

# 商品先物価格変動へのニューラルネットモデルの適用

提出版 H18.10.12

高見茂雄

富山大学経済学部

takami@eco.u-toyama.ac.jp

**要約:** われわれはデータが整備され、流動性に富み、かつ比較的銘柄数が少ない上場商品先物に注目し、東京工業品取引所の10品目、東京穀物商品取引所の8品目、合計18種類商品先物のデータをもとに、実証分析を行った。用いた分析手法は、データ種別として、終値だけのデータと終値に罫線情報を加えたデータに2分、モデルとして、線形モデルとニューラルネットモデルとを用いて、 $2 \times 2 = 4$ 通りの分析結果を検討する手法をとった。さらに、月次、週次、日次それぞれの期間間隔で、ほとんど同じ手法を用い比較検討を行った。

得られた結果は、月次データについては、ほとんどすべての商品先物で、終値データだけの場合も罫線情報を加味したデータの場合も、ニューラルネットモデルは線形モデルより適合度で勝り、しかも、追加的な罫線情報の価値はニューラルネットモデルの方がよりよく吸収していることが観察できた。この点では、実際の商品先物価格はランダムな動きではなくテクニカルな動きをしているという先行研究とインプリケーションにおいて通じるところがある。しかし、週次、日次と期間間隔を狭めた分析では、この命題は当てはまらなかった。

**キーワード:** 上場商品先物、ARMAモデル、ニューラルネットモデル、罫線情報、平均2乗誤差(MSE)、自己相似性

## 目次

- 1.はじめに
- 2.データ
- 3.分析手法
- 4.月次データの分析結果
- 5.週次・日次データの分析結果
- 6.結論

### 1.はじめに

蓑谷(2001, p.1)が述べているように、金融時系列データが企業財務データや国民所得データなどのデータに比べ、興味深い点は、期種の豊富さにある。後者は四半期、年次のデータにほぼ限定されるのに対し、金融時系列データは日次、週次、月次はもちろんのこと、場合によってはティック情報までアベイラブルであり、かつ、始値、高値、安値、終値の四本値や取引量も整備されている。これらデータ量の豊富さは研究を進めるにあたり、優位に立っているに違いない。しかしながら、豊富なデータ量を用いたモデル設計といえども、万能のモデルは考えられず、結局、特定の金融商品、特定の時期を抜き出してモデルを設計することになる。この点で、特定の金融商品の特定の時期だけのデータをとって、特

定の時系列モデルが一般的に当てはまるという推論には無理があり、また、実務上、過去のデータにもとづく将来の相場予測は保証の限りではない。とはいうものの、全く時系列モデル設計に意味がないとはいえない。刈屋(2003, p.4)が「効率的市場仮説の立場に立てば、将来を予測できるモデルはありえないことになる。しかし、・・・仮に効率的市場が存在するとしても、それは多くの投資家が市場の予測に関わり、与えられている情報をありとあらゆる方法で利用した結果として成立するものであり。その意味で予測は必要であり・・・」と述べているように、予測可能かという問以前に、予測を行うことには少なくとも実際上の意義がある。

それでは、これまで金融時系列データに対し、どのようなモデルが検討してきたかを McNelis(2005, pp.13-21)にもとづき簡単にレビューする。表 1 が示すように、金融時系列モデルは伝統的に線形 ARMA モデルに代表されるように、パラメーターが一意的に決定される線形モデルから出発した。しかし、実際の金融時系列データでは非線形的挙動が数多く観測されてきたことから、一つの方向として、ボラティリティーに時系列を組み込む GARCH モデル、もう一つの方向として複雑な価格変動を 2 次、3 次など高次の項も加えた多項式モデルが試みられてきた。前者はボラティリティー・パラメーターを決定する問題設定につきパラメトリックモデルではあるが、線形モデルのように最小 2 乗法(OLS)で一意的に解は得られない。これに対し、後者は最小 2 乗法で一意解が得られる半面、パラメーター数の膨張が起こりうる面からセミ・パラメトリックモデルといえる。McNelis (2005, pp.13-21)には含まれていないが、複数のレジーム(状況)を前提とするレジーム・スイッチングモデルはパラメトリックであるが、一意解の得られない GARCH モデルの該当箇所に分類される。これらに対し、ニューラルネットワーク<sup>1</sup>、ならびに決定木、カオス、フラクタル、複雑性、自己組織化といった非線形モデルは一意解が不可で、かつセミ・パラメトリックモデルという特徴をもつ。これらのモデルはもともと市場の効率性や無裁定関係などの経済学的インプリケーションを把握すること自体は目的としていない。実務的に予測精度を上げることを目的としている。そして、特に値動き、すなわち経路依存のパターンを試行錯誤でつかもうとする。この点で過去の値動きのパターンを重視するテクニカル分析と親和性がある。

表 1 時系列モデル分類(McNelis(2005, p.20)から引用)

一意解	パラメトリック	セミ・パラメトリック
可	線形モデル	多項式モデル
不可	GARCHモデル	ニューラルネットモデル

反面、ニューラルネットモデルをはじめとする非線形モデルにも欠点がある。まず、解が一意的ではなく、ローカルミニマムに陥る可能性がいつもある。このためモデル設計、パラメーター選択が分析者の手腕に委ねられることになる。ただし、たとえばニューラルネットではノード数と初期ウエイトに注意する(磯貝(2000, p.494))など、研究の蓄積から注意すべき事項は絞られつつある。

<sup>1</sup> 以下簡略化して「ニューラルネット」の用語を用いる。またニューラルネットの説明は 3 節で行う。

また、オーバーフィッティングの問題もある<sup>2</sup>。Campbell et al. (1997, pp.523-)は「非線形モデルはフィットしすぎるために、真の非線形経済関係のみならずノイズも拾ってしまう」と指摘している。その対策として、磯貝(2000, p.10)は別途サンプル期間を設けて、フィッティングをチェックする方法などを紹介しているが、Campbell et al. (1997)がいうように、理論モデルとの整合性をみるしか根本的な方法はなく、先に理論モデルありきが分析の前提になる。このため、実際の金融時系列データから、背後にある非線形関係を探索するアプローチをとれば、常にノイズを拾うリスクに気をつけなければならない。

ニューラルネットモデルの金融時系列への応用はサーベイ論文 Zhang et al.(1998, pp.39-40)にまとめられている。外国為替、株式、債券、商品先物別に 23 件の研究が紹介されているが、圧倒的に株式への応用研究が多いなか、Grundnitski and Osborn(1993)は S&P 株価指数と金先物を Kohzad et al. (1996)は小麦と生牛現物を対象とした研究である。また研究手法はバラエティーに富むが、Makridakis et al.(1982)で、M-Competition といわれる手法が多く引用されている。それは、ニューラルネットモデルと伝統的な ARMA(あるいは ARIMA)モデルとの適合度比較にもとづく手法である。

また、日本の金融時系列に関しても、株式を対象にした研究が多いが、TOPIX へのニューラルネットモデル以外の非線形モデルの研究では永原(1999)、田中(1999)、東田(2004)、ニューラルネットモデルの研究では、馬場(1998)、Kamijo(1990)、磯貝(2000)、高橋(2002)、高見・上坂(2006)、高見(2006)の先行研究がみられる。このうち、高見・上坂(2006)は TOPIX データを対象に、ニューラルネットモデルは線形モデルより、罫線情報を生かし適合度を高めているというインプリケーションを導出しているが、TOPIX だけの一金融時系列、かつ 1992 年初年から 2002 年末までの週次データと限定的である。これに対し、高見(2006)は同じく、TOPIX 週次データ(1992 年初年から 2005 年末)を対象とするも、構造変化のない 18 区間を対象にニューラルネットモデルと線形モデルの適合度を比較しており、期間の制約をある程度解決している。しかしながら、銘柄は TOPIX 週次のみであり、銘柄間の差異についての分析に課題を残している。

