

懸賞論文 優秀賞

深層学習を用いたカオス時系列解析によるテクニカル分析

三井住友アセットマネジメント

中川 慧

日興グローバルラップ

今村 光良

要 旨

本論文ではカオス時系列解析の枠組みのもと深層学習を組み合わせたテクニカル分析手法の提案を行う。カオス時系列解析では、まず時系列データを高次元空間に対して「埋め込み」を行う。そして埋め込んだ高次元空間における幾何学的な軌道（アトラクタ）を用いて予測や制御を行う手法である。したがって高次元空間上でのアトラクタの再現（関数近似）が予測には必須であるが、この関数近似に画像認識などの高次元データ解析で有効性が認められている深層学習を用いる。

当該手法を用いて日経平均株価を対象に実証分析を行った結果、深層学習を用いたカオス時系列解析により作成されたシグナルは高い予測力と収益性を持つことが確認できた。

1. はじめに

通常、株価や為替などの経済時系列データは非常に複雑な挙動を示す。予測や制御への活用のため、これらの経済時系列データを時系列解析の枠組みでモデル化するケースは数多く存在する。通常の時系列解析の枠組みでこのような複雑・不規則な挙動の時系列データを説明するためには、攪乱項を加える必要がある。この攪乱項は通常、ホワイトノイズといわれる確率変数である。つまり、ある一定の幅で変動し平均すれば0になる確率変数で予測が不可能な項である。このような攪乱項を排除し、時系列のトレンド抽出を行うのがテクニカル分析で使用されている移動平均等の手法である。

一方で、このような確率論的な攪乱項を用いなくとも、決定論的に複雑な変動を作り出せることが知られており、これが時系列のカオス性の特徴の一つである。もし、複雑な挙動をしている時系

列データにカオス性があり、その背後にある何らかの決定論的法則を見出すことができれば、近未来を予測することが可能になる。時系列データの複雑な挙動を生み出す原因を、我々の観測できない誤差項として排除するのではなく、時系列データを生成するシステムに本質的に内在する非線形性に求める解析手法をカオス時系列解析という。カオス時系列解析による枠組みはテクニカル分析でいうところのフォーメーション分析との等価性が指摘されている¹⁾。

カオス時系列解析は Takens の埋め込み定理²⁾に基づいて、まず時系列データを高次元空間へ埋め込む。そして埋め込んだ高次元空間における幾何学的な軌道（アトラクタ）を用いて予測や制御を行う手法である。したがって高次元空間上でのアトラクタの再現（関数近似）が予測には必須である。従来は、類推法やヤコビ行列推定法などの局所線形近似法や動径基底関数（RBF）ネットワーク

1 やニューラルネットワークなどの非線形近似手法
 2 が用いられていた³⁾。低次元のカオス性を示す時系
 3 列データは、これらの方法で十分な予測精度を得
 4 ることができるが、高次元のカオス性しか示さない
 5 時系列データの場合は予測が困難となる。特に経
 6 済時系列データはその傾向が強いとされている⁴⁾。

7 そこで、近年の人工知能・機械学習の分野のブ
 8 レークスルーと言われ、目覚ましい発展を遂げて
 9 いる深層学習を関数近似に用いることで当該問
 10 題の解決にあたる。深層学習とは人間の脳（神
 11 経細胞）の働きを模した教師あり学習手法であ
 12 り、ニューラルネットワークを多層化したもので
 13 ある。従来では多層化したネットワークを学習す
 14 ることは困難であったが、近年、事前学習（pre-
 15 training）を行うことで学習が可能になったことを
 16 皮切りに、画像認識、音声認識、自然言語処理な
 17 どの高次元空間にデータが存在するような場面で
 18 他の機械学習の手法を圧倒する高い性能を示して
 19 いる⁵⁻⁷⁾。そのため、カオス時系列解析に関して
 20 も深層学習をアトラクタの再現という高次元空間
 21 上の関数近似に利用することにより精度が向上す
 22 る可能性があると考えられる。

23 本稿では、カオス時系列解析の枠組みに従って
 24 株価を高次元空間へ埋め込み、高次元空間上へ埋
 25 め込んだアトラクタを深層学習で再現し、予測を行
 26 うテクニカル分析手法を提案する。当該手法を用い
 27 て日経平均株価指数を対象に実証分析を行った結
 28 果、高い予測力と収益性を持つことが確認できた。

