

IFTA 東京大会 2015 講演論文

ニューラルネットワークの集団学習による価格変動パターンの自動検出および自信度の評価

茨城大学工学部 知能システム工学科
教授 鈴木 智也

要 旨

本講演では、テクニカル分析の予測可能性および収益性の向上を目指して、3つのアイディアを導入した。第一に、複雑な株価変動内に隠れた法則性を自動検出すべく、伝統的な機械学習モデルの1種であるニューラルネットワークを導入した。第二に、その予測力を高める工夫として集団学習法を適用し、予測結果の自信度を評価する新しいテクニカル指標（コンセンサスレシオ）を提案した。第三に、その自信度が高い銘柄を選択する枠組みとして2段階選抜法を提案した。これらの妥当性を評価すべく、日本および米国の約1000銘柄に対して4期間の投資シミュレーションを行ったところ、良好なパフォーマンスを得たので紹介する。

1. はじめに

近年の人工知能ブームを受け、ニューラルネットワークが再び注目されている。予測モデルといえば、線形単回帰分析が最も初歩的であるが、単変量から多変量（重回帰）に拡張し、さらに平面から曲面（非線形）に変更することで、より複雑な法則性を表現できる。しかし人間が知覚できる複雑さには限りがあるため、法則性の検出は機械（コンピュータ）にやらせようという発想が生まれる。ニューラルネットワークはこのような機械学習の方法論であり、多変量かつ非線形な特徴を持つ高度な予測モデルである。

●プロフィール
鈴木 智也 CFTe®

新潟県新潟市生まれ。2000年に東京理科大学理学部応用物理学専攻を卒業し、同年より東京理科大学大学院理学研究科物理学専攻に進学。2002年に同大学院修士課程を修了し、2005年に同大学院博士課程を修了。その後、東京電機大学工学部助手、同志社大学理工学部専任講師、茨城大学工学部准教授を経て、2016年より現職。




る。しかし予測に用いる情報は過去の株価変動のみである点において、伝統的なテクニカル分析と同じである。それゆえ欧米では、機械学習によるテクニカル分析を「モダンテクニカル分析」と呼ぶ場合もある。本講演では、さらに一歩二歩踏み込んだ新しいモダンテクニカル分析を提案すべく、集団学習法をも導入することで予測力の向上を図り、予測自信度を評価するための新しいテクニカル指標を紹介する。さらに、これらを活かした実践的な銘柄選抜法も検討する。

2. 講演スライドの紹介


本章では、講演に用いたスライドを抜粋して要旨を述べる。なお講演の雰囲気や再現するために、口語体によって説明文を記述する。

2-1. アノマリーを学習するニューラルネットワーク

周知のように、金融市場には効率的市場仮説に反するアノマリー（異常現象）が存在します。収益率




の変動は完全なランダムウォークではなく、時間的な相関構造を持っています。特にボラティリティークラスター化が最も明確ですが、収益率の変動規模はクラスター化する性質があり、時間的に正の相関を持ちます。その他、国や時期によって特徴が異なりますが、モメンタム効果（正の相関）やリターンリバーサル（負の相関）といった傾向が、収益率変動から観測されます。




しかし実際の金融市場は非常に複雑であるため、相関構造を明確に捉えるのは困難です。そこで疑問なのですが、なぜ従来の分析では線形相関にこだわるのでしょうか。確かに「線」の関係の方が我々人間にとって分かりやすいでしょう。



しかし実際の金融市場は人間の都合に合わせてくれません。よって、より複雑な「曲線」の関係も視野に入れて検討すべきです。



もし曲線の関係が存在するならば、非線形予測モデルが有用です。直線のように簡単な法則のみならず、曲線のように複雑な法則も表現できます。





そのため本講演では、非線形予測モデルとしてニューラルネットワークを用います。しかしその予備知識として、単一ニューロンモデルを先に紹介させていただきます。ニューロンは結合荷重 w に応じて過去の収益率データ x を入力し、これらを加算して1期後の予測値 $x(t+1)$ を出力します。つまり従来の重回帰分析と同じであるため、非線形ではなく、線形の予測式に相当します。




つまり、入力（説明変数）と出力（目的変数）の関係は、1枚の平面によって表現されます。この傾きは結合荷重 w によって決定されます。

この非線形関数 F を挿入すると、先ほどの平面は「曲面」になります。しかし全体の形は未だ単純です。これでは複雑な法則性を表現できません。




次のステップとして、非線形の予測式に拡張します。たとえば、ニューロンの後ろに非線形関数 F を挿入してみましょう。この F は、スライド中の数式にある F に相当します。この関数 F の形は曲線ですよ。これが非線形と呼ばれる理由です。