ところで、株式を対象とした場合、銘柄間の差異を研究することは、東洋経済新報社(2005)のデータベースでもその銘柄数は 3,826 社を数えるので、全銘柄を調べることは物理的に不可能である。一方、一部の個別銘柄だけ抜き出し比較する場合、銘柄抽出に恣意性が入り込む余地がある。そこで、われわれはデータが整備されており、比較的銘柄数が少ない商品先物に注目する。商品先物を対象としたニューラルネットモデルの応用研究は日本では皆無と考えられ、先行研究との比較はできないものの<sup>3</sup>、流動性に富んだ価格形成が行われていて、ニューラルネットモデルの対線形モデル適合度優位性がある程度恣意性を排除しつつ検証できるのではと考えるからである。また、日本を代表する上場商品先物から銘柄を抽出することで、冒頭述べたような銘柄抽出の恣意性からある程度まぬがれ、経済的インプリケーションも得られるものと期待できる。

本論文の構成は以下の通りである。第 2 節では日本を代表する商品先物市場、東京工業品取引所 10 上場商品先物と東京穀物商品取引所 8 上場商品先物から抽出した分析対象データを述べる。第 3 節では

<sup>2</sup> 他にも、常識では考えられない見せ掛けの相関を拾ってくるデータスヌーピングバイアスを指摘しているが、本論文では TOPIX の時系列データだけを分析するので、その問題は取り上げない。

<sup>3</sup> 複数の商品相場間の共和分関係の先行研究は、効率的市場仮説の実証の観点から、たとえば、Chowdhury (1991), Beck(1994), 神木ら(2000), 北川(2001)など多くの研究を数える。

分析のプラン、ならびにニューラルネットモデルの解説を述べる。第 4 節では月次データから得られた分析結果を、第 5 節では第 4 節の結果を踏まえ、それらは、週次・日次データからの分析結果と差異があるかを論じる。そして、第 6 節では結論ならびに今後の課題を述べる。

## 2. データ

2 節では分析の対象の、日本の上場商品先物の抽出基準、ならびにデータ加工手順を述べる。社団法人 全国商品取引所連合会の商品別出来高推移資料<sup>4</sup>によれば、平成 17 年の全国商品取引所出来高合計 113,115 千枚のうち、農水種類上場商品 18 品目の出来高は 27,848 千枚、経産種類上場商品 13 品目出来高は 85,267 千枚から構成される。合計 31 品目の出来高は国際生糸の 1.6 千枚からガソリンの 29,420 千枚まで分布しているが、農水種類上場商品先物は東京穀物商品取引所の 8 品目、経産種類上場商品は東京工業品取引所の 10 品目で 99.1%カバーできる<sup>5</sup>。また、平成 17 年の取引所別出来高は東京工業品取引所 61,780 千枚、東京穀物商品取引所 25,573 千枚、中部商品取引所 21,950 千枚と続くが、上位 2 取引所で全体の出来高の 77.2%を占める<sup>6</sup>ので、東京工業品取引所 10 上場商品先物と東京穀物商品取引所 8 上場商品先物を分析すれば、日本の上場商品先物の特性がほぼ解明できると考えられる。

これらを勘案して、われわれは東京工業品取引所と東京穀物商品取引所から、それぞれ、10 上場先物、8 上場先物商品のすべての限月の価格日足 4 本値(始値、高値、安値、終値)のデータ提供を受けた。そして、以下のデータ加工を行った。まず限月交代ごとに上場商品を入れ替え、すべての時点で先限先物商品のデータを採用し、全期間を通した日次時系列データ 4 本値を作成した。これは日本の先物市場においては、米国と対極的に、先限物がいちばん流動性に富むとされるからである<sup>7</sup>。次に、18 商品について、制度変更や流動性の面で問題のある期間を除外し、ふるいに残った期間の日次時系列データから、週次、月次データもそれぞれ、商品別、4 本値別に作成した。表 2 は、そのデータ数を商品別に示す。

---

<sup>4</sup> 商品別出来高推移と取引所別出来高推移は <http://www.ifce.or.jp/Siryo.html> からダウンロードして、入手した。

<sup>5</sup> 正確には、たとえばガソリンは、東京工業品取引所と中部商品取引所に重複して上場されており、どちらの市場がより流動性あるかを考慮すべきではあるが、本論文では、簡便のため、東京穀物取引所と東京工業品取引所の上場商品に限定して分析を進めた。

<sup>6</sup>平成 12 年から 16 年までは中部商品取引所の方が、東京穀物商品取引所より出来高で上回っているものの、取引金額では、一貫して、東京工業品取引所 > 東京穀物商品取引所 > 中部商品取引所の順位で推移している。

<sup>7</sup> また、(株)商品市況研究所発行の「日刊 Derivatives Japan」のチャートでも先限物をつなげた月足を呈示しており、マーケットの関心は先限物にあることがうかがわれる。

表 2 分析データ標本数(商品別)

商品 符号	上場商品名	取引所	データ初 日	データ終日	月次 データ数	週次 データ数	日次 データ数
11	金	東工取	1992.1.6	2005.12.30	168	726	3,433
12	銀	東工取	1992.1.6	2005.12.30	168	726	3,433
13	白金	東工取	1992.1.6	2005.12.30	168	726	3,433
14	パラジウム	東工取	2000.4.4	2005.12.30	69	298	1,408
21	アルミニウム	東工取	1992.4.7	2005.12.30	105	453	2,139
31	ガソリン	東工取	1999.7.5	2005.12.30	78	337	1,590
32	灯油	東工取	1999.7.5	2005.12.30	78	337	1,590
33	原油	東工取	2001.9.10	2005.12.30	52	223	1,053
34	軽油	東工取	2003.9.8	2005.2.10	18	74	345
81	ゴム	東工取	1992.1.6	2005.12.30	168	726	3,419
AC	アラビカコーヒー	東穀	1998.6.16	2005.12.30	91	392	1,847
CO	とうもろこし	東穀	1992.4.20	2005.12.30	166	711	3,357
NG	非組換え大豆	東穀	2000.5.18	2005.12.30	68	292	1,380
RB	小豆	東穀	1984.4.2	2005.12.30	261	1129	5,466
RC	ロブスタコーヒー	東穀	1998.6.16	2005.12.30	92	393	1,849
SB	大豆	東穀	1993.6.28	2005.12.30	151	649	3,066
SG	粗糖	東穀	1994.8.1	2005.12.30	137	592	2,797
SM	大豆ミール	東穀	2001.10.11	2005.12.30	51	219	1,032

東工取:東京工業品取引所、東穀:東京穀物商品取引所

このうち、アルミニウム、ガソリン、灯油、原油、ゴム、アラビカコーヒー、とうもろこし、非組換え大豆、ロブスタコーヒー、大豆ミールは上場以来、2005年末取引日まですべてのデータを対象とする。金、銀、白金は東工取の貴金属先物システム売買以降後から2005年末取引日までを対象とする。パラジウムは1992年8月より上場されているが、2000年2月、ロシアの政情不安によるパラジウムの供給途絶などにより、ストップ高が連続したため、東京工業品取引所は2月24日から全限月について納会日まで価格凍結措置を行っていた。そのため、新たに発会する限月（2000年4月4日）以降の時期を分析対象に採用している。また、軽油は2005年3月限より休止することを受け、2月23日から、出来高0の営業日が散見されたため、前週の2月10日前までに対象を限定している。最後に、小豆、大豆、粗糖については、それぞれ、1984年4月、1993年6月、1994年8月に、呼値の変更があり、取引価格の桁が変わるほどの価格の乖離が見られたので、呼値変更以降のデータに対象を限定した。

### 3. 分析手法

#### 3.1 分析プラン

第1節で述べたように、われわれの目的は、金融時系列データにはニューラルネットモデルがどの程度当てはまるかを検証することにある。しかし、すべての銘柄・期間を調べることはできないので、2節の通り、日本を代表する商品先物価格変動に限定して調ことにした。そこで、分析手法にはさまざまな方法が考えられるが、図1に即して説明する。

