

Time Series Prediction of Stocks by Neural Network Ensembles

ニューラルネットワークアンサンブルによる株価の時系列予測

数理情報学専攻 076209 加倉井 智

指導教員 合原 一幸 教授

1 はじめに

人間の脳神経系をモデルにした情報処理システムを Neural Network とよぶ。NN (Neural Network) は学習能力を持ち、必要とされる機能を、提示されるサンプルデータに基づいて自動形成することができるため、パターン認識や時系列予測に広く応用されている。

本研究ではその1つの応用例として複数の銘柄の株価予測に注目した。従来の株価予測に関する研究は、その大部分が単一の株価をいかに精度よく予測するかについての研究であり、複数の銘柄の株価を同時に予測する研究はほとんどなされていない。今回提案する Constructive Neural Network Ensemble の拡張アルゴリズムを用いて複数銘柄の株価予測を行ったところ、値の予測精度に関しては単純な NN よりも精度が向上することが分かり、ある期間においては効率的な資産運用が可能になることが分かった。

2 Neural Network Ensemble

人間の脳内には数百億個から数千億個のニューロンが存在しており、それらが相互に結合することによって巨大なネットワークを構成し、人間の記憶や判断等の高度な情報処理を行っている。

Neural Network とはそのネットワークを模してつくられた情報処理システムのことを指し (図 1), 学習という操作により複雑で定式化が困難な入出力関係を近似表現できるという特徴から、パターン認識や時系列予測等に広く応用されてきた。

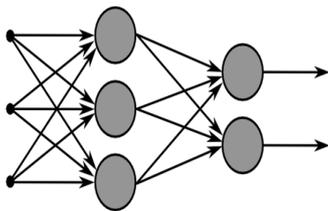


図 1. Neural Network

さらに複数の NN を組み合わせることによって作られる複合システムのことを Neural Network Ensemble と呼ぶ。この NN Ensemble は、予測誤差の大きさが

Ensemble を構成する個々の NN の予測誤差の重み平均よりも必ず小さくなるということが示されているため、本研究ではこの NN Ensemble を用いてより予測誤差の小さい株価予測を行うことを目的とする。

3 提案 Ensemble モデル

図 2 にアルゴリズムの概要を記す。アルゴリズムは初期設定後、NCL (Negative Correlation Learning) と呼ばれる学習を行い、学習誤差が十分に小さくない場合は Ensemble の構造を修正する Constructive Learning という学習に移り、構造修正後再び NCL で学習を行う、という流れになっている。

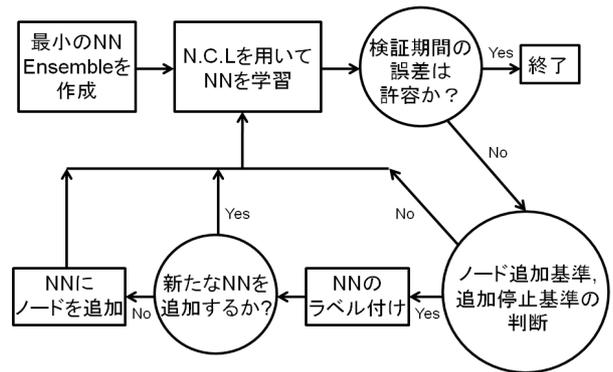


図 2. アルゴリズムの概要

NCL (Negative Correlation Learning) とは Ensemble 学習法の 1 つであり、個々の NN を同時にかつ相互影響を受けながら学習を進めることを可能にしている。この手法によって個々の NN は互いに負の相関を持つようになり、結果 Ensemble 全体の性能も向上することが知られている。

まず i 番目の NN の出力値を f_i とし、Ensemble 全体の出力値を f_{ens} とする。ただし $\sum_i w_i = 1, w_i \geq 0$ なる w_i を用いて $f_{ens} = \sum_i w_i f_i$ とする。このとき出力すべき真の値を Φ とすると $(f_{ens} - \Phi)^2 = \sum_i w_i (f_i - \Phi)^2 - \sum_i w_i (f_i - f_{ens})^2$ が成立する。

