

機械学習による理論株価の評価および投資家心理の抽出

塚原 悠輝[†] 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 東京都丸の内千代田区 1-9-1

E-mail: [†]{21nm461f,tomoya.suzuki.lab}@vc.ibaraki.ac.jp, ^{††}riku.tanaka@daiwa-am.co.jp

あらまし 企業財務情報に基づく伝統的な企業価値評価モデルを機械学習で拡張することでモデルの汎用性を高め、企業価値と資産価格の乖離に着眼することで集団的な投資家心理によるミスプライシングの抽出を試みた。金融市場の効率性を鑑みれば乖離が大きいほど適正価格への修正が起こるため、この修正過程を利用したポートフォリオ運用によりモデルの妥当性を検証した。その結果、リスクリターン比に優れた運用パフォーマンスが得られ、リスクプレミアム以上の収益性を統計的検定により確認した。

キーワード 企業価値, 資産価格, 機械学習, 行動経済学, ポートフォリオ運用

Evaluation of Fundamental Stock Prices without Investor Psychological Biases by Machine Learning

Yuuki TSUKAHARA[†], Riku TANAKA^{††}, and Tomoya SUZUKI^{†,††}

[†] Graduate School of Science and Engineering, Ibaraki University
Nakanarusawa 4-12-1, Hitachi, Ibaraki, 316-8511 Japan

^{††} Daiwa Asset Management Co.Ltd. 1-9-1 Marunouchi Chiyoda-ku, Tokyo, 100-6701 Japan
E-mail: [†]{21nm461f,tomoya.suzuki.lab}@vc.ibaraki.ac.jp, ^{††}riku.tanaka@daiwa-am.co.jp

Abstract The purpose of this study is to separate the true equity value and other investors psychology from the actual stock prices. We applied machine learning approach to improve traditional valuation models like DDM, RIM, and OVM and to detect nonlinear and nonstationary dynamics hidden in financial growth of each company. However, because the true equity value is completely unknown, we confirmed the validity of our approach by stock portfolio simulations based on the value and growth strategy from the viewpoint of market efficiency.

Key words Corporate valuation, asset pricing, machine learning, behavioral economics, portfolio management

1. はじめに

バリューストック効果や小型株効果など EMH (効率的市場仮説) や CAPM (資本資産価格モデル) では説明できない金融市場のアノマリーが数多く報告されており、その発生メカニズムとしてリスクプレミアム仮説とミスプライシング仮説が代表的である。前者は APT (裁定価格理論) のように各金融資産の価格変化率は共通のリスクファクターに分解でき、特にマルチファクターモデル [1] では市場要因に加えてバリューストック効果や小型株効果に関するファクターをリスクプレミアムとして追加している。そして個別企業の株価は、各リスクに対する感応度を係数とした重回帰式によって決定づけられる。

しかし現実はいずれも複雑なため、モデルの不足を埋めるかのように毎年新しいリスクファクターが次々と発表されている。ついに近年において 200 種以上に達し [2], この乱立状態はファクター動物園 (Factor Zoo) として疑問視されている [3]。そこで演繹的にモデルを構築するのではなく、機械学習によって帰納的にモデリングする事例 [4] や、機械学習を導入しつつも既存のマルチファクターモデルとの整合性を重視する事例 [5] がある。しかし先行事例の多くは資産価格を評価するモデルであり、リスクプレミアム仮説を背景にしている。

一方、ミスプライシング仮説は行動経済学によってサポートされている。金融資産の価格が本質的な価値から乖離する可能性を陽に認めており、ミスプライスは投資家

らの心理バイアスによって生じる。人間心理のモデル化は困難なため、ファンダメンタル分析では本質的価値^(注1) (Intrinsic value) をモデル化する。代表的な演繹的モデルとしてDDM (配当割引モデル) やRIM (残余利益モデル) があるが、いずれも企業財務に関する成長予想を含むため、本質的価値は一意に定まらない。そこでデータから帰納的にモデリングすることも考えられるが、目的変数となる本質的価値は観測不可能である。しかし企業や時刻の区別を問わず、パネルデータを一気に機械学習することでノイズのように心理バイアスを除去できるならば、観測可能な資産価格を目的変数とするアプローチも考え得る [6–8]。

