

ウェーブレット変換とGAにより最適化されたフuzzy推進システムを用いた株価予測

岸川, 善紀

<https://doi.org/10.15017/3000224>

出版情報：経済論究. 105, pp.13-26, 1999-11-30. 九州大学大学院経済学会
バージョン：
権利関係：

ウェーブレット変換とGAにより最適化された ファジイ推進システムを用いた株価予測

岸 川 善 紀

1 まえがき

ファジイ推論システムは、自動制御や画像処理のような多様で実際的な課題において、曖昧さを処理する技術分野に適用されてきた。ファジイシステムは言語学的な if-then ルール(プログラミングルール)より成り立っているため、データマイニングなど、多量のデータに埋め込まれた規則正しさを計算するための応用としても注目される。

本論文では、遺言的アルゴリズムを基礎とした多段ファジイ推論システムにおいて、株価のウェーブレット変換を入力として用いることにより株価の予測を行なう。これまで、経験論に基づき、株価の価格変動が予測の難しいランダムな時系列としてみなされているとしても、株価トレンドを示す図表を用いた将来価格を予測するための多くの伝統的な手法がある。しかしながら、これらの予測手段は常に秘密の一種として人間の専門家によって開発されているため、数学的モデルによる定式化は難しい。知能システムを用いることにより、株価予測を自動化することが期待できる。

株価予測の従来の研究として、線形予測、ニューラルネットワーク、そしてニューロファジイシステムのようなデジタル信号処理の手法が知られている。しかしながらそれらは常に入力としての直接的な株価データそのものを用い、それらは人間の専門家により解釈されると

考えられる短期的な特徴を取り入れていない。これを解決する一つの選択肢はスペクトルや過渡的な波のような短期的な特徴を発見する、または計算することである。

本論文で述べるようにウェーブレット係数が短期スペクトルのような短期的特徴を説明しているので、推論システムの入力変数としてこれらの係数を用いることが適切である。もしファジイ推論システムとウェーブレット変換による信号処理を結合させるならば、株価の集合から規則を発見する新しい知能信号処理システムを構成できることが期待できる。

しかしながら一般的にファジイ推論システムに含まれるルール数が巨大になり(入力変数の数の指数関数)、システムを実現することは非生産的な効果の無いものになる。

推論ルールの数を減らすいくつかの手法がある。意味の無いルールを取り除き、入力変数とメンバーシップ関数の数を減らし[4]、調整によってルールの数を減らす[5][6]、または分布されたファジイシステムを導入する[7]、等のように適応性のある手続きを用いる方法がある。しかし、これらの適応性のある手法の実行はつねに対象となる問題に依存し、その手続きは他の多くの問題に必ずしも適用可能ではない。

多段ファジイ推論システムが提案されてから、具体的な応用としてクロセクション分析[8][9]の一種である法人債券(社債)の分類に適用されている。しかしながら、特徴の連鎖的な時間領域でのパラメータの結合を考慮しなければ

ならない時系列分析への適用はこれまで存在しない。

本論文では、株価のトレンドの予測への階層的多段ファジイ推論システムの適用について述べる。システムは従来の単一ステージのシステムと比較してより少ない数のルールを含んでおり、現実的応用に適している。[3][8][9]システムにおいて推論システムはいくつかのステージに分割され、入力変数の一部分のみが推論の各ステージで入力信号として用いられ、格段の出力が次の段での入力として用いられる。それゆえ推論ルールの統計的な数は単一ステージのシステムと比較して著しく小さくなり、しかも同時にシステムの性能は低下しない。

また、メンバーシップ関数の形状を最適化するために GA を用いる [10]。非対称のメンバーシップ関数のケースにおいて、メンバーシップ関数の形状を決定しそして非線形最適化問題を解かなければならないのでメンバーシップ関数の最適化は簡単ではない。

本論文では、この手法を日本の証券市場の株価の自動的な予測システムに用いている。推論システムの入力変数は株価のウェーブレット係数を用いることによって短期的な特徴を持つものにしていく。シミュレーションの結果より、従来の手法と比較して正確な予測が約 5% 程改良されたことを示し、より効率の高いシステムであることを示した。

以下では 2 において、システムの概要を示す。3 において、GA を用いたメンバーシップ関数の最適化を基礎とする多段ファジイ推論システムの設計を示す。4 において、ウェーブレット変換を用いた株価の特徴抽出が論じられる。5 において、本手法を株価の価格変動を予測することに適用し、その結果はニューラルネットワークを含む従来のシステムと比較される。

2 システム概要

2.1 ファジイ推論システムと学習

本論文で扱われているファジイ推論システムの 3 つのサブシステムを含んでいる。すなわち、1) 時系列データ管理システム、2) ウェーブレット変換を用いた特徴抽出、3) ファジイ推論システムである。さらにファジイ推論システムは 2 つの部分から構成される。すなわち観測データを用いた学習過程と、将来の価格を予測するためのルールの適用である。

時系列データ管理システムにおいては、観測された株価は株価のフラクタル構造により抽出される時系列の特徴も同時に蓄積される [13]。株価をフラクタル時系列とみなすことは以下の分析で役に立つ [14]。データベースシステムはフラクタル構造を基礎として抽出された株価の過渡的な波もストアする。企業の名前や観測の日付と同じように、これらの過渡的な波による株価を検索することができる。

ウェーブレット変換を基礎とする特徴を抽出するサブシステムにおいて、株価のウェーブレット係数は株価の特徴化をするために用いられる。ウェーブレット係数の数は観測の長さにより制限される。株価時系列はまた、ウェーブレット係数によって計算される、時系列のフラクタル次元を基礎において、いくつかのセグメントに分割される。

