

March 2026

ICE を用いた企業の株価指数と
財務指標との関係分析

Analysis of the Relationship Between Stock Price
Indices and Financial Indicators Using ICE

山口 健二

Kenji Yamaguchi

Research Institute of Economic Science

College of Economics, Nihon University

ICE を用いた企業の株価指数と財務指標との関係分析
Analysis of the Relationship Between Stock Price Indices and Financial Indicators Using
ICE

山口 健二
Kenji Yamaguchi

要旨

本研究では、日本の自動車関連企業 63 社を対象として、財務データと株価指数との関係を、Individual Conditional Expectation (ICE) を用いて分析した。目的変数として、短期株価指数、中期株価指数を用い、説明変数として売上高、利益率、棚卸資産比率、有形固定資産比率、ROA、ROE の 6 項目について、5 年間平均値および 10 年間平均値を設定し、分析にあたっては、各ケースについて予測モデルを構築したうえで、予測精度を確認するとともに、ICE により各企業における予測応答を可視化した。その結果、各ケースにおいて一定の当てはまりが確認された一方で、予測値は実測値よりもばらつきが小さく、平均的な傾向を捉える一方で、極端な変動の再現には限界があることが確認された。また、ICE により、企業ごとに予測値が大きく反応する財務指標が異なり、その応答の仕方も一様ではないことが示された。以上より、ICE は、企業財務データと株価指数との関係を企業ごとに検討するための一つの分析手法として位置づけることができる。

1. はじめに

株価は、企業の財務的健全性や成長性、収益性を反映する重要な指標の一つである。株価が上昇している企業は、市場において将来性があると評価されている可能性が高く、逆に株価が低迷している企業は、収益性や成長性、あるいは経営環境に何らかの課題を抱えている可能性がある。そのため、株価と企業の財務データとの関係を分析することは、企業の経営実態や市場からの評価を把握するうえで重要である。

企業の財務データとしては、売上高や利益率、棚卸資産比率、有形固定資産比率、ROA、ROE など、さまざまな指標が存在する。一般に、売上高が増加している企業や収益性の高い企業は市場から好意的に評価されやすく、株価が上昇する傾向があると考えられる。また、在庫管理の効率性や設備投資の状況も、企業の競争力や将来性に関わるため、株価に何らかの影響を与える可能性がある。しかし実際には、これらの財務指標と株価との関係は単純ではなく、企業規模や業種、経済環境、投資家心理など多くの要因が複雑に関係するため、単純な線形関係として捉えることは難しい。

従来、このような関係を分析するためには、重回帰分析などの統計的手法が用いられてきた。重回帰分析は、各説明変数が目的変数に与える影響を係数として示すことができるため、

解釈がしやすいという利点がある。一方で、説明変数と目的変数の関係が非線形である場合や、変数間に複雑な相互作用が存在する場合には、その構造を十分に捉えることが難しい。また、実際の企業データでは、売上高や利益率、在庫関連指標などが相互に関連していることも多く、単純な回帰モデルでは企業ごとの特性を十分に表現できない場合がある。

このような問題に対して、近年では XGBoost に代表される機械学習による回帰手法が用いられるようになってきた。XGBoost は、決定木を逐次的に組み合わせることにより、高い予測性能を実現する手法であり、説明変数と目的変数の非線形な関係や相互作用を捉えることが可能である。そのため、企業の財務データと株価変動との関係を分析するうえでも有用な手法であると考えられる。もっとも、XGBoost のような機械学習モデルは、重回帰分析と比べて内部構造が複雑であり、どの説明変数がどのように予測に関与しているかを直接把握しにくいという課題がある。

これまで筆者は、機械学習回帰と SHAP 値を用いて、企業ごとの財務特性と株価変動との関係を可視化する分析を行ってきた。SHAP 値は、各説明変数がモデル予測にどの程度寄与したかを把握するうえで有効であり、また、二次元レジリエンス指数のような派生的な分析枠組みも検討してきた。しかし、これらの手法は、主として「各変数が予測値にどの程度寄与したか」を示すものであり、「ある企業において、特定の財務指標を変化させたとき、予測値がどのように変化するか」を直接的に見るものではない。

