

為替情報の幾何的特徴を用いた売買アルゴリズムの検討

Examination of trading algorithm applying geometry characteristics for foreign exchange data

河合 継¹, 新田 翔^{1,2}, 山口 航^{1,3}, 木村 祐輔¹, 西山 昇⁴

Kei Kawai¹, Sho Nitta^{1,2}, Wataru Yamaguchi^{1,3}, Yusuke Kimura¹, and Noboru Nishiyama⁴

¹クリスタルメソッド株式会社

¹ Crystal method co.ltd

²東京理科大学工学研究科経営工学専攻

² Department of Management Science, Graduate School of Engineering,
Tokyo University of Science

³東京工業大学情報理工学院情報工学系

³ Department of Computer Science, School of Computing, Tokyo Institute of Technology

⁴千葉商科大学会計大学院 客員教授

⁴ MBA Program, Graduate School of Accounting & Finance, Chiba University of Commerce

Abstract: In this paper, we examined a new method to predict fluctuation of foreign exchange rate. We input information extracted from historical data into PointNet++, which is proposed by C.R.Qi et al.[3] and predicted US Dollar to Yen Exchange rate 5 minutes later. The results implied that although there was tendency of overfitting, our method might capture a part of some structured factors of foreign exchange fluctuation. It is suggested that various range of approach related to machine learning could be useful for financial problems.

1. はじめに

外国為替取引は人々の関心を集め続けている。2015年のチャイナショック時には、瞬時に6円以上の円高が進行し、話題となった。為替取引が行われる理由は様々であるが、2018年時点で個人投資家でも25倍のレバレッジを利用可能、ショートポジションを取る際のハードルが株式取引よりも相対的に低い、などといった特徴から外国為替取引では短期取引を志向する投機的な行動が多くみられると言われている。そうした市場環境の中で、取っているポジションのリスクを定量的に把握したり、売買タイミングを判定したりするようなアルゴリズムへの高い需要が存在すると予想される。

近年、機械学習を活用することで、金融商品の取引において高いリターンを達成しようとする試みが活発に行われている。例えば石原[4]は多層ニューラルネットワークと遺伝的アルゴリズムを用いたトレーディング手法によって、TOPIXを上回る運用成績を達成したことを報告している。また、今村ら

[5]では、金融実務に置いて伝統的に用いられているペア・トレードと呼ばれる手法と、LSTM (Long Short Term Memory) を組み合わせることで、良好な結果を得たと報告している。

これらは、株式市場でのAIの応用例であるが、本稿では、為替取引における機械学習的なアプローチを検討する。具体的には、三次元点群形式のデータの幾何的な構造を捉えることに長けた PointNet++ と呼ばれる学習器を用いて、為替取引における売買タイミングを予測する手法の検討を行う。今回、為替取引にこれを応用する背景には以下のような状況がある。

まず、梅田ら[6]が指摘するように、従来使われている統計的な解析手法では、データの分布を仮定する必要があった。しかし、ビッグデータの収集および処理が可能になりつつある近年、単純な分布を仮定するだけでは必ずしも説明できない事象も多く知られるようになってきた。これに対し、データ特有の特徴を利用した個別の解析手法を構築したり、R.Fujimaki et al [1]のように、出来るだけ情報を保存

したまま複数の分布を組み合わせようとする工夫がなされてきた。しかし、それらの場合でもデータの詳細な情報が事前に必要になったり、データが局所的に従っている分布についての仮定が必要になったりと、問題は完全には解決されなかった。

そこで、梅田ら[6]のように、「データの形」を把握することで、従来の統計的データ解析手法が取りこぼしていた情報を汲みとろうとしてきた背景がある。

このような状況を踏まえ、本稿では三次元の点群形式データの幾何的な特徴を処理することに長けた PointNet++ を学習器として採用し、為替の変動予測を行った。さらに、その変動予測に基づく売買アルゴリズムのパフォーマンス測定を行った。次節以降、この PointNet++ を用いて行った実験について説明する。