ファジイ推論システムにおいて、多段ファジイシステムはルールの数を減らすために導入される。一般的にファジイ推論システムを含むルールの数は、入力変数の数の指数関数である。多段推論システムにおいて、入力変数は各ステージにおいて分散的に用いられ、これによりルールの数が減らされる。メンバーシップ関数

の形状が推論システムの性能に影響を与えるので、これらの形状は、逆伝播アルゴリズムによる重みの最適化と結合されたGAを用いることにより最適化される。

3 多段ファジイ推論

3.1 ファジイ推論ルール

ここで扱われる多段ファジイ推論システムはそれぞれ N_i の言語記述的 if-then ルールを含む N ステージのルールの組合せにより表現される多入力単一出力システムである。

(Stage 1)

If x_1 is A_{11}^1 and ... and x_M is A_{1M}^1
then y_1 is w_1^1

If x_1 is A_{11}^2 and ... and x_M is A_{1M}^2
then y_1 is w_1^2

.....

If x_1 is A_{11}^{n1} and ... and x_M is A_{1M}^{n1}
then y_1 is w_1^{n1}

(Stage 2)

If x_1 is A_{21}^1 and ... and x_M is A_{2M}^1 and y_1 is B_2^1
then y_2 in w_2^1

If x_1 is A_{21}^2 and ... and x_M is A_{2M}^2 and y_1 is B_2^2
then y_2 in w_2^2

.....

If x_1 is A_{21}^{n2} and ... and x_M is A_{2M}^{n2} and y_1 is B_2^{n2}
then y_2 in w_2^{n2}

(Stage N)

If x_2 is A_{N1}^1 and ... and x_M is A_{NM}^1 and y_{N-1} is B_N^1

then y_n is w_N^1

.....

If x_1 is A_{N1}^2 and ... and x_M is A_{NM}^2 and y_{N-1} is B_N^2

then y_n is w_n^2

.....

If x_1 is A_{N1}^{nN} and ...and x_M is A_{NM}^{nN} and y_{N-1} is B_N^{nN}

then y_N is $w_N^{nN}(1)$

$x_j(j=1, 2, \dots, M)$ は入力変数である。 A_j^k は i 番目のステージ、 j 番目の入力変数 x_j に与えられたファジイ集合である。実数 w_i^k は、各推論ルールに用いられるウェイトである。出力変数 $y_i(i=1, 2, \dots, N-1)$ は i 番目のステージの推論の結果であり、その次のステージでの入力変数として用いられる。 B_i^k は k 番目のルールと i 番目のステージ、そして y_{i-1} におけるファジイ集合である。

出力 y_N は最終ステージにおいて算出され、それは全体の推論の結果となる。

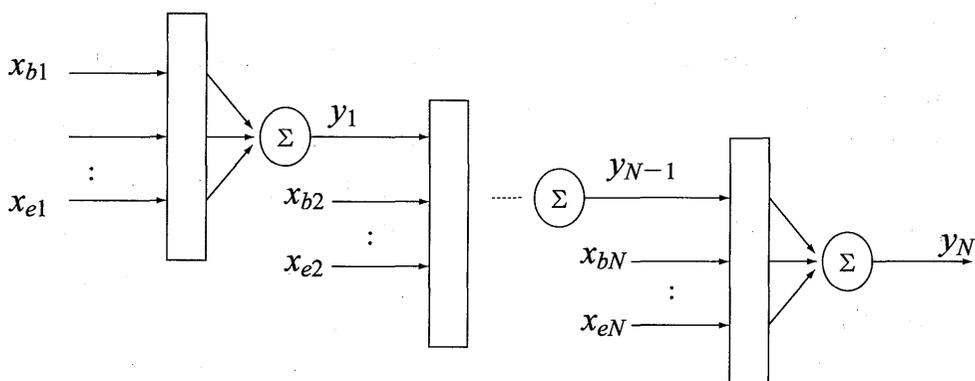
我々は出力を決定するための後述される単純化された簡易化されたファジイ推論を用いる [11]。この簡易ファジイ推論により、 i 番目のステージの推論で算出される出力は、以下の式で与えられる。

$$\mu_i^k = \prod_{j=1}^{M^*} \mu A_{ij}^k(x_j) \quad (2)$$

$$y_i = \frac{\sum_{k=1}^{ni} \mu_i^k w_i^k}{\sum_{k=1}^{ni} \mu_i^k} \quad (3)$$

μA_{ij}^k は、ファジイ関数 A_{ij}^k のメンバーシップ関数である、 μ_i^k は i 番目のステージにおける k 番目のルールの適合度である。 M^* は i 番目のステージにおける入力変数の数であり、その最大値は $M+1$ である。なぜなら前のステージの出力は次のステージの入力として用いられるからである。しかし、常にシステムへの入力変数の一部だけが、各ステージの入力として用いられる。そのため、 M^* は $M+1$ より十分に小さい。

出力 y はウェイト w_i^k と μ_i^k とを掛け合わせた合計値によって得られたものを、 μ_i^k の合計値にて割ったものとして求められる。 i 番目のス



各段につき変数の一部が入力として用いられる

図1 多段ファジイ推論システム

ステージの入力として用いる出力変数 y_{i-1} に対しては、我々はメンバーシップ関数 $\mu B_i^k(y_{i-1})$ を $\mu A_i^k(x_j)$ の代わりに用いられる。

3.2 ウェイトの最適化

本論文において、パラメータ(ウェイト w_i^k とメンバーシップ関数 μA_i^k と μB_i^k の形状)は観測データの例からの学習によって最適化される。最適化されたシステムによって株価のトレンドを予測する。

システムへの入力変数はウェーブレット係数のような株価トレンドの特徴であり、出力 y は株価の予測である。パラメータはあらかじめ与えられた値へ出力 y を適合させる方向で調整される。ウェイト w_i^k はニューラルネットワークの設計に使用され、逆伝搬アルゴリズムを用いることにより最適化される。メンバーシップ関数の形状は GA によって最適化される。これら二つの手続きが、交互に適用される。