29
 30 **2. カオス時系列解析**

31
 32 通常確率論的な時系列解析においては、ラン
 33 ダムに変化する確率変数によって表現されてきた。
 34 一方で、カオス時系列モデルでは確率変数を使う
 35 ことなく、複雑な変動を表現することができる。
 36 確率論的な時系列解析とカオス時系列解析とは、
 37 前者が時系列の統計的特徴量（平均、自己共分散
 38 など）を解析するのに対して、後者は幾何学的な
 39 軌道（アトラクタ）の特徴を解析する点で異なる。

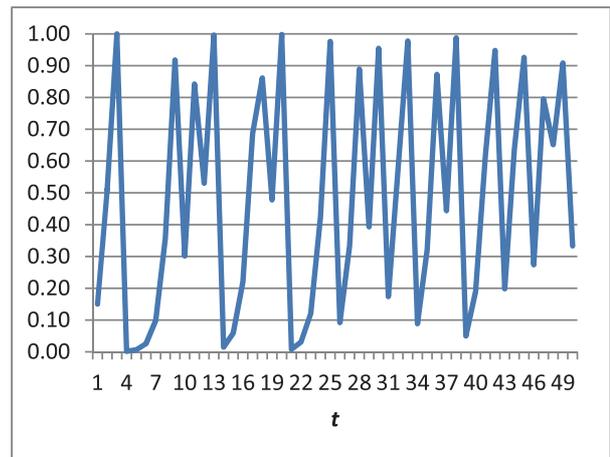
40 時系列データがカオス性を満たすと、(1) 背後
 41 には決定論的なシステムが存在し、(2) 初期値の
 42 変化に対する鋭敏性を持ち、したがって、(3) 長

期予測ができないという際立った特徴を持つ。 1

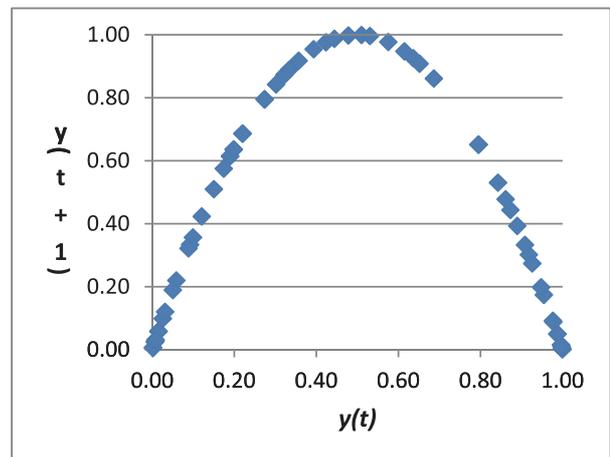
2 このようなカオス性を満たす典型的な例とし
 3 て、ロジスティック写像がある。ロジスティック
 4 写像は、式 1 という非常に簡単なルールによっ
 5 て定まっているが、グラフを描くと複雑な変動をし
 6 ている。これがカオス性の特徴 (1) 決定論的な
 7 システムの例である。初期値 0.15 から計算され
 8 たグラフを図 1 に示す。 8

$$y(t+1) = 4y(t)(1 - y(t)) \quad (式 1) \quad 10$$

11
 12 図 1 の通り、ロジスティック写像は複雑な変動
 13 をするが、元の次元よりも高次元の空間（ロジス
 14 ティック写像の場合は 2 次元）へ写像すること
 15 によって、ある規則性が浮かび上がってくる。これ
 16 を埋め込みという。具体的には、ロジスティック
 17



28
 29 図 1. ロジスティック写像



30
 31
 32
 33
 34
 35
 36
 37
 38
 39
 40
 41
 42 図 2. 2次元空間への埋め込み

1 写像を2次元空間上の1点 $Y(t) = (y(t), y(t+1))$
 2 としてプロットする。図2の通り、一見すると複
 3 雑に見える時系列データでも高次元空間へ埋め込
 4 むことにより、幾何学的な規則性を見つけ出すこ
 5 とができる。