2. PointNet++

C.R.Qi et al [2]は、物体を描画した点群を三次元ボクセルや画像に変換することなく、直接処理することができる PointNet と呼ばれるアーキテクチャを提案した。これに対し、C.R.Qi et al [3]によって提案された PointNet++ は、PointNet のネットワークに階層的な構造を導入することで、インプット情報の局所的な構造を捉える精度を向上させたものである。

2.1. データの取得

FXDD (URL : <https://secure.fxdd.com/us/jp/forex-resources/forex-trading-tools/metatrader-1-minute-data/>) より、2005年1月から2018年7月までのドル円の1分足の為替データを入手した。なお、入手したデータは5分足に直してから使用した。

2.2. 入力値

ここでは、学習器に入力したデータの説明を行う。まず、金融実務においてよく参照される指標を15個リストアップした (表1)。これらの指標に対し、主成分分析(PCA)と t-SNE を用いて次元削減を行った。次元削減後の各データの次元は三とし、これを PointNet++ の入力とした。

表1 : 入力データ作成に用いた指標

指標	タイムピリオド
Absolute Price Oscillator	12, 26
Aroon Down	14
Aroon Up	14
Average True Range	12
Chande Momentum Oscillator	14
Rate Of Change	10
Minus Directional Movement	14
Midpoint	14
Plus Directional Movement	14
Relative Strength Index	12
Slow %D	5, 3
Slow %K	5, 3
Simple Moving Average	24
Ultimate Oscillator	7, 14, 28
William's %R	14

2.3. 主成分分析(PCA)と t-SNE(t-distributed Stochastic Neighbor Embedding)

両手法は、多次元データを次元圧縮するときに利用される。PCA は線形変換系手法の代表的な圧縮方法であるが、多次元データに多変量正規分布が仮定されている。

一方 t-SNE は、多変量正規分布が仮定されていないデータであっても次元圧縮に利用できる手法とされており、クラスターを可視化する際に有効な手法とされている。

3. 実験

まず、教師データに関する説明を行う。連続する512時点分の三次元データを間隔256で移動させて、学習器にインプットする。正解ラベルの作成は、5分後の価格変動に応じて行った。ラベルの設定は、表2の通りである。

表2 : ラベルの設定

変動	ラベル
n pips 以上上昇	UP
n pips 以上下落	DOWN
その他	STAY

n=1,5

また、全データの4分の3を学習用データに、4分の1をテスト用データに割り当てた。

以上の条件のもとで学習を行った。エポック数は251、バッチサイズは16とし、最適化手法は Adam (Adaptive Moment Estimation)を用いた。

また、学習後の PointNet++を用いた売買アルゴリズムのシミュレーションを行った。対象となる区間は学習に用いていない期間(2015-03-12 18:05:00 ~ 2018-07-28 00:30:00)で、入力に対する出力が「UP」

である場合には買いを、「DOWN」である場合には売りを入れ、「STAY」である場合には何もしないという条件を設定した。なお、売買を行った場合は、次のステップで反対売買するものとする。また、スプレッドや取引手数料は考慮に入れていない。