すなわち、まず最初にメンバーシップ関数の形状が固定されているという仮定のもとにウェイト w_i^k が最適化される。次に、メンバーシップ関数の形状が、ウェイトが与えられたものと仮定して最適化される。

まず、最初に逆伝搬アルゴリズムを用いたウェイト w_i^k の最適化を示す。最小化されるための評価関数は、規定された値 y^p と p 番目の学習データの出力 y との間の二乗誤差である。後述の議論では、 y^p は株側の上昇または下降に対応する実数である。

$$J_p = (y - y^p)^2 / 2 \tag{4}$$

ウェイト w_i^k を最適化する手続きは、後述の逆伝搬アルゴリズムにより与えられる [12]。

$$\delta_N = y - y^p \tag{5}$$

$$\Delta w_N^k = \epsilon \delta_N \mu_N^k / \sum_{k=1}^{NN} \mu_N^k \tag{6}$$

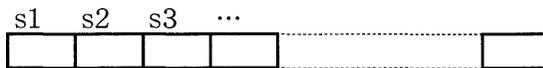
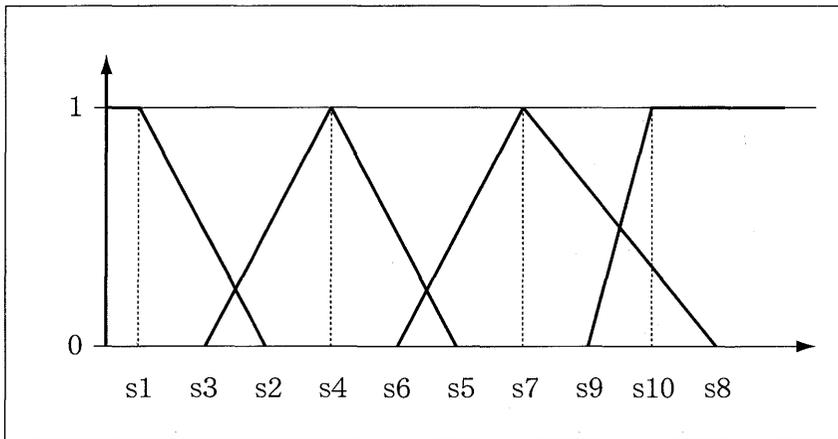
$$\delta_i = B^{-1} \delta_{i+1} \sum_{k=1}^m (w_{i+1}^k - \sum_{k=1}^m w_{i+1}^k \mu_{i+1}^k) \partial \mu_i^k / \partial x_j \tag{7}$$

$$B = \left(\sum_{k=1}^{ni+1} w_{i+1}^k \mu_{i+1}^k \right)^2 \tag{8}$$

$$\Delta w_i^k = \epsilon \delta_i (\mu_i^k / \sum_{k=1}^{ni} \mu_i^k) \tag{9}$$

δ_i は、 N 番目のステージから最初のステージへと逆伝播される中間値であり、そして Δw_i^k はウェイトを更新するための増加量である。

これらの公式は、ファジイシステムとニューラルネットワークの関係性を考慮しながら、ニューラルネットワークにおける従来の最適化アルゴリズムを用いることによって得られる。



Example: if s1 is 0.11248 then



図2 メンバーシップ関数

式の導出の詳細は付録で示す。

3.3 メンバーシップ関数の最適化

一般的にはメンバーシップ関数の形状は、三角形や台形の形の関係である。メンバーシップ関数の幾何学(形状)はシステムの性能を推論する。後述の議論において、我々はGAを用いることにより三角形のメンバーシップ関数の形状を最適化する。これを用いると、同じアルゴリズムを他のメンバーシップ関数に応用できるからである。

入力変数 x_j は $0 \leq x_j \leq 1$ に標準化されていると仮定する。三角形のメンバーシップ関数は、三角形の底 (X_1 と X_2 で記述される)と頂点(横座標は X_c)を一致させる横座標を用いて定義される。ルールにおける各メンバーシップ関数のこれら(入力変数の組合せのための) X_1, X_c, X_2

は、数の系列(ストリング)として配列される。数の系列はGAにおいて、ストリングまたは個体として呼ばれる。図2において、 X_1^i, X_c^i そして X_2^i が i 番目のメンバーシップ関数の横座標を示している。以下では、簡単のためにこれらの横座標は図2における $X_1^1, X_c^1, X_2^1, X_1^2, X_c^2, X_2^2, \dots$ を順序通り並べて、 s_1, s_2, \dots ,として記述することにする。個体の表現において我々はこれを簡単化することができる。何故なら、 X_1, X_c, X_2 の値は一より小さいからである。これらの数にとって、小数点以下は5桁の数の組として表現される。それゆえ、1つのファジイシステムに対応する個体は、 $N * M^{m_b}$ の整数を含む。 m_b はメンバーシップ関数の数である。

従来のGAにおいて、ビットパターンの組合せとして系列を表現することが行なわれている。しかしながら、メンバーシップ関数の底と

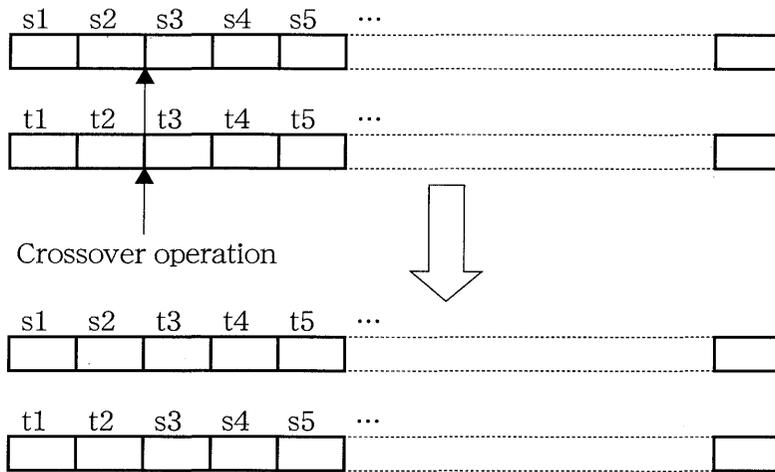


図3 GAオペレーション (交叉)

