

# テクニカル指標による金融取引の戦略木構築

## Construction of a Strategy Tree in Financial Transaction using Technical Indicators

加藤 旺樹<sup>1</sup> 穴田 一<sup>1</sup>

Ohki Kato<sup>1</sup> Hajime Anada<sup>1</sup>

<sup>1</sup> 東京都市大学大学院 総合理工学研究科

<sup>1</sup> Graduate School of Integrative Science and Engineering, Tokyo City University

**Abstract:** In recent years, many researchers have studied stock trading using technical analysis. However, it is necessary to have deep knowledge to use such technical analysis and it is difficult to make a profit using such techniques. Therefore, we construct an evolutionary model to create a profitable investment strategy using technical indicators.

### 1. はじめに

近年、テクニカル分析を用いた株式売買に関する研究が多く行われている。テクニカル分析を用いた投資では、相場のトレンドや転換点を判断するテクニカル指標を用いることで、過去の値動きのパターンから将来の値動きを予測し売買を行う。しかし、そのためには専門的な知識を必要とする上、利益を上げにくいという問題がある。

松村らは、テクニカル指標を用いた投資戦略を木構造で戦略木として表現した。そして、それぞれの個体が戦略木を持ち、その戦略木に従い株式売買を行うモデルを構築した[1][2]。戦略木を個体の遺伝子として遺伝的操作を用いることで、より利益が高くなるように個体を進化させ、各個体が持つ戦略木の特徴を分析した。

そこで本研究では、松村らの研究で用いられた戦略木を用いて、より利益を生み出すテクニカル指標を用いた投資戦略の構築を目的とする。

### 2. 提案手法

それぞれの個体が戦略木を持ち、その戦略木にしたがって取引を行う。その取引結果から個体を評価した値である適応度を求め、戦略木を個体の遺伝子として遺伝的操作を用いることでより適応度が高くなるように個体を進化させていく。

#### 2.1. テクニカル指標

テクニカル指標は株式の売買タイミングを判断するために使われる指標で、トレンド系、オシレータ系、出来高系の3つがある。トレンド系は株価の推移からトレンドを判断する指標、オシレータ系は株

価の推移からトレンドの転換点を判断する指標、出来高系は売買が成立した株数の推移からトレンドの転換点を判断する指標である。

#### 2.2. 戦略木

戦略木は、複数の非終端ノードと終端ノードからツリー状に構成される[1][2]。それぞれの数字がテクニカル指標や売買行動を表し、各ノードから一番上のノードまでのノード間を結ぶ枝の数を各ノードの深さとする。非終端ノードでは、テクニカル指標に基づく判定処理によって左右どちらかのノードを実行する。終端ノードでは、株式の売買行動を実行する。使用するノードは松村らの研究にならう。表1に終端ノードと非終端ノードの例を示す[1][2]。




図1 戦略木の例

各個体は戦略木を持ち、戦略木に従って当日の行動を決定する。一番上のノードからテクニカル指標に基づく判定処理により、左右どちらかのノードを実

行するのかわ決定していくことを繰り返し、到達した終端ノードの行動を実行する。判定に使用するデータは、各指標に必要な日数分の始値、高値、安値、終値、出来高の日足データである。

表1 ノードの例

種類	番号	内容
終端ノード	1	1株購入, 資金がないときは待機
	2	1株売却, 株式がないときは待機
	3	待機
	4	保有している株式をすべて売却
	5	資金が許す限り株式を購入
非終端ノード	6	前日の終値が前々日の終値を上回れば左のノードを実行, それ以外であれば右のノードを実行
	⋮	⋮
	34	前日の総資産が前々日の総資産を上回れば左のノードを実行, それ以外であれば右のノードを実行

## 2.3. 遺伝子操作

戦略木を個体の遺伝子として、交叉や突然変異、淘汰の操作でより高い利益を生み出す個体を作り出していく。

### 2.3.1. 初期個体生成

表1のノードの中から無作為に1つを選択する。そのノードが終端ノードであれば、戦略木の生成を終了する。非終端ノードであれば、その非終端ノードの左右にノードを無作為に選択して付け加える。この作業を、全ての非終端ノードの左右に終端ノードが付け加えられるまで繰り返す。初期個体の生成は、初めからノード数の多い木になることを防ぐため、深さ4には終端ノードを付け加える。初期個体はN個体生成する。

### 2.3.2. 評価

個体の適応度は利益の幾何平均とする。複数の期間でそれぞれ取引を行った時の利益の幾何平均を適応度とすることで、どの期間でも利益を上げている個体の適応度が高くなるようにする。さらに、学習データを銘柄ごとに短く分割することでトレンド等の時系列の特徴を出やすくした状態で学習を行う。期間をより細かく分割し、分割したそれぞれの期間で取引させた時の利益の幾何平均を適応度とすることで、多くの変動パターンを学習出来ると考えたからである。しかし、利益は負になることがあり、そ