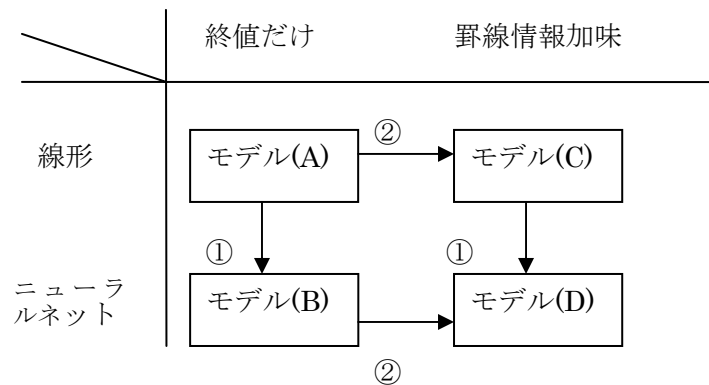


図 1 分析プラン

まず、Makridakis et al.(1982)以来研究されて来ている通り、線形モデルとニューラルネットワークモデルとの誤差を比較する手法を採用する(図 1 での①の矢印)。次に、高見・上坂(2006)が採用しているように、終値だけの情報にもとづくモデルと終値と罫線情報にもとづくモデルとを比較し、線形、ニューラルネットワークモデルでどれだけ改善があったかを比較する(図 1 での②の矢印)。もし罫線情報を加味したデータの方が改善するのなら、実際の相場はランダムではなく、テクニカル的な動きをしているというインプリケーションが得られる。ここで、罫線情報とは、

実体 = 終値 - 始値

上影 = 高値 - max( 始値, 終値)

下影 = min( 始値, 終値) - 安値

を表し、罫線(ローソク足)を作図する基本的データを示す。ただし、本論文が高見(2006)と異なる点は、期間の扱い方である。高見(2006)は期間選択の恣意性を軽減させるために、構造変化のない 18 期間について、線形モデルとニューラルネットワークモデルとを比較した<sup>8</sup>。これに対し、本論文は表 2 の各商品先物、同一期間を対象に、日次、週次、月次それぞれにおいて、差異があるかを調べる。これは、裏返していえば、Zhang et al.(1998, p.54)と Hill et al.(1996, p.1088)が指摘するように、期間間隔が短い方が、ニューラルネットワークモデルは線形モデルより適合度が高いことがいえるかという課題につながる。その根拠は特異点(非連続点や非線形な点)を含むからとされているが、反対に、もし、日次、週次、月次それぞれにおいて、特異点を含む確率が自己相似的なら、期間間隔からは無差別であるといえる。そこで、本論文では、まず 4 節で月次時系列データを分析した後、5 節で週次、日次データを取り上げ、比較分析を進める。

### 3.2.線形モデル(ARMA)

ここでは、図 1 で採用する線形モデル(ARMA)のパラメーター設定について一般的に説明する( 図

<sup>8</sup> 高見(2006)は終値情報だけの比較にとどまる。つまり、図 1 の①の左側矢印の範囲に限定して分析している。

1 のモデル(A)とモデル(C)が該当する)。ARMA(p, q)モデルは、Makridakis et al.(1982)以来ニューラルネットモデルとの比較対象として用いられているが、終値  $C_t$  を例にとれば、一般的に(1)式の通り表される。すなわち、 $C_t$  は  $t-p$  期から  $t-1$  期までの終値の自己回帰と  $t-q$  期から  $t-1$  期までの外生的ショックから構成されるモデルであり、パラメーター( $\phi_1, \phi_2, \dots, \phi_p, \theta_1, \theta_2, \dots, \theta_q$ )は、誤差項が独立した均一分散正規分布にしたがうとの前提に立っているため、最小 2 乗法により一意的に決定される。

$$C_t = \phi_1 C_{t-1} + \phi_2 C_{t-2} + \dots + \phi_p C_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (1)$$

$$\varepsilon_i \sim IID N(0, \sigma)$$

しかしながら、いたずらに (p, q) に大きな値をとることはモデルが冗長になるばかりではなく、経済的意味が希薄になる恐れもある。そこで、高々(3, 3)に限定し、自由度を加味した Schwartz 基準で最適になるよう、パラメーター( $\phi_i, \theta_i$ ) ( $i=1,2,3$ ) の取捨選択を行うことにした。

### 3.3.ニューラルネットモデル

ここでは、図 1 のモデル(B)とモデル(D)に適用するニューラルネットモデルを説明する。ニューラルネットとはデータマイニング手法の一手法であり、図 2 のように人間の脳細胞ニューロンに見立てて説明される。つまり、過去 3 連続時点入力信号  $X_{t-1}, X_{t-2}, X_{t-3}$  がどのようにシナプスを活性化させ、いかなる経路で電気信号を送り、最終的に  $X_t$  値を出力させるかを探索的計算方法によって解を求める手法である。目的関数は理論値と実際値との最小 2 乗誤差で、その極小化を計算目的とし、計算結果はシナプス間細胞体(ユニット)間を結ぶ軸索の重みの強弱で表現される。

また、誤差逆伝播学習法という自動的微分イテレーションアルゴリズムが用いられること、微分演算の簡素化のため、シグモイド関数変換を行っていることが特徴である。そして、複雑な非線形関係も中間層を設けることで表現できる点がメリットである。一方、得られた解は局所的最適解であって大域的最適解であることは保証の限りではないこと、微分演算の速度を調整するパラメーターなどの設定に職人芸経験的知恵が要求されること、初期値に大きく依存されること、背後の意味づけが難しいことなどはデメリットといえる。




図 2 ニューラルネット説明図

Neurosim/L V4<sup>9</sup>は与えられたパラメーター設定の下、初期条件で与えられた重みを誤差が最小になるようイテレーションを何万回と行う計算プロセスを行い、最終的に最適な重みベクトルを求めることを目的とする。l 回目のイテレーションで k 層 i ユニットから k+1 層 j ユニットへの重みのベクトルを  $W_{ij}^k(l)W_{ij}$ 、誤差を  $E(l)$ 、イテレーション回数を l とすれば、 $\varepsilon, \alpha, S$  の学習パラメーターが与えられたとき、重み差分  $\Delta W_{ij}^k(l)$  は (2) 式の漸化式で表される(田辺(2003, p.77))。

$$\Delta W_{ij}^k(l) = -\varepsilon \frac{\partial E(l)}{\partial W_{ij}^k(l)} + \alpha \Delta W_{ij}^k(l-1) + S \quad (2)$$

つまり、右辺 3 項の学習パラメーターは l-1 回目の重みが誤差に与える影響に強弱を与える倍率が  $\varepsilon$ 、重み修正の慣性度合いを与える倍率が  $\alpha$ 、S が閾値として働く。これらの設定によって、イテレーションの緩急、収束・振動が決まってくる。

本論文ではニューラルネットで最適解を求めること自体は目的としていない。ある程度の計算量で探索的に得られた結果を、線形モデルと比較することに焦点をおいている。すなわち、簡単に最適 ARMA モデル並みの解が見つかるかどうかを調べる。そのため、パラメーターはイテレーション回数を 10,000 回から 100,000 回に、許容誤差率を 10% から 5% 以下に厳格化し<sup>10</sup>、5 種類の初期値からスタートして、最適の結果を用いることにした。それ以外は Neurosim/L V4 のデフォルト設定<sup>11</sup>にもとづく。また、簡単のため、中間層は 1 層 2 ユニットに設定してある。これは同一ソフトウェアを用いた高見・上坂(2006)と高見(2006)の設定と同様である。

#### 4. 月次データの分析結果

第 4 節では、18 種類の商品先物月次データにもとづき、図 1 の 4 種類のモデルの分析結果を検討する。ここで、モデル間の適合度比較には誤差の評価が不可欠であるが、その評価基準は明確に決まった指標はない。Zhang et al. (1998, pp51-52) ニューラルネットの実証研究をレビューし、絶対平均誤差 (MAD)、残差平方和 (SSE)、平均 2 乗誤差 (MSE)、平均 2 乗誤差の平方根 (RMSE)、絶対平均比誤差 (MAPE) がよく用いられ、とくに平均 2 乗誤差がいちばん用いられているという。たしかに、それぞれの指標には長所と短所がある。平均 2 乗誤差にも、オーダーの異なる商品間の比較には不適であること、自由度を加味していないことなどの指標としての欠点もある。しかし、本論文は理論的に最適な指標を選ぶことを目的としていないので、いちばんよく用いられている平均 2 乗誤差をもって評価基準とする。4.1. 節では終値情報のみでの両者モデルの比較(図 1 の①の左側)、4.2. 節では罫線情報を加味した両者モデルの比較(図 1 の①の右側)、そして、4.3. 節では罫線情報を加えたことによる適合度の改善効果の比較(図 1 の②)の結果を検討する。