6 次に、初期値を0.15と0.15001に設定した2つ
 7 のロジスティック写像のグラフを図3に示す。こ
 8 の図3のグラフから t が10くらいまで2つのロジ
 9 スティック写像は同じ挙動を示すが、それ以後は
 10 徐々に離れ始め、 t が14を越えた辺りからは全く
 11 別の挙動を示す。つまりカオス性の特徴(2)初期
 12 値の変化に対する鋭敏性を持ち、したがって初期
 13 値に観測誤差がどんなにわずかでも発生する現実
 14 的な状況下では、短期的な予測は可能でも、誤差
 15 の影響が拡大されるので、(3)長期予測はできない。

16 一般には、カオス性を持つ1次元の時系列デー
 17 タを式2のように適当な遅れ時間 τ と、 d 次元の
 18 高次元空間に1点 $Y(t)$ として埋め込むことで当
 19 該時系列の変動が捉えることができる(Takensの
 20 埋め込み定理²⁾。

$$Y(t) = (y(t), y(t-\tau), \dots, y(t-(d-1)\tau)) \quad (\text{式2})$$

このベクトルを d 次元の高次元空間に順次プロッ
 トしていくと軌道(アトラクタ)が描かれる。 d 次
 元の高次元空間に埋め込みをした後に、アトラクタ
 の幾何学的な特徴を関数近似して表現し予測する。
 これがカオス時系列解析の手順である。3次元空間
 へ埋め込み予測を行うイメージを図4に示す。

3. 深層学習

深層学習(Deep Learning)とは、深い、つまり
 多くの層を持ったニューラルネットワークモデルを
 用いた機械学習手法の総称である。ニューラルネッ
 トワークは人間の脳(神経細胞)の働きを模した教
 師あり学習手法である。ニューラルネットワークを
 具体的な問題に応用する場合には層の数や層の中の
 ノードをいくつにするかを定める必要がある。一般
 に、層を増やすとより複雑な問題に対応できる。式
 3および図5に隠れ層を1つだけ持つ順伝播型の
 ニューラルネットワークの数式とモデルを示す。

$$y_k(x, w) = \sigma \left(\sum_{j=1}^M w_{kj}^{(2)} h \left(\sum_{i=1}^D w_{ji}^{(1)} x_i + w_{j0}^{(1)} \right) + w_{k0}^{(2)} \right) \quad (\text{式3})$$