そこで本研究では、XGBoost による回帰モデルを構築したうえで、Individual Conditional Expectation (ICE) を用いて、企業ごとの財務指標と株価指数との関係を分析する。ICE は、特定の企業について他の説明変数を固定し、ある説明変数のみを変化させたときに、モデルの予測値がどのように変化するかを可視化する手法である。この手法を用いることにより、企業ごとにどの財務指標に対して株価指数が相対的に大きく反応するのか、また、その反応の仕方がどのような形をとるのかを確認することが可能となる。

本研究の目的は、企業の株価指数と財務データとの関係を、XGBoost と ICE を用いて分析し、企業ごとの予測応答の違いを明らかにすることである。具体的には、日本の自動車関連企業を対象として、短期的な株価変動および中期的な株価変動を目的変数とし、5 年間平均および 10 年間平均の財務データを説明変数とする複数のケースを設定する。そして、各ケースにおける予測精度を確認するとともに、ICE を用いて、売上高、利益率、棚卸資産比率、有形固定資産比率、ROA、ROE といった財務指標が、企業ごとの株価予測にどのような反応をもたらすかを考察する。

本稿の構成は以下のとおりである。第 2 節では、株価と財務データの関係、ならびに機械学習を用いた分析手法に関する既存研究について整理する。第 3 節では、本研究で用いる ICE の考え方と、その特徴について説明する。第 4 節では、XGBoost と ICE による分析結果を示し、企業ごとの予測応答の違いについて考察する。最後に、第 5 節で本研究のまとめと今後の課題を述べる。

2. 既存研究

株価を規定する要因については、これまで多くの研究が行われてきた。ファイナンスや会計の分野では、企業の財務指標と株価との関係を分析する研究が蓄積されており、売上高、利益率、ROA、ROE、負債比率、配当、企業規模などが、株価や企業価値に関連する指標として取り上げられてきた[1]。とりわけ、投資家にとって ROE は企業の収益性を示す重要な指標であり、日本企業の ROE 水準を巡っても、企業価値向上との関連から議論がなされてきた[2]。このように、企業財務に関する各種指標は、株価を理解するうえで基本的かつ重要な情報であると位置づけられている。

一方で、株価は企業の財務データのみによって決まるものではなく、マクロ経済環境や市場全体の動向にも強く影響される。例えば、金利、インフレ率、鉱工業生産、為替動向など、企業外部の経済条件が株価形成に与える影響についても多くの検討がなされている。したがって、株価は企業内部の財務要因と外部環境要因の双方によって規定されるものであり、個々の企業の財務データだけでその変動を完全に説明することは難しい。

株価の予測に関する研究としては、従来から時系列分析に基づく手法が数多く用いられてきた。特に、株価や収益率の分散やボラティリティに着目した研究では、ARCH モデルをはじめとする各種の時系列モデルが開発され、金融市場の変動性を捉えるために利用されてきた[3]。これらのモデルは、時系列的な依存構造や分散の変動を表現する点で有用であるが、どの企業財務指標が株価変動と関係しているかを直接的に示すには限界がある。また、株価変動の背後にある企業ごとの財務特性を解釈するという観点からは、時系列モデルのみでは不十分な場合がある。

さらに、会計情報を用いたファンダメンタル分析では、棚卸資産や利益率などの財務変数が将来利益や企業価値の予測に有用であることが指摘されてきた。特に、棚卸資産や在庫回転率に関する情報は、企業の生産・販売活動や需給調整の状況を反映しており、将来の収益性や業績見通しと一定の関係を持つとされている。ただし、棚卸資産の増加は常に否定的に評価されるわけではなく、需要増加への備えや価格変動への対応といった積極的な要因による場合もあり、その解釈には注意が必要である。すなわち、財務データは単に数値として扱うだけでなく、その背後にある企業行動や経営環境を踏まえて理解する必要がある。

