

複数時間スケールのファインチューニングによる 金融機械学習の精度向上

雨谷 暉樹[†] 田中 陸^{††} 鈴木 智也^{†,††}

† 茨城大学大学院理工学研究科 〒316-8511 茨城県日立市中成沢町 4-12-1

†† 大和アセットマネジメント株式会社 〒100-6701 東京都千代田区丸の内 1-9-1

E-mail: †{21nm404n,tomoya.suzuki.lab}@vc.ibaraki.ac.jp, ††riku.tanaka@daiwa-am.co.jp

あらまし 投資信託など資産運用実務では、売買回転率の増加によるオペレーションの負荷や取引コストの増大により中長期の運用が一般的である。しかし運用モデルの構築において機械学習を適用する場合、時間スケールを長期化するほど学習データ数が減少するため学習精度の低下を引き起こす。そこで本研究では、対象タスクの時間スケールのみならず、より短期の時間スケールの学習データを併用することでデータ拡張を施し、機械学習の対象タスクが長時間スケールであっても汎化性能の劣化を抑制できることを示す。

キーワード 複数時間スケール、オートエンコーダ、データ拡張、ファインチューニング、マルチファクターモデル

Long-term modeling of financial machine learning with multiple time scales

Kazuki AMAGAI[†], Riku TANAKA^{††}, and Tomoya SUZUKI^{†,††}

† Graduate School of Science and Engineering, Ibaraki University

4-12-1 Nakanarusawa, Hitachi-shi, Ibaraki, 316-8511 Japan

†† Daiwa Asset Management Co.Ltd. 1-9-1 Marunouchi, Chiyoda-ku, Tokyo, 100-6701 Japan

E-mail: †{21nm404n,tomoya.suzuki.lab}@vc.ibaraki.ac.jp, ††riku.tanaka@daiwa-am.co.jp

Abstract In asset management businesses such as operating mutual funds, medium or long-term investments are common in terms of operational loads and transaction costs. However, the number of training data are more insufficient for applying machine-learning methods to longer time-scale investments, which reduces the generalization ability of trained machine-learning models. To solve this problem, we try to perform a data augmentation technique using multiple time-scale data including shorter time-scale data than the target task, and confirm its effectiveness to keep a better generalization ability of trained models even if the target task of machine-learning methods is longer time scale.

Key words multiple time scale, autoencoder, data augmentation, fine tuning, multi factor model

1. まえがき

株式市場においては、Fama による効率的市場仮説 [1] があり、株価に関する情報は瞬時に織り込まれ、株価はランダムウォークする。これが真実であれば、株式運用において過去の時系列情報は無価値である。しかし一方で、クロスセクション情報の有用性は比較的認知されており、機械学習を適用する研究が多く行われている [2]~[4]。実務においては、多銘柄の共分散構造を利用したポートフォリオ運用やファクター運用、ペアトレーディング等が用いられている。特に裁定価格理論 [5] やマルチファクターモデル [6], [7] の枠組みにおいて、これまで数百に及ぶファクターが提案されており [8]、動的に変化する経済環境下において有用なファクターを特定することは容易ではなく

い。そこで本研究では、オートエンコーダを用いることで有効なファクターを潜在変数として動的に推定する。

オートエンコーダを学習する際、学習データには株価から算出した収益率データを使用する。一般的に機械学習において、高精度なモデルを構築するためには、膨大な学習データが必要である。しかし、単一時間スケールでは学習に使用できるデータが少ないため、充分な学習精度を得ることが難しいことに加えて、未知の市場状態に直面する可能性が大きくなる。そこで本研究では、データ拡張を試みる。データ拡張は画像認識や自然言語処理などの様々な分野で研究が行われている。本研究では、テストデータとして使用する時間スケールよりも短期の時間スケールのデータも学習に併用することでデータ拡張を行い、金融機械学習における有効性を検証する。

その活用事例として、ポートフォリオ運用における銘柄選択に着眼する。学習したオートエンコーダの出力をマルチファクターモデルに準拠した理論値とみなし、実現値との乖離を評価することで現時点における異常な株価変動を検出し [9]、適正価格への修正を利用した運用手法を提案する。

さらに、FX 市場でもファクターの存在が指摘されており、様々な実証分析がなされている [10]～[12]。オートエンコーダは収益率データさえあれば学習可能であるため、株式市場のみならず FX 市場においても本手法を適用し、その有用性を確認することで、金融市場における汎用的なポートフォリオモデルを構築できることを検証する。