<sup>9</sup> 4, 5 節の分析では富士通(株)製のニューラルネットソフト Neurosim/L V4 を使用した。ニューラルネットの基礎的説明は田辺(2003)を参照。

<sup>10</sup> 月次データには 5%、週次データには 2.4%、日次データには 1.1% を適用した。その根拠は 5 節で述べる。

<sup>11</sup> (2)式で  $\varepsilon=5.0$ ,  $\alpha=0.4$ ,  $S=0.0$  と設定してある。



#### 4.1.終値情報だけのモデルの適合度比較

##### [線形 ARMA モデル](モデル(A))

3.3.節で述べたように、われわれは高々 $(p, q) = (3, 3)$ の ARMA モデルを用いる。ただし、平均値 $\mu$ とトレンド項 $at$ も加える。しかし、自由度を加味した Schwartz 基準にもとづき、最適パラメーター $(\phi_i, \theta_i)$  ( $i=1,2,3$ ) を決定するにしても、 $(C_{t-1}, \varepsilon_{t-1})$  ( $i=1,2,3$ ) 変数の選択の組み合わせは $2^8=256$ 通りもある。そこで、探索の簡便化のために、まず、すべての変数を使用した回帰結果から、 $t$ 値がいちばん有意でない変数を除き、さらに回帰を更新して行く方法をとった。もっとも、この山登り法では途中で局所解に陥る可能性があるため、いちばん簡潔な $(1,0)$ あるいは $(0,1)$ モデルも検証し、それらと比較しいちばん Schwartz 値が最小になるモデルをもって最適モデルと定めた。18 種類の商品先物の結果は表 3 に示す通りであるが、4.2.節のニューラルネット結果と対比してコメントする。

$$C_t = \mu + at + \phi_1 C_{t-1} + \phi_2 C_{t-2} + \phi_3 C_{t-3} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \theta_3 \varepsilon_{t-3} \quad (2)$$

$$\varepsilon_i \sim IID N(0, \sigma)$$

表 3 終値だけの回帰結果(モデル(A))

商品名	$\mu$	$a$	$\phi_1$	$\phi_2$	$\phi_3$	$\theta_1$	$\theta_2$	$\theta_3$	$R^2$	Schwartz 値	N	MSE
11 金	10.411		0.9818						0.92	10.8	167	2,636
12 銀			1.0048			-0.183			0.84	8.0	167	163.4
13 白金			1.0086			-0.067			0.97	12.1	167	9,666
14 パラジウム	968.0		1.6598	-1.337	0.6434	-0.767	0.9899		0.96	13.4	66	25,413
21 アルミニウム	191.2			0.8626		0.9712			0.79	7.1	103	61.22
31 ガソリン				1.0235		0.964			0.91	18.9	76	8,473,684
32 灯油			1.012						0.90	18.9	77	8,636,364
33 原油			1.0218						0.94	18.0	51	3,490,196
34 軽油			1.0113						0.60	19.1	17	10,000,000
81 ゴム			1.0048						0.91	7.4	167	90.52
AC アラビカコーヒー			0.4096		0.5751	0.5848	0.7854		0.91	17.3	88	1,590,909
CO とうもろこし	14883.5		0.8983						0.81	16.3	164	628,049
NG 非組換え大豆			1.0038						0.85	18.3	67	4,656,716
RB 小豆	11369.3			0.7231		0.8432			0.72	16.4	259	718,147
RC ロブスタコーヒー			0.435		0.5314	0.6578	1.068	0.3811	0.96	16.6	89	752,067
SB 大豆	30248.0			0.8621		0.9075			0.86	18.0	149	3,348,993
SG 粗糖			1.0047						0.89	17.7	136	2,705,882
SM 大豆ミール	27167.3	143.47	0.7542						0.73	18.1	50	3,400,000

##### [ニューラルネットモデル](モデル(B))

3.3.節で述べたように、ニューラルネットモデルでは探索的アルゴリズムで解を求めるので、局所解に陥る可能性は高く、計算結果は最適解の保証の限りではない。しかし、高見(2006)が TOPIX データで試みたように、Neurosim/L V4 のパラメーターのデフォルト設定は経験的に線形モデルよりよい結果を速く探索している。さらに、本論文では中間層数 2、100,000 回のイテレーション、5 種類の初期値と設定し、より大域的に探索を行うので、算出結果はある程度信頼がおけるものとする。

金商品の事例でその結果を説明する。図 3 は得られたネットワーク図を示す。




図 3 ネットワーク図 (金)

図 3 の結果は第 1 番目の初期値を用い、100,000 回目のイテレーションで得られた結果である。全体の 84% が許容誤差 5% 以内に当てはまっている。出力結果は軸索の重みであるが、図 3 で、濃い線が負、薄い線が正の符号を取り、絶対値が大きいほど線は太くなっている。入力層から中間層への軸索符号と中間層から出力層への符号は同じになっている場合が多いものの、 $C_{t-3} \rightarrow H_2 \rightarrow C_t$  に向かう経路では、符号が異なっており、この点で線形モデルでは表すことが難しい複雑な関係を反映している。また、図 3 では軸索の重みに数値が記載されているが、入力層から中間層  $H_1, H_2$  への関係は(3), (4)式で、中間層から出力層への関係式は(5)式で示される。

$$H_1 = [1 + \exp\{-(-5.92c_{t-3} - 1.36c_{t-2} - 6.04c_{t-1})\}]^{-1} + 10.20 \quad (3)$$

$$H_2 = [1 + \exp\{-(-1.95c_{t-3} + 2.60c_{t-2} + 8.84c_{t-1})\}]^{-1} - 1.90 \quad (4)$$

$$c_t = [1 + \exp\{-(-3.60H_1 + 2.42H_2)\}]^{-1} + 0.96 \quad (5)$$

ただし、Neurosim/L V4 のアルゴリズムは(6)式の変数変換を行い、0.1~0.9 の値に基準化している。

$$c = \frac{C_s - \min(C)}{\max(C) - \min(C)} \quad (6)$$

ニューラルネット分析結果は、それぞれの商品で図 3 のようにネットワーク図で示すのが、わかりやすいが、冗長であるから、表 4 で軸索の太さを数値で示す。

表 4 終値だけのニューラルネット分析結果(モデル(B))