これは古典的には、重回帰式型のOVM (オールソンモデル) [9] が存在する。しかし解釈性を重視するため、2章で述べる制約 (線形性を仮定するなど) を多数含んでいる。近年においては資産運用業務においても例外ではなく、AI技術や機械学習の活用が進んでいる [10–12]。解釈性は犠牲になるが、汎用性や表現力を強化できる点は実務において捨て難いメリットである。また新規に機械学習を導入するのではなく、伝統的モデルを基礎にすることでブラックボックス問題を緩和できる [8]。そこで本研究では、OVMを機械学習で拡張することで非線形な企業価値評価モデルを構築する。

このモデルが妥当ならば、PBR (株価純資産倍率) やV/P レシオ [13] (価値と価格の比) のように割安・割高の判断に活用できるだろう。ミスプライスが修正される方向にポートフォリオを構築し、その後の運用パフォーマンスを観測する。これは伝統的なバリューストック投資に相当するが、近年においてバリューストック効果は消滅した旨の実証分析があり [14, 15]、同種の運用スタイルの無力化が指摘されている。しかし先述のように真の企業価値は観測不可能であるため、バリューストックの特定は企業価値評価モデルに依存する。つまり運用パフォーマンスが良好であれば、本稿の企業価値評価モデルは一般的なモデルよりも妥当であることを意味する。

2. 企業価値評価モデル

株価 P_t の本質的価値を V_t とし、1株当たり配当を d_t とする。投資家が期待する収益率 (資本コスト) :

$$r = \frac{E_t[d_{t+1}] + (E_t[P_{t+1}] - P_t)}{P_t} \quad (1)$$

にて、 $P_t = V_t$ の仮定より^(注2)、DDM (配当割引モデル) :

$$V_t = \frac{E_t[d_{t+1}] + E_t[V_{t+1}]}{1+r} = \sum_{\tau=1}^{\infty} \frac{E_t[d_{t+\tau}]}{(1+r)^\tau} \quad (2)$$

が得られる。

さらに1株当たり純資産を B_t 、1株当たり純利益を x_t 、残余利益を $x_t^a = x_t - rB_{t-1}$ とする。式 (2) にクリーンサープラス関係 ($B_t = B_{t-1} + x_t - d_t$) を適用すると、RIM (残余利益モデル) :

$$V_t = B_t + \sum_{\tau=1}^{\infty} \frac{E_t[x_{t+\tau}^a]}{(1+r)^\tau} \quad (3)$$

が得られる。

上記のモデルは無限の将来にわたる予想を含むため、時間発展のダイナミクスについて何らかの仮定を必要とする。そこでオールソンは、残余利益 x_t^a の時間発展に次式のLIM (線形情報モデル) を仮定している [9]。

$$x_{t+1}^a = \omega x_t^a + \nu_t + \epsilon_{t+1}^a \quad (4)$$

$$\nu_{t+1} = \gamma \nu_t + \epsilon_{t+1}^b \quad (5)$$

式 (4) より $\nu_t = E_t[x_{t+1}^a] - \omega x_t^a$ が得られるため、これらを式 (3) のRIMに代入して整理すると、OVM (オールソンモデル) :

$$V_t = \theta_1 B_t + \theta_2 x_t + \theta_3 d_t + \theta_4 E_t[x_{t+1}] \quad (6)$$

が得られる。ここで

$$\theta_1 = (1+r)(1-\omega)(1-\gamma) / [(1+r-\omega)(1+r-\gamma)] \quad (7)$$

$$\theta_2 = -\omega\gamma(1+r) / [(1+r-\omega)(1+r-\gamma)] \quad (8)$$

$$\theta_3 = \omega\gamma r / [(1+r-\omega)(1+r-\gamma)] \quad (9)$$

$$\theta_4 = (1+r) / [(1+r-\omega)(1+r-\gamma)] \quad (10)$$

である。LIMやCAPMより ω, γ, r を推定し、上式に代入することで本質的価値の推定値 $\hat{V}_t$ を得る。もしくは観測可能な P_t の重回帰式:

$$P_t = \theta_1 B_t + \theta_2 x_t + \theta_3 d_t + \theta_4 E_t[x_{t+1}] + \epsilon_t \quad (11)$$