2. 複数時間スケールによるデータ拡張

本研究では、日次スケールの株価時系列 $p(t)$ から様々な時間スケール τ の収益率データを複製することで、オートエンコーダの学習データを増加させる。また、本節では学習データを用いてオートエンコーダを学習し、テストデータを用いて学習済みオートエンコーダを評価する。

まず、時点 t における銘柄 i の株価を $p_i(t)$ とし、時間スケール τ における株価の収益率 $r_{i,\tau}(t)$ を算出する。

$$r_{i,\tau}(t) = \frac{p_i(t) - p_i(t-\tau)}{p_i(t-\tau)} \quad (1)$$

ここで $\tau = 1$ ならば日次スケール、 $\tau = 20$ ならば月次スケールに相当する。なお本稿を通じて、1 週間を 5 営業日として表現する。

次に、同時刻の全銘柄 ($i = 1 \sim N$) のクロスセクション情報を作成する。

$$\mathbf{r}_\tau(t) = [r_{1,\tau}(t), r_{2,\tau}(t), \dots, r_{N,\tau}(t)] \quad (2)$$

これをオートエンコーダの入力層に投入するが、 τ に応じて収益率 $r_{i,\tau}(t)$ のスケールが異なるため、 $\mathbf{r}_\tau(t)$ を構成する全要素の標準偏差 $\sigma_\tau(t)$ で正規化する。

$$\mathbf{r}_\tau^\dagger(t) = \frac{\mathbf{r}_\tau(t)}{\sigma_\tau(t)} \quad (3)$$

学習データに関して、各時間スケールでデータ数を統一する。時間スケール τ において、テスト期間のある時点 t_{test} から直近過去 $(\tau-1)$ サンプルのデータは、式 (1) により時点 t_{test} と相関を持つため、学習データとして使用しない（学習データがテストデータと相関があると、オートエンコーダが過学習するほど精度が高くなり、汎化性能の評価として適切ではなくなるため）。そこで、時点 t_{test} の直近過去 $(\tau-1)$ サンプルのデータを取り除いた後の 1200 サンプル（約 5 年分）の収益率を学習データとして使用する。つまり、時間スケール τ における時点 t_{test} の学習期間 $t_{\tau,train}(t_{test})$ は以下となる。

$$\begin{aligned} t_{\tau,train}(t_{test}) = & [t_{test} - (\tau-1) - 1, \\ & t_{test} - (\tau-1) - 2, \\ & \dots, \\ & t_{test} - (\tau-1) - 1200] \end{aligned} \quad (4)$$

表 1: オートエンコーダのハイパーパラメータ

ハイパーパラメータ	使用した値
epochs	50
batch_size	128
optimizer	Adam
中間層の層数	1

つまり時間スケール τ によらず、学習データは 1200 サンプルとする。

最終的に、テストデータとして使用する時間スケール τ_{test} の学習データ集合 $S_{\tau_{test}}(t_{test})$ は以下となる。

$$S_{\tau_{test}}(t_{test}) = [\mathbf{r}_\tau^\dagger(t') \mid t' \in t_{\tau,train}(t_{test}), \tau \in 1 \sim \tau_{test}] \quad (5)$$

このように複数時間スケールのデータを同時にオートエンコーダに投入し学習を行う。

なお、单一時間スケール τ_{test} のみでオートエンコーダを学習する場合、学習データ集合 $S_{\tau_{test}}(t_{test})$ は以下となる。

$$S_{\tau_{test}}(t_{test}) = [\mathbf{r}_\tau^\dagger(t') \mid t' \in t_{\tau,train}(t_{test}), \tau \in \tau_{test}] \quad (6)$$

また、オートエンコーダは入力層・中間層・出力層の全結合型の構造で、出力層には linear 関数を使用する。オートエンコーダの中間層で抽出された潜在変数は、従来のマルチファクターモデル [6], [7] と対応する。なお、オートエンコーダに用いた各種ハイパーパラメータを表 1 に示す。未記載のものはデフォルト値を用いた。

3. 分析

3.1 データセット

本研究では、日本株式市場を対象に分析を行う。分析のユニバースとして、TOPIX 構成銘柄（上場廃止銘柄を含む）を使用する。期間は 2010 年 1 月～2021 年 12 月とし、この内 2016 年 1 月～2017 年 10 月で複数時間スケールのデータを活用する有効性の検証及びモデルの最適化を行い（～4.3 章）、2018 年 1 月～2021 年 12 月で最適化されたモデルを用いて運用シミュレーションを行う（4.4 章）。データは全て Refinitiv Eikon から取得した。