そこで、いよいよ単一ニューロンモデルをたくさん結合させてネットワーク化してみましょう。これがニューラルネットワークです。




IFTA 東京大会 2015 鈴木氏講演




ネットワーク化によってたくさんの曲面がミックスされますので、全体としてより複雑な曲面を表現できます。これがニューラルネットワークの利点です。



では、どうやって曲面の組合せ方を決めるのでしょうか。実はこれを「学習」と呼び、機械学習法においては過去の実現データを正しく再現できるように、適切な結合荷重 w をコンピュータによって探します。簡潔に言えば、ニューラルネットワークが算出した予測値とその真値（教師信号）を比較し、両者のズレが小さくなるように結合荷重 w を調整します。このアルゴリズムとして、逆誤差伝搬法（バックプロパゲーション）が有名です。




この調整は、入力データを時間シフトさせながら、全ての学習データに対して行われます。そして、全データにおける誤差が十分に小さくなるまで、100 回でも 1000 回でも調整を繰り返します。コンピュータは文句を言わず迅速かつ正確に仕事をしてくれます。これが機械学習や人工知能のメリットですが、人類にとって脅威とも言われる所以です。



さて、全ての結合荷重 w が最適化されたら、ニューラルネットワークの学習は完了です。スライドにおいて、太い矢印は結合荷重が強く、細い矢印は結合荷重が弱いことを意味しています。


2-2. オーバーフィッティング（過学習）対策

How to Determine the Number of Neurons and Input data



オーバーフィッティングという概念をご存知でしょうか。投資の分野ではカーブフィッティングとも呼ばれます。簡潔に言えば、過去の学習データを過度に学習しすぎて、肝心の新規データに対して当てはまらなくなる現象です。予測モデルが複雑なほど過度な学習が可能になるため、ニューラルネットワークにおいては結合するニューロン数を制限する必要があります。では、どのようにニューロン数を決定したら良いのでしょうか。ポイントは、バックテスト（学習データに対する当てはまりを評価）ではなく、フォワードテスト（新規データに対する当てはまりを評価）が重要です。


How to Set the Number of Neurons and Input data



スライドに示すように、予測モデルの複雑さ（ニューロン数）を増すほど、バックテストの成績は向上します。これは学習データ内のノイズまでも学習したからです。その結果、新規データに対するフォワードテストの成績は低下します。このよう


なオーバーフィッティングを防ぐためには、フォワードテストの成績によって予測モデルの複雑さ（ニューロン数）を決める必要があります。しかし、あまり古いデータは使いたくないので、バックテストもフォワードテストも実施する場合、直近のデータだけで足りるのでしょうか。

Cross Validation Method



そこで、データを節約する方法として、クロスバリデーション（交差確認）法を紹介します。スライド中の「Now」を現在時刻とします。これより過去のデータで両方のテストを実施する必要があります。そこで、まずデータを2分割し、それぞれバックテストとフォワードテストに割当てます。バックテストではニューラルネットの結合荷重 w を最適化し、フォワードテストではニューロン数の妥当性を評価します。次に2分割したデータを入れ替えて、同様のテストを行います。これにより、データ数を減らすことなく両方のテストを実施できます。最終的に2つのフォワードテストを総合して、最も過学習が起こらないニューロン数を採用します。

Forward Tests



クロスバリデーション法によって最適化されたニューラルネットワークが、現在時刻「Now」以降においてどの程度機能するかシミュレーションしてみました。用いたデータは、東京証券取引場の590銘柄とNY証券取引場の500銘柄です。データに欠損が無い銘柄からランダムに選出しました。さらに、バックテスト（5年間）とフォワードテスト（2.5年間）の組合せとして、異なる4期間を試してみました。つまり、

(590+500) 銘柄 x 4 期間 x 2 市場=8720 銘柄より、約 8800 銘柄を分析することに相当します。

Forward Tests

[Results] Average of prediction accuracy

Term	Tokyo	New York
(1)	54.8%	59.1%
(2)	55.8%	52.7%
(3)	51.6%	52.0%
(4)	54.8%	53.2%


Accuracy over 50% is good.

新規データに対する予測精度はスライドのとおりです。本講演では、明日の株価が上がるか下がるかを予測対象にしているため、50%が予測精度の評価ラインになります。結果として、東京市場およびNY市場の全期間において50%以上の予測精度を達成しています。しかし、十分に高いと言い切るに

は不十分な印象です。

2-3. 集団学習法による予測力の向上

Will tomorrow's price be up or down?



Q. You have 19 kinds of prediction methods.
Each prediction accuracy is 53%.

What percentage can you win
by following **their majority decision** ?
(Consensus of more than 10 predictors)

そこで2つ目の方法論として、集団学習法を導入します。これによりニューラルネットワークの予測力を更に引き出します。このメカニズムを理解するために、次の問題を考えてみましょう。

[問題]


明日の株価が上がるか下がるか（2択問題）を予測する際に、正答率53%の予測法が19個あります。この多数決を信じた場合、多数決の正答率はいくらになるでしょうか？

Answer

If each predictor is independent,
the probability that x out of 19 are correct is

$$B(x) = {}_{19}C_x p^x (1-p)^{19-x}, \text{ where } p = 0.53.$$

Binomial distribution



$$\text{Accuracy of the majority : } \int_{10}^{19} B(x) dx = 0.60$$

It's improved, 53% $\Rightarrow$ 60%

確率論の知見により、19個の予測法のうち x 個正解する確率は二項分布によって計算できます。多数決とは半数（10個）以上のコンセンサスなので、 $x=10 \sim 19$ の範囲で二項分布を積分すれば、多数決の正答率が得られます。その結果、個別の正答率