頂点を含む情報を保存することは重要であるので、直接的にメンバーシップ関数を表現する個体を用いる。

GAにおいてまず最初に個々の組合せ(個体群集合)は乱数を用いることで生成される。各個体は推論システムの実現に対応する。個々の性能を評価した後、交叉や突然変異のような遺伝的操作は、新しい個体を創造するための個体群へ適用される。

方程式における逆伝搬アルゴリズムによるファジールールのウェイトの最適化とGAを用いることによるメンバーシップ関数の最適化を結合させる(1)-(5)。

まず最初にメンバーシップ関数の形状が先のステージでの個体の集合を用いることにより決定される。次に、逆伝搬はウェイトの最適化をするために適用される。個体群において i 番目の個体の能力は p_i により記述されるが、これは、この個体により対象が正確に分類される割合として決定される。すなわち、メンバーシップ関数の形状を表現している各個体のために、方程式(1), (2)を用いることにより、ファジイ推論の分類の割合 (p_i と記す) を計算する。ここで i 番

目の個体の適応度として p_i をとる。例えば、入力データ x_1, x_2, \dots, x_M を用いることによって分類される2つのグループ(AとB)に属する N 個のテストデータがあるとする。もし、 i 番目の個体を用いることにより、実現される推論システムが N_A および N_B のデータを正確にグループAとBに分類するならば、 $p_i = (N_A + N_B) / N$ である。

次に、個体群へGA操作を適用する。GAの手続きとして交叉と突然変異を用いる。まず適応度に依存して個体を並べる。それからより高い p_i を持つ個体群から個体の一組を選択し、図3のように交叉を適用する。新たに発生した2つの個体は個体群の中のより p_i の低い2つの個体と取り換える。突然変異は個体群の中から、完全にかき離れた個体を発生させるために、ある個体に適用される。

3.4 全体のアルゴリズム

逆伝搬アズゴリズムとGAを含む学習の全体のアルゴリズムは、次のように要約される。(step 1)

初期値としてメンバーシップ関数の形状が与

えられる。すなわち、横座標 X_i^i , X_i^j , と X_i^c が次のように与えられる。 $\varepsilon_1, \varepsilon_2, \varepsilon_c$ は正規乱数として発生した乱数である。

$$X_1^i=0, X_c^i=d+\varepsilon_c, X_2^i=2d+\varepsilon^2 \quad (10 a)$$

$$X_1^j=1-2d+\varepsilon_1, X_c^j=1-d+\varepsilon_c, X_2^j=1 \quad (10 b)$$

$$X_i^i=(i-1)d+\varepsilon_1(1<i<I) \quad (10 c)$$

$$X_c^i=id+\varepsilon_c(1<i<I) \quad (10 d)$$

$$X_2^i=(i+1)d+\varepsilon_2(1<i<I) \quad (10 e)$$

上の式において $d=1/(I+1)$ であり、 I はひとつのルール集合のためのメンバーシップ関数の数である。

(step 2)

横座標 X_i^i , X_c^i , X_2^i を系列に表現する。各系列は、システムの実現に一致される。それらは $s1, s2, \dots$ と記述される。

(step 3)

ルールのウェイトを逆伝搬アルゴリズムを用いることにより最適化する。最適化は各ファジィ推論システム(個体)のために200回繰り返される。

(step 4)

個体により実現化されたファジィ推論システムにより正確な分類の割合(適応度) ρ_i を見積もる。 ρ_i に関して個体を並べ、そして個体群としてそれを作る。GA を個体群に適用する。

(step 5)

GA アルゴリズムを適用した後、反復の回数を増加させる。もし(step 3)と(step 4)において最適化の総計が600を越えるならば、多段ファジィ推論システムの学習を終了する。そうでない場合は、個体群において新たに個体を発生させるためのウェイトを最適化するため(step 2)へと行く。

4 ウェーブレット変換による特徴化

4.1 株価のウェーブレット変換

ウェーブレット係数が短期スペクトルのような短期的特徴を記述しているので、将来の株価を予測するためにウェーブレット係数を予測することは適切である。この株価の短期的特徴を用いる推論システムは、ニューラルネットワークのような観測された株価のみを用いる予測システムより優れている。この論文では、多段ファジィシステムの入力変数としてウェーブレット係数を用いる。時系列 $x(t)$ のウェーブレット変換は次のように定義される[16]。

$$x(t)=\sum_n \sum_m x_n^m \phi_n^m(t). \quad (11)$$

$$x_n^m = \int_{-\infty}^{\infty} x(t) \phi_n^m(t) dt. \quad (12)$$

$$\phi_n^m(t) = 2^{m/2} \phi(2^m t - n). \quad (13)$$

ここで、整数 m と n はスケールとシフトの指数である。簡単のために用いる時系列 $x(t)$ のサンプリング間隔を1であると仮定する。各ウェーブレット関数 ϕ_n^m は重ならないため、整数 m と n は次のように制限される。