商品 符号	$C_{t-3}H_1$	$C_{t-2}H_1$	$C_{t-1}H_1$	H <sub>1</sub> 定 数	$C_{t-3}H_2$	$C_{t-2}H_2$	$C_{t-1}H_2$	H <sub>2</sub> 定 数	$H_1C_t$	$H_2C_t$	$C_t$ 定 数	収束 率	MSE
11	-5.92	-1.36	-6.04	10.20	-1.95	2.60	8.84	-1.90	-3.60	2.42	0.96	84%	2,459
12	-6.20	-5.15	-7.97	15.37	0.00	1.02	11.48	-3.68	-3.49	1.68	1.77	72%	142.6
13	2.03	-0.94	-8.49	5.09	2.81	3.31	2.95	-8.32	-3.11	1.44	0.00	90%	9,880
14	-5.39	-1.94	0.00	3.28	-15.8	-9.92	13.91	6.25	-5.97	2.77	1.92	74%	30,044
21	-3.88	1.05	-9.18	9.20	1.65	0.74	5.57	-0.72	-4.11	2.82	1.20	64%	54.34
31	0.00	-2.26	-0.23	2.45	2.65	-12.6	3.49	4.64	-11.6	4.83	3.78	73%	6,103,903
32	1.18	-7.49	2.20	1.68	1.41	-7.25	4.91	0.43	-6.90	7.10	-0.53	56%	7,713,521
33	0.00	1.03	-6.81	3.56	3.22	2.29	1.93	-0.69	-3.40	2.31	0.00	65%	2,817,088
34	0.00	-3.25	0.00	3.10	0.00	-22.0	0.00	16.14	-11.0	5.60	3.30	53%	1,900,353
81	0.49	0.00	-6.17	6.11	-0.46	1.96	5.17	-1.41	-6.02	2.67	3.29	73%	89.22
AC	0.89	-0.49	-4.03	0.37	7.37	-1.29	0.00	-7.43	-7.02	4.20	1.68	61%	1,555,375
CO	3.28	-1.12	-8.33	5.21	0.95	0.00	6.99	-1.44	-3.35	2.40	0.67	57%	599,513
NG	-3.62	2.02	-5.33	0.95	-5.99	5.14	8.78	-6.41	-4.17	1.93	0.00	66%	3,839,647
RB	0.00	1.17	-4.26	-0.47	1.17	1.90	1.73	-3.26	-6.13	3.84	0.00	55%	711,777
RC	2.52	-0.85	-6.71	0.46	-0.65	-3.44	6.23	-6.51	-4.60	1.89	0.43	82%	840,082
SB	-2.01	0.86	-3.63	1.40	-3.61	2.23	2.51	-1.97	-3.54	3.05	0.45	61%	3,148,596
SG	0.00	1.38	-7.80	7.02	-0.49	-0.78	6.77	-0.41	-6.84	4.04	2.65	78%	2,560,742
SM	-4.58	-2.97	2.57	0.00	-15.7	-10.2	21.56	0.00	-5.69	3.06	0.00	56%	2,331,956

18 商品先物の結果を検討すれば、0 値が散見されるものの、金で指摘したように、符号の反転は銀を除きすべての商品で観察でき、一般的にニューラルネットモデルは商品先物価格変動の複雑な関係を表しているといえる。

表 5 は終値だけの線形モデル(A)とニューラルネットモデル(B)との適合度を平均 2 乗誤差(MSE)で比較した結果である。改善率は線形モデルの平均 2 乗誤差を基準として、ニューラルネットモデルがどのくらい低くできたかを表している。

表 5 モデル(A), (B)の適合度比較

商 品 符	商品名	MSE 線 形モデル (A)	MSE NNモデル (B)	改善率
11	金	2,636	2,459	-6.7%
12	銀	163.4	142.6	-12.7%
13	白金	9,666	9,880	2.2%
14	パラジウム	25,413	30,044	18.2%
21	アルミニウム	61.22	54.34	-11.2%
31	ガソリン	8,473,684	6,103,903	-28.0%
32	灯油	8,636,364	7,713,521	-10.7%
33	原油	3,490,196	2,817,088	-19.3%
34	軽油	10,000,000	1,900,353	-81.0%
81	ゴム	90.52	89.22	-1.4%
AC	アラビカコーヒー	1,590,909	1,555,375	-2.2%
CO	とうもろこし	628,049	599,513	-4.5%
NG	非組換え大豆	4,656,716	3,839,647	-17.5%
RB	小豆	718,147	711,777	-0.9%
RC	ロブスタコーヒー	752,067	840,082	11.7%
SB	大豆	3,348,993	3,148,596	-6.0%
SG	粗糖	2,705,882	2,560,742	-5.4%
SM	大豆ミール	3,400,000	2,331,956	-31.4%

表5は白金、パラジウム、ロブスタコーヒーをのぞき、18商品先物のうち15商品先物でニューラルネットワークモデルの方が、適合度で勝る結果を表している。3.3節で述べたように、本論文ではいたずらにニューラルネットワークの適合度を改善させることは目的にしておらず、2商品の例外は見られたけれども、それ以上の探索は行わなかった。たとえば、中間層、イテレーション回数、初期値を増やすことで、よりよい解が見つかる可能性はある。しかし、本論文では、ある程度効率的と思われるパラメーター設定で、18商品に通して機械的に探索したことにより、比較的簡単に見つかった解でも、最小2乗法による線形モデル一見解より、パフォーマンスがよいことを示したところに意義がある。

## 4.2. 罫線情報を加味したモデルの適合度比較

### [線形モデル](モデル(C))

モデル(C)は基本的には(1)式から派生したモデルではあるが、モデル(A)と異なる点は、終値  $C_i(t-1, t-2, t-3)$  だけではなく、 $JT_i$ (実体)、 $UK_i$ (上影)、 $SK_i$ (下影)を含む他変数のモデルとなる点である。そのため、時期の異なる他変数間の交差項を考慮すれば、理論的にはパラメーター数の膨張が起こり、探索的方法で最適モデルを選択することは、物理的に不可能である。そこで、交差項、トレンド項、MA項は捨象し、(7)式の簡潔なモデルで最小2乗法によってパラメーターを決定させることにした。

$$C_t = \mu + \phi_1 C_{t-1} + \phi_2 C_{t-2} + \phi_3 C_{t-3} + \sum_{i=1}^3 (\phi_i^{JT} JT_{t-i} + \phi_i^{UK} UK_{t-i} + \phi_i^{SK} SK_{t-i}) + \varepsilon_t \quad (7)$$

すなわち、(7)式モデルは(2)式トレンド項、MA項部分を退化させ、罫線情報を表す変数の1次項だけで表したモデルである。表6はその回帰結果を示すが、シャドー部分の有意な係数は少なく、 $R^2$ 自体は高いものの、この線形モデルは罫線情報をあまり生かしきれてないことがうかがわれる。

表6 罫線情報を加味した回帰結果(モデル(C))

商品符号	$\mu$	$C_{t-1}$	$C_{t-2}$	$C_{t-3}$	$JT_{t-1}$	$UK_{t-1}$	$SK_{t-1}$	$JT_{t-2}$	$UK_{t-2}$	$SK_{t-2}$	$JT_{t-3}$	$UK_{t-3}$	$SK_{t-3}$	$R^2$	Schwarz値	N	MSE
11	2.3	0.64	0.68	-0.32	0.28	0.12	0.02	-0.29	-0.19	0.06	0.03	0.07	-0.23	0.92	11.1	165	2658
12	0.4	0.60	0.62	-0.19	0.22	0.01	-0.05	-0.25	0.07	-0.05	-0.06	-0.87	-0.54	0.85	8.3	165	153.9
13	-27.7	0.82	0.75	-0.55	0.12	-0.14	-0.37	-0.44	0.07	0.52	-0.15	0.13	0.31	0.98	12.3	165	8821
14	15.7	-0.37	1.99	-0.62	1.48	0.30	-1.15	-0.77	-0.32	0.00	-0.04	1.45	-2.15	0.96	13.8	66	25574
21	8.8	1.44	-0.88	0.39	-0.48	0.23	-0.05	0.47	-0.22	0.26	0.02	0.01	0.25	0.79	7.5	102	61.43
31	-1,488.4	-0.23	0.80	0.49	1.24	0.57	-0.15	0.16	0.75	-0.40	-0.30	0.12	-0.29	0.93	19.3	75	6360000
32	191.7	-1.07	1.87	0.17	2.23	0.18	0.65	0.02	-0.47	0.40	-0.15	0.04	0.66	0.92	19.3	75	7013333
33	-268.8	0.57	0.78	-0.26	0.33	-0.20	-1.44	-0.45	0.54	-0.81	-0.32	-0.44	0.02	0.96	18.6	49	2612245
34	3,098.7	2.57	11.21	-11.65	-0.92	-5.10	11.18	-12.30	-21.30	1.15	1.01	-14.65	-12.99	0.99	17.8	15	299004
81	0.8	0.72	-0.75	1.05	0.19	-0.06	-0.33	1.18	0.12	-0.27	-0.04	0.13	-0.14	0.92	7.7	165	84.21
AC	1,526.2	-0.35	0.53	0.70	1.32	0.25	0.03	0.83	0.40	-0.19	0.01	-0.23	-0.15	0.92	17.8	88	1545455
CO	2,036.5	1.07	-0.02	-0.20	-0.12	0.15	0.20	-0.06	-0.32	0.16	0.10	-0.04	0.68	0.83	16.5	162	569375
NG	2,245.7	0.11	2.02	-1.19	0.72	0.04	0.21	-1.20	0.06	-0.48	-0.10	-0.65	0.81	0.87	18.9	65	4000000
RB	1,820.5	1.15	0.56	-0.88	-0.34	0.35	-0.11	-0.87	-0.48	0.00	0.00	0.25	0.26	0.74	16.5	258	674419
RC	325.0	0.68	1.11	-0.87	0.32	0.11	-0.08	-0.79	0.44	-0.06	-0.12	0.18	0.46	0.96	17.1	89	827866
SB	2,002.3	0.81	0.58	-0.45	0.06	0.17	-0.23	-0.41	-0.37	0.40	-0.02	-0.30	0.78	0.88	18.1	148	2810811
SG	694.3	1.86	-0.54	-0.35	-0.74	0.29	-0.18	-0.30	0.35	0.30	0.05	-0.26	-0.25	0.90	18.0	134	2440299
SM	1,093.1	0.88	1.53	-1.40	0.01	-0.51	-0.73	-1.50	0.40	-1.19	-0.26	-0.45	0.18	0.76	18.8	48	3000000

