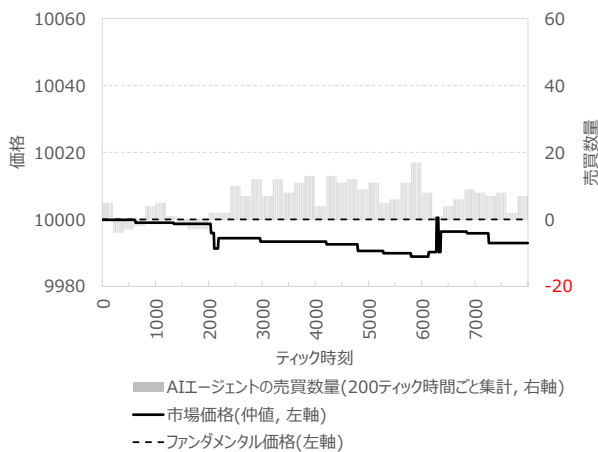


図 4: AI エージェントの売買が市場価格に影響を与えないバックテストの場合

ラス、売りがマイナス)である。2000 ティック時刻あたりでは AI エージェントが大量に買うことで市場価格を上昇させている。3000 ティック時刻あたりでは買いの量を減らしているにもかかわらず市場価格は上昇を続けている。市場価格はファンダメンタル価格を上回っており、ノーマルエージェントのファンダメンタル戦略(式(1)の第1項)は下落を予想している。しかし、2000 ティック時刻あたりで AI エージェントの大量の買いで作られた大きな上昇により、ノーマルエージェントのテクニカル戦略(式(1)の第2項)は大きな上昇を予想すること

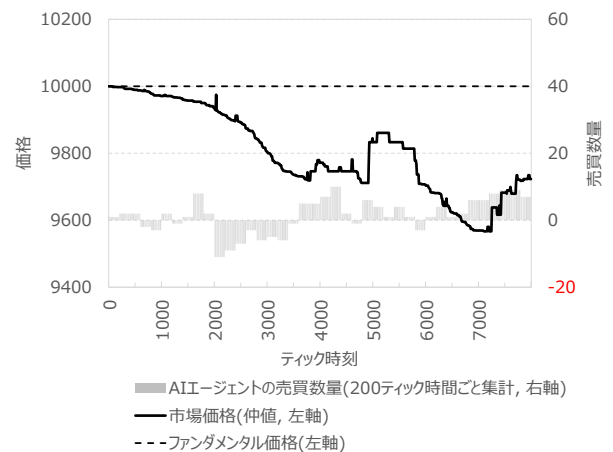


図 5: 試行 5

になってしまい、ファンダメンタル戦略の下落予想を上回ってしまう。そのため、AI エージェントが買いの量を減らしても、市場価格は上昇を続けている。その後、4000 ティック時刻から 6000 ティック時刻くらいまで AI エージェントは売っているが、3000 ティック時刻付近の上昇のおかげで、2000 ティック時刻付近で買った値段よりも高く売ることができている。

AI エージェントのこれらの取引行為は相場操縦に他ならない。

図 4 は、AI エージェントの売買が市場価格に影響を与えないバックテストの場合の市場価格と AI エージェントの売買数

量である(図2および図3とは価格を示す左縦軸のケールが違うことに注意)。AIエージェントの売買が市場価格に影響を与えないため、市場価格の推移は図2のAIエージェントがいな場合と全く同じとなる。AIエージェントは、市場価格がファンダメンタル価格を下回っているほど多く買う傾向にあり、通常のファンダメンタル戦略をとっている。つまり、バックテストの場合、相場操縦という取引手法は発見しない。

このことは、人工知能が人工市場シミュレーションを使って自分の取引が市場価格に与える影響を多く学習できる場合には相場操縦という取引戦略を発見できるが、実データを用いたバックテストでは相場操縦という取引戦略を発見できない可能性を示唆している。

3.2 さらに10試行を行った結果

これまで行ったシミュレーションは、各人工市場に共通に与えたノーマルエージェントのパラメータセット、1つに対して行われたものであった。そういう意味ではこれまでに行ったシミュレーションが1試行と言える。ここでは、さらに10個のパラメータセットを用いて10試行を行った結果を見る。