$$m=2^k, n=Jm(J=1, 2, \dots, K=0, 1, \dots) \quad (14)$$

ウェーブレット係数の他に入力変数として株価のフラクタル次元も用いる。他の例から見られるように、株価はフラクタル時系列によりモデル化される。フラクタル次元は時系列の複雑さに符号する。与えられた時系列 $x(t)$ がフラクタルであるかどうかを試す2つの手法がある。最初の手法は十分な最も近い M 個のサンプルを合計することにより発生される時系列の分散を計算することである。そして、これら時系列の分散を調べる。 M 個のサンプルを次のように合計する。

$$x_1(M) = M^{-1} \sum_{j=(t-1)M+1}^{tM} x_j \quad (15)$$

$x_1(M)$ の分散は原時系列がフラクタルであるならば、次のように書かれる。

$$\text{var}(x_1(M)) = \sigma m^{-\beta} \quad (16)$$

σ は原時系列の分散であり、 $0 < \beta < 1$ である。

二番目の手法は時系列のスペクトルを調べることである。そのスペクトルは周波数に対して徐々に小さくなる $1/f$ の群に属している。その条件はウェーブレット係数の分散により表現される。

$$\text{var}(x_n^m) = \sigma^2 2^{-\gamma m} \quad (17)$$

$$\gamma = 5 - 2D \quad (18)$$

ここに示されるように、フラクタル次元 D は式(17)に含まれる。式(17)の対数をとることにより、 $\log(\text{var}(x_n^m))$ は指数 m の線形回帰により近似できることが示される。

$$R_w = \left[\frac{\sum_m (\log(\text{var}(x_n^m)) - c_0 - c_1 m)^2}{M_s X_r} \right]^{1/2} \quad (19)$$

M_s は指数 m の数であり、 X_r は x_n^m の範囲であり、 c_0 、 c_1 は回帰係数である。それから、 $\log(\text{var}(x_n^m))$ と回帰線との間の平均二乗誤差の平方根をとることによって、時系列がフラクタルとして接近しているかどうかを試す測度を定義できる。

理論的に式(19)における平均二乗誤差は、フラクタル時系列にとってはゼロである。フラクタル時系列の反対の挙動をする例としてあげられている指数的に減少するスペクトルを持つと仮定される ARMA 時系列においては R_w は約 0.05 である。従って、時系列をフラクタルと認識するしきい値として、0.02 を用いる。

4.2 入力変数としてのウェーブレット係数

多段ファジイ推論システムにおいて、株価のトレンドから得られるウェーブレット係数が入

力変数として用いられる。入力変数の数は、一段のみのファジイシステムのそれよりも多くできる。しかしながら、現実の適用において利用できる係数の数は制限される。式(14)において見られるように、スケール指数 m の最大値は時系列 $x(t)$ の長さ L を用いることにより定義される。すなわち、与えられたスケール指数 m におけるウェーブレット係数の数は次の式により決定される。

$$N_m = L/2^m \quad (20)$$

もし、最間領域において、特徴抽出を考慮することにより N_m を選択するならば、 m の最大値は周波数領域における分析に対応するように決定される。数年間における株価の構造的変化を参考にすれば、 L の最大値は約 2000 に制限されることがわかる。従って、 m の最大値は 6 に決定する。すでに触れられたように、フラクタル次元と株価の分散は入力変数としても用いられる。そしてファジイ推論システムの格段への入力変数は次のように与えられる。

第 1 段：フラクタル次元、分散、 x_n^0 、 x_n^1

第 2 段： x_n^2 、 x_n^3 、 x_n^4

第 3 段： x_n^5 、 x_n^6

5 応用例

5.1 株側の上昇/下降の予測

多段ファジイ推論システムは、実際の市場における株価の価格変動(上昇または下降)を予測することに応用される。すべての株価データは記録され、シミュレーション実験において学習とテストのために利用できる。シミュレーション実験の課題は、時刻 t における T 時間後の株価 $S(t+T)$ の正確な予測の割合を評価することである。後に示す問題は、ファジイ推論システムを評価するうえで考えなければならない点

である。

(1)上昇/下降の定義

(2)現在時刻と、どのくらい離れているのか

(3)出力の離散化

最初の問題は、どのように株価の(上昇, 下降)の変化の幅を決定するか、ということである。そのため、価格変動分 $S(t+T)-S(t)$ のしきい値として $\theta(T)$ を導入する。そのしきい値は推論の性能に影響する。時間 t に独立な2つのしきい値 $\theta(T)$ を定義する。株価の上昇の場合において、しきい値 $\theta(T)$ に $U(T)$ を用いる。株価の下降の場合において、しきい値 $\theta(T)$ に $D(T)$ を用いる。例えば、もし推論システムが $S(t+T)-S(t) > U(T)$ であると推定するならば、システムは株価の上昇を予測する。一方、もし $S(t+T)-S(t) < D(T)$ と推定するならば、システムは株価の下降を予測する。二番目の問題に関連して、推論を評価するためにいくつかの T の値を選ぶ。 $\theta(T)$ と T の間のいくつかの結合をとるとき、 T の値における推論の一種の依存性を発見することができる。すでに見られるように、ウェーブレット係数 x_n^m が 2^m の時間間隔毎に計算される。それゆえ、すべてのウェーブレット係数が時間 t において必ずしも計算されるわけではないケースが存在する。これらのケースにおいて、 t の周辺の最も近い時間で計算されるウェーブレット係数を用いる。

第三の問題は、学習のための出力の規定された値をどのように選択するか、そしてどのような推論の結果を認識するかである。簡単のために、株価の上昇と下降のみを考慮する。学習過程において、規定値 $1(0)$ は株価の上昇(下降)の事例を割り当てる。それから、推論システムのパラメータは推論の出力が価格の上昇/下降のとき $1/0$ となるように調整される。一方、推論の過程において、システムがもし推論システ

ムの出力 y がそれぞれ $0.5 < y \leq 1$ そして $0 \leq y \leq 0.5$ であるならば、将来の株価が上昇/下降となると予測される。