により偏回帰係数 θ を推定し、

$$\hat{V}_t = \hat{\theta}_1 B_t + \hat{\theta}_2 x_t + \hat{\theta}_3 d_t + \hat{\theta}_4 E_t[x_{t+1}] \quad (12)$$

によって V_t の推定値を得る。さらに $\hat{V}_t$ と P_t の乖離を調べることで、資産価格 P_t の割安・割高を判断する。

なお企業規模によるスケールの違いを調整するために、式 (11) を先月株価 P_{t-1} で除す場合 [16] や、純資産 B_t で除したPBR (Price Book-value Ratio) を目的変数とする場合 [17] もある。

$$\frac{P_t}{B_t} = \theta_1 + \theta_2 \frac{x_t}{B_t} + \theta_3 \frac{d_t}{B_t} + \theta_4 \frac{E_t[x_{t+1}]}{B_t} + \epsilon'_t \quad (13)$$

いずれの場合も、 $E_t[x_{t+1}]$ にはアナリスト予想値を用いることが想定されるが [18, 19]、日本においては四半期毎

(注1) : 世俗的に、理論株価と呼ばれることもある。

(注2) : 市場の効率性によりミスプライスは無いと仮定する。

の決算短信にて経営者自身による予想値が公開される。これは誰でも入手可能であり、アナリスト予想に劣後しない有用情報であるため [20, 21]、本研究では経営者予想値を採用する。

3. 機械学習による OVM の非線形モデル化

前章の企業評価モデルは理論的な導出のためにシンプルな仮定を置き、より複雑な現実との対応よりも演繹的に解釈できることを優先している。しかし財務データは一般的に非定常であるため、式 (4)(5) における LIM の係数推定は困難であり [22, 23]、そもそも残余利益の時間発展ダイナミクスは LIM のように線形的ではなく、非線形性を有する可能性が高い [24, 25] ^(注3)。そこで本章では現実との対応を優先し、機械学習を導入することで OVM の拡張を試みる。

しかし企業評価に用いる財務情報は年に数回しか変化しないため、機械学習に十分なデータ数を確保することが難しい。また企業評価モデルでは各係数が一定であることを仮定しているが、実際には時変する可能性があるため古いデータの利用は避けたい。そこで時系列方向のみならずクロスセクション方向も含むパネルデータによりデータ数を増やす必要がある。またサンプル数が多いほど $E[V_t] = P_t - E[e_t] \rightarrow P_t$ であるため、式 (11) における係数推定の妥当性も高まる。

しかしモデル係数 θ は、個別企業 i によって異なるだろう。特に資本コスト r は CAPM (資本資産価格モデル) によって推定される場合が多い ^(注4)。

$$r_{i,t} = r_f + \beta_{i,t}(E_t[r_{m,t+1}] - r_f) \quad (14)$$

ここで r_f は無リスク金利、 $E_t[r_{m,t+1}]$ は市場期待リターン、 $\beta_{i,t}$ は企業 i の市場ベータ ^(注5) である。つまり従来の OVM であっても、 r を伴う偏回帰係数 θ (式 (7)～式 (10)) は企業 i 毎で異なるため、クロスセクション回帰による係数推定はできない。そこで本稿では、企業 i に固有な特徴を説明変数とみなすことで、クロスセクションの機械学習により全企業共通のダイナミクス $\mathbf{F}$ を推定する。

そこで式 (13) を次式に置き換え、

$$\frac{P_{i,t}}{B_{i,t}} = \mathbf{F} \left[\frac{x_{i,q_t}}{B_{i,t}}, \frac{d_{i,y_t}}{B_{i,t}}, \frac{E_t[x_{i,q_t+1}]}{B_{i,t}}, \frac{E_t[d_{i,y_t+1}]}{B_{i,t}}, \beta_{i,t}, \sigma_{i,t}, E_t[r_{m,t+1}] \right] + \epsilon'_{i,t} \quad (15)$$