表1は、その10試行の結果の概要である。 P_{min} , P_{max} はそれぞれ、市場価格の最小値、最大値である。“結果タイプ”の列では、“売買せず”はAIエージェントが全く売買しなかった場合を、“相場操縦(買い上げ)”は、AIエージェントが市場価格を上昇させるために大きな買いを行った場合を、“相場操縦(空売り下げ)”は、AIエージェントが市場価格を下落させるために大きな売りを行った場合を、“ファンダメンタル戦略”は、AIエージェントが、市場価格がファンダメンタル価格より安いときに買い、高いときに売る傾向があった場合を、それぞれ示している。

相場操縦の場合は、 $P_{max}/P_f - 1$ または $P_{min}/P_f - 1$ が示すように、市場価格が大きく上昇するか大きく下落しており、AIエージェントの売買が市場価格に大きな影響を与えていることを示しています。ファンダメンタル戦略の場合は、AIエージェントの売買数量が少なくないに関わらず、 $(P_{max} - P_{min})/P_f$ は小さく、市場価格に大きな影響を及ぼしていないことが分かる。

表1では、AIエージェントの売買が市場価格に影響を与えるシミュレーションの場合と、影響を与えないバックテストの場合の結果も示している。シミュレーションの場合、8試行で相場操縦となり、残り2試行で売買せずとなった。これらの結果は、人工知能が最適な戦略として相場操縦を発見するのは簡単であることを示唆している。バックテストの場合は、相場操縦の場合はひとつもなかった。このことは、自分の売買が市場価格に影響を与える考慮できないバックテストでは、人工知能は相場操縦という戦略を発見できない可能性を示唆している。

図5は、試行5について、図3と同じように、市場価格と200ティック時間ごとに集計したAIエージェントの売買数量(買いがプラス、売りがマイナス)を示した。試行5においては、AIエージェントは多くの売りを行い市場価格に影響を与え、大きく下落させた。このことは、人工知能は図3のような買い上がりの相場操縦だけでなく、図5のような空売り下げの相場操縦も発見しうることを示唆している。

4. まとめと今後の課題

本研究では図1のように、遺伝的アルゴリズムを用いた人工知能が人工市場シミュレーションを用いて学習するモデルを構築し、人工知能の作成者が相場操縦という取引戦略を全く意図していなかったにも関わらず、人工知能が学習を通じて相場

操縦という取引戦略を発見するのか調べた。

その結果、人工知能は相場操縦に他ならない取引を最適な取引として見つけ出した。これは、人工知能が人工市場シミュレーションを使って自分の取引が市場価格に与える影響を多く学習できる場合には、人工知能の作成者が全く意図していなくても、相場操縦という取引戦略を発見できる可能性を示している。ただし、実データを用いたバックテストでは相場操縦という取引戦略を発見できない可能性も示唆した。

これらの結果は、株式取引を行う人工知能の作成者には、人工知能が相場操縦を行わないようにする義務を負わせるなどの規制の必要性を示唆している。

本研究では図1全体でいえば11試行しか行っていない。本研究の目的は、人工知能が学習を通じて相場操縦という取引戦略を発見する可能性があるかどうかを調べることであり、1試行で相場操縦が行われれば十分目的を達している。法規制を考える上では、少なからず可能性があるかどうか重要であるからだ。しかし、それをどれくらい発見しやすいかを調べることも重要であろう。そのためには、もっと多くの試行が必要である。それには高速な計算機が必要であり、今後の課題である。

付録

モデル構築の基本理念

人工市場シミュレーションを用いれば、まだ導入したことがない手数料体系を調べたり、その変更の純粋な効果やメカニズムを議論したりできる。これが人工市場シミュレーション研究の強みである。そして、多くの人工市場シミュレーション研究がこれまでにない環境が与える影響や、規制やルールの変更を分析してきた[水田 19b, 高安 20, Mizuta 19c]。

ただその効果は確実な予想ではない。さまざまなケースでのシミュレーションを行い、これまで予想されていなかった、“あり得る”メカニズムでの現象を見つけておくことが、人工市場シミュレーションの大きな役割となる。金融市場でこれから実際におこる現象を定量的にも忠実に再現することが目的ではなく、環境の変化が、どのようなメカニズムで価格形成に影響を与え、どのようなことが起こり得るのかという知識獲得が目的である。これは例えば実証分析など他の手法ではできないことである。