3.2 ファインチューニングとの比較

前章のデータ拡張の他に、ファインチューニングによる複数時間スケールのデータ活用も考えられる。ファインチューニングとは、大規模なデータを用いて事前学習を行い、その後に対象タスクの小規模データを用いてモデルを微調整する機械学習手法である。

複数時間スケールのデータを活用してファインチューニングを行う場合、対象タスクの時間スケール τ_{test} に対して、事前学習で使用する学習データ集合 $S_{\tau_{test}}^{pre}(t_{test})$ は以下となる。

$$S_{\tau_{test}}^{pre}(t_{test}) = [\mathbf{r}_\tau^\dagger(t') \mid t_{test} \in t_{\tau,train}(t_{test}), \tau \in 1 \sim \tau_{test}-1] \quad (7)$$

表 2: 最適化する項目

項目	比較対象
ファインチューニング	あり, なし
中間層の活性化関数	linear 関数, tanh 関数

その後, モデルを微調整するために使用する学習データ集合 $S_{\tau_{test}}^{ft}(t_{test})$ は以下となる.

$$S_{\tau_{test}}^{ft}(t_{test}) = [r_{\tau}^{\dagger}(t') \mid t' \in \tau_{train}(t_{test}), \tau \in \tau_{test}] \quad (8)$$

このように対象タスクの時間スケールよりも短期の時間スケールのデータで事前学習を行い, その後に対象タスクの時間スケールのデータでモデルを微調整する.

なお, 学習に使用する期間は式(4), ハイパーパラメータは表 1 と同じである.

3.3 汎化性能

式(5)によるデータ拡張(以降, MTS: Multiple Time Scale)の有効性を検証するため, 2016 年 1 月～2017 年 10 月をテスト期間として汎化誤差の比較を行う. 汎化誤差の評価指標として, テスト期間の各時点での RMSE の平均値を使用する. 比較手法として, 式(6)による単一時間スケールのみで学習したモデル(以降, STS: Single Time Scale)を使用する. また, モデルの最適化も同時に実行する. 最適化する項目を表 2 に示す. 式(7)および式(8)によるファインチューニングを活用するモデル(以降, FT: Fine Tuning)は前節の通りである. つまり, MTS, STS, FT 及び各モデルの中間層を linear 関数, tanh 関数とした場合の全 6 種類のモデルで汎化誤差の比較を行う. なお本節では, 中間層の圧縮率 C は 50% とする.

図 1 に, テスト期間における各時間スケールの汎化誤差の結果を示す. 以下に, 得られた結果とその考察を示す.

- MTS 及び FT は, STS より汎化誤差が小さい. この結果から, 学習に複数時間スケールのデータを活用することが有効であることが分かる. 複数時間スケールのデータを活用することで汎化誤差が小さくなかった理由として, 元々のファクターモデルには固有の時間スケールがないため, 複数時間スケールのデータを活用することがデータ拡張に貢献できたと考えられる.
- MTS は, FT より汎化誤差が小さい. この結果から, 学習に複数時間スケールのデータを活用する場合, ファインチューニングを適用するよりも, それぞれを同時に学習した方が高精度なモデルを構築できることが分かる. ファインチューニングを活用したときに汎化誤差が大きくなかった理由として, 事前学習を行った後に対象の時間スケールでモデルを再学習した際に過学習を引き起こしたと考えられる. これは前述の通り, 本来のマルチファクターモデルには固有の時間スケールは無いが, 対象の時間スケールでファインチューニングするとデータに制限が加わってしまうためと考えられる.
- MTS 及び FT では, 中間層の活性化関数が linear 関数の方が tanh 関数より汎化誤差が小さい. STS では, $\tau_{test} \leq 14$ のとき tanh 関数の方が linear 関数より汎化誤差が小さいが,

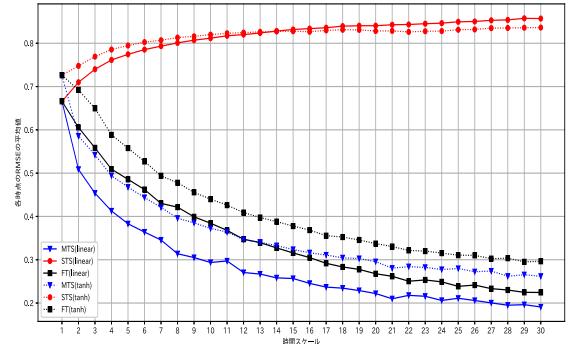


図 1: テスト期間における各時間スケールの汎化誤差. 凡例の括弧内は中間層の活性化関数を示す.