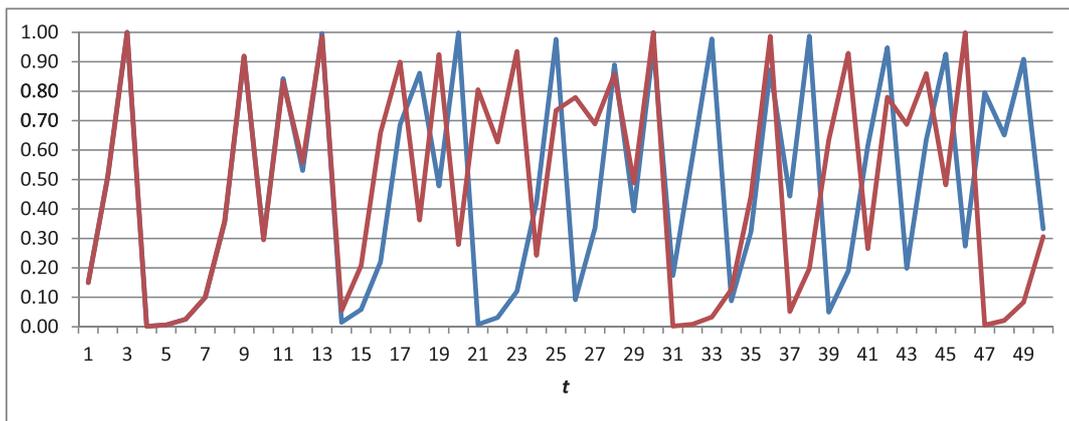


図3. 初期値0.15(青線)と0.15001(赤線)のロジスティック写像

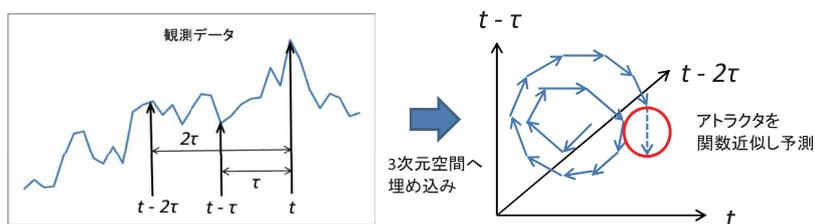


図4. カオス時系列解析のイメージ

1 x_i が D 次元の入力データであり、 y_i が K 次元
 2 の出力データである。また、 M が隠れ層を構成
 3 するノードの数で、 α_j と α_k は活性と呼ばれ、そ
 4 れぞれ $h(\cdot)$ と $\sigma(\cdot)$ という非線形の活性化関数に渡
 5 される。活性化関数には、以下のような Sigmoid
 6 関数 (式 4) や双曲線正接関数 (式 5)、ReLU
 7 (Rectified Linear Unit) 関数 (式 6) などが問題
 8 に応じて用いられる。

9
 10
$$h(x) = \frac{1}{1+e^{-x}} \quad (\text{式 4})$$

11
 12
$$h(x) = \tanh(x) \quad (\text{式 5})$$

13
 14
$$h(x) = \max(0, x) \quad (\text{式 6})$$

15
 16 なお、活性化関数が非線形であることがニュー
 17 ラルネットワークの本質であり、単なる線形関数
 18 を活性化関数に用いると、式 3 から線形関数の線
 19 形結合は再び線形になるため、多層化する恩恵が
 20 受けられない。 $w_{ji}^{(1)}$ 、 $w_{j0}^{(1)}$ と $w_{kj}^{(2)}$ 、 $w_{k0}^{(2)}$ はそれ
 21 ぞれ入力層と隠れ層の活性に係る重みとバイアス
 22 である。図 5 の通り、入力データが非線形に変換
 23 されて隠れ層、出力層へと順方向に伝播するモデル
 24 となっている。このモデルは原理上、十分に多
 25 くのノードを持つ層が一つあれば、任意の連続関
 26 数を近似できることが示されている⁸⁾。

27 このような隠れ層を持つ順伝播型のニューラル

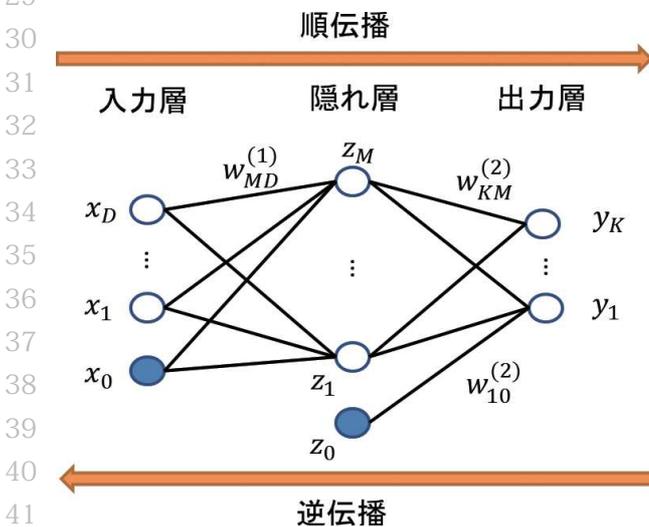


図 5. 順伝播型ニューラルネットワーク

ネットワークは、高速に学習する誤差逆伝播法
 と呼ばれる訓練方法によって学習できるようにな
 った⁹⁾。誤差逆伝播法とはネットワークの出力
 結果と実際の出力結果との誤差を最小にするよう
 に、出力層から入力層に向かって、ネットワーク
 の各層間の重みを修正する方法である。順伝播は
 式 3 の通り非線形計算だが、逆伝播は線形計算
 である。順伝播は活性化関数が非線形なので、層
 の入出力関係も非線形になる。例えば、出力層に
 ロジスティック関数を用いた場合には出力は常に
 [0,1] の範囲に限定される。一方で逆伝播は
 微分により線形化するため、出力層から入力層に
 向かって誤差が伝播するにつれ、急速に小さくな
 り消失するか、大きくなり発散するかのいずれか
 となる。そのため重みの更新が困難になり学習が
 うまくいかないという勾配消失問題が指摘されて
 いた。