すなわち Ensemble 全体の予測誤差を小さくするためには、右辺の $\sum_i w_i (f_i - \Phi)^2$ の値をできるだけ小さく

くし、かつ $\sum_i w_i (f_i - \Phi)^2$ の値をできるだけ大きくする必要があるのである。この考えのもとで新たな関数 p_i , \hat{E}_i を以下のように定義する。

$$p_i = (f_i - f_{\text{ens}}) \sum_{j \neq i} (f_j - f_{\text{ens}}) \quad (1)$$

$$\hat{E}_i = \frac{1}{2} \sum_i (f_i - \Phi)^2 + \lambda p_i \quad (2)$$

なお p_i は penalty function と呼ばれるもので各 NN の出力値と Ensemble 出力値との間の相関を表している。また λ はパラメータであり、 \hat{E}_i は通常の誤差の拡張である。ここでこの \hat{E}_i を BP (Backpropagation) と呼ばれる NN の学習によって小さくすることで、各 NN の予測誤差を小さくすると同時に Ensemble 出力値との間の相関を小さくする。それにより、この Negative Correlation Learning によって Ensemble 予測誤差 $(f_{\text{ens}} - \Phi)^2$ をできるだけ小さくするように学習することができる。

Constructive Learning は NN 自身が小さなネットワーク構造から徐々に必要なノードやネットワークを適宜加えていくアルゴリズムである。本研究における Constructive Learning は個々の NN の中間層のノード数だけではなく、ネットワーク自体も Ensemble に追加する手法を取っているため、学習が十分に進んだ後では最適な NN の構造および Ensemble 構造が得られると考えられる。

提案モデルは Negative Correlation Learning を用いることで個々の NN 自体の予測誤差を小さくするだけではなく、Ensemble 全体の性能を向上させることができる。そして Constructive Learning によって NN の構造のみではなく、NN Ensemble 自体の構造を自動的に変化させることができ、より論理的で効果的な Ensemble の設計を可能としている。さらにもとの CNNE [1] の拡張として多次元の変数および出力に対応させ、複数銘柄の株価の時系列予測を行っている。

4 数値実験

本研究では三菱商事、三井物産、住友商事の 3 銘柄を対象に、ある 1 年間の営業日 (244 営業日) の株価予測を行った。まず図 3 は 08 年 1 月 4 日から 08 年 12 月 29 日までの三井物産の株価予測の様子を表している。図の横軸は実際の株価、縦軸は予測値であり、傾き 1 の直線に近いほど予測精度は高いといえる。予測は時刻 t の 3 企業の株価を入力とし、時刻 $(t + 1)$ の 3 企業の株価を出力として予測する 3 入力 3 出力の NN モデル

で行った。なお比較として同入出力数のノードを持ち、Ensemble 中の最も予測誤差が小さい NN と同じ数の中間層ノード数を初めから持つ NN (SNN) による予測も記している。

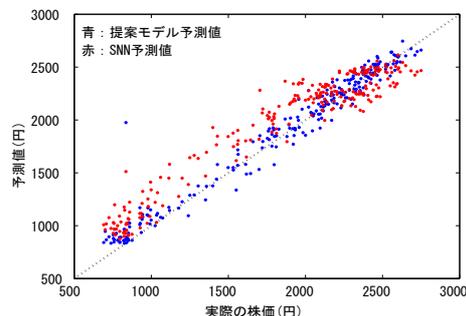


図 3. 08.1.4 から 08.12.29 の三井物産の予測 (800 営業日学習)

また図 4 は予測値の値上がり幅に応じて株式売買を行った場合の資産増加の様子を記している。また比較として、初期資産を各銘柄の株式に比例配分した後何もしない場合の様子も記す。

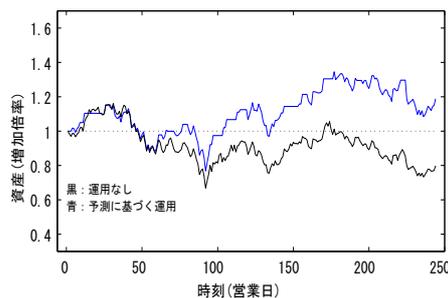


図 4. 07.9.3 から 08.8.29 の予測に基づく資産運用の様子 (800 営業日学習)

5 おわりに

本研究では NN Ensemble を用いた複数銘柄の株価の予測を行った。値の予測に関しては提案モデルの方が単純な NN よりも予測精度が高いことが分かり、ある区間においては効率的な資産運用が可能となり資産が増加することも分かった。今後の課題は、より多くの企業 (東証一部上場企業数約 1700) の株価予測について調査、数値実験を行いたいと考えている。

参考文献

- [1] Md. M. Islam, X. Yao: Evolving Artificial Neural Network Ensembles. *IEEE Computational Intelligence Magazine*, (2008), pp. 31-42.