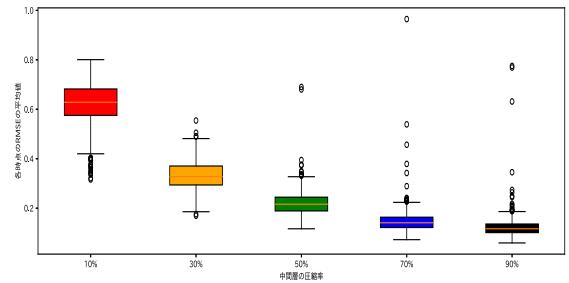


図 2: 中間層の圧縮率 C を変化させた場合の汎化誤差

$\tau_{test} \geq 15$ のとき linear 関数の方が tanh 関数より汎化誤差が小さくなっている.

MTS 及び FT は, 概ね時間スケールが大きくなるにつれて汎化誤差は小さくなる. 時間スケールが大きくなるにつれて汎化誤差が小さくなる理由として, 時間スケールが大きくなると短期の時間スケールが増加するため, それに伴い学習データも増加するためと考えられる.

以上の結果から, ファインチューニングなし, 中間層の活性化関数は linear 関数, つまり中間層の活性化関数が linear 関数の MTS が最適なモデルであると考えられる. よって, 以降の実験ではこの最適化されたモデルを使用する.

3.4 中間層の圧縮率

オートエンコーダの中間層の圧縮率 C (中間層の次元数 / 入力層の次元数 N) を変化させた場合の効果を検証する. 本節では月次スケールでの比較を行うため $\tau_{test} = 20$ とする.

図 2 に, 圧縮率 C を変化させた場合の汎化誤差の結果を示す. 結果として, 圧縮率 C が大きいほど復元しやすいため汎化誤差を小さくできている. 概ね 50% ならば汎化誤差が収束しているため, 以後の実験では圧縮率 C を 50% に固定する.

4. 運用シミュレーション

4.1 運用手法

提案手法を異常検知に活用し, ポートフォリオ運用を行う. 本研究では, 月次スケールでの運用を目的としているため $\tau_{test} = 20$ とする.

時点 t_{test} の収益率の実現値 $r_{\tau_{test}}^\dagger(t_{test})$ を学習済みオートエンコーダに投入し、復元値 $\hat{r}_{\tau_{test}}^\dagger(t_{test})$ を得る。実現値 $r_{\tau_{test}}^\dagger(t_{test})$ との乖離を

$$e_{i,\tau_{test}}(t_{test}) = r_{i,\tau_{test}}(t_{test}) - \hat{r}_{i,\tau_{test}}(t_{test}) \quad (9)$$

とし、各銘柄 i の異常度 $A_{i,\tau_{test}}(t_{test})$ を次式で評価する。

$$A_{i,\tau_{test}}(t_{test}) = \frac{e_{i,\tau_{test}}(t_{test})}{\xi_{i,\tau_{test}}(t_{test})} \quad (10)$$

ここで $\xi_{i,\tau_{test}}(t_{test})$ は、学習データ集合 $S_{\tau_{test}}(t_{test})$ における銘柄 i の復元誤差 (RMSE) である。銘柄 i 每の学習難易度に基づいて、異常度の評価基準を補正している。なお、時点 t_{test} が進むたびに学習データ集合 $S_{\tau_{test}}(t_{test})$ を更新し、オートエンコーダを再学習する。

式 (10) の異常度 $A_{i,\tau_{test}}(t_{test})$ に基づいてポートフォリオを構成する銘柄 i を選択する。過剰な群集心理によって異常が発生すると仮定すると、異常度 $A_{i,\tau_{test}}(t_{test})$ には個別事情 (ニュースなどの材料) に加えて、群集心理によるミスプライスも含まれる可能性がある。ミスプライスは市場の効率性により適正価格に修正されるならば、その修正力によるリバーサル現象が期待される [13]。そこで、各時点で異常度 $A_{i,\tau_{test}}(t_{test})$ の大きさに応じて銘柄を 5 分位にグループ化し、1Q を最小分位、5Q を最大分位とする。モデルが適切に異常を検知できているならば、1Q には割安銘柄、5Q には割高銘柄が分類される。組入比率は各分位において等ウェイトとし、20 日周期の運用シミュレーションを実行する。

