

日本におけるアクティビストおよび PE ファンドの 投資先企業分類モデル構築と投資基準分析

中坪 諒真

Ryoma Nakatsubo

1. 導入

1.1. 研究の背景

近年、日本においてアクティビストおよびプライベートエクイティファンド（PE ファンド）の投資活動が急速に拡大している。アクティビストは、通常、大量の株式を保有し、企業経営陣に提案や要求を行い、株主価値の向上を通じた利益獲得を狙う。一方で、PE ファンドは企業を買収し、経営権を完全に取得した上で事業再編やコスト削減を行い、企業価値を高めるという異なるアプローチを取る。両ファンドは、潜在的価値を秘めつつ市場で過小評価されている企業に焦点を当てる傾向があるが、その投資基準には大きな違いも多いと考えられる。

1.2. 先行研究

アクティビストと PE ファンドの投資活動に関する研究は、企業価値向上への影響を明らかにする観点から広く行われてきた。アクティビスト研究の代表例として Brav et al. [1] は、アクティビストが特定の財務指標、特に ROE や EV/EBITDA を重視する傾向を示唆した。一方 PE ファンドの研究では、Phalippou and Gottschalg [2] が、PE ファンドは配当性向や売上成長率など、長期的な成長を測る指標に注目することを示している。

1.3. 研究の目的

以上の研究は、アクティビストと PE ファンドがいずれも企業価値の向上に貢献するかが主要な論点となっており、投資先企業の特徴を定量的に評価した研究は少ない。特に 2014 年以降の日本市場を対象とした研究はほぼ行われていない。本研究では RQ を「アクティビストと PE ファンドの投資先企業は、財務及び株式関連指標においてどのような特徴があるのか。」と設定し、両者の投資基準の共通点と相違点を定量的に明らかにすることを目指す。本研究の貢献は、特に投資家に対して新たな収益機会に繋がりうる実務的な示唆を提供することである。

2. 分析手法

本研究では、Kim, Benahderrahmane, and Rahwan [3] および Petersone et al. [4] の手法を参考に、アクティビストおよび PE ファンドが投資先企業を選定する基準を明らかにするため、以下に分析プロセスの概要を示す。

2.1. データ収集

日本の上場企業を対象に、財務データ（例：売上高、営業利益、ROE）や株式関連指標（例：時価総額、配当性向、浮動株比率）とアクティビストおよび PE ファンドに投資先企業リストを Bloomberg Terminal から収集した。特徴量は複数の先行研究や実務家によるレポートを参照した。

2.2. データ前処理

業種内パーセンタイル変換、KNN や Mice Forest による欠損値補完、SMOTE 等によるオーバーサンプリング、データの標準化を行い、データの不均質性やスケールのばらつきに対応した。

2.3. 機械学習モデルの構築

XGBoost、LightGBM など複数の機械学習手法を適用し、アクティビストおよび PE ファンドの投資先企業を分類するモデルを構築した。

2.4. モデルの評価と解釈

モデルの性能評価には、ROC-AUC スコアを使用した。また、SHAP (Shapley Additive Explanations) を用いて各特徴量がモデル予測に与える影響を可視化し、アクティビストと PE ファンドの投資基準の違いを明らかにした。

2.5. ケーススタディ

構築したモデルを用いて、2025 年の投資先企業を予測し、業種別の投資先分布や予測確率の高い企業の年毎の予測確率推移を分析した。

3. 結果

3.1. モデルの精度

アクティビストモデルにおいては、欠損値補完を行わずサンプリングも行わないデータを使用した XGBoost モデルの AUC-ROC 値が最高で、0.742 を記録した。これに対し、PE ファンドモデルでは、KNN を用いた欠損値補完および SMOTE サンプリングを組み合わせた XGBoost モデルが最良であり、AUC-ROC 値が 0.798 を示した。Figure 1 と Figure 2 に、正解ラベルごとの

予測確率分布を示す（赤：非投資先、青：投資先）。




Figure 1: Predicted Probability Distributions for Best Activist Model (No Complement+No Sampling+XGBoost)