人工市場モデルは普遍的に存在するマクロ現象を再現すべきであると考えられる。人工市場シミュレーションでは、マクロ現象である市場価格のリターンや売買数量をモデル化しない。あくまで、投資家を模した“エージェント”と取引所を模した“価格決定メカニズム”といったミクロメカニズムをモデル化し、そのミクロメカニズムの相互作用の積み上げとしてマクロ現象が出力される。そのため、ミクロメカニズムのモデル化は現実の市場に即したものとし、結果として出力されるマクロ現象は、現実の市場で普遍的に存在するマクロ的性質を再現されるように作る必要がある。

しかし、普遍的ではなく特定の時期や資産、地域で出現するマクロ的性質すべてを再現することは本研究の目的ではない。必要以上に多くのマクロ的性質を一つのモデルで再現しようとすると、過剰に複雑なモデルをもたらす、関連する要素が多くなりすぎて、発生メカニズムの理解を妨げてしまう。

実際、複雑な人工市場モデルに対して、モデルが複雑になるとパラメータが増えモデルの評価が困難になるという批判がある[Chen 12]。モデルが複雑すぎると関連する要素が多くなりすぎて、発生メカニズムの理解を妨げてしまう。また、パラ

表 2: AI エージェントがいない場合の各種統計量

リターン標準偏差	0.0103%	
リターン尖度	1.54	
	ラグ	
	1	0.081
二乗リターンの	2	0.041
自己相関係数	3	0.032
	4	0.047
	5	0.018

メータが増えるほどさまざまな出力がだせるようになり、モデルを作った人が導きたい結果へ恣意的に導くためのパラメータ設定が行われる恐れがある。シンプルでパラメータが少ないモデルほど、パラメータ調整によって特定の結果に導くことが困難であるため評価が容易となる。

以上により、本研究では、分析目的を果たせる範囲内なるべくシンプルなモデルの構築を行っている。実際の市場を完全に再現することを目的としておらず、普遍的ではなく特定の時期や資産、地域で出現するマクロ的性質すべてを再現することや、実際には存在するであろう投資家をすべて網羅することはあて行っていない。

[Weisberg 12] が述べているように、よいシミュレーションモデルとはその研究目的によって異なる。そのため、本研究のモデルは本研究の目的にのみおいてよいモデルであり、他の研究目的においてはよいモデルではない。また [Weisberg 12] が述べているように、数理モデルと異なり、シミュレーションモデルは投資家などのミクロの行動やその行動の理由と、市場価格などのマクロ現象との相互作用のメカニズムの解明ができることが強みである。例えば、ノーベル経済学賞を受賞したシェリングはシミュレーションモデルを用いて人種隔離のメカニズムを議論したが、そのモデルではメカニズムの解明に焦点を当てたためどこにも存在しないシンプルな町を簡潔にモデル化して、実際に存在する町の隔離状況の説明や予測はできないモデルであった [Schelling 06]。本研究でも、数理モデルが強みとするマクロ現象の特徴分析や予測といったことは目的とせず、メカニズムの解明に焦点をあてている。

モデルの妥当性

人工市場モデルの妥当性は実証分析で得られている fat-tail や volatility-clustering といった代表的な stylized fact が再現できるかどうかで評価される [LeBaron 06, Chen 12, 水田 14]。ファット・テールは、市場価格のリターンの分布が正規分布ではなく裾が厚い、すなわち、尖度が正であることである。ボラティリティ・クラスタリングは市場価格のリターンの 2 乗が、大きなラグでも自己相関係数が有意に正であることである。

[Sewell 11] など多くの研究で述べられているように、金融市場は不安定であり、安定的に、どのような時期にも有意に観測されるスタイライズド・ファクトはファット・テールとボラティリティ・クラスタリングの 2 つしかない。