しかしながら教師なし学習手法である制約ボル
 ツマンマシンや自己符号化器 (オートエンコー
 ダー) を用いた事前学習 (pre-training) を層ご
 とに行い、層を積み重ねて、最後にニューラル
 ネットワーク全体の学習を誤差逆伝播法で行う解
 決手法が提案された¹⁰⁻¹¹⁾。制約ボルツマンマシン
 も自己符号化器も主成分分析と同じようにデータ
 を圧縮した表現を学習する構造になっている。そ
 れらを積み重ねることで、圧縮した表現をさらに
 圧縮し、抽象化していくことで学習を進めてい
 る。これらの解決手法やさらに改良を加えた深層
 学習によって画像認識、音声認識、自然言語処理
 などの高次元空間にデータが存在するような場面
 で他の機械学習の手法を圧倒する高い性能を示し
 ている⁵⁻⁷⁾。ただし、深層学習を用いてネットワ
 ークを構成するには、中間層の数やユニット数、各
 層の活性化関数等の制御すべきパラメータが膨大
 になるため、解くべき問題に合った構造のネット
 ワークを熟慮しなければならない。

4. 実証分析

本章では、本稿で提案した深層学習を用いたカ
 オス時系列解析によるテクニカル分析の有効性の
 検証を行う。具体的には、(1) カオス時系列解析

1 の枠組みに従って時系列データを高次元空間へ埋め込み、(2) 高次元空間上へ埋め込んだアトラクタを深層学習で再現する。ただし先に述べた通り、
2 深層学習のネットワークの構造はアトラクタを近似するような構成を考える必要がある。本稿では
3 アトラクタの近似に適切であると考えられるネットワーク構造を提案する。そして、(3) 再現されたアトラクタを用いてシグナルを日々作成し、予
4 測を行う。

10 分析対象は日経平均株価指数 (NKY Index) の
11 終値であり、対象期間は 1970 年 1 月初から
12 2016 年 11 月末 (営業日ベース) までである。学
13 習期間が 1970 年 1 月初から 2006 年 12 月末まで、
14 テスト期間が 2007 年 1 月初から 2016 年 11 月
15 末までである。以上を用いてシグナルによる上下
16 予想の精度と、当該シグナルに基づき仮想的に売
17 買した場合のパフォーマンスの両方を評価する。
18 データは情報端末である Bloomberg から取得し
19 た。また深層学習は Chainer¹²⁾ を使用して実装し、
20 分析は Python 上で行った。具体的な分析手順は
21 以下の通りである。

(1) カオス時系列モデル推定

先行研究⁴⁾ で指摘されている高次元カオス性を
とられるため埋め込み次元 d を 5、そして遅れ時
間を、週次を意味する 5 として日経平均株価指数
の埋め込みを行う。埋め込みにあたっては対数化
や収益率への変換は行わない。そして埋め込んだ
5 次元空間上で深層学習を用いてアトラクタの学
習を行う。

(2) 深層学習のネットワーク構成

埋め込み次元 $d = 5$ に対して、入力層のユニッ
ト数が $d \times d = 25$ 、ユニット数が $d \times n = 5 \times 50$
 $= 250$ の中間層が 10 層、出力層のユニット数が
 $d = 5$ となるように深いニューラルネットワーク
を構成した。当該構成では、入力層は 5 次元のベ
クトルを 1 つの入力単位として割り当てられてお
り、この 1 入力に対して、中間層の $n = 50$ 個の
ユニットが個別に割り当てられている。そして中
間層間は全ノード結合により接続されている。各
層の活性化関数は式 6 の ReLU 関数を用いた。こ
の構成では 1 日先ではなく、遅れ時間先の時点の
株価を予測する。直感的には、入力層の入力単位