4.2 銘柄選択の傾向

まず、2016 年 1 月～2017 年 10 月をテスト期間として、銘柄選択の傾向について確認する。1Q の割安銘柄をロング、5Q の割高銘柄をショートするロングショートポートフォリオを構築する場合、異常度が正負に振動すると、同じ銘柄を交互にロングとショートを交互に繰り返す可能性がある。その場合は売買サイクルが早まるため、取引コストおよびオペレーションの負荷が増大する。そこで 2 種類の方法を用いて異常度の振動を確認する。それぞれの方法の具体的な手順を以下に示す。

方法 1：自己相関

- (1) 全銘柄の異常度を全期間分計算する。
- (2) 各銘柄で異常度の自己相関を計算する。

方法 2：Jaccard 係数

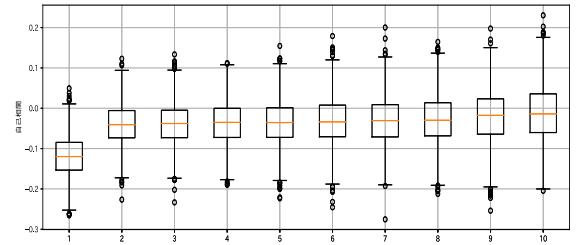
- (1) 採用銘柄 (1Q・5Q) を全期間分取得する。
- (2) 下記の採用銘柄の一致率 (Jaccard 係数) を計算する。

$$A(n) = \frac{|PF_{LS}(0) \cap PF_{LS}(n)|}{|PF_{LS}(0) \cup PF_{LS}(n)|} \quad (11)$$

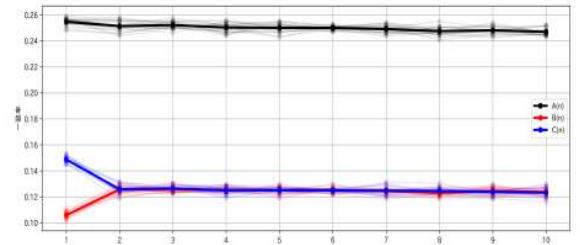
$$B(n) = \frac{|PF_L(0) \cap PF_L(n)| + |PF_S(0) \cap PF_S(n)|}{|PF_{LS}(0) \cup PF_{LS}(n)|} \quad (12)$$

$$C(n) = \frac{|PF_L(0) \cap PF_S(n)| + |PF_S(0) \cap PF_L(n)|}{|PF_{LS}(0) \cup PF_{LS}(n)|} \quad (13)$$

ここで、 $PF_{LS}(n)$ は n 時点後の 1Q または 5Q 採用銘柄集合、 $PF_L(n)$ は n 時点後の 1Q 採用銘柄集合 (ロングポートフォリオ)、 $PF_S(n)$ は n 時点後の 5Q 採用銘柄集合 (ショートポート



(a) 方法 1：自己相関



(b) 方法 2 : Jaccard 係数

図 3: 異常度の振動を確認。自己相関 (上図) は構築日が異なる 20 組の平均値を示す。Jaccard 係数 (下図) は構築日が異なる 20 組それぞれの一一致率を細線で示し、それらの平均値を太線で示す。

フォリオ) である。なお $n = 0$ の場合、異常度を算出した時点の採用銘柄集合である。

自己相関とは、各銘柄の現時点と n 時点後の異常度の相関係数である。つまり、自己相関は異常度が振動しているならば -1 に近づき、逆に異常度が一定の値を推移するならば 1 に近づく。

Jaccard 係数とは、2 つの集合に含まれている要素のうち共通要素が占める割合である。つまり、1Q と 5Q に交互に採用される銘柄が多く存在するならば $C(n)$ の値が大きくなり、1Q または 5Q のいずれか片方に採用され続ける銘柄が多く存在するならば $B(n)$ の値が大きくなる。また、1Q または 5Q のいずれかに採用され続ける銘柄が多く存在するならば $A(n)$ の値が大きくなる。本節では、運用手法の妥当性を検証するため、特に $B(n)$ と $C(n)$ の大小関係に注目する。 $B(n) < C(n)$ ならば 1Q と 5Q で交互に採用されている銘柄が多く存在すると考えられ、 $B(n) > C(n)$ ならば 1Q または 5Q のいずれかに採用され続けている銘柄が多く存在すると考えられる。