の部分は5%有意水準の偏回帰係数

## [ニューラルネットモデル](モデル(D))

モデル(D)はモデル(B)、モデル(C)とそれぞれ対比させるため、比較の次元でなるべくパラメーター設定を同一にしている。モデル(B)、すなわち終値だけのニューラルネットモデルと比較するためには、中間層 2、許容誤差率 5%、イテレーション回数 100,000 回、初期値 5 種類、その他同一のデフォルト設定で、計算させた。一方、モデル(C)との比較では、入力層の変数を(7)式の 12 個の変数、 $C_{t-i}$ ,  $JT_{t-i}$ ,  $UK_{t-i}$ ,  $SK_{t-i}$  ( $i = 1, 2, 3$ )を用いている。18 商品先物の分析結果は冗長になるので、ここでは割愛する。

表 7 は罫線情報を加味したモデルによる線形モデルとニューラルネットモデルの適合度を比較した結果を表す。

表 7 モデル(C) (D)の適合度比較

商品符号	商品名	MSE 線形 モデル(C)	MSE NNモデル (D)	改善率
11	金	2658	2,472	-7.0%
12	銀	153.9	126.7	-17.7%
13	白金	8821	8,038	-8.9%
14	パラジウム	25574	7,319	-71.4%
21	アルミニウム	61.43	53.47	-12.9%
31	ガソリン	6360000	3,982,280	-37.4%
32	灯油	7013333	5,215,892	-25.6%
33	原油	2612245	1,131,979	-56.7%
34	軽油	299004	364,413	21.9%
81	ゴム	84.21	76.34	-9.3%
AC	アラビカコーヒー	1545455	925,783	-40.1%
CO	とうもろこし	569375	466,506	-18.1%
NG	非組換え大豆	4000000	1,943,173	-51.4%
RB	小豆	674419	589,476	-12.6%
RC	ロブスタコーヒー	827866	659,030	-20.4%
SB	大豆	2810811	2,148,360	-23.6%
SG	粗糖	2440299	2,290,993	-6.1%
SM	大豆ミール	3000000	929,097	-69.0%

標本数の少ない軽油を除いて、すべての商品先物でニューラルネットモデルの方が勝っている。かつ、表 5 の改善率と対比すれば、すべてで改善率絶対値が大きい。これは、ニューラルネットモデルは罫線情報をより生かすモデルといえるとともに、実際の商品先物価格はランダムな動きではなくテクニカル的な動きをしていると、TOPIX を対象に論じる高見・上坂(2006)の主張と通じるところがある。

### 4.3. 罫線情報の改善効果比較

われわれは表 7 でニューラルネットモデルの方が線形モデルより、罫線情報をより生かしていると観察したが、罫線情報が追加的に適合度をどれだけ改善したかは、3.1.節の図 1 の矢印②で示したように、それぞれのモデルの改善度を比較することで明らかになる。

表 8 野線情報による改善度比較

商品 符号	商品名	線形モデルの改善率	NNモデルの改善率
11	金	0.8%	0.5%
12	銀	-5.8%	-11.1%
13	白金	-8.7%	-18.6%
14	パラジウム	0.6%	-75.6%
21	アルミニウム	0.3%	-1.6%
31	ガソリン	-24.9%	-34.8%
32	灯油	-18.8%	-32.4%
33	原油	-25.2%	-59.8%
34	軽油	-97.0%	-80.8%
81	ゴム	-7.0%	-14.4%
AC	アラビカコーヒー	-2.9%	-40.5%
CO	とうもろこし	-9.3%	-22.2%
NG	非組換え大豆	-14.1%	-49.4%
RB	小豆	-6.1%	-17.2%
RC	ロブスタコーヒー	10.1%	-21.6%
SB	大豆	-16.1%	-31.8%
SG	粗糖	-9.8%	-10.5%
SM	大豆ミール	-11.8%	-60.2%

表 8 はそれぞれのモデルで、終値だけの情報を基準として、野線情報を加味した後で、どの程度適合度の改善が見られたか、平均 2 乗誤差を比較することで求めた数値である。線形モデルの場合（モデル(A)→(C)）金、パラジウム、アルミニウムで平均 2 乗誤差の増加、すなわち適合度の悪化がみられたが、ニューラルネットモデルの場合(モデル(B)→(D))、悪化した商品は金のみである。標本数の少ない軽油を除き、金も含め改善の割合は大きい。これらから、ニューラルネットモデルの方が追加的野線情報(それは価格変動の経路を示す)、をより有効に吸収していることを示唆している。

## 5. 週次・日次データの分析結果

5 節では 4 節での月次時系列データでの結果が、週次、日次データでも、どの程度あてはまるか、また、3.1 節で述べたように、期間間隔が短い方が、ニューラルネットモデルは線形モデルより適合度が高いかを検証する。週次、日次データとも 4 節月次データでの分析と同様に、図 1 の通り、4 つのモデルの適合度を比較する手法をとる。また、線形モデル(A), (C)のパラメーター設定も同一とする。ニューラルネットモデル(B), (D)も同じ設定としたいが、許容誤差 5%の設定のみ変える。それは、ブラウン運動においては、時間間隔が  $1/n$  になれば、空間間隔は  $1/\sqrt{n}$  になるという自己相似性が働くという命題<sup>12</sup>を考慮する必要があるからである。すなわち、商品先物価格変動がブラウン運動に従うかは検証しなくてはならないが、少なくとも、連続過去 3 期のデータを取って、現在のデータを推定する問題で、月次データと日次データとが動く幅が同程度であるとするのは無理な前提であり、許容誤差は調整を要する<sup>13</sup>。そこで、ここではブラウン運動に従うものとして、平方根の比で週次、月次データの許容誤差を設

<sup>12</sup> 長井(1999, p.5)はブラウン運動のスケール則として取り上げている。また、Neurosim/ LV4 の許容誤差は 2 乗誤差ではなく、絶対値誤差を使用しているので(田辺(2003, p.26)、平方根の比で調整することにした。

<sup>13</sup> 実際日次データで、月次データと同様に 5%許容誤差をとって分析したところ、Neurosim/L V4 はすぐ収束したが、著しく精度が低かった。

定する。すなわち、表 2 から、いちばん標本データ数の多い小豆は、月数：週数：日数 = 261：1,129：5,466  
につき、(8), (9)式の通り、それぞれ 2.4%, 1.1%に設定する。

$$\text{週次許容誤差} = (5\%) \sqrt{\frac{261}{1,129}} = 0.02404 = 2.4\% \quad (8)$$

$$\text{日次許容誤差} = (5\%) \sqrt{\frac{261}{5,466}} = 0.010926 = 1.1\% \quad (9)$$

以下、われわれは 5.1節で週次データ、5.2節で日次データの分析結果を検討するが、冗長であるので、表 5, 7, 8 に該当する適合度改善率の結果のみを呈示する。