5.1.1 シミュレーションの事例

シミュレーション実験において、推論システムは以下の2つの場合について評価される。

(1)上昇/下降の2値の予測

(2)上昇/無変化/下降の3値の予測

第一番目の2値の予測の場合はシステムは将来的な価格変動の上昇または下降を予測する。将来の価格変動 $S(t+T)-S(t)$ を $\theta(T)$ と比較することによって価格の上昇, 下降があると予測する。そして株価が上昇(下降)のとき、離散化された出力は $1(0)$ となる。

3値の予測の場合、価格の上昇/下降の場合と同じように将来の価格に“変動無し”を定義する。価格の変動無しとみなすのは $S(t+T)-S(t) < U(T)$ であり、かつ、 $S(t+T)-S(t) > D(T)$ であるときである。この事例においては上昇, 変動無し, そして下降のとき、離散化された出力 $1, 0.5, 0$ を割り当てる。一方、推論システムをテストする過程において推論の入力から将来の価格が上昇する, 変動無し, 下降する, というのを決定するのは推論システムの出力 y がそれぞれ $2/3 < y \leq 1, 1/3 < y \leq 2/3$ そして $y \leq 1/3$ のときである。

5.2 シミュレーション実験の結果

実際の応用において、学習用のデータセットおよびテスト用のデータセットはデータベースから別々に選択される。しかし、シミュレーション実験において学習用のデータがまたテスト用にも用いられるケースもまた推論の結果として示している。次の2つのケースを考える。

(Test A) 学習用データがまたテスト用にも含まれる

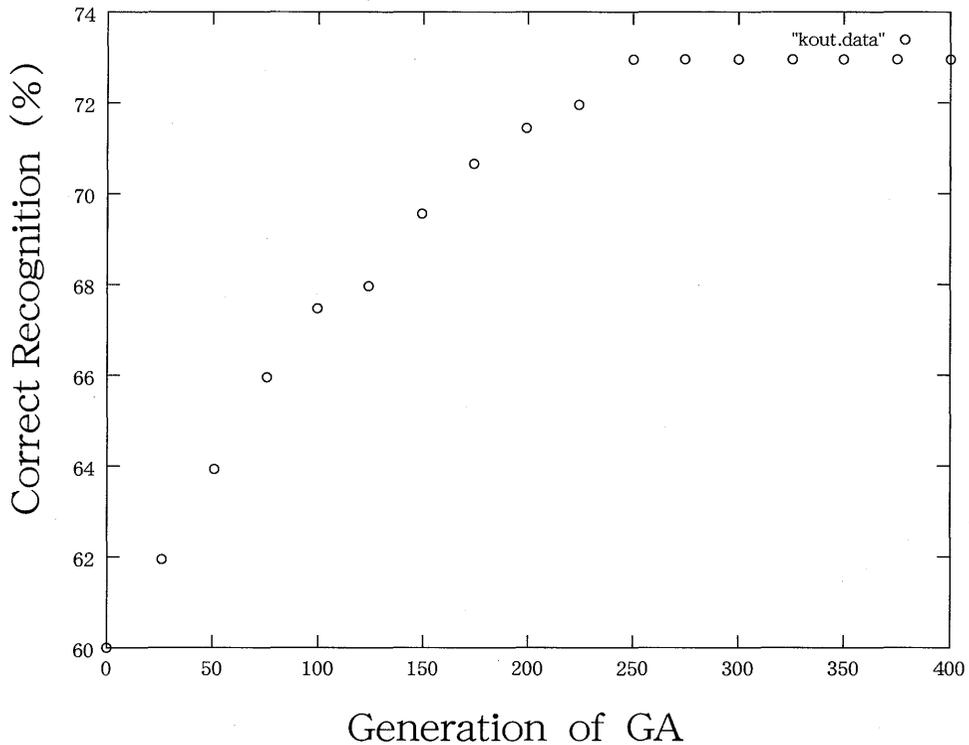


図 4

(Test B)データが学習用そしてテスト用に別々に選択される

株価の選択は次のようにする。

株の数：100

株の種類：電化製品，機械，貿易会社等

標準化された株価： $0 < x(t) < 150$

学習用そしてテスト用のデータセットはCD-ROMに記録された1970年から1982年までの公表データを用い編成される。それらの株価データから期間中の小さな株価の変動しか示さないものは削除することにより，CD-ROMから100のデータを選ぶ。その株価が用いられる産業の種類は電化製品，機械，そして貿易企業である。

株価が変化する，または変化しないことが観測される一つの株価のトレンドをおよそ10から30地点ほど発見する。これらの点において推論される特徴は学習そしてテストシステムにうつ

される。学習用そしてテスト用のデータは次のようである。

学習用：3-30

テスト用：1-420

シミュレーションのパラメータは次のように選択される。

メンバーシップ関数の数： $M_B = 4$ or 5

(GAにおける)個体群の大きさ：50

突然変移の確率：0.01

表1と表2は2値予測の株価の U ， D そして T の代表的な組合せをした場合に正しく予測したものの詳細なデータを示す。表3は株価の上昇そして下降の事例のそれぞれの正しい予測の割合である。結果としては，株価の予測は平均して70% (Test A)そして68% (Test B)の割合で正確な予測を行なった。 $\theta(T)$ and T の間の結合に依存している予測にたいした違いがない

表1.2 値予測, Test A (%) ($M_B=5$)

T	U=20, D=10	U=15, D=15	U=20, D=20
20	77	76	77
30	78	75	78
50	79	74	76

表2.2 値予測, Test B (%) ($M_B=5$)

T	U=20, D=10	U=15, D=15	U=20, D=20
20	73	71	72
30	72	73	71
50	74	72	70

表3.2 値予測(上昇/下降のケース), Test B (%) ($M_B=5$)