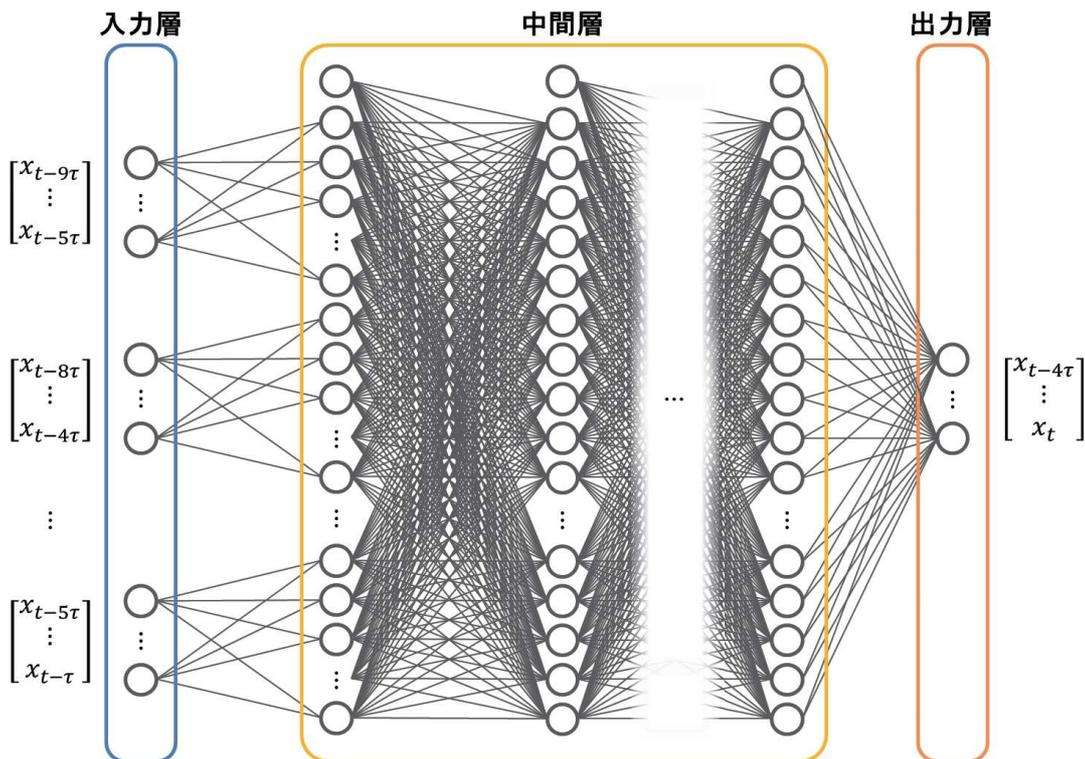


図 6. アトラクタの再現に用いたネットワークの構造

1 をアトラクタ上の1つのベクトル(5次元)として、
 2 それを埋め込み次元と同じだけ用意し、アトラク
 3 タ上の次の時点のベクトルを予測させる構造であ
 4 る。具体的な構成は図6の通り。

5 以上の構成を持つネットワークを1970年1月
 6 初から2006年12月末までを学習期間として学
 7 習させる。その際、学習期間の日経平均株価指
 8 数を[0,1]の範囲に基準化を行う。学習は自己符号
 9 化法を用いて各層ごとに誤差逆伝播法を行い、重
 10 みの初期値を事前学習したあと、当該初期値を用
 11 いて全体を誤差逆伝播法で学習する。なお、今回
 12 は2006年12月末以降使用可能なサンプルが増
 13 えてもネットワークの再学習を行わなかった。

14
 15 **(3) シグナルの作成**

16 学習したアトラクタを用いて、当日の終値まで
 17 を[0,1]の範囲に基準化して入力層に与え、出
 18 力された出力値(すなわち5営業日後の株価)が
 19 本日の株価と比較して上昇していれば買い、下落
 20 していれば売りのシグナルを日次で得る。

21
 22 **(4) 分析結果**

23 学習したアトラクタを用いて出力された予測値
 24 と5営業日後の実測値との符号一致率と、予測
 25 値と実測値との二乗誤差平均が表1である。直近
 26 5年では60%、全期間でも57%という高い予測
 27 精度である。ただし、リーマンショックのあった
 28 2008年については正答率が50%を下回る結果と