ポートフォリオの構築日が異なる独立なシミュレーションを 20 回実行し、図 3a に各銘柄の異常度の自己相関の平均値を箱ひげ図で表した結果、図 3b に Jaccard 係数をプロットした結果を示す。図 3a から、各銘柄の自己相関の中央値は $n = 1$ のとき 0 より小さく、 $n \geq 2$ のとき概ね 0 であることが分かる。図 3b から、Jaccard 係数は $n = 1$ のとき $B(n) < C(n)$ であり、 $n \geq 2$ のとき $B(n) \approx C(n)$ であることが分かる。以上の結果から、この運用手法は 1 時点後にドテンエントリーする傾向があると考えられる。

4.3 銘柄選択に制約を設ける場合

前節で 1 時点後まで異常度が振動し、ドテンエントリーする

傾向があることが分かった。そこでドテンエントリーを防ぐために運用手法に制約を設ける。制約は2種類あり、それぞれの具体的な内容を以下に示す。

制約1

- 1Qまたは5Qに採用された銘柄は1時点後では新規にエントリーしない。

制約2

- 1Qに採用された銘柄が1時点後に5Qに採用された場合、その銘柄はエントリーしない。
- 5Qに採用された銘柄が1時点後に1Qに採用された場合、その銘柄はエントリーしない。

この2種類いずれかの制約を設けることによって、ドテンエントリーを防ぐ運用を行うことができる。

4.4 運用パフォーマンス

これまでのテスト期間以降の2018年1月～2021年12月を運用期間として、2種類の運用シミュレーションを行う。1つ目は、各時点の異常度に応じて5分位のロングポートフォリオを構築し、5分位すべての獲得リターンの平均値（ベンチマーク）を控除する運用シミュレーションである。2つ目は、1Q採用銘柄をロング、5Q採用銘柄をショートするロングショートポートフォリオを構築し、運用手法に制約を設けた場合と設けない場合の運用シミュレーションである。図4に、ポートフォリオの構築日が異なる独立な運用シミュレーションを20回実行した結果を示す。図4aはアクティブリターン、図4bはスプレッドリターンを累和した時系列グラフである。

図4aから、運用パフォーマンスは分位順になっており、異常度 $A_{i,\tau_{test}}(t_{test})$ に基づく銘柄選択の妥当性を確認できる。図4bから、運用パフォーマンスは右肩上がりに推移しており、安定した運用ができていることが分かる。また、制約を設けた場合でも安定した運用ができており、売買に制限を設けることによって売買コストを抑えながら運用を行うことができると考えられる。

5. FX市場への適用

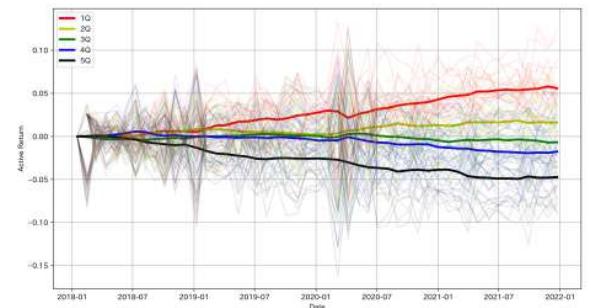
5.1 データセット

オートエンコーダはマルチファクターモデルの拡張であるため、収益率データさえあれば学習を行うことができる。そこで提案手法が株式市場だけでなくFX市場でも有効か検証を行う。分析のユニバースとして、G10加盟国通貨を使用する。具体的には、日本円、米ドル、ユーロ、ポンド、カナダドル、イスラエル・ペソ、スウェーデンクローナの全組合せ（21通貨ペア）である。期間は2010年8月～2021年12月とし、この内2016年1月～2017年10月で汎化性能を確認し、2018年1月～2021年12月で運用シミュレーションを行う。