T	株価上昇	株価下降
20	73	70
30	75	72
50	72	71

表4.3 値予測, Test A (%) ($M_B=5$)

T	U=20, D=10	U=15, D=15	U=20, D=20
20	69	70	71
30	68	71	71
50	71	70	70

表5.3 値予測, Test B (%) ($M_B=5$)

T	U=20, D=10	U=15, D=15	U=20, D=20
20	62	67	66
30	63	64	69
50	65	67	68

表6.3 値予測(上昇/無変化/下降のケース), Test B (%) ($M_B=5$)

T	上昇	無変化	下降
20	67	67	66
30	65	69	64
50	63	71	65

ことが分かる。実際 $20 \leq T \leq 50$, $150 \leq U \leq 20$, and $10 \leq D \leq 20$ を選択したところ将来の株価を70%の信頼度で予測した。

表4と表5は3値の株価の U , D そして T の結合に依存している正しい予測の比率である。

(Case A と Case B) 表6は株価の上昇, 変動無し, 下降の事例のそれぞれの予測の詳細である。結果としてはわずかに2値予測に劣る。しかし, 正しい予測の比率は3値であるにもかかわらず60%を越えている。

5.3 ニューラルネットワークとの比較

株価予測のための多くの実験的手法は2つのカテゴリに分類される。第一は, 株価, 分散, そして取引量の間関係と経済指標を発見する統計的手法であり, これらにおいては株価と関連した経済情報から得られた統計を利用する。そのモデルは仮説の検証により評価される。

第二の手法は観測された株価を用いることによる株価の直接予測である。ARMA 過程と線形予測により時系列をあてはめるモデルが, よく知られている。最近, 我々は階層型ニューラルネットワーク(簡単のためにニューラルネットワークと呼ぶ)と単一ステージファジィ推論を基礎においた予測が, 線形手法などより優れたよりよい結果を与えたことを示されている。これらの論文において扱われた予測は, 二番目の手法に属している。ここでは, 特にニューラルネットワークにより実現されたシステムとの性能の比較に注目する。何故なら, ニューラルネットワークは従来の手法の中で最も良い手法のひとつだからである。比較のための条件に近付けるためにシミュレーション実験におけるシステムの入力変数は, 多段ファジィシステムのそれと同じであると仮定する。ニューラルネットワークの入力変数の数は7つ, すなわちフラクタル次元, 株価トレンドの分散, そして7つのウェーブレット係数である。隠れ層のユニットの数は6, そして出力層は1ユニットを持つ。分類のための値の定義1, 0.5, 0はファジィ推論システムと同じように株価の上昇, 変動無し, 下降,

の学習のために用いた。同じように、システムはニューラルネットワークの出力 y の値がそれぞれ $2/3 < y \leq 1$, $1/3 < y \leq 2/3$, $y \leq 1/3$, のとき、株価が上昇、変動無し、下降すると予測する。シミュレーション実験の結果は、表 7 (2 値予測, Test B), 表 8 (3 値予測, Test B) にそれぞれ示される。結果は多段ファジイシステムの方がより良い性能を示すことが分かる。

ニューラルネットワークへの入力変数に関して、ウェーブレット変換のような特徴のかわりに直接的に株価を用いることができる。しかしこの性能は多段ファジイ推論のそれより悪くなる(実験の詳細はここでは省く)。

表 7. 2 値予測, TestB (%) ($M_B=5$)

T	U=20, D=10	U=15, D=15	U=20, D=20
20	64	63	64
30	65	69	68
50	66	66	67

表 8. 3 値予測, TestB (%) ($M_B=5$)

T	U=20, D=10	U=15, D=15	U=20, D=20
20	61	63	62
30	61	63	65
50	62	62	64

6 議論

本論文で示した推論システムは、ニューラルネットワークより、よい予測を提供するけれども、学習データとテストデータの結合、および推論のためのパラメータに注意を払わなければならない。

(1) 学習, テストデータの結合

実験において予測のルールが株 A を用いて学習することによって得られるケースを選択する。それから株 B の将来の株価変動が株 B の予

測と同様に予測される。認識の平均的割合は、表 1 と表 3 に概要が示されている。一般的に株 A の学習をもとにした株 A の予測は株 B を用いたものより良好である。しかしその違いは注目する程ではなく、平均およそ 2% である。

(2) ウェーブレット係数

シミュレーション実験におけるウェーブレット係数の拡張指数 m は 6 以下に制限され、 $m=6$ の時、64 日周期の発生と一致する、しかし証券市場においてオプションのような取引は 3 ヶ月以内に閉じられる。従って、 $m=6$ のときは m の最高の選択であると思われる。

(3) 二値と三値の予測

3 値予測において、2 値予測のそれに加えて変動無しと言う予測を導入する。言い替えると、2 値予測において学習とテストの両方の株価の上昇または下降を見る時刻のみを選択している。しかし、実際の適用において価格の変動無しというケースを無視することはできない。それで、3 値予測は推論システムの能力の実際的な側面を反映していると考えられる。

(4) 失敗例

予測における大半の失敗例は株価の変動が単調であるか複雑であった株において起こる。第一のケースでは、ウェーブレット係数により述べられる特徴の変化が非常に小さい場合である。何故なら係数が計算されないからである。他方、もし価格が急速に動くならば、 $\theta(T)$ と T の間の結合が非常に大きくなり、学習データによって得られる結合と対応しないことになる。