この点に関連して、サプライチェーン・マネジメントの研究では、在庫管理や需要予測、設備投資、生産体制などが企業業績に与える影響が論じられてきた[4]。グローバルな生産・販売体制を持つ企業では、在庫や固定資産の管理が業績のみならず市場評価にも影響を及ぼす可能性がある。特に、製品開発能力とサプライチェーン能力の適合や調整が企業業績に重要であることが指摘されており、在庫比率や有形固定資産比率といった財務指標も、単なる会計上の数値ではなく、企業の経営構造や競争力を示すシグナルとして捉えることができる[5]。

このように、財務指標と株価との関係は従来から研究対象とされてきたが、その関係は必

ずしも線形ではなく、また企業ごとに異なる可能性が高い。例えば、ある企業では売上高の増加が株価上昇と強く結びつく一方、別の企業では利益率や在庫関連指標の方が重要となることが考えられる。そのため、全企業に共通する単純な線形モデルのみで、企業ごとの予測構造を十分に表現することは難しい。

この問題に対して、近年では機械学習を用いた予測研究が注目されている。機械学習モデルは、多数の説明変数の間に存在する非線形な関係や複雑な相互作用を取り込むことができるため、従来の線形回帰では捉えにくかった構造を表現できる可能性がある。特に、決定木を基礎とするアンサンブル学習は、説明変数間の関係を柔軟に学習できることから、予測問題において広く用いられている。もっとも、機械学習モデルは一般に内部構造が複雑であり、予測精度が高い一方で、その予測がどのような構造に基づいているのかを解釈することが難しいという問題がある。

このような背景から、機械学習モデルの説明可能性に関する研究も進められてきた。例えば、SHAP 値は、各説明変数がモデル予測に対してどの程度寄与したかを把握するための代表的手法の一つであり、企業財務データと株価変動の関係を可視化する際にも有効である。しかし、SHAP 値は主として予測値の分解に関する情報を与えるものであり、特定の企業において、ある説明変数の値を変化させたときに予測値がどのように変動するかを直接表すものではない。

そこで、本研究では、機械学習モデルとして XGBoost を用いるとともに、その予測構造をより直感的に把握するために ICE (Individual Conditional Expectation) を用いる。ICE は、特定の企業について他の変数を固定し、ある説明変数のみを変化させた場合に予測値がどのように変動するかを可視化する手法であり、個別企業ごとの予測応答を確認することができる。この点で、財務指標と株価変動との関係を、企業ごとの非線形な応答として把握するうえで有用であると考えられる。

3. ICE について

機械学習モデルを用いて企業の株価指数を予測する場合、予測精度の高さだけでなく、どの説明変数がどのように予測値に関与しているのかを把握することが重要である。特に、本研究のように、売上高、利益率、棚卸資産比率、有形固定資産比率、ROA、ROE といった複数の財務指標を説明変数として用いる場合、単に予測値を得るだけでは、各企業においてどの財務指標に株価指数が反応しやすいのかを理解することは難しい。そのため、機械学習モデルの予測構造を可視化するための手法が必要となる。

機械学習モデルの解釈手法の一つとして、Partial Dependence Plot (PDP) がある。PDP は、ある説明変数と予測値との関係を平均的に可視化する手法である。例えば、ある企業群について、売上高成長率のみを変化させ、他の変数は観測データ全体に基づいて平均化することにより、「売上高成長率が上昇したとき、予測値が全体としてどのように変化するか」

を確認することができる。PDP は、変数と予測値との大まかな関係を把握するうえで有用であり、非線形な関係が存在する場合にも、その形状を視覚的に確認できるという利点がある。

ただし、PDP はあくまで全体平均の関係を示すものである。すなわち、企業ごとの違いを平均化してしまうため、個別企業の予測応答を把握するには限界がある。例えば、ある企業では在庫比率の上昇が株価指数の予測値を押し上げる一方、別の企業では逆に押し下げた場合があったとすると、PDP ではその差異が平均化され、全体としては変化が小さいように見えることがある。このように、個別企業の特性を重視する本研究においては、PDP だけでは十分ではない。