### 5.1.週次データの分析結果

表 9 は週次データの分析結果を集約して示す。

表 9 週次データ分析結果

商品 符号	商品名	MSE 線形 モデル(A)	MSE NNモ デル(B)	改善率	MSE 線形 モデル(C)	MSE NN モデル(D)	改善率	線形モ デルの 改善率	NNモデ ルの改 善率
11	金	739	718	-2.8%	726	711	-2.1%	-1.7%	-1.0%
12	銀	39	38.17	-2.5%	38	37	-2.9%	-3.0%	-3.3%
13	白金	2,667	2,745	2.9%	2,623	2,757	5.1%	-1.6%	0.5%
14	パラジウム	6,217	6,552	5.4%	5,471	5,515	0.8%	-12.0%	-15.8%
21	アルミニウム	14.41	14	-5.9%	14.21	12.98	-8.7%	-1.3%	-4.3%
31	ガソリン	1,639,640	1,602,570	-2.3%	1,609,610	1,525,153	-5.2%	-1.8%	-4.8%
32	灯油	2,011,940	1,929,166	-4.1%	1,831,832	1,637,342	-10.6%	-9.0%	-15.1%
33	原油	882,883	818,784	-7.3%	850,000	804,144	-5.4%	-3.7%	-1.8%
34	軽油	1,712,329	1,223,660	-28.5%	1,158,845	609,698	-47.4%	-32.3%	-50.2%
81	ゴム	21.57	21.75	0.8%	20.95	20.86	-0.5%	-2.9%	-4.1%
AC	アラビカコーヒー	574,359	560,373	-2.4%	541,237	549,053	1.4%	-5.8%	-2.0%
CO	とうもろこし	176,305	173,562	-1.6%	172,560	167,623	-2.9%	-2.1%	-3.4%
NG	非組換え大豆	1,082,759	1,048,219	-3.2%	1,003,472	956,609	-4.7%	-7.3%	-8.7%
RB	小豆	159,716	157,549	-1.4%	156,444	152,795	-2.3%	-2.0%	-3.0%
RC	ロブスタコーヒー	271,100	265,355	-2.1%	253,663	248,873	-1.9%	-6.4%	-6.2%
SB	大豆	1,023,184	1,016,212	-0.7%	984,496	968,851	-1.6%	-3.8%	-4.7%
SG	粗糖	608,475	610,811	0.4%	598,639	586,566	-2.0%	-1.6%	-4.0%
SM	大豆ミール	844,037	842,556	-0.2%	768,519	679,767	-11.5%	-8.9%	-19.3%

まず、図 1 の矢印①で、終値だけのモデル(A),(B)の比較結果は表 9 の 3~5 列目が該当する。白金、パラジウム、ゴム、粗糖をのぞき、18 商品先物のなかで、14 品目でニューラルネットモデルの方がよいパフォーマンスを上げている。月次データ分析結果に対応する表 5 では、15 品目該当したので、同程度のパフォーマンスといえるかもしれないが、白金、パラジウムは共通するが、劣位の品目は異なっているものがある。また、アラビカ、ロブスタコーヒーをのぞき、改善率は下回る。

つぎに、図 1 の矢印①で、罫線情報を加味したモデル(C),(D)の比較結果は 6~8 列目が該当する。こ

の場合は、白金、パラジウム、アラビカコーヒーをのぞき、15品目でニューラルネットモデルの方がよいパフォーマンスを上げている。月次データの分析結果を表す表7と比較すれば、軽油をのぞいて、改善率は下回っている。

最後に、図1の矢印②で、罫線情報の価値を表す改善度比較は、9, 10列が該当する。線形モデルではすべての商品先物で、ニューラルネットモデルでは白金をのぞいたすべての商品先物で改善している。ただし、月次データの分析結果を表す表8と比較すれば、金、白金、原油、ゴム、ロブスタコーヒーの5品目で、ニューラルネットモデルは改善率が劣っている。

## 5.2. 日次データの分析結果

表10は週次データの分析結果を集約して示す。

表 10 日次データ分析結果

商品 符号	商品名	MSE 線形 モデル(A)	MSE NN モデル(B)	改善率	MSE 線形 モデル(C)	MSE NN モデル(D)	改善率	線形モ デルの 改善率	NNモデ ルの改 善率
11	金	145	155	7.1%	143	142	-0.6%	-1.5%	-8.5%
12	銀	7.66	7.64	-0.3%	7.57	7.50	-0.9%	-1.2%	-1.8%
13	白金	587	631	7.5%	583	620	6.3%	-0.6%	-1.8%
14	パラジウム	1,163	1,274	9.6%	1,144	1,265	10.6%	-1.7%	-0.8%
21	アルミニウム	3.28	3.28	0.2%	3.21	3.21	0.0%	-2.1%	-2.3%
31	ガソリン	310,453	316,924	2.1%	308,129	311,012	0.9%	-0.7%	-1.9%
32	灯油	348,237	348,991	0.2%	342,155	342,994	0.2%	-1.7%	-1.7%
33	原油	188,213	188,147	0.0%	185,714	188,437	1.5%	-1.3%	0.2%
34	軽油	246,554	239,332	-2.9%	230,389	215,655	-6.4%	-6.6%	-9.9%
81	ゴム	4.61	4.76	3.3%	4.58	4.71	2.9%	-0.8%	-1.1%
AC	アラビカコーヒー	119,306	121,726	2.0%	116,594	117,407	0.7%	-2.3%	-3.5%
CO	とうもろこし	40,226	40,740	1.3%	39,356	39,869	1.3%	-2.2%	-2.1%
NG	非組換え大豆	227,306	227,513	0.1%	223,837	220,682	-1.4%	-1.5%	-3.0%
RB	小豆	31,296	31,662	1.2%	31,101	31,525	1.4%	-0.6%	-0.4%
RC	ロブスタコーヒー	74,134	78,085	5.3%	72,589	75,727	4.3%	-2.1%	-3.0%
SB	大豆	206,007	210,247	2.1%	203,722	205,176	0.7%	-1.1%	-2.4%
SG	粗糖	118,026	122,364	3.7%	117,752	120,276	2.1%	-0.2%	-1.7%
SM	大豆ミール	388,350	139,796	-64.0%	138,970	137,221	-1.3%	-64.2%	-1.8%

まず、図1の矢印①で、終値だけのモデル(A),(B)の比較結果は表10の3~5列目が該当する。日次データではニューラルネットモデルの方が劣位にある場合が多い。改善したのは、軽油と大豆ミールだけである。この点月次、週次データ分析結果と大きく異なっている。

つぎに、図1の矢印①で、罫線情報を加味したモデル(C),(D)の比較結果は6~8列目が該当する。この場合でもニューラルネットモデルの方が勝るのは、金、銀、軽油、非組換え大豆、大豆ミールの5品目に限られている。

最後に、図1の矢印②で、罫線情報の価値を表す改善度比較は、9, 10列が該当する。線形モデルではすべての商品先物で、ニューラルネットモデルでは原油をのぞいたすべての商品先物で改善している。ただし、月次データの分析結果を表す表8と比較すれば、金、アルミニウムを除き、16品目で、ニューラルネットモデルは改善率が劣り、改善度合も%1桁台ばかりである。



表 9, 10 の分析結果から、月次から週次、日次へと時間間隔を狭くすると、ニューラルネットモデルの対線形モデル優位性はしだいに損なわれてきている。その意味で、自己相似性や、Zhang et al.(1998)の期間間隔が短い方が、ニューラルネットモデルは線形モデルより適合度が高いことという指摘は当てはまらない。

この分析結果にはさまざまな要因が考えられる。ひとつは比較尺度の平均 2 乗誤差はデータ数  $N$  で割っているとはいえ、月次に比べ、週次、日次のデータ数の膨張が分析に影響を与えている可能性である。たとえば、データ数が多ければ、Neurosim/L V4 で、イテレーション回数を多くする必要があるかもしれない。しかし、回数をかえて試験的に試みたが、収束率はさほど改善は見られなかった。また、許容誤差の設定に問題があるかもしれない。しかし、(8), (9)式は一定の理論的基盤にもとづいているので、他の決め方は恣意性が入り込む恐れがある。これら、分析上の技術的要因の他に、そもそも、相場形成において、月次、週次、日次それぞれ、マーケット参加者は過去何期前までのデータを念頭において、取引を行っているのかという実際上の問題もある。この点で、機械的に 3 期までのデータで現在のデータを予測する本論文の手法は再検討の要がある。