予測システムはこれらの問題を抱えているが、ウェーブレット変換とファジイ推論システムによる特徴抽出は株価のよりよい予測を提供することを期待されている。

7 結論

本論文は知能信号処理の手法のひとつとしてGAを基礎においた多段ファジイ推論システムの設計と応用を示した。株価予測への応用において、ウェーブレット変換は株価トレンドの短期的特徴を記述するために用いられる。フラクタル次元と時系列の分散は入力変数としても用いられる。推論システムを複数の段に分割することにより、ルールの総計は単一段のシステムと比較して十分に小さくなる。よりよい性能を与えるため推論ルールのメンバーシップ関数の形状はGAを用いることにより最適化される。シミュレーション実験は株価変動について約70%の正確な予測を与える推論システムを示した。結果はニューラルネットワークによる予測と比較され、ファジイシステムはよりすぐれた予測を与えることを示した。

解決されるべき問題は株価トレンド一時的な波の予測のような分野へのシステムの拡張であり、今後検討を続けていきたい。

参考文献

- [1] I.A.Zadeh: "Fuzzy sets", *Information and Control*, 8, pp.338-353(1996).
- [2] T.Takagi and M.Sugeno: "Fuzzy identification of system and its application to modeling and control", *IEEE Trans. System Man and Cybernetics*, SMC-15, pp.116-132(1985).
- [3] G.V.S Raju, Jun Zhou: "Adaptive hierarchical fuzzy controller", *IEEE Transaction on Systems, Man, and Cybernetics*, Vol 23, No.4(July/August, 1993).
- [4] H. Miyazaki, S. Fukumoto, and Y. Ishizaki: "Fuzzy modeling based on deleting rules", *Trans. IEICE*, Vol. J77-A, 11, p..555-562(1994-11).
- [5] H. Ishibuchi, K. Ozaki, N. Yamamoto and H. Tanaka: "Selection of fuzzy if-then rules by a genetic method", *Trans. IEICE*, Vol. J76-A, 10, pp.1465-1473(1993-10).
- [6] T. J. Procyk and E. H. Mandami: "A linguistic self-organizing process controller", *Automatica*, 15, pp.15-30(1979).
- [7] H. Ishibashi, K. Nozaki, and H. Tanaka: "Distributed representation of fuzzy rules and its application to pattern classification", *Fuzz Sets and System*, 51, pp.21-32(1992).
- [8] K. Tan and S. Tokinaga: "Applying the multi-stage fuzzy inference system with the genetic algorithm", technical Report of IEICE, DSP97-161, pp.105-112(1998).
- [9] K. Tan and S. Tokinaga: "The design of multi-stage fuzzy inference system with smaller number of rules based upon the optimization of rules by using the GA", *Trans. IEICE Section E to appear*.
- [10] D. E. Goldberg: *Genetic Algorithm in Search, Optimization and Machine Learning*, Addison-Wesly, Reading, Mass.(1989).
- [11] S. Murakami and M.Maeda: "Automobile speed control system using a fuzzy logic controller", in *Industrial Applications of Fuzzy Control*, ed. M.Sugeno, pp.105-123, Elsevier Science Publisher (1985).
- [12] D. E. Rumelhart, G. E. Hinton and R. J. Williams: "Learning internal representation by error propagation, Paralell distributed processing", McClelland and the PDP Research Group ed. MIT Press, 1989.
- [13] S. Tokinaga and Y. Kishikawa: "Applying the the prediction method based upon the scale expansion to the feature extraction of tractal geometry", technical Report of IEICE, DSP98-13, pp.91-98(1998).
- [14] Y. Ikeda and S. Tokinaga: "Evaluation of stock option prices by using the prediction of fractal time-series", *Journal of Operations Research Society of Japan*, Vol.42, No.1, pp.18-31, 1999.
- [15] Japanese Ministry of Finance: "Stock prices in CD-ROM" Touyou Keizai Simmpou-sha(1992).

(付録)

$$J = (y - y_N)^2 / 2 \quad (A1)$$

ここで y は望ましい出力であり、 y_N は推論システムの出力である。それから n 番目の段で、 $\Delta w_N^k = \partial J_p / \partial w_N^k$ を以下の式から得られる。

$$\partial J_p / \partial w_N^k = (\partial J_p / \partial y_N) (\partial y_N / \partial w_N^k) \quad (A2)$$

ここで $\partial J_p / \partial y_N = \delta_N$ は以下の式で定義される。

$$\delta_N = y - y_N \quad (A3)$$

$N-1$ 番目のステージにおいて、次の $\Delta w_{N-1}^k = \partial J_p / \partial w_{N-1}^k$ を同様に

$$\partial J_p / \partial w_{N-1}^k = (\partial J_p / \partial y_{N-1}) (\partial y_{N-1} / \partial w_{N-1}^k) \quad (A4)$$

部分導関数の各組を代入することによって、以下の式を得る。

$$\Delta w_{N-1}^k = \delta_{N-1} \mu_{N-1}^k / \sum_{k=1}^{n_{N-1}} \mu_{N-1}^k \quad (A5)$$

後述の関係式と式 (A5) を用いて、以下の式を得る。

$$\delta_{N-1} = \sum_{j=1}^{m^*} (\partial J_p / \partial y_{N-1}) (\partial y_{N-1} / \partial x_j) \quad (A6)$$

合計値の組合せを代入することにより、以下の再帰的な関係を得る。

$$\delta_{N-1} = B^{-1} \delta_N \sum_{k=1}^m (w_N^k - \sum_{k=1}^k \mu_N^k) (\partial \mu_N^k / \partial x_j) \quad (A7)$$

$$\Delta w_{N-1}^k = \varepsilon \delta_N (\mu_{N-1}^k / \sum_{k=1}^{n_{N-1}} \mu_{N-1}^k) \quad (A8)$$

ここで

$$B = \left(\sum_{k=1}^{n_{N-1}} w_N^k \mu_N^k \right)^2 \quad (A9)$$

同じ関係が $i (i=1, 2, \dots, N-1)$ について維持される。