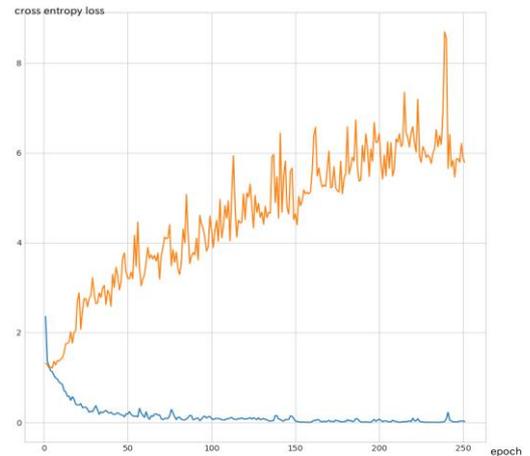


図 1 -b: t-SNE/ 1 pips

3. 結果

3.1. 学習の結果

学習の結果、loss は図 1、accuracy は図 2 のように推移した。

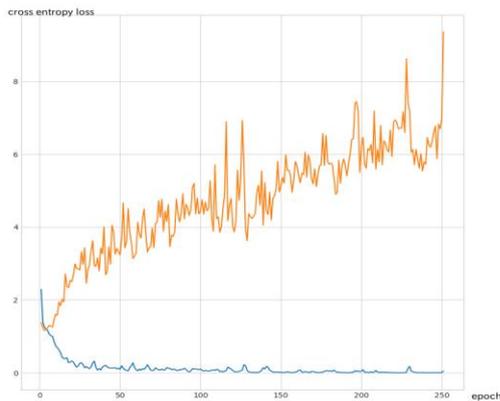


図 1 -a: PCA/ 1 pips

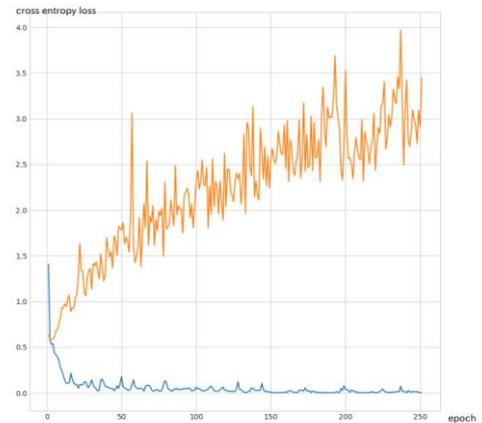


図 1 -c: PCA/ 5 pips

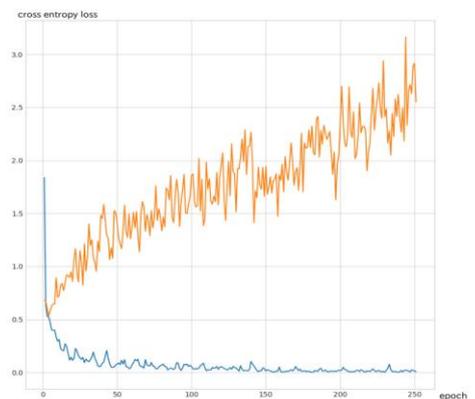


図 1 -d: t-SNE/ 5 pips

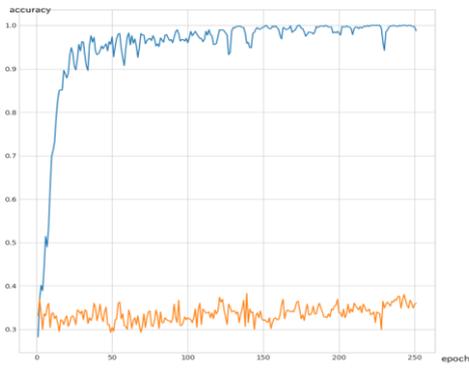


図 2-a: PCA/ 1 pips

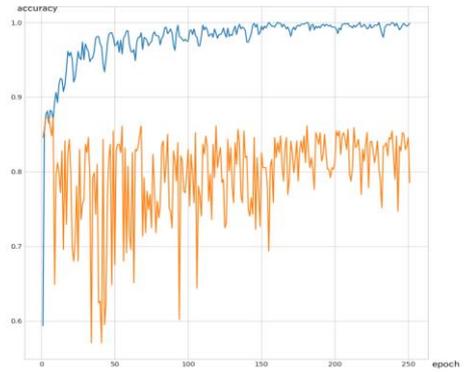


図 2-d: t-SNE/ 5 pips

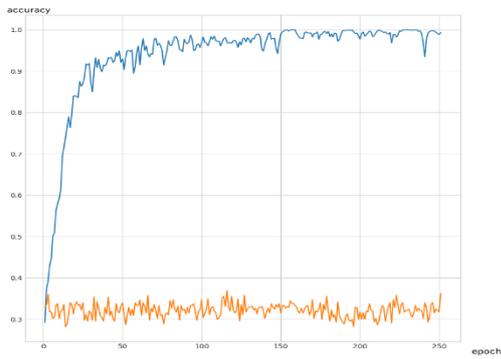


図 2-b: t-SNE/ 1 pips