そこで用いられるのが、Individual Conditional Expectation (ICE) である。ICE は、PDP と同様に、ある説明変数を変化させたときの予測値の変化を可視化する手法であるが、その対象を「全体平均」ではなく「個別観測」に置いている点に特徴がある。すなわち、特定の企業について、他の説明変数とその企業の値に固定したまま、ある一つの説明変数のみを変化させ、そのときの予測値の変化を描く。これにより、個々の企業において、ある財務指標に対して株価指数がどのように反応するかを確認することができる。

具体例として、ある企業の売上高成長率だけを動かし、その他の変数、例えば利益率、棚卸資産比率、有形固定資産比率、ROA、ROE をその企業の現在の値に固定したとする。このとき、売上高成長率が 0.90 のとき予測値が 0.98、0.95 のとき予測値が 0.99、1.00 のとき予測値が 1.01 になったとすれば、当該企業では売上高成長率の上昇に伴って株価指数の予測値が上昇する傾向があると解釈できる。一方で、別の企業では、売上高成長率が 0.90 から 1.00 へ上がったとしても予測値がほとんど変わらない場合もあり、その場合には、売上高成長率は当該企業にとって相対的に重要度の低い変数である可能性がある。また、売上高成長率がある水準までは予測値が上昇するが、それ以上では逆に低下するような形を示すこともあり、このような場合には非線形な関係が存在すると考えられる。

このように、ICE では企業ごとに 1 本の曲線が得られる。横軸は対象となる説明変数の値、縦軸はそのときのモデル予測値である。曲線の傾きが大きければ、その変数に対して予測値が敏感に反応していることを意味し、逆に曲線がほぼ平坦であれば、その変数を変化させても予測値はあまり変わらないことを意味する。また、曲線が直線的でなく折れ曲がったり、ある区間で急激に上昇または低下したりしている場合には、当該変数と予測値との間に非線形な関係が存在していることが分かる。

本研究においては、各企業について各説明変数の ICE 曲線を描くとともに、その変動幅にも着目する。ここでいう変動幅とは、ある説明変数を一定の範囲で変化させたときの予測値の最大値と最小値の差である。例えば、ある企業に対して在庫比率の ICE 曲線を描いた結果、予測値の最小値が 0.96、最大値が 1.01 であった場合、その変動幅は 0.05 となる。この変動幅が大きいほど、その企業において当該説明変数が予測値に与える影響が大きいと解釈できる。逆に、変動幅が 0.01 程度であれば、その説明変数はその企業の予測に対して

あまり大きな役割を果たしていないと考えられる。

なお、ICE を用いる際には、その解釈に注意が必要である。第一に、ICE はあくまで学習済みモデルの予測応答を可視化したものであり、説明変数と目的変数の因果関係を直接示すものではない。例えば、ある企業において ROA の値を高くすると予測株価指数が上昇したとしても、それは「ROA を上げれば必ず株価が上がる」という意味ではなく、モデルが学習した関係に基づく予測上の応答を表しているに過ぎない。第二に、ICE ではある一つの説明変数のみを変化させ、他の変数を固定するため、実際の企業データでは必ずしも生じない組み合わせの入力値が含まれる可能性がある。例えば、売上高成長率のみを大きく変化させても、実際には利益率や在庫比率も同時に変化することが多いため、ICE の曲線は現実の企業行動をそのまま再現しているわけではない。したがって、ICE の結果は、予測構造の理解のための手掛かりとして用いることが適切である。

それでも、ICE は本研究の目的に対して有用である。なぜなら、本研究の関心は、企業ごとにどの財務指標に対して株価指数が相対的に大きく反応するかを把握することにあるからである。PDP のように全体平均の関係をみるだけでは、企業間の異質性が見えにくい。ICE を用いれば、個々の企業に対して、ある説明変数が予測にどの程度関与しているかを視覚的に確認することができる。すなわち、ICE は、企業ごとの予測構造の違いを把握するための手法として位置づけられる。