3.2. SHAP による特徴量の重要度分析

両モデルとも時価総額およびその業種内比較値、流動比率、EV/EBITDA が高い影響力を持つことが確認された。これは、投資先企業の規模や財務安定性、割安性が、両ファンドにとって投資先選定の重要な基準となっていることを示唆している。一方で、アクティビストモデルでは浮動株比率や自己株式取得額が重要視される傾向があり、PE ファンドモデルでは配当性向や売上成長率といった要素が重視されることが明らかとなった (Figure 3, Figure 4)。




Figure 2: Predicted Probability Distributions for Best PE Fund Model (KNN+SMOTE+XGBoost)




Figure 3: Relationship between Features and SHAP Values on Activist Best Model (Top 5)




Figure 4: Relationship between Features and SHAP Values on PE Fund Best Model (Top 5)

3.3. ケーススタディ：2025 年の投資先企業予測

アクティビストモデルでは、機械や建設、IT 関連の業種が予測上位に挙げられ、PE ファンドモデルで同様の業種が多く予測された。両モデルの予測結果は、両ファンドが類似した業種に関心を持っていることを示している (Figure 5, Figure 6)。




Figure 5: Number of Companies Predicted by Industry based on Activist Best Model (Top 5)




Figure 6: Number of Companies Predicted by Industry based on PE Fund Best Model (Top 5)

4. 考察

両ファンドに共通する投資基準として、時価総額、流動比率、EV/EBITDA の重要性が挙げられる。これらは投資対象企業の規模、財務の安定性、割安性を示す指標であり、両ファンドが投資判断の主要基準としていることが確認された。

一方で、相違点も顕著であり、アクティビストは浮動株比率や自己株式取得額、対時価総額ネットキャッシュ比率を重視し、企業の資本政策の柔軟性や株主還元に着目する傾向が見られた。これに対して、PE ファンドは配当性向や成長率など、買収後の経営改善や再成長を見越した要素を重視する傾向が示された。

投資基準の相違は、その投資アプローチ、時間軸、リスク許容度の違いに起因するものと考えられる。アクティビストは短期から中期的な視点で株価向上を狙い、経営陣とのエンゲージメントを通じた迅速な改善を志向する。一方で PE ファンドは中長期の視点で企業全体を買収し、バリューアップを実行するため、より包括的な財務構造や成長性を考慮している。

また、投資基準の重要性が高い項目が共通していることから、アクティビストから PE ファンドへの売却ケースが増加することが示唆された。アクティビストは経営陣に短期的な改革を促し、その後 PE ファンドが企業を買収し長期的な成長戦略を遂行することは、ファンド側、企業側の双方にとってメリットが大きく、今後の連携が期待される。

5. 結論

本研究では、アクティビストと PE ファンドの投資基準を分析するために、高精度の機械学習モデルを構築し、両者の投資基準における共通点と相違点を見出した。その中で、共通する要素の方が相違する要素よりも影響が大きい可能性が示唆された。これは、両ファンドの投資行動の理解を深め、実務における投資戦略や企業価値向上の指針を提供する有用な知見であると言える。

一方で、非財務データやファンドごとの個別戦略を考

慮できていない点、データ不均衡の影響などが課題として残る。今後、これらを使用データの拡充によるモデル精度の向上や、ファンドごとに分析することでよりミクロなトレンドを抽出し、投資家の投資戦略多様化への貢献に繋げたい。

参考文献

- [1] A. Brav, W. Jiang, F. Partnoy, and R. Thomas, “Hedge fund activism, corporate governance, and firm performance,” *The Journal of Finance*, vol. 63, no. 4, pp. 1729–1775, Jul. 19, 2008.
- [2] L. Phalippou and O. Gottschalg, “The performance of private equity funds,” vol. 22, pp. 1747–1776, Apr. 1, 2009.
- [3] M. Kim, S. Benahderrahmane, and T. Rahwan, “Interpretable machine learning model for predicting activist investment targets,” *The Journal of Finance and Data Science*, vol. 10, p. 100 146, Dec. 1, 2024.
- [4] S. Petersone, A. Tan, R. Allmendinger, S. Roy, and J. Hales, “A data-driven framework for identifying investment opportunities in private equity,” Apr. 4, 2022.

著者

中坪 諒真

東京大学大学院工学系研究科技術経営戦略学専攻
田中研究室 修士 1 年

【発表日】 2025 年 7 月 27 日