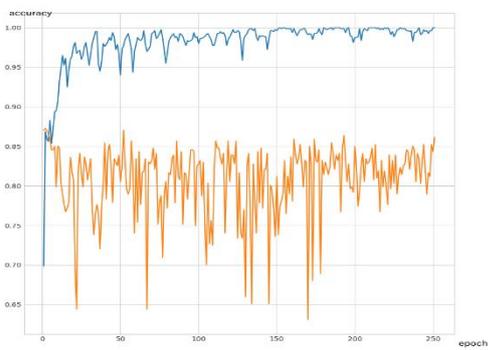


図 2-c: PCA/ 5 pips

3.2. 売買シミュレーションの結果

学習済みの PointNet++を用いて売買のシミュレーションを行った結果は図3の通りである。

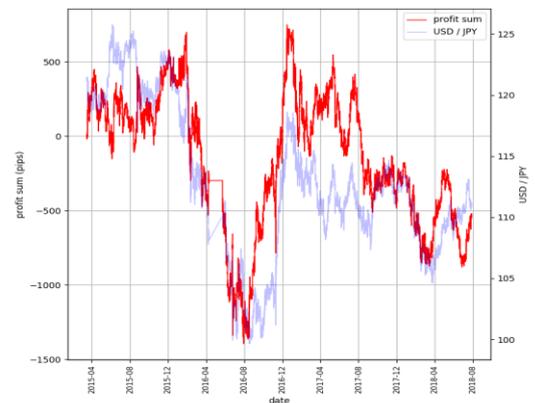


図 3-a: PCA/ 1 pips

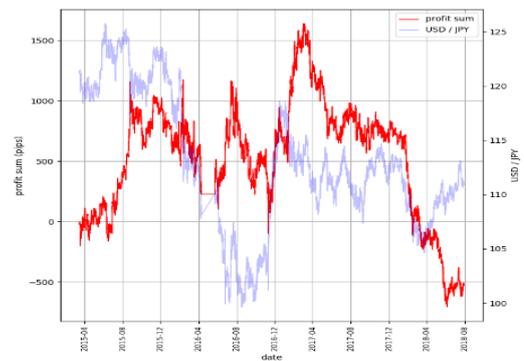


図 3-b: t-SNE/ 1 pips

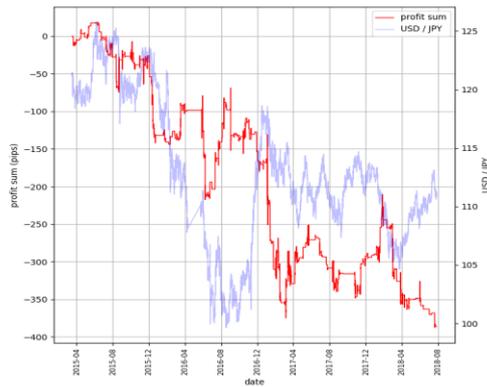


図 3 - c : PCA / 5 pips

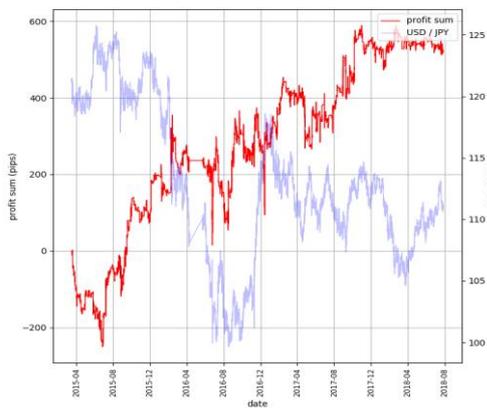


図 3 - d: t-SNE / 5 pips

4. 考察

4つの売買シミュレーションの中で唯一、t-SNE/5 pips のものだけは最終的に利益を出している (図 3-d)。同じ5 pips でも、t-SNE が順調に利益を上げていっている反面、PCA では徐々に負けが増えている (図 3-c, 図 3-d)。まず、この理由を考えてみたい。

