

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

Portfolio Management by Anomaly Detection with Autoencoder in Forex Markets

雨谷 暦樹^{1 *}
Kazuki Amagai¹

川田 瑛貴¹
Eiki Kawada¹

田中 陸²
Riku Tanaka²

鈴木 智也^{1,2}
Tomoya Suzuki^{1,2}

¹ 茨城大学大学院理工学研究科

¹ Graduate School of Ibaraki University

² 大和アセットマネジメント株式会社

² Daiwa Asset Management Co.Ltd.

Abstract: There are three main factors known to exist in the foreign exchange market: carry, value, and trend, but the effectiveness of these factors is temporally changed by global market conditions. In this research, we extract latent factors from foreign exchange rates by a data-driven approach using the autoencoder. Then, we evaluate the possibility of market mispricing by the concept of anomaly detection, considering the exchange rate restored by the autoencoder as the theoretical value expressed by the factor-risk premiums. Moreover, assuming that the misprice is immediately modified into the reasonable value, we construct a portfolio of multiple currency pairs based on the modification process of mispricing. As a result, we confirmed the possibility of obtaining the excess return (i.e., alpha) as in the stock portfolio management.

1 はじめに

様々な金融資産の価格形成過程において、ファクターという共通の潜在因子の存在を仮定して、分析やモデリングすることが伝統的である。特に株式や債券などの伝統的資産を想定したFama-French型やBARRA型のマルチファクターモデル [1, 2] が主流であるが、仮想通貨 (暗号資産) のような非伝統的資産においてもファクターの特定や存在検証が進んでおり [3], 本稿で着目する外国為替市場においても主にキャリー, バリュウ, トレンドに関する3つのファクターの存在が知られている [4, 5].

しかし有効とされるファクターは年々増加しており, ファクター動物園 [6] のように疑問視されている。おそらくファクターの多くは情報が重複しており, より本質的なファクターが内在すると思われる。更にたとえ本質的なファクターを幾つか特定できたとしても, 経済環境や景気局面によって各ファクターの有効性が動的に変化する可能性もある。そこで本研究では, オートエンコーダの中間層によりファクターをデータドリブ

ン的に抽出し, さらにオートエンコーダを逐次的に再学習することにより, ファクターの有効性の動的変化に対応する。なおオートエンコーダはニューラルネットワークを基盤とするため, ファクターの非線形性や交互作用を表現できる。

オートエンコーダの出力層では, 中間層で抽出した非線形ファクターを線形結合することで, 入力情報 (個別銘柄のリターン) を復元する。この構造は従来のマルチファクターモデルに相当し, 復元誤差を最小化することで, 復元された出力値は期待リターンに相当する。これをモデルによる理論値とみなし, 実現値と比較することで異常検知を行う [7-9]。この異常値は一般的に固有リターン (スペシフィックリターン) と呼ばれ, 共通ファクターで表現できない個別事情 (ニュースなどの材料) のみならず, 過大反応等の群衆心理によるミスプライスが含まれると考えられる。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, 固有リターンは時系列特性 (過小反応ならばモメンタム [10], 過大反応ならばリバーサル [11]) を持つ可能性がある。特にリバーサルについては specific-return-reversal strategy [12] のような運用戦略も存在する。しかし先行研究の多くは, 主に株式市場を想定している。そこで本研究は, 外国為替市場においても同様の議

*連絡先: 茨城大学理工学科機械システム工学専攻
〒316-8511 茨城県日立市中成沢町 4-12-1
E-mail: 21nm404n@vc.ibaraki.ac.jp

論が成り立つか否かを検証し、さらにオートエンコーダによるマルチファクターモデルの非線形化によって、より精緻な固有リターンの抽出を目指す。この妥当性の検証として、異常度に応じた分位ポートフォリオを構築し、適正価格への修正力を運用パフォーマンスによって評価する。もし抽出された固有リターンにミスプライスが内在するならば、運用パフォーマンスには既存のファクターリターンでは表現できない超過リターン（つまりアルファ）を確認できるだろう。なお外国為替市場は、国家の消滅や誕生がない限り通貨ペアは不変であるため、生存者バイアスや遡及バイアスによる影響はほぼ無いと考えられる。したがって逆張りになりやすいミスプライスの分析対象として都合が良い。

2 方法

2.1 オートエンコーダの活用

時点 t における通貨ペア i ($i = 1, 2, \dots, n$) のリターンを $r_i(t)$ とする。オートエンコーダの入力層（ニューロン数は n ）に、全通貨ペアのリターン

$$\mathbf{r}(t) = [r_1(t), r_2(t), \dots, r_n(t)] \quad (1)$$

を入力し，中間層で 50% に圧縮して共通ファクターを抽出する。本研究では，中間層が 1 層のオートエンコーダを基本とするが，より多層の必要性については 4 章で議論する。