の場合適応度を求めることができない。そこで、利益が負の場合、取引させた中で最も小さい利益の絶対値を全ての利益に足すことで補正する。

### 2.3.3. ノード削除

戦略木によって行動を決定する際に同じ数字のノードを2回目以降実行する場合、そのノードでは左右どちらのノードを実行するのかわ決まっているため、絶対に到達できないノードが生まれてしまう。例えば、図1では、深さ1と深さ2に6番のノードがある。深さ1にある6番で左のノードを実行する場合、深さ2の6番も左のノードを実行することになり、その逆側の深さ3の7番のノード以下には到達できない。これらのノードは売買行動に関係なく適応度に影響を与えないが、ノード数を制限していないためこのようなノードが際限なく増えていく。これでは交叉時、適応度に影響を与える部分が選ばれにくくなり、進化が停滞しやすく効率的な学習が妨げられる。そこで、戦略木がある程度大きくなってから必要ない部分を削除するために、101世代以降では毎世代評価で使われなかったノードの削除を行う。ノードの削除を101世代以降で行うのは、初期世代から行くと戦略木が大きくなってしまいうからである。

### 2.3.4. 交叉

現世代の全個体から適応度を用いたルーレット選択により親となる2個体を選択する。それぞれの個体から無作為に1つずつノードを選び、そのノード以下の部分木を交換することで子を2個体作り出す。これらの操作を繰り返すことでN個体を作り出す。

### 2.3.5. 突然変異

現世代の個体Nと交叉によって出来たN個体について適応度の順位に基づいて突然変異を施すか決定する。個体*i*の突然変異が起きる確率 $P_i$ は次式で定義される。

$$P_i = (\text{Rank}_i - 1) \times 0.1 \quad (\%) \quad (1)$$

ここで、 $\text{Rank}_i$ は個体*i*の適応度の順位である。これにより、順位の高い個体は突然変異する確率が低くなる。突然変異を施す場合、個体を構成する各ノードが突然変異率  $p(\%)$  に基づき終端ノードなら他の終端ノード、非終端ノードなら他の非終端ノードに無作為に変化させる。これらの個体を次世代に残す。

### 2.3.6. 次世代に残す個体の選択

次世代に残す個体を現世代のN個体と、交叉と突然変異によってできたN個体から適応度の順位を用

いたルーレット選択によって選び出す。こうすることで、個体の多様性を保ちつつ順位の高い個体を次世代に残りやすくする。

## 2.4. 提案手法の流れ

個体を N 個体用意する。個体はそれぞれ戦略木と現金残高、保有株式数の情報を持ち、1 日 1 回売買行動する。各個体は独立して、戦略木に従い定めた期間、複数銘柄でそれぞれ取引を行う。取引は過去のデータを用いて実市場と同じ動きを再現した市場で行い、株式の注文は注文を出した日の終値で成立させる。提案手法は以下の流れで行う。

- I) 初期個体生成
- II) 初期個体の評価
- III) 初期個体のノード削除
- IV) 交叉
- V) 交叉によって出来た個体の評価
- VI) 交叉によって出来た個体の使われないノード削除
- VII) 突然変異
- VIII) 突然変異した個体の評価
- IX) 突然変異した個体の使われないノード削除
- X) 次世代に残す個体の選択

IV)~X)を、決められた世代数まで繰り返す。

## 3. 結果

本研究では、取引銘柄は東京証券取引所 1 部に上場している銘柄とした。使用したのは、出来高が多く長い期間データを取ることが出来る表 2 の 10 銘柄である。

表 2 取引銘柄

業種	銘柄
製造業	キャノン
水産・農林業	極洋
鉱業	日鉄鉱業
建設業	積水ハウス
金融保険業	野村ホールディングス
不動産業	三井不動産
運輸・情報通信業	KDDI
電気・ガス業	大阪ガス
サービス業	セコム
商業	イオン

個体数 N=100, 世代数 5000, 試行回数 50,  $p = 0.5$  (%) とし、学習を行う学習期間とテストを行うテスト期間を表 3 のように設け、シミュレーションを行った。学習期間の分割の刻みは、2 年、1 年、6 ヶ月の 3 つである。分割した期間においてそれぞれ元金 10 万円

とし取引を行い、2 年刻みであれば、1 銘柄につき 6 年間の学習期間を 2005 年 1 月~2006 年 12 月、2007 年 1 月~2008 年 12 月、2009 年 1 月~2010 年 12 月の 3 期間に分け、10 銘柄分で 30 パターンの株価変動で取引し適応度を計算する。テスト期間の特徴として、ケース 1 は横ばい、ケース 2 はなだらかな上昇トレンド、ケース 3 は激しい上下変動をとまらぬ上昇トレンドとなっている。

表 3 取引期間

学習期間	テスト期間	
2005 年 1 月~2010 年 12 月	ケース 1	2011 年 1 月~2012 年 12 月
	ケース 2	2013 年 1 月~2014 年 12 月
	ケース 3	2015 年 1 月~2016 年 12 月

図 2 にその世代で適応度が最も高い個体の 1 年間に換算した学習期間での平均利益を示す。この図は、50 試行を平均したものであり、縦軸は平均利益(万円)、横軸は世代数を表し、黒線は既存手法の平均利益、オレンジ線は 2 年刻みによる提案手法の平均利益、青線は 1 年刻みによる提案手法の平均利益、緑線は 6 ヶ月刻みによる提案手法の平均利益を表す。