この効果を検証すべく、先述のデータに対して予測シミュレーションを行いました。結果として、全てのケースにおいて予測精度は60%近くまで向上しています。これにより、集団学習法の導入は有用だと考えられます。しかし工夫次第で、もっと予測精度を向上できるかもしれません。

Forward Tests

[Results] Average of prediction accuracy


Term	Tokyo	New York
(1)	54.8% → 59.9%	59.1% → 61.7%
(2)	55.8% → 57.9%	52.7% → 55.6%
(3)	51.6% → 55.5%	52.0% → 55.3%
(4)	54.8% → 57.0%	53.2% → 54.6%

All the cases were improved by *the ensemble learning*.

2-4. 2段階選抜法による優良銘柄の抽出

1. First Selection

removes unpredictable stocks through the backtest



まず第1に、バックテストの成績が悪い銘柄を除外します。これらはニューラルネットワークおよび集団学習でも予測困難であるため、比較的ノイズな(法則性の低い)銘柄だと推測されます。一方、バックテストの成績が良い上位25%を残し、これを「第1次選抜」と呼ぶことにします。

My Technical Indicator

Tomoya Suzuki, Yushi Ohkura: "Financial Technical Indicator Based on Chaos Gating Predictors for Adaptive Stock Selection in Japanese and American Markets," *Physica A*, 2016.

Consensus Ratio of Majority

$$\text{Ratio of Up} = \frac{\text{The number of Up}}{\text{The number of (Up+Down)}}$$



[Strategy] When Ratio of Up is over θ .

- Buy this stock
- Sell it next day


次に、第1次選抜を通過した銘柄を対象に投資を開始します。しかしこれらは、バックテスト期間の総合成績が良好だっただけで、毎日予測しやすいとは限りません。そこで、先ほどの集団学習の多数決を利用して「予測の自信度」を銘柄毎に評価します。これを「コンセンサスレシオ」と呼び、次式のように定義します。

P (株価上昇) = 株価上昇と予測した予測法の個数 / 集団学習で複製した予測法の個数

ここで P は確率を意味し、 P が1に近いほど多数決のコンセンサスが高い(予測に自信がある)と言えます。したがって売買判断の一例として、 P (株価上昇) が閾値を超えた銘柄を購入し、翌日に手仕舞する方法が考えられます。


2. Second Selection

dynamically finds out the most reliable stocks each day




もし閾値を設定しないのなら、毎日において P (株価上昇) が最大な銘柄に集中投資する方法が最も手軽です。これを「第2次選抜」と呼ぶことにします。

なお余談ですが、もし予測困難な銘柄に対してコンセンサスレシオを適用すると、偶然的に高いコンセンサスを得る場合があります。これを防止するために第1次選抜がフィルター（足切り）として機能します。



最後に、これまでのアイデアを全て用いた投資シミュレーション結果を示します。投資期間は約600日（約2年半）です。結果として、2段階選抜による運用成績（資産増幅率）は市場平均よりも優れています。さらに予測正答率も60%～70%まで向上しています。



このような結果はNY市場でも同様です。つまり良好な運用成績および予測正答率を示しています。

2-5. まとめ

Summary

1. **Neural Network** is useful to detect complex nonlinear patterns of financial markets.
2. **Ensemble Learning** can enhance predictive power.
3. **Consensus ratio** can be a new technical indicator for adaptive stock selection.
4. More research is necessary to obtain real returns.

Questions & comments: tomoya.suzuki.lab@vc.ibaraki.ac.jp
My laboratory's Web page: http://tsuzuki.ise.ibaraki.ac.jp/TS_lab/

最後に本講演をまとめます。第一に、金融市場に内在する複雑で非線形なパターンを機械的に学習する方法としてニューラルネットワークを適用しました。第二に、集団学習法によってニューラルネットワークの多数決を取ることで予測力を強化しました。第三に、コンセンサスレシオが最大の銘柄を選択することで、毎日の投資対象を適応的に切替えることができます。

なお、本講演の骨格は参考文献3)に基づいています。もし詳細を把握したい場合は、こちらをご覧ください。ただし非線形予測モデルとして、ニューラルネットワークではなく、より簡単なk近傍法を採用しています。この点において、本講演は参考文献3)の発展研究として位置付けられます。なお本講演で示した研究の一部は、文部科学省科学研究補助金（No.25330280）の助成を受けたものです。

<参考文献>

- 1) 西垣 通 (2013)『集合知とは何か』中央公論新社.
- 2) ジェームズ・スロウィツキー (2009)『みんなの意見』は案外正しい』角川書店.
- 3) Tomoya Suzuki, Yushi Ohkura (2016) "Financial Technical Indicator Based on Chaotic Bagging Predictors for Adaptive Stock Selection in Japanese and American Markets," Physica A, vol.442, pp.50-66.