中間層の活性化関数には ReLU 関数を用い、ファクターの非線形性に対応する。出力層の活性化関数には linear 関数を用い、ファクターを線形結合することで従来のマルチファクターモデルを模倣する。しかしファクターの交互作用を表現するには中間層を 2 層以上にする必要があるため、この効果についても 4 章で議論する。

出力層で $r_i(t)$ を復元するため，入力層と同じニューロン数 n を設定する．復元されたリターンを $\hat{r}_i(t)$ とし，マルチファクターモデルによる理論値とみなす．これはファクターリスクプレミアムを反映した期待リターンに相当する．

この理論値を参照しつつ、実現リターン $r_i(t)$ の異常度 $A_i(t)$ を算出する.

$$A_i(t) = \frac{e_i(t)}{E_i(t)} \quad (2)$$

$$e_i(t) = r_i(t) - \hat{r}_i(t) \quad (3)$$

ここで $E_i(t)$ は、学習期の実現値 $r_i(t)$ と理論値 $\hat{r}_i(t)$ の二乗平均平方誤差 (RMSE) である。前章で述べたように $e_i(t)$ は固有リターンに相当し、RMSE で正規化することで異常度を評価する。学習期において標準的な




図 1: ミスプライスの修正過程

固有リターンのスケールを RMSE によって銘柄毎に評価し、これを超過するほどミスプライスによって固有リターンが異常に拡大したとみなす。

オートエンコーダの実装には、TensorFlow (バージョン 2.6.0) を用いた。最適化アルゴリズムには学習率 0.001 の Adam を用い、ミニバッチサイズは 32 とした。その他のハイパーパラメータはデフォルト値を用いた。なお過学習対策として Early Stopping を用いた。オートエンコーダを毎日再学習し、理論値 $\hat{r}_i(t)$ と異常度 $A_i(t)$ を動的に推定する。

2.2 異常度によるポートフォリオ構築

先述のように、異常度 $A_i(t)$ が大きいほどミスプライスの可能性が高まるならば、適正価格への修正力によるリバーサル現象が期待される (図 1)。 $A_i(t) > 0$ であるほど割高, $A_i(t) < 0$ であるほど割安と考えられるが、本研究のように通貨ペアを対象とする場合、基準とする通貨に偏りがあるため、割高や割安の出現傾向にも偏りが生じる。そこで本研究では異常度 $A_i(t)$ に絶対値を付与し、 $|A_i(t)|$ の上位 10 通貨ペアでポートフォリオを構築する。その際に、 $A_i(t)$ の符号がマイナスの割安通貨ペアをロング (Buy)、プラスの割高通貨ペアをショート (Sell) し、毎日ポートフォリオをリバランスする。

3 分析

3.1 データセット

ポートフォリオを構成するユニバースは、G10 加盟国通貨とする。具体的には、日本円、米ドル、ユーロ、ポンド、カナダドル、スイスフラン、スウェーデンクローナ的全組合せ（21 通貨ペア）である。日足データとして、2010 年 6 月 3 日～2020 年 12 月 31 日の Bid（売値）の終値を用いる。学習期間を 1063 日（約 4 年）、検証期間を 132 日（約 6 ヶ月）とし、動的に再学習しながら 2015 年 1 月 1 日～2020 年 12 月 31 日をテスト期間とする。

3.2 マルチファクターモデル

2章で述べた提案手法の有効性を検証すべく、2種類の分析を行う。まず第一に、ベンチマークとして既存ファクターの観点からポートフォリオを構築した場合と運用パフォーマンスを比較する。その際のファクターとして、外国為替市場において一般的に知られているキャリー (carry), バリュウ (value), トレンド (trend) の3種を用いる。さらに2.2章で述べたように、売買ポジションは異常度 $A_i(t)$ に対して逆張りのになるため、単に直近の実現リターン $r_i(t)$ を逆張りするだけの短期リバーサル (reversal) をファクターとして比較対象に加える。これらの4種のファクターに基づいてポートフォリオを構築するが、その詳細については付録に示す。評価指標はそれぞれ異なるものの、選出方法や構成銘柄数は提案手法に準拠する。

第二に、提案手法が既存ファクター以外の超過リターンを獲得できているか検定する。その方法として、提案手法による獲得リターン $r_{AE}(t)$ を、上記4ファクターによる獲得リターンで回帰し、切片 α が有意に0以上であるかを t 検定する。

$$\begin{aligned} r_{AE}(t) - r_f(t) = & \alpha + \beta^{carry}(r_{carry}(t) - r_f(t)) \\ & + \beta^{value}(r_{value}(t) - r_f(t)) \\ & + \beta^{trend}(r_{trend}(t) - r_f(t)) \\ & + \beta^{reversal}(r_{reversal}(t) - r_f(t)) \\ & + \epsilon(t) \end{aligned} \quad (4)$$