(注3)：残余利益が正であれば事業は拡大され、負であれば事業は縮小されるため、持続係数 ω は定数ではなく残余利益の関数 $f(x_t^a)$ であろう。

(注4)：市場リスク以外のリスクプレミアムを考慮する場合は、より多くのリスクファクターを含むマルチファクターモデル [1] を用いる場合もある。

(注5)：市場リスクファクターに対する感応度の意。

機械学習によって推定された $\hat{\mathbf{F}}$ を用いて、

$$\frac{\hat{V}_{i,t}}{B_{i,t}} = \hat{\mathbf{F}} \left[\frac{x_{i,q_t}}{B_{i,t}}, \frac{d_{i,y_t}}{B_{i,t}}, \frac{E_t[x_{i,q_t+1}]}{B_{i,t}}, \frac{E_t[d_{i,y_t+1}]}{B_{i,t}}, \beta_{i,t}, \sigma_{i,t}, E_t[r_{m,t+1}] \right] \quad (16)$$

を得る。ここで t は月足を意味し、 x_{i,q_t} は前四半期末の純利益 (1 株当たりの実績値)、 d_{i,y_t} は前年度末の配当 (1 株当たりの実績値)、 $E_t[x_{i,q_t+1}]$ は今四半期末の予想純利益 (1 株当たりの経営者予想値)、 $E_t[d_{i,y_t+1}]$ は今年度末の予想配当 (1 株当たりの経営者予想値) である。さらに資本コスト $r_{i,t}$ に関する変数として、市場ベータ $\beta_{i,t}$ とボラティリティ $\sigma_{i,t}$ は企業 i の直近 36 ヶ月間の月足リターンから算出し、市場期待リターンは $E_t[r_{m,t+1}]$ は TOPIX の直近 36 ヶ月間の月足リターンの平均値とする。なお決算後の財務情報が一般公開されるまで最大 2 ヶ月間のタイムラグがあり、さらに株価に織り込まれるまで時間を要するため、式 (15) の株価 $P_{i,t}$ は 3 ヶ月後の実現値を用いる。一方、 $\beta_{i,t}$ 、 $\sigma_{i,t}$ 、 $E_t[r_{m,t+1}]$ はタイムラグが無いため、 $P_{i,t}$ と同月の値とする。

機械学習には XGBoost を使い、決定木の数を 1000、学習率を 0.03、損失関数を RMSE とし、その他ハイパーパラメータはデフォルト値とする。株価 $P_{i,t}$ は毎月変動するため、直近 36 ヶ月間 (当月を含まない) を学習期間とし、毎月 $\mathbf{F}$ を再学習する。推定された $\mathbf{F}$ に 3 ヶ月前の財務情報を投入し、企業価値 $\hat{V}_{i,t}$ を推定する。

以上の方法について動作確認を行う。分析期間は 2008 年 1 月 31 日～2021 年 6 月 30 日とする。分析対象企業 i は以下の基準で選出した。

- 東証 1 部上場企業である。
- 一般事業会社 (銀行、証券、保険、その他金融業を除く) である。
- 純資産が常に正である。
- 四半期や通期の財務データが、2 期以上連続して欠損しない。

財務データが 1 期だけ欠損する場合は、直前の値で補完した。なお財務データおよび株価データは Refinitiv Eikon より取得した。

図 1 に、推定された本質的価値 $\hat{V}_{i,t}$ と資産価格 $P_{i,t}$ の相関図を示す。おおむね直線上にフィットしており、乖離部分は投資家心理によるミスプライスと考えられる。そこで乖離率 $\xi_{i,t}$

$$\xi_{i,t} = \frac{P_{i,t} - \hat{V}_{i,t}}{\hat{V}_{i,t}} \quad (17)$$

を図 2 に示す。投資家心理は 0 を中心に振動しており、定常的な中心回帰性を確認できる。ただし業種や企業自




図1 本質的価値の推定値 $\hat{V}_{i,t}$ と資産価格の実現値 $P_{i,t}$

身の流行によって、市場価格 $P_{i,t}$ が恒常的に本質的価値から乖離する可能性がある。これはダミー変数の適用により機械学習を工夫する余地があるが^(注6)、本稿では企業 i 毎に移動平均値を控除することで恒常的な乖離を補正する。

$$\begin{aligned}\xi_{i,t}^\dagger &= \xi_{i,t} - \frac{1}{M} \sum_{m=0}^M \xi_{i,t-m} \\ &= \frac{P_{i,t}}{\hat{V}_{i,t}} - \frac{1}{M} \sum_{m=0}^M \frac{P_{i,t-m}}{\hat{V}_{i,t-m}}\end{aligned}\quad (18)$$