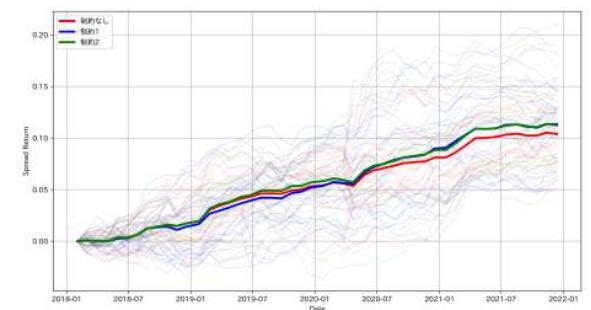
5.2 汎化性能

2016年1月～2017年10月をテスト期間として、汎化誤差の比較を行う。3.3節と同様にMTS、FT、STSを用い、各オートエンコーダの中間層をlinear関数、tanh関数とした場合の全6種類のモデルで汎化誤差の比較を行う。

図5に、各時間スケールの汎化誤差の結果を示す。結果とし



(a) 5分位のロングポートフォリオ(制約なしの場合)



(b) 1Q採用銘柄をロング、5Q採用銘柄をショートするロングショートポートフォリオ

図4: 運用パフォーマンス。構築日が異なる20組それぞれの累和リターンを細線で示し、それらの平均値を太線で示す。

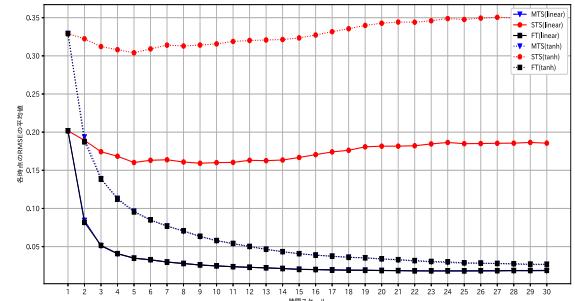


図5: テスト期間における各時間スケールの汎化誤差。凡例の括弧内は中間層の活性化関数を示す。

て、FX市場でも複数時間スケールのデータを活用することで汎化誤差を低減できている。株式市場の結果との相違点として、FTの汎化誤差がMTSと同等であることが挙げられる。これは銘柄数が減少したことによって、同時にモデルのパラメータ数も減少し、ファインチューニングを行ったときに過学習を引き起こさずに学習できたと考えられる。しかし、元々のファクターモデルには固有の時間スケールがないため、MTSの汎化誤差と同等であったと考えられる。

5.3 運用手法

FX市場でも、提案手法を異常検知に活用し、ポートフォリオ運用を行う。しかし、FX市場は株式市場と以下の3つの点

で異なるため、これらを考慮した運用手法を改めて構築する。

- ・ 株式市場より流動性が高い。
- ・ 株式市場より銘柄数（通貨ペア数）が少ない。
- ・ 各通貨ペアで基軸通貨が異なる。

1つ目の流動性の違いに関して、FX市場は株式市場を含めた他の市場より流動性が高いことが知られている。そのため、先行研究 [14] でもミスプライスに対する修正スピードが速い可能性が示唆されている。そこで株式市場を対象としたシミュレーションでは $\tau_{test} = 20$ として 20 日周期の運用を行ったが、FX市場では $\tau_{test} = 3$ として 3 日周期の運用を実行する。

2つ目の銘柄数（通貨ペア数）の違いに関して、株式市場では約 1700 銘柄で運用を行ったが、FX市場では 21 通貨ペアで運用を行う。しかし、株式市場と同様に 5 分位のポートフォリオを構築した場合、1つのポートフォリオには約 4 通貨ペアしか組み込まれないことになる。これでは充分にリスク分散ができず、ポートフォリオの獲得リターンに大きなノイズが含まれてしまう可能性がある。そこでFX市場では、分位数を 2 分位にしてポートフォリオを構築する。

3つ目の基軸通貨の違いに関して、株式市場ではすべての銘柄において同一通貨による運用を前提としているが、FX市場は基軸通貨が各通貨ペアで異なる。割高や割安の判断は基軸通貨によって符号が逆転するため、FX市場ではポートフォリオの構築方法を以下のように改める。まず、異常度 $A_{i,\tau_{test}}(t_{test})$ に絶対値を付与する。次に、絶対値を付与された異常度 $|A_{i,\tau_{test}}(t_{test})|$ の上位 11 通貨ペア（1Q）と下位 10 通貨ペア（2Q）で別々にポートフォリオを構築する。このとき、 $A_{i,\tau_{test}}(t_{test})$ の符号がマイナスの割安通貨ペアをロング、プラスの割高通貨ペアをショートする。モデルが適切に異常を検知できているならば、1Q にはミスプライスが大きい銘柄、2Q にはミスプライスが小さい銘柄が分類される。