ここで、 $\epsilon(t)$ は残差、 $r_f(t)$ は無リスクリターン、 $r_{carry}(t)$ はキャリーファクターによる獲得リターン、 $r_{value}(t)$ はバリュウファクターによる獲得リターン、 $r_{trend}(t)$ はトレンドファクターによる獲得リターン、 $r_{reversal}(t)$ はリバーサルファクターによる獲得リターンである。なお、 β^{carry} , β^{value} , β^{trend} , $\beta^{reversal}$ は各ファクターに関する感応度 (偏回帰係数) である。

3.3 運用パフォーマンス

図2に、提案手法とベンチマークの運用パフォーマンスを示す。縦軸の累和リターンとは、各種ポートフォリオの獲得リターン $r_*(t)$ を時系列方向に加算した総リターンを意味する。結果として、提案手法 (AE: オートエンコーダ) は各ベンチマーク (既存ファクター) よりも安定的に高い運用益を得ている。なお本研究で分析した範疇においては、トレンドとキャリーファクターによる収益性は見受けられない。

表1に、式(4)における切片 α と偏回帰係数 β を示す。まず、切片 α は有意に0より大きいので、提案手法は既存ファクターでは説明できない追加的なリターンを享受できている。トレンドとキャリーについては




図2: 提案手法とベンチマークの累和リターン

表1: 4ファクターモデルによる α と β の有意性検定 (*は1%水準で有意)

	係数	t 値
切片 α	0.0003	5.298*
キャリー β^{carry}	0.0006	0.030
トレンド β^{trend}	-0.0480	-3.350
バリュウ β^{value}	-0.2452	-12.672*
リバーサル $\beta^{reversal}$	0.1371	0.014*

提案手法と有意な関係性は見受けられない。バリュウは有意にマイナスであるため、提案手法は割安通貨をショート、割高通貨をロングする傾向にあると言える。リバーサルは有意にプラスであるため、提案手法も短期的な逆張り傾向にあると言える。

4 追加検証

4.1 ポートフォリオの通貨ペア数

前章のポートフォリオはいずれも10通貨ペアで構築したが、本節ではペア数を {1, 5, 10, 15, 21} のように変化させた時、提案手法による運用パフォーマンスがどのように変化するか検証する。

図3に、通貨ペア数を変化させた時の累和リターンを示す。通貨ペア数が少ないほど、異常度が大きい通貨ペアに厳選できるため、累和リターンは大きくなっている。しかしリスク分散の観点から、通貨ペアを増やす効果が考えられる。そこで、図4にそれぞれのシャープレシオ:

$$SR = \frac{E[r_{AE}(t)] - E[r_f(t)]}{S[r_{AE}(t)]} \quad (5)$$

を示す。ここで $E[*]$ は平均値 (期待リターン), $S[*]$ は標準偏差 (リスク) を意味する。最もシャープレシオが




図 3: ポートフォリオを構成する通貨ペア数を変えた場合の累和リターン




図 4: ポートフォリオを構成する通貨ペア数を変えた場合のシャープレシオ

高い通貨ペア数は10であり、ある程度の通貨ペアでリスク分散することにより収益を安定化できる。

4.2 時間スケール

これまで時刻 t を日足で定義していたが、本節では2日足、週足、月足のように時間スケールを拡大しつつ、同様の異常検知および運用シミュレーションを実施する。その結果を図5に示す。日足が最良の運用パフォーマンスを示している。理由として、時間スケールを拡大するほどオートエンコーダの学習に用いるデータサンプル数が減少するため、関連研究 [7] においてこの対策を検討している。さらに外国為替市場は流動性が高いため、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る。

4.3 オートエンコーダの構造

これまでオートエンコーダの中間層は1層のみであったが、中間層で抽出したファクター間の相互作用を表現するには、2層以上の中間層が必要である。そこで本節では、表2に示すオートエンコーダを構成し、そ




図 5: 時間スケールを変えた場合の累和リターン




図 6: オートエンコーダの構造を変えた場合の累和リターン

れぞれの運用パフォーマンスを比較する。なお表中のニューロン数は、左右が入力層と出力層であり、それらの間が中間層(1層~2層)である。

図6に、それぞれの運用パフォーマンスを示す。複雑なモデルによる過学習のためか、多層化しない方がパフォーマンスが良い。中間層に用いるニューロン数も少ない方が概ね良い傾向を示している。

5 まとめ

オートエンコーダを用いた異常検知により、ミスプライスが疑わしい通貨ペアを選出し、その修正力を想定した売買ポジションで外国為替ポートフォリオを構築した。運用シミュレーションの結果、従来のファクターでは説明できない追加的なリターン(アルファ)を得られることを確認した。

