

ニューラル・ネットワークによる時系列データ予測 2L-10 株の売買タイミング予測

木本隆¹⁾ 依田守生²⁾ 武岡正和²⁾

1) 富士通研究所 2) 日興証券株式会社

1.0 はじめに

人間の脳をモデル化し、多数の並列的に動作するニューロン素子を互に結合したニューラル・ネットワークは、ニューロン間の結合の強さ(重み)の自動調節によって学習機能を実現できる。我々は、パターン認識、制御などの従来の工学的応用分野のみならず、予測問題全般にニューラル・ネットワークが適応できることを期待し、その実証を試みた。

証券アナリストが適切な株の売買タイミングを分析する場合には、株のテクニカル指標、経済指標、社会情勢などの時々刻々と変化する時系列パターンを総合的に利用し判断すると言われている。しかし、実際には専門家自身がどのくらい過去の経験に基づき予測を行なっているかはあいまいであるし、その判断基準も、政治情勢や経済システムの変化に伴い変化させているはずである。このため従来の統計手法では精度の高い予測が難しかった。

我々は、このような予測問題に対してニューラル・ネットワークの学習が有効であると考え、TOPIXの売買タイミング予測を例題として、専門家以上に高精度な予測システムの構築を目指した。

ングの関係を学習した複数のニューラル・ネットワークが売買タイミングを予測する。売買タイミングはTOPIXの上昇局面では買い、下降局面では売りタイミングになるように数値化した。本予測システムは、各種テクニカル指標、経済指標とTOPIXの売買タイミングの関係を学習した複数のモジュール化したニューラル・ネットワーク¹⁾を構造化し、未来の売買タイミングを予測する。

TOPIXとは、東京証券取引所の第一部上場銘柄の株価を発行部数により荷重平均したもので、東京証券取引所の株の動きを平均的に反映した指標であり、株価の動きを見る指標としては最適である。

2.2 教師データ

売買タイミングは1個の出力ユニットにアナログ値で表現する。教師データとして用いた売買のタイミングは、週次リターンの指数荷重平均である。ここで、TOPIXの週次リターンを r_t とすると、教師データ(売買タイミング) $r_N(t)$ を以下のように定義した。

$$r_t = \ln(\text{TOPIX}(t) / \text{TOPIX}(t-1))$$

TOPIX(t) : t週のTOPIXの平均値

$$r_N(t) = \sum \phi^i r_{t+i} \quad \phi^N = 0.1 \quad (N: \text{荷重平均区間})$$

ニューラル・ネットワークは現在の入力指標と以

2.0 アーキテクチャ

2.1 システム概要

図1に開発した予測システムの基本的な構成を示す。移動平均、出来高などのテクニカル指標と為替レート、金利などの経済指標とTOPIXの売買タイミ

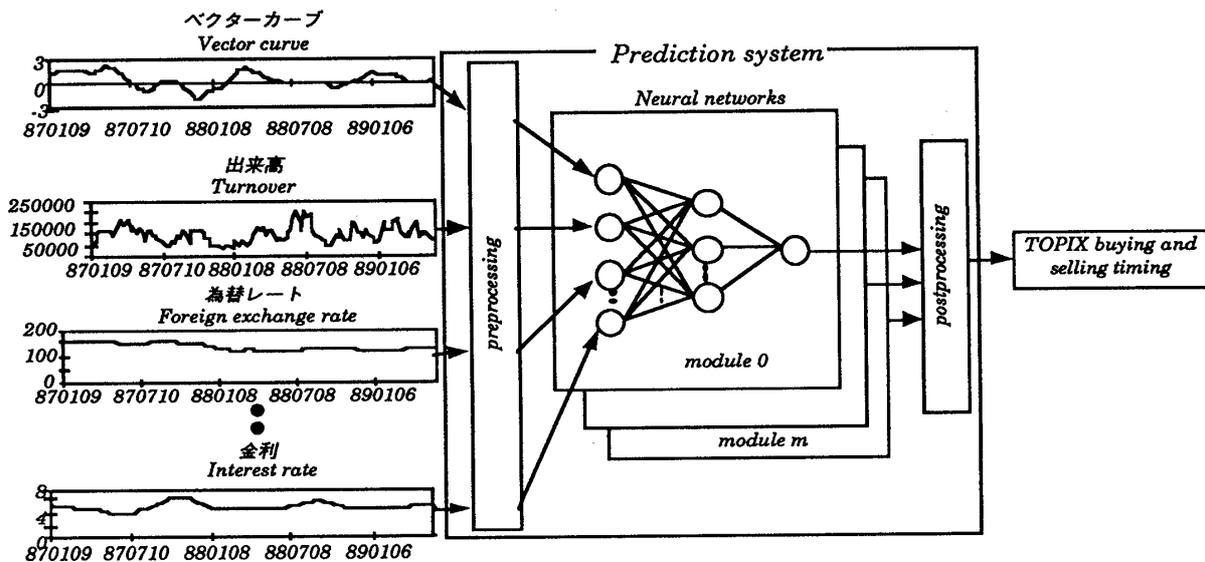


図1. システムアーキテクチャ

Time-sequence Data Prediction with Neural Networks

Takashi Kimoto¹⁾, Morio Yoda²⁾ and Masakazu Takeoka²⁾

1) FUJITSU LABORATORIES LTD., KAWASAKI 2) The Nikko Securities Co., Ltd.