図 2 最良個体の平均利益の世代推移 (学習期間)

学習期間において既存手法が最も利益を上げることが出来ている。これは既存手法では稼ぎやすい上昇トレンドのみで利益を上げるように進化しており、提案手法では様々なパターンの変動で利益を上げようと進化しているため上昇しているところで十分に稼ぐことが出来ていないためである。短く分割し学習を行ったものほど利益を上げることが出来ていないのはより多くのパターンで利益を上げようと進化しており、上昇トレンドで稼ぐことがより難しくなっているためである。

図 3 にその世代で適応度が最も高い個体のケース 1 のテスト期間での利益を示す。この図は、50 試行を平均したものであり、縦軸は利益(万円)、横軸は世

代数を表し、黒線は既存手法の利益、オレンジ線は2年刻みによる提案手法の利益、青線は1年刻みによる提案手法の利益、緑線は6ヶ月刻みによる提案手法の利益を表す。




図3 最良個体の利益の世代推移 (ケース 1)

ケース 1 のテスト期間において、最終世代ではどの刻みによる提案手法も既存手法の利益を上回っている。既存手法は学習期間では最も利益を上げることが出来ていたが、ケース 1 のテスト期間では成果を上げることが出来ていない。提案手法は学習期間では既存手法より利益を上げることが出来ていなかったが、ケース 1 のテスト期間では成果を上げることが出来ている。これは、既存手法は上昇トレンドのみでしか稼ぐことが出来ないように進化したためテスト期間の変動に対応できず、提案手法は様々なパターンの変動で利益を上げようと進化しているためケース 1 のテスト期間の変動にも対応することが出来たからだと考えられる。また、ケース 1 のテスト期間では、短く分割し学習を行ったものほど利益が上がっており、最も細かく分割した 6ヶ月刻みによる提案手法が最も利益を上げている。

ケース 2 でもケース 1 と同様に最終世代ではどの刻みによる提案手法も既存手法の利益を上回っており、短く分割し学習を行ったものほど利益を上げることが出来た。

図 4 にその世代で適応度が最も高い個体のケース 3 のテスト期間での利益を示す。この図は、50 試行を平均しており、縦軸は利益(万円)、横軸は世代数を表し、黒線は既存手法の利益、オレンジ線は2年刻みによる提案手法の利益、青線は1年刻みによる提案手法の利益、緑線は6ヶ月刻みによる提案手法の利益を表す。

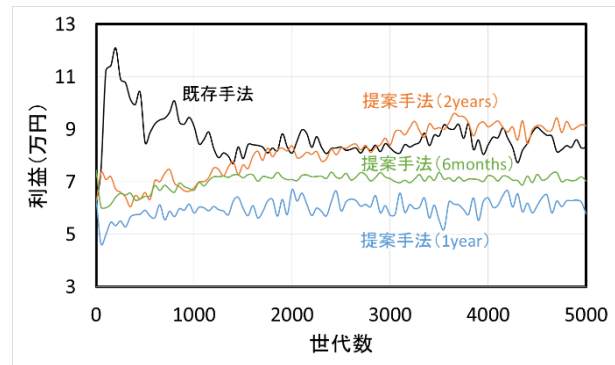


図 4 最良個体の利益の世代推移 (ケース 3)

この期間は強い上昇トレンドの期間であるため上昇トレンドに特化する既存手法が成果を上げることが出来ている。提案手法も学習が進むにつれて利益が上がっているが、6ヶ月刻みと1年刻みによるものは既存手法に劣っている。これは学習期間と同じように提案手法は様々な変動で利益を上げることが出来るように進化しているため、上昇しているところで十分に稼ぐことが出来ていないからだと考えられる。2年刻みによる提案手法は既存手法に勝っている。これは刻み方によって学習させる変動の特徴が異なるため、それがこのテスト期間の変動と合ったからだと考えられる。

#### 4. 今後の課題

本研究では、学習期間を2年、1年、6ヶ月の3種類に区切り学習を行っている。より多くの変動パターンを学習させるため、さらに細かく区切ることも考えている。また本研究では、学習期間を区切る際に1月を初めとしている。そこで、学習期間を季節や年度によって区切ることも考えている。季節を考慮した区切り方であれば、春を3月～5月、夏を6月～8月、秋を9月～11月、冬を12月～2月として区切り学習を行う。年度を考慮した区切り方であれば、4月を初めとして学習期間を区切り学習を行う。

#### 参考文献

- [1] 松村幸輝, 国屋美敬, 木村周平: 遺伝的プログラミング手法に基づくエージェントベーストレーダモデル, 情報処理学会論文誌, Vol.47, No9, pp.2869-2886, (2006)
- [2] 松村幸輝: 進化計算手法にクラスタリングを応用した株式投資の戦略木最適化モデル, 情報処理学会論文誌, Vol.49, No1, pp.457-475, (2008)