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。

表 2: オートエンコーダの構造

モデル名称	各層のニューロン数
AE	21-10-21
AE15	21-15-21
AE10-10	21-10-10-21
AE15-15	21-15-15-21

A Appendix

3.2 章で用いたベンチマークの詳細を示す。

キャリー（金利）によるポートフォリオを構築する場合、翌日先物レート $TF_i(t)$ と直物レート $p_i(t)$ の乖離率：

$$A_i(t) = \frac{TF_i(t) - p_i(t)}{p_i(t)} \quad (6)$$

を算出し、オートエンコーダによる提案手法と同様に $|A_i(t)|$ が大きい上位 10 通貨ペアを選出する。その際に、 $A_i(t)$ の符号がマイナス（高金利）な通貨ペア i をロング、プラス（低金利）な通貨ペア i をショートする。

トレンドによるポートフォリオを構築する場合、短期と長期の移動平均乖離率：

$$A_i(t) = \frac{SMA(50)_i(t) - SMA(200)_i(t)}{SMA(200)_i(t)} \quad (7)$$

を算出し、 $|A_i(t)|$ が大きい上位 10 通貨ペアを選出する。その際に、 $A_i(t)$ の符号がプラスな通貨ペア i をロング、マイナスな通貨ペア i をショートする。なお、 $SMA(k)_i(t)$ は過去 k 日間の単純移動平均値を表す。

バリュウによるポートフォリオを構築する場合、直物レート $p_i(t)$ と購買力平価 $ppp_i(t)$ の乖離率：

$$A_i(t) = \frac{p_i(t) - ppp_i(t)}{ppp_i(t)} \quad (8)$$

を算出し、 $|A_i(t)|$ が大きい上位 10 通貨ペアを選出する。その際に、 $A_i(t)$ の符号がマイナス（割安）な通貨ペア i をロング、プラス（割高）な通貨ペア i をショートする。なお $p_i(t)$ と同様に、 $ppp_i(t)$ も 2 通貨ペアの比率（レート）とする。各通貨の購買力平価は、経済協力開発機構 OECD (<https://www.oecd.org/sdd/prices-ppp/>) より取得した。

短期リバーサルによるポートフォリオを構築する場合、当日のリターン：

$$A_i(t) = r_i(t) \quad (9)$$

を算出し、 $|A_i(t)|$ が大きい上位 10 通貨ペアを選出する。その際に、 $A_i(t)$ の符号がマイナスな通貨ペア i をロング、プラスな通貨ペア i をショートする。

参考文献

- [1] E.F. Fama, K.R. French: “The cross-section of expected stock returns,” The Journal of Finance, vol.47, no.2, pp.427–465, 1992.
- [2] B. Rosenberg: “Extra-market components of covariance in security returns,” Journal of Financial and Quantitative Analysis, vol.9, no.2, pp.263–274, 1974.
- [3] Q. Wang, T. Chong: “Factor pricing of cryptocurrencies,” North American Journal of Economics and Finance, vol.57, 101348, 2021.
- [4] 渡辺桂士, 鶴田大: “為替ファクターリターンを活用した投資戦略,” 証券アナリストジャーナル, vol.54, no.7, pp.66–75, 2016.
- [5] J.P. Byrne, R. Sakemoto: “The conditional volatility premium on currency portfolios,” Journal of International Financial Markets, Institutions and Money, vol.74, 101415, 2021.
- [6] 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.
- [7] 川田瑛貴, 田中陸, 鈴木智也: “複数時間軸情報を用いたオートエンコーダによる行動経済学的特性の抽出,” 人工知能学会金融情報学研究会, SIG-FIN28-13, 2021.
- [8] 工藤大輝, 福西亮介, 黛広樹, 鈴木智也: “機械学習による中古車落札価格の要因分析及び割安評価,” 情報処理学会論文誌, Vol.14, No.3, pp.39-50, 2021.
- [9] Y. Tsukahara, R. Tanaka, T. Suzuki: “Nonlinear modeling for equity valuation by machine learning,” Nonlinear Theory and its Applications, IE-ICE, vol.E13-N, no.2, 2022 (in press).
- [10] D. Blitz, J. Huij, M. Martens: “Residual momentum,” Journal of Empirical Finance, vol.18, pp.506–521, 2011.
- [11] D. Blitza, J. Huij, S. Lansdorpa, M. Verbeekb: “Short-term residual reversal,” Journal of Financial Markets, vol.16, pp.477–504, 2013.
- [12] B. Rosenberg, K. Reid, R. Lanstein: “Persuasive evidence of market inefficiency,” The Journal of Portfolio Management, vol.11, no.3, pp.9–16, 1985.