上のように定義した未来の売買タイミングの対応関係をバックプロパゲーション法により学習する。

2.3 適応的予測手法

株価予測のように時々刻々とその予測ルールが変化する経済システムの予測においては、その変化に追従して、学習予測する必要がある。

このため、学習期間、予測期間を移動しながら予測する適応的予測手法を開発した。週次リターンのN週加重平均 $r_N(t)$ を以下のように予測するものである。

図3のようにある時点より過去Mヵ月を学習し、次のLヵ月を予測する。これを繰り返し未来に前進する。このLヵ月ごとの予測期間をつなぎあわせたものを予測結果とみなし、この結果により評価する。

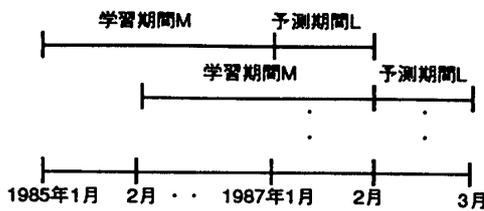


図2. 適応的予測

3. 評価

3.1 モジュール化ネットワーク

本予測システムは複数のネットワークをモジュール化し、これらの予測結果の加算平均をとることで予測精度の向上を図った。

まず、各予測期間に対して学習データの異なる独立した4つのネットワーク・モジュールが学習する。これらのネットワークの予測出力を平均化したものが予測システムの予測出力になる。これを適応的予測により月毎に繰り返し予測し、予測精度の検証を行なった。予測期間は1987年1月から1989年9月までの33ヵ月である。

予測期間における教師データと予測システムの予測出力との相関係数を表1に示す。表1に示すように、予測システムは各ネットワークより大きな相関係数を獲得することができた。

表1. 相関係数

	Correlation Coefficient
Network1	0.435
Network2	0.458
Network3	0.414
Network4	0.457
System	0.527

3.2 売買シミュレーション

株の売買をシミュレーションすることで、本システムの有効性を検証した。図3に売買シミュレーションの結果を示す。TOPIXの資産変化を点線で示し、実線で予測システムによる売買を行なった場合の資産変化を示す。本シミュレーションはシステムの予測精度が適切に評価できるように一点売り一点買いで行なった。これは、買いの場合には手持ちの資金ですべて株を買い、売りの場合は手持ちの株をすべて売るというものである。図の下に予測システムによる売買の履歴を示している。1987年1月のTOPIXの資産を1.0とすると、1989年9月にTOPIXの資産変化は1.67、予測システムにより売買した場合の資産変化は1.98を示し、予測システム用いれば、市場平均より47%多くの利益を上げることがわかった。この結果、本システムの有効性が確認された。

4.0 まとめ

本論文では、我々の構築している株売買タイミング予測について述べた。モジュール化ニューラル・ネットワークにより、TOPIX（東京証券取引所株価指数）の売買のタイミングを予測するシステムは、売買シミュレーションにより市場平均より46%大きな運用実績が上げられることが示された。

今後、本予測システムをより実用的で汎用的な経済予測システムに成長させるために研究を行なっていく予定である。

謝辞

本研究を支援してくださる榎橋情報処理研究部門長、林人工知能研究部長、石井システム研究部長、浅川室長に深く感謝いたします。

References:

- [1] S. Nagata, T. Kimoto and K. Asakawa, Control of Mobile Robots with Neural Networks, INNS, 1988, 349
- [2] H. Sawai, A. Waibel, et al., Parallelism, Hierarchy, Scaling in Time-Delay Neural Networks for Spotting Japanese Phonemes/CV-Syllables, IJCNN vol II, 1989, 81-88
- [3] D. E. Rumelhart, et al., Parallel Distributed Processing vol. 1, The MIT Press, 1986
- [4] R. Masuoka, et al., A study on supplementary learning algorithm in back propagation, 日本人工知能学会全国大会予稿集, 1989, 213-217.
- [5] T. Kimoto, K. Asakawa, M. Yoda and M. Takeoka, Stock Market Prediction System With Modular Neural Networks. IJCNN '90 June, 1990

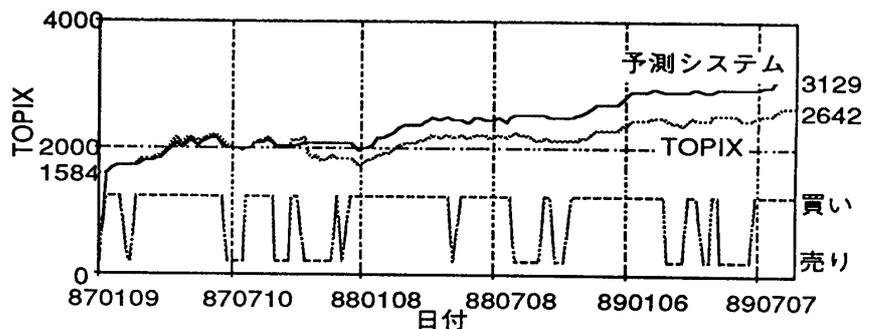


図3. 売買シミュレーション結果