5.4 運用シミュレーション

2018 年 1 月～2021 年 12 月をテスト期間として、前節の FX 市場に合わせた運用手法を用いて運用シミュレーションを行う。図 6 に、ポートフォリオの構築日が異なる独立な運用シミュレーションを 3 回実行した結果を示す。運用パフォーマンスは分位順になっており、異常度 $A_{i,\tau_{test}}(t_{test})$ に基づく銘柄選択及びその符号に応じた売買選択の妥当性を確認できる。

6. まとめ

複数時間スケールのデータを活用してオートエンコーダの学習を行った。複数時間スケールのデータを活用することで、单一時間スケールのみで学習する場合よりも汎化性能が向上したことを確認した。また、応用事例としてオートエンコーダを活用したポートフォリオ運用を行った。これによりミスプライスしている銘柄を特定し、適正価格への修正を利用した運用を行い、ポートフォリオ運用の妥当性を確認した。さらに、FX 市場への適用も行った。株式市場と同様に、FX 市場でも複数時間スケールのデータを活用することの有効性を確認した。また、流動性の高い FX 市場に合わせた運用手法を構築し、その妥当性を確認した。



図 6: 絶対値を付与した異常度の上位 11 通貨ペア（1Q）または下位 10 通貨ペア（2Q）で構成されたロングショートポートフォリオ。構築日が異なる 3 組それぞれの累和リターンを細線で示し、それらの平均値を太線で示す。

本稿の内容は筆者個人の見解であり、所属組織の公式見解ではありません。本研究の一部は、JSPS 科研費 (20K11969) の助成により行われました。

文 献

- [1] E. Fama: "Efficient Capital Markets: A Review of Theory and Empirical Work," *The Journal of Finance*, vol.25, no.2, pp.383–417, 1970.
- [2] S. Sugitomo and S. Minami: "Fundamental factor models using machine learning," *The Journal of Mathematical Finance*, vol.8, no.1, pp.111–118, 2018.
- [3] K. Nakagawa, T. Uchida, T. Aoshima: "Deep factor model: Explaining deep learning decisions for forecasting stock returns with layer-wise relevance propagation," *Lecture Notes in Computer Science*, vol.11054, pp.37–50, 2019.
- [4] S. Gu, B. Kelly, D. Xiu: "Autoencoder asset pricing models," *The Journal of Econometrics*, vol.222, Issue 1, Part B, pp.429–450, 2021.
- [5] R. Roll and S. Ross: "An empirical investigation of the arbitrage pricing theory," *The Journal of Finance*, vol.35, no.5, pp.1073–1103, 1980.
- [6] E.F. Fama and K.R. French: "The cross-section of expected stock returns," *The Journal of Finance*, vol.47, no.2, pp.427–465, 1992.
- [7] B. Rosenberg: "Extra-market components of covariance in security returns," *The Journal of Financial and Quantitative Analysis*, vol.9, no.2, pp.263–274, 1974.
- [8] G. Feng, S. Giglio, D. Xiu: "Taming the factor zoo: a test of new factors," *The Journal of Finance*, vol.75, no.3, pp.1327–1370, 2020.
- [9] 川田瑛貴, 田中陸, 鈴木智也: "オートエンコーダの異常検知による行動経済学的特性の抽出," 電子情報通信学会総合大会, N-2-16, 2021.
- [10] J.H. Choi and S. Suh: "Conditionally-hedge currency carry trades," *The Journal of International Financial Markets, Institutions and Money*, vol.79, 101591, 2022.
- [11] M. Obstfeld and A.M. Taylor: "Nonlinear aspects of goods-market arbitrage and adjustment: Heckscher's commodity points revisited," *The Journal of the Japanese and International Economies*, vol.11, no.4, pp.441–479, 1997.
- [12] I. Filippou, A.E. Gozluklu, M.P. Taylor: "Global political risk and currency momentum," *The Journal of Financial and Quantitative Analysis*, vol.53, no.5, pp.2227–2259, 2018.
- [13] H. Gotou and T. Suzuki: "Biased reactions to abnormal stock prices detected by autoencoder," *Journal of Signal Processing*, vol.20, no.4, pp.157–160, 2016.
- [14] 雨谷暦樹, 川田瑛貴, 田中陸, 鈴木智也: "FX 市場におけるオートエンコーダの異常検知を活用したポートフォリオ運用," 人工知能学会金融情報学研究会, SIG-FIN28-14, pp.73–77, 2021.