## 6. 結論

ニューラルネットモデルの金融時系列への応用は、米国のデータを中心に、外国為替、株式、債券、商品先物、数多くの研究蓄積がある。日本でも株式、TOPIX を中心として、多くに研究がみられる。しかし、これら研究はインデックスや特定株式に銘柄が限定されており、一般的にニューラルネットモデルが適合的であるかは十分な検証がなされていないと考えられる。一方、商品先物の応用研究は、日本のデータを用いた研究は皆無と考える。しかし、本論文では上場商品先物に注目した。上場商品先物はデータが整備されており、流動性に富んだ価格形成が行われていて、かつ比較的銘柄数が少なく、銘柄抽出の恣意性をある程度排除できると考えたからである。

われわれの用いた分析手法は基本的には高見・上坂(2006)と高見(2006)の研究によっている。すなわち、データ種別として、終値だけのデータと終値に罫線情報を加えたデータに 2 分、モデルとして、線形モデルとニューラルネットモデルとを用いて、 $2 \times 2 = 4$  通りの分析結果を検討する手法をとった。さらに、月次、週次、日次それぞれの期間間隔で、ほとんど同じ手法を用い比較検討を行った。

得られた結果は、月次データについては、ほとんどすべての商品先物で、終値データだけの場合も罫線情報を加味したデータの場合も、ニューラルネットモデルは線形モデルより適合度で勝り、しかも、追加的な罫線情報の価値はニューラルネットモデルの方がよりよく吸収していることが観察できた。この点では、実際の商品先物価格はランダムな動きではなくテクニカルな動きをしていると、TOPIX を対象に論じる高見・上坂(2006)の主張とインプリケーションにおいて通じるところがある。

しかし、週次、日次と期間間隔を狭めた分析では、しだいにこの命題が当てはまらなくなってきた。その理由は技術的、実際の、いろいろな要因がありうると思われるが、その解明は今後の課題として進めなくてはならない。

本論文はさまざまな限定の上にもとづいた分析に立っている。ニューラルネットモデルは一意的に解がえられないがために、パラメーター設定の巧拙がかかわってくるので、最適な結果はいわば永遠の課

題を背負っているといえる。それは単に、ニューラルネットモデルのパラメーター設定方法のことだけではない。たとえば、高見(2006)のように週次、日次データを構造変化のない期間に分割し、データ数を月次データと同じ程度に設定することも、取り組まなくてはならない課題である。それら、多々課題を残しているとはいうものの、本論文の貢献は、ニューラルネットモデルの応用において、ほとんど取り組まれていなかった、上場商品先物を実証研究対象とし、ある程度の結論を導きだしたこと、簡潔な分析方法を呈示したことにあると思料する。

**謝辞：**本研究に対し、社団法人日本商品先物振興会、2005年度「商品先物取引に係る研究調査助成金制度」より研究助成を受けた。ここに、感謝の意を表明する。ならびに、東京工業品取引所市場構造研究所の山岡博士氏と東京穀物商品取引所の上柳隆裕氏からは、上場先物商品のデータ提供を受け、筆者からの質問に対し迅速かつ適格な回答をいただいた。また、両氏には論文原稿に眼を通していただき、貴重なコメントをいただいた。重ねて、感謝申し上げる。なお、本論文に残りうる誤りに関して、責任の所在は筆者にあることは言うまでもない。

#### **[参考文献]**

- Beck, Stacie E.(1994) “Cointegration and Market Efficiency in Commodities Futures Market,” *Applied Economics*, Vol.26, 249-257.
- Chowdhury, Abdur R.(1991) “Futures Market Efficiency: Evidence from Cointegration Tests” *Journal of Futures Markets*, Vol.11, No.5, 577-589.
- Grundnitski, Gary and L. Osborn (1993) “Forecasting S&P and Golod Futures Prices: Application of Neural Networks,” *Journal of Futures Markets*, Vol. 13, No.13, 631-643.
- Hill, Tim, M.O’Conner and W. Remus (1996) “Neural Network Models for Time Series Forecast,” *Management Science*, Vol.42, No.7, 1082-1092.
- Kamijo, Ken-ichi and T. Tanigawa (1990) “Stock Price Pattern Recognition: A Recurrent Neural Network Approach,” *Proceedings of the IEEE International Joint Conference on Neural Networks*, San Diego, CA, I215 –I221.
- Kohzadi, Nowrouz, M. S. Boyd, B. Kermanshahi and I. Kaastra (1996) “A Comparison of Artificial Neural Network and Time Series Models for Forecasting Commodity Prices,” *Neurocomputing*, Vol.10, 169-181.
- Makridakis, S., A. Anderson, R. Carbone, R. Fildes, M. Hibon, R. Lewandowski, J. Newton and R. Winkler (1982) “The Accuracy of Extrapolation(Time Series) Methods: Results of a Forecasting Competition,” *Journal of Forecasting*, Vol.1, 111-153.
- McNelis, Paul D.(2005) “Neural Networks in Finance: Gaining Predictive Edge in the Market” Elsevier Academic Press.
- Zhang,Guopiang, B.E.Patuwo and M.Y. Hu(1998) “Forecasting with Artificial Neural Network” *International Journal of Forecasting*, Vol.14, 35-62.

- 馬場則夫(1998)「ニューラルネットを活用した株式売買意思決定支援システムの構築」MTEC Journal, Vol.11, 3-41.
- 東田啓(2004)「非線形予測によるテクニカル分析は利益をもたらすか—TOPIXでの実験—」横浜経営研究, 第24巻4号, 101-108.
- 磯貝明文(2000)「ニューラルネットワークによる株価予測—実務上の使いやすさの観点から—」システム/制御/情報, Vol.44, No.9, p.492-498.
- 神木良三・伊東史朗・廣江満郎・八田英二・佐竹光彦・北川雅章・南波浩史(2003)「日本の商品先物市場の効率性—共和分分析による実証研究—」先物取引研究(日本商品先物振興協会), 第4巻、2号, 1-28.
- 刈屋武昭(2003)「金融時系列分析入門」竹村・刈屋・矢島・田中・竹内「統計科学のフロンティア 8 経済時系列の統計」岩波書店の第1章, 1-101.
- 北川雅章(2001)「繭糸先物市場の効率性—共和分分析による効率的市場仮説の検証—」経済学論叢(同志社大学経済学会), 第52巻, 4号, 450-483.
- 蓑谷千鳳彦(2001)「金融データの統計分析」東洋経済新報社.
- 永原裕一(1999)「株価指数(TOPIX)の非定常時系列モデル及びその景気先行性の検証」政経論叢(明治大学), 第68巻, 1号, 29-56.
- 長井英生(1999)「確率微分方程式」共立出版.
- 日本テクニカル・アナリスト協会編(2004)「日本テクニカル分析大全」日本経済新聞社.
- 高橋朋一(2002)「株価の回帰曲線への当てはめとニューラルネットワークによる株価予測システム」青山経済論集, 第54巻, 1号, 27-47.
- 高見茂雄(2006)「TOPIXの予測可能性—構造変化のない期間での線形モデルとニューラルネットワークモデルの適合度比較—」証券アナリストジャーナル, Vol.44, No.7, 84-96.
- 高見茂雄・上坂博亨(2006)「TOPIX 相場変動のニューラルネットによる可視化」経営財務研究, 第25巻, 2号, 50-68.
- 田辺和俊(2003)「Neurosim/Lによるニューラルネットワーク入門」日刊工業新聞社.
- 田中航一(1999)「TOPIX(1990-1997)にみられる変動の非線形特性について—複雑系の視点からの接近—」大阪商業大学論集, 第113巻, 871-885.
- 東洋経済新報社(2005)「株価 CD-ROM2005」
- 吉富康成(2002)「ニューラルネットワーク」朝倉書店.