しかも、これらは統計量の有意に正であることだけが安定して観測され、値そのものは、時期によって異なる。ファット・テールについては、実証分析でよく観測されるリターンの分布の尖度は 1 ~ 100 程度であり、ボラティリティ・クラスタリングについては、実証分析でよく観測されるリターンの自己相関係数は 0 ~ 0.2 程度と、かなりばらつきがある [Sewell 11]。

本研究のように、金融市場に共通する性質を分析対象とする

人工市場が再現すべきは、これらの統計量が有意に正であり、問題ない範囲に値が収まっていることであって、特定の値に近づけることは本質的ではない。

表 2 は、AI エージェントがいない場合の毎期のリターン $\log(P^t/P^{t-1})$ の標準偏差と尖度、リターンの 2 乗の自己相関である。リターンの尖度がプラスで、ファット・テールが再現されている。また、リターンの 2 乗の自己相関もプラスで、ボラティリティ・クラスタリングが再現されていると考えられる。

留意事項

本論文はスパークス・アセット・マネジメント株式会社の公式見解を表すものではありません。すべては個人的見解であります。

参考文献

- [アル 18] アルゴリズム・AI の利用をめぐる法律問題研究会：投資判断におけるアルゴリズム・AI の利用と法的責任，日本銀行 金融研究所 (2018)，
https://www.boj.or.jp/announcements/release_2018/re1180911a.htm/
- [Chen 12] Chen, S.-H., Chang, C.-L., and Du, Y.-R.: Agent-based economic models and econometrics, *Knowledge Engineering Review*, Vol. 27, No. 2, pp. 187–219 (2012),
<http://dx.doi.org/10.1017/S0269888912000136>
- [Goldberg 89] Goldberg, D. E.: *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley Professional (1989)
- [LeBaron 06] LeBaron, B.: Agent-based computational finance, *Handbook of computational economics*, Vol. 2, pp. 1187–1233 (2006),
[http://dx.doi.org/10.1016/S1574-0021\(05\)02024-1](http://dx.doi.org/10.1016/S1574-0021(05)02024-1)
- [水田 14] 水田 孝信：人工市場シミュレーションを用いた金融市場の規制・制度の分析，博士論文，東京大学大学院工学系研究科 (2014)，
<http://hdl.handle.net/2261/59875>
- [水田 19a] 水田 孝信：高頻度取引（3 回シリーズ第 3 回）：高頻度取引ではないアルゴリズム取引と不正取引の取り締まり高度化，スパークス・アセット・マネジメント (2019)，
<https://www.sparx.co.jp/report/special/2764.html>
- [水田 19b] 水田 孝信：人工市場シミュレーションを用いた金融市場の規制やルールの議論，証券アナリストジャーナル，Vol. 57, No. 5 (2019)，
https://www.saa.or.jp/learning/journal/each_title/2019/05.html
- [Mizuta 19c] Mizuta, T.: An agent-based model for designing a financial market that works well, *arXiv* (2019)，
<https://arxiv.org/abs/1906.06000>
- [水田 20] 水田 孝信：人工知能が不正取引を行ったら誰の責任か？，スパークス・アセット・マネジメント (2020)，
<https://www.sparx.co.jp/report/special/3071.html>

[Schelling 06] Schelling, T. C.: *Micromotives and Macrobehavior*, W. W. Norton & Company (2006), (邦訳: 村井章子: ミクロ動機とマクロ行動, 勁草書房 (2016))
<http://www.keisoshobo.co.jp/book/b251669.html>

[Sewell 11] Sewell, M.: Characterization of financial time series, *Research Note, University College London, Department of Computer Science*, No. RN/11/01 (2011),
<http://finance.martinsewell.com/stylized-facts/>

[高安 20] 高安美佐子, 和泉潔, 山田健太, 水田孝信: マルチエージェントによる金融市場のシミュレーション, コロナ社 (2020),
<https://www.coronasha.co.jp/np/isbn/9784339028225/>

[Weisberg 12] Weisberg, M.: *Simulation and Similarity: Using Models to Understand the World*, Oxford Studies in the Philosophy of Science (2012), (邦訳: 松王政浩: 科学とモデル-シミュレーションの哲学 入門-, 名古屋大学出版会 (2017))
<http://www.unp.or.jp/ISBN/ISBN978-4-8158-0872-3.html>