本稿では $M = 36$ (36ヶ月間) とし、 $\xi_{i,t}^\dagger$ に基づいて割高・割安銘柄を判別する。なお PBR との類似性により、 $\xi_{i,t}^\dagger$ を PIR (Price Intrinsic-value Ratio) と名付ける。補正後の様子を図3に示す。平均値は図2とほぼ同一であるが、標準偏差のみ縮小している。つまり恒常的に割安銘柄 ($\xi_{i,t} < 0$) または割高銘柄 ($\xi_{i,t} > 0$) を補正できている。

図4に、説明変数の重要度 (Feature importance) を示す。先行研究 [18-21] と同様に、予想値 (特に予想配当 $E_t[d_{i,y_t+1}]$) の重要度が際立っている。一方、予想純利益 $E_t[x_{i,q_t+1}]$ の重要度は低いが、予想配当と情報が重複しているためと考えられる。さらに、OVM に用いる x_{i,q_t} 、 d_{i,y_t} の重要度が高く、最後に資本コストに関する $\sigma_{i,t}$ 、 $\beta_{i,t}$ 、 $E_t[r_{m,t+1}]$ が続く。

4. ポートフォリオ運用による妥当性の検証

資産価格 P は必ずしも本質的価値 V を反映しているとは限らず、一時的にミスマッチが起こる可能性がある。その際は金融市場の効率性により、本質的価値へ修正されるように資産価格が推移することが期待されるため (図2)、この修正過程を利用したポートフォリオ運用により PIR 指標 (式 (18)) の妥当性を検証する。

ポートフォリオ運用の方法は、以下の通りである。




図2 乖離率 $\xi_{i,t} = \frac{P_{i,t} - \hat{V}_{i,t}}{\hat{V}_{i,t}}$ の平均値と標準偏差




図3 補正後 $\xi_{i,t}^\dagger$ の平均値と標準偏差




図4 説明変数の重要度

- 機械学習の再学習や PIR の算出は毎月末に行う。
- PIR に応じて投資対象銘柄を5分位に分ける。
- 第1分位 (割高銘柄) をショートし、第5分位 (割安銘柄) をロングする。
- 売買割合は全て等ウェイトとする。
- 翌月末に上記を繰り返すことで毎月ポートフォリオを再構築する。

図5に、ロング (購入) のみのポートフォリオまたはショート (空売り) のみのポートフォリオによる獲得リターン $r_{p,t}$ の累計グラフを示す。ロングポートフォリオはベンチマーク (TOPIX) を超えており、バリュー (割安) 株効果を抽出したと言える。一方、ショートポートフォリオはグロース (成長) 株を売却することを許容するため、時代のトレンドに左右されやすい傾向にある。

(注6) : 今後の課題とする。




図 5 ロングポートフォリオとショートポートフォリオの累計リターン。図中の直線は毎月 0.5% の運用手数料の累計値。




図 6 分位毎のロングポートフォリオの累計アクティブリターン

図 6 に、分位毎の累計リターンを示す。分位毎にロングポートフォリオを構築し、TOPIX のリターンを控除したアクティブリターン ($r_{p,t} - r_{m,t}$) を累計している。収益力が分位順に並んでおり、PIR 指標による銘柄評価の妥当性を確認できる。