1 なった。これは学習期間中に存在しないアトラク
 2 タの構成が出現したことで学習モデルでは予測で
 3 きず精度が悪化したと考えられる。テスト期間全
 4 体におけるシグナルは、上昇が54%、下落が46%
 5 であるに対して、予測されたシグナルは、上昇予
 6 測が57%、下落予想が43%と極端なシグナルの
 7 偏りは確認できなかった。また、テスト期間全体
 8 の株価が13,163円、5日間のボラティリティが
 9 3.7%であるので、5日分の変動は487円程度で
 10 ある。表1の二乗誤差平均から、予測された5日
 11 後の株価自体の水準は通常の5日分の変動よりは
 12 狭いレンジで予測できている。

13 表2がシグナルに基づき、シグナルの発生した
 14 翌日の終値で日経平均株価を買いあるいは売りを

16 表1. 日経平均株価の予測結果

期間	正答率	二乗誤差平均
2007	56.50%	342.3
2008	47.76%	560.2
2009	60.49%	312.9
2010	53.06%	280.1
2011	53.47%	253.3
2012	66.94%	206.6
2013	62.04%	400.4
2014	56.97%	363.5
2015	60.66%	375.3
2016	55.16%	433.7
直近5年	60.35%	337.0
全期間	57.33%	351.9

30 表2. シグナルに基づく売買結果

期間	リターン	標準偏差	シャープレシオ
2007	15.30%	7.63%	2.01
2008	-18.68%	16.61%	-1.12
2009	35.74%	10.81%	3.30
2010	3.46%	8.06%	0.43
2011	0.33%	9.34%	0.04
2012	41.65%	6.72%	6.20
2013	45.75%	9.84%	4.65
2014	10.42%	8.23%	1.27
2015	19.56%	7.90%	2.48
2016	10.62%	10.45%	1.02
直近5年	25.60%	8.63%	2.97
全期間	17.25%	9.56%	1.80

1 行い、予測した5営業日後にポジションを閉じる
 2 という仮想的な売買を行った結果である。リター
 3 ン、標準偏差、シャープレシオはそれぞれ年率換
 4 算している。またレバレッジがかからないよう
 5 に1回あたりの売買単位を1/5にしているが、売
 6 買コストは考慮していない。表1の予測結果が
 7 良好な年ほど売買結果も良好となっている。全体
 8 としても年度のリターンがマイナスとなったのは
 9 2008年以外にはなく、さらにシャープレシオも
 10 1.8と良好な結果となった。

11 5. まとめ

12 本論文ではカオス時系列解析の枠組みのもと深
 13 層学習を組み合わせたテクニカル分析手法の提案
 14 を行った。カオス時系列解析では、高次元空間上
 15 でのアトラクタの再現(関数近似)が予測には必
 16 須である。日経平均株価を用いた実証分析の結果、
 17 この関数近似に深層学習を用いることで、カオス
 18 時系列解析による予測は高い予測力と収益性を持
 19 つことを持つことが確認できた。

20 さらに発展として、今回は2006年12月
 21 末以降サンプル数が増えても追加の学習を行わ
 22 ず、学習モデルを変更しなかった。そのため新た
 23 なデータが入手可能になり次第逐次学習するオン
 24 ライン学習や都度ネットワークを再度学習し直す
 25 などの学習方法でさらなる精度向上が可能かどう
 26 か検討する。加えて、アトラクタの再現という問
 27 題に合わせたかたちで深層学習の構造をより洗練
 28 させることが挙げられる。例えば、時系列構造を
 29 考慮することができると言われている Recurrent
 30 Neural Network (RNN) や Long Short-Term
 31 Memory (LSTM)、アトラクタの幾何学的な構造
 32 をとられるために画像認識の分野で精度が確認さ
 33 れている Convolutional Neural Network (CNN)
 34 等を用いることが考えられる。

35 謝辞

36 本論文の執筆にあたって、三井住友アセットマ
 37 ネジメントおよび日興グローバルラップのクオン
 38 ツチームの皆さまには有意義な議論をさせて頂き
 39 深く感謝いたします。なお、ここで示された内容