本実験では、PointNet++を用いることによって、できるだけデータが持つ構造をそのまま扱おうという意図があった。一方、PCA には非線形な構造を捉えきれないというデメリットがあり、データの次元を削減して三次元とした時点で既に、本来存在していた構造が失われていた可能性がある。これに対し、t-SNE による次元削減では、データの構造に関する情報を失うことがなかったと考えれば、この結果にも説明がつく。もちろんこの結果が偶然にすぎないという可能性も排除しきれない。

図 1 は学習器が過学習に陥っていることを示唆している。学習が進むごとに訓練データに対しては loss の減少が見られるが、未知データに対しては loss の減少が見られない。これは、学習器が、為替変動の本質的要因を完全に捉えきれていない可能性を意味する。

accuracy に対しても同様のことが言える。訓練データでは精度の向上が見られるのに比べ、1 pips の未知データでは3分の1程度の正答率に留まっている。5 pips の未知データでは高い正答率が達成されているが、これは「STAY」に分類されたデータ数が圧倒的に多いため、大多数の局面で「STAY」と予想しておけば正答率自体は高い水準をキープ出来たということであろう。

過学習に陥った原因であるが、為替の短期的な変動が、本質的にランダムである可能性が挙げられる。為替レートがランダムに変動するのであれば、ヒストリカルデータから未来の変動を予測するという試み自体が無理となる。あるいは、今回分析したデータに含まれない、金利等の経済指標の影響で価格変動している可能性もある。

5. 終わりに

本研究では、機械学習の分野で発展してきた、情報を損なわずにデータを扱う手法が金融データに対しても適用できる可能性が示唆された。

t-SNE と PointNet++を組み合わせた手法の中の一つのパターンでは、未知データに対する売買シミュレーションにおいて最終的に利益を確保することが示された。

一方で課題は多い。まず、過学習をどのように克服するかがある。本実験では、学習が進むに連れて、未知データに関する loss が大きくなるという、汎用的な特徴でなく、より局部の特徴のみをとってしまっている過学習の傾向が生じた。

この原因がネットワークにあるのか、インプット情報にあるのかははっきり特定できていない。

そして、今回は経済のファンダメンタルな情報を考慮できなかったことも大きい。通貨の価値は、その国の経済状況や政治リスクに影響を受ける。

今回は超短期取引でのシミュレーションとはいえ、それらの情報を検証対象にできなかったことは、市場変動の説明要因を損なっていた可能性がある。

次回以降は、これらの課題点を念頭に置き、予測の精度向上を目指したい。

参考文献

- [1] R.Fujimaki, S.Morinaga: Factorized Asymptotic Bayesian Inference for Mixture Modeling. Proceedings of the fifteenth international conference on Artificial Intelligence and Statistics(AISTATS),2012.
- [2] C.R.Qi, H.Su, K.Mo, and L.J.Guibas: Pointnet: Deep learning on point sets for 3d classification and segmentation, IEEE Conference on Computer Vision and Pattern Recognition,2017
- [3] C.R.Qi, H.Su, and L.J.Guibas: Pointnet: PointNet++: Deep Hierarchical Feature Learning on Point Sets in Metric Space, Neural Information Processing Systems,2017
- [4] 石原龍太: 多層ニューラルネットワークと GA を用いた TOPIX 運用 AI, 第19回 人工知能学会 金融情報学研究会(SIG-FIN), 2017
- [5] 今村光良, 中川慧, 吉田健一: 機械学習を用いた共和分ペア・トレード戦略, 第19回 人工知能学会 金融情報学研究会(SIG-FIN), 2017
- [6] 梅田裕平, 金児純司, 菊地英幸: トポロジカルデータアナリシスと時系列データ解析への応用, FUJITSU, Vol. 69, No. 4, pp. 97-103, 2018