図 7 に、ロングショートポートフォリオの累計リターンを示す。なお比較のため、従来の PBR 指標によるロングショートポートフォリオも示す。さらに式 (18) と同様に、恒常的なミスプライスを補正するために $M = 36$ (36 ヶ月間) の平均値を除去した場合も示す。

$$\eta_{i,t} = \frac{P_{i,t}}{B_{i,t}} \quad (19)$$

$$\eta_{i,t}^{\dagger} = \frac{P_{i,t}}{B_{i,t}} - \frac{1}{M} \sum_{m=0}^M \frac{P_{i,t-m}}{B_{i,t-m}} \quad (20)$$

ここで $\eta_{i,t}$ が PBR 指標であり、 $\eta_{i,t}^{\dagger}$ が補正後の値である。結果として、我々の PIR 指標は PBR 指標や TOPIX よりも安定的に高いリターンを獲得しており、リスクリターン比 (mean/std) も大きく改善できている。つまり PIR 指標の想定どおり、市場のミスプライスを抽出できたと示唆される。

次に、PIR 指標で抽出されたミスプライスがリスクプレミアムでは説明できないアノミーを含むか検証すべく、各ポートフォリオによる獲得リターン $r_{p,t}$ を次式のコントロール変数を用いて回帰する。




図 7 ロングショートポートフォリオの累計リターン。最上位 (第 1 分位) 20% をショートし、最下位 (第 5 分位) 20% をロングしている。

表 1 3 ファクターモデルによる有意差検定。係数に付与した * と ** はそれぞれ $p < 0.05$ と $p < 0.001$ を意味する。

	Long		Short		Long & Short	
	係数	t 値	係数	t 値	係数	t 値
α	0.0048*	3.51	0.0037*	2.68	0.0085**	4.62
β^{Mkt}	0.0007	1.85	0.0014*	3.59	0.0020**	4.08
β^{SMB}	0.0055**	7.72	-0.0072**	-9.91	-0.0017	-1.74
β^{HML}	0.0025**	4.79	-0.0008	-1.41	0.0018*	2.49

$$r_{p,t} - r_{f,t} = \alpha + \beta^{\text{Mkt}} f_t^{\text{Mkt}-\text{RF}} + \beta^{\text{SMB}} f_t^{\text{SMB}} + \beta^{\text{HML}} f_t^{\text{HML}} + e_t \quad (21)$$

ここで $r_{f,t}$ は無リスク金利、 $f_t^{\text{Mkt}-\text{RF}}$ は市場ファクターリターンから無リスク金利を控除したもの、 f_t^{SMB} はサイズファクターリターン、 f_t^{HML} はバリューファクターリターンであり、それぞれ K.R. French のホームページ [26] より取得した。

各係数の検定結果を表 1 に示す。特にロングショートポートフォリオの α に強い有意性を確認でき、式 (21) のリスクプレミアムでは説明できないアノミーの存在を確認できる。当然ながら式 (21) 以外のリスクファクターによるプレミアムを含む可能性は残るが、投資家心理によるミスプライスを抽出できた可能性も充分に考え得る。

5. ま と め

伝統的なオールソンモデルを機械学習によって拡張し、市場価格と本質的価値の乖離を評価した。さらにポートフォリオ運用による獲得リターンが、リスクファクター以外のアルファで表現できることを確認し、この乖離が市場のミスプライスである可能性を示した。

今後の課題として、業種や特定企業に関するダミー変数の導入や、機械学習の再学習やポートフォリオのリバランス頻度 (毎月、四半期、半年、1 年) を変えて検証する。

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。本研究は JSPS 科研費 (20K11969) の助成により行われました。