40 は三井住友アセットマネジメントおよび日興グ
 41 ローバルラップとしての見解をいかなる意味でも
 42 表しません。

43 <参考文献>

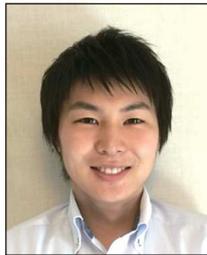
- 44 1) 鈴木智也 (2014) 「決定論的時空間テクニカル
 45 分析」, 『テクニカルアナリストジャーナル』, Vol.1 46
- 47 2) F. Takens (1981) "Detecting strange
 48 attractors in turbulence", 'Dynamical systems
 49 and turbulence', pp366-381 50
- 51 3) 合原一幸, 池口徹, 山田泰司, 小室元政 (2000)
 52 『カオス時系列解析の基礎と応用』, 産業図書 53
- 54 4) J. Ramsey, C. Sayers, and P. Rothman (1990)
 55 "The Statistical properties of dimension
 56 calculations using small data sets: Some
 57 economic applications", 'International
 58 Economic Review'31, pp991-1020 59
- 60 5) A. Krizhevsky, I. Sutskever, and G. Hinton
 61 (2012) "Imagenet classification with deep
 62 convolutional neural networks" 'In Advances
 63 in neural information processing systems
 64 pp1097-1105 65
- 66 6) F. Seide, G. Li, and D. Yu (2011) "Conversa-
 67 tional Speech Transcription Using Context-
 68 Dependent Deep Neural Networks" 'In
 69 Interspeech', pp437-440 70
- 71 7) R. Socher, J. Pennington, H. Huang Y. Ng
 72 and D. Manning (2011) "Semi-supervised
 73 recursive autoencoders for predicting
 74 sentiment distributions" 'In Proceedings of
 75 the Conference on Empirical Methods in
 76 Natural Language Processing', pp151-161 77
- 78 8) G. Cybenko (1989) "Approximation by
 79 superpositions of a sigmoidal function"
 80 'Mathematics of control, signals and systems'
 81 2(4), pp 303-314 82
- 83 9) D. Rumelhart, G. Hinton, and R. Williams
 84 (1988) "Learning representations by back-
 85 propagating errors" 'Cognitive modeling'5(3) 86
- 87 10) G. Hinton, S. Osindero, and Y. Teh (2006) "A
 88 fast learning algorithm for deep belief nets" 89

1 'Neural computation'18(7), pp1527-1554
 2 11) Y. Bengio, P. Lamblin, D. Popovici, and
 3 H. Larochelle (2007) "Greedy layer-wise
 4 training of deep networks" 'Advances in
 5 neural information processing systems'19
 6

7 ●プロフィール

8 **中川 慧**

9 2012年京都大学経済学部卒。同
 10 年ニッセイアセットマネジメン
 11 ト入社。2014年より三井住友ア
 12 セットマネジメントにてクオンツ
 13 ファンドマネージャーを務める。
 14 2016年10月より日興グローバ
 15 ルラップ株式会社へ出向し、クオ
 16 ンツアナリストを務める。2015
 17 年筑波大学ビジネス科学研究科修
 18 了(経営学)。
 19
 20
 21
 22
 23
 24
 25
 26
 27
 28
 29
 30
 31
 32
 33
 34
 35
 36
 37
 38
 39
 40
 41
 42



12) S. Tokui, K. Oono, S. Hido, and J. Clayton 1
 (2015) "Chainer: a Next-Generation Open 2
 Source Framework for Deep Learning" 'In 3
 Neural Information Processing Systems 4
 (NIPS)' 5
 6

7 ●プロフィール

8 **今村 光良**

9 2014年北陸先端科学技術大学院
 10 大学修了(情報科学)。同年日本
 11 ヒューレットパッカード株式会社
 12 (現:日本ヒューレットパッカー
 13 ドエンタープライズ株式会社)に
 14 入社。その後、日本マイクロソ
 15 フト株式会社にてネットワークエン
 16 ジニアを務め、現在日興グローバ
 17 ルラップ株式会社のクオンツアナ
 18 リストを務める。
 19
 20
 21
 22
 23
 24
 25
 26
 27
 28
 29
 30
 31
 32
 33
 34
 35
 36
 37
 38
 39
 40
 41
 42