文 献

- [1] E.F. Fama and K.R. French, “Common Risk Factors in the Returns on Stocks and Bonds,” *Journal of Financial Economics*, vol. 33, no. 1, pp. 3–56, 1993.
- [2] C. R. Harvey, Y. Liu, and H. Zhu, “... and the Cross-Section of Expected Returns,” *The Review of Financial Studies*, vol. 29, no. 1, 2016.
- [3] G. Feng, S. Giglio, and D. Xiu, “Taming the Factor Zoo: A Test of New Factors,” *Journal of Finance Volume*, vol. 75, no. 3, pp. 1327–1370, 2020.
- [4] S. Gu, B. Kelly and D. Xiu: “Empirical Asset Pricing via Machine Learning,” *The Review of Financial Studies*, vol. 33, no. 5, pp. 2223–2273, 2020.
- [5] S. Gu, B. Kelly and D. Xiu: “Autoencoder Asset Pricing Models,” *Journal of Econometrics*, vol. 222, no. 1, pp. 429–450, 2021.
- [6] 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.
- [7] 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.
- [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数理モデル化と応用, vol. 14, no. 3, pp. 39–50, 2021.
- [9] J.A. Ohlson, “Earning, Book Values, and Dividends in Equity Valuation: An Empirical Perspective,” *Contemporary Accounting Research*, vol. 18, no. 1, pp. 107–120, 2001.
- [10] A.M. Ozbayoglu, M.U. Gudelek, and O.B. Sezer, “Deep Learning for Financial Application: A Survey,” *Applied Soft Computing*, vol. 93, pp. 1–29, 2020.
- [11] O. Berat, S. Mehmet, U. Gudelek, and A.M. Ozbayoglu, “Financial Time Series Forecasting with Deep Learning: A Systematic Literature Review 2005–2019,” *Applied Soft Computing*, vol. 90, pp. 1–32, 2020.
- [12] O.L. Bustos and A.P. Quimbaya, “Stock Market Movement Forecast: A Systematic Literature Review,” *Expert Systems with Applications*, vol. 156, 113464, pp. 1–15, 2020.
- [13] R. Frankel and C.M.C. Lee, “Accounting Valuation, Market Expectation, and Cross-sectional Stock Returns,” *Journal of Accounting and Economics*, vol. 25, no. 3, pp. 283–319, 1998.
- [14] 田村浩道, Alex Chen, “グローバル株式市場におけるバリュファクターパフォーマンスの比較,” 証券アナリストジャーナル, vol. 59, no. 3, pp. 6–16, 2021.
- [15] 工藤秀明, 片山大輔, 高柳健太郎, “バリュ投資の再考,” 証券アナリストジャーナル, vol. 59, no. 3, pp. 17–28, 2021.
- [16] S. Brown, K. Lo, and T. Lys, “Use of R^2 in Accounting Research: Measuring Changes in Value Relevance Over the Last Four Decades,” *Journal of Accounting and Economics*, vol. 28, no. 2, pp. 83–115, 1999.
- [17] 太田浩司, 斎藤哲朗, 吉野貴晶, “Feltham-Ohlson モデルの実証研究,” 現代ファイナンス, vol. 36, pp. 3–34, 2015.
- [18] 太田浩司, “オールソンモデルによる企業評価,” 証券アナリストジャーナル, vol. 38, no. 4, pp. 62–75, 2000.
- [19] P. Dechow, A. Hutton, and R. Sloan, “An Empirical Assessment of the Residual Income Valuation Model,” *Journal of Accounting and Economics*, vol. 26, pp. 1–34, 1999.
- [20] 太田浩司, “予想利益の精度と価値関連性—1/B/E/S, 四季報, 経営者予想の比較,” 現代ファイナンス, vol. 18, pp. 141–159, 2005.
- [21] 村宮克彦, “経営者が公表する予想利益に基づく企業価値評価,” 現代ファイナンス, vol. 23, pp. 131–151, 2008.
- [22] J.N. Myers, “Implementing Residual Income Valuation with Linear Information Dynamics,” *Accounting Review*, vol. 74, no. 1, pp. 1–28, 1999.
- [23] 高橋美穂子, “会計数値と企業評価モデル—線形情報モデルを用いた企業評価に関する実証研究,” 会計, vol. 159, no. 5, pp. 797–809, 2001.
- [24] G. Biddle, P. Chen, and G. Zhang, “When Capital Follows Profitability: Non-linear Residual Income Dynamics,” *Review of Accounting Studies*, vol. 6, pp. 229–265, 2001.
- [25] 中條良美, “日本企業の非線型残余利益ダイナミクスの検証,” 現代ディスクロージャー研究, no. 4, pp. 9–20, 2003.
- [26] Kenneth R. French — Data Library, https://mba.tuck.dartmouth.edu/pages/faculty/ken.french/data_library.html (最終閲覧日: 2021 年 10 月 1 日).