以上より、本研究では、XGBoost により株価指数を予測したうえで、ICE を用いて各企業における説明変数と予測値との関係を可視化する。これにより、各企業の株価指数がどの財務指標に対して比較的大きく反応するのか、企業ごとの特徴を考察する。

4. XGBoost と ICE による分析

4.1 使用するデータ

本研究で用いるデータは、日経 NEEDS Financial QUEST から取得した、日本の自動車関連企業の株価データおよび財務データである。対象企業は、日本の製造業のうち自動車関連に属する企業であり、自動車会社、自動車部品会社、自動車車体会社を含む。分析対象企業数は計 63 社である。なお、財務データの基準日の整合性を保つため、決算期が 3 月末でない企業は除外している。

本研究では、目的変数として短期的な株価変動と中期的な株価変動の 2 種類を用いる。短期的な株価変動は、2022 年 2 月の終値を 1 としたときの 2022 年 3 月の株価指数(Target1) である。中期的な株価変動は、2021 年 3 月の終値を 1 としたときの 2022 年 3 月の株価指数 (Target2) である。いずれも、1 を基準とした株価指数であり、1 を上回れば株価上昇、1 を下回れば株価下落を意味する。

説明変数としては、企業の財務データ 6 項目を用いる。具体的には、(前年比) 売上高・

営業収益 [累計]、(売上高に対する) 税金等調整前当期純利益 [累計]、(売上高に対する) 棚卸資産、(売上高に対する) 有形固定資産、使用総資本事業利益率、ROE (自己資本利益率) である。分析上の名称としては、それぞれ Net Sales、Net Income before Income Taxes and Others / Net Sales、Inventories / Net Sales、Tangible Fixed Assets / Net Sales、ROA、ROE とする。なお、売上高・営業収益については幾何平均を用いている (表 1)。

本研究では、これら 6 項目について、2018 年から 2022 年までの 5 年間平均値と、2013 年から 2022 年までの 10 年間平均値の 2 種類を用意した。したがって、目的変数 2 種類と説明変数 2 種類の組合せにより、分析ケースは 4 通りとなる。すなわち、Target1 と 5 年平均財務データを組み合わせた Case1、Target1 と 10 年平均財務データを組み合わせた Case2、Target2 と 5 年平均財務データを組み合わせた Case3、Target2 と 10 年平均財務データを組み合わせた Case4 である (表 2)。

表 1：説明変数として使用した財務データと分析上の名称

日経 NEEDS Financial QUEST 上の名称	分析上の名称【略称】
(前年比) 売上高・営業収益 [累計]	(Ave5) Net Sales 【(Ave5) NS】
(売上高に対する) 税金等調整前当期純利益 [累計]	(Ave5) Net Income before Income Taxes and Others / Net Sales 【(Ave5) NI】
(売上高に対する) 棚卸資産	(Ave5) Inventories / Net Sales 【(Ave5) IVT】
(売上高に対する) 有形固定資産	(Ave5) Tangible Fixed Assets / Net Sales 【(Ave5) TFA】
使用総資本事業利益率	(Ave5) ROA
ROE (自己資本利益率) (A)	(Ave5) ROE

(10 年間の財務データの平均値を使用した場合は、(Ave10)となる)

表 2：目的変数と説明変数の組合せ (Case1~Case4)

ケース	目的変数	目的変数の定義	説明変数
Case1	Target1(短期的株価変動)	2022 年 2 月の終値を 1 としたときの 2022 年 3 月の株価指数	2018 年から 2022 年の 5 年間の財務データ 6 項目の各平均値
Case2	Target1(短期的株価変動)	2022 年 2 月の終値を 1 としたときの 2022 年 3 月の株価指数	2013 年から 2022 年の 10 年間の財務データ 6 項目の各平均値
Case3	Target2(中期的株価変動)	2021 年 3 月の終値を 1 としたときの 2022 年 3 月の	2018 年から 2022 年の 5 年間の財務データ 6 項目の各

		株価指数	平均値
Case4	Target2(中期的 株価変動)	2021年3月の終値を1としたときの2022年3月の株価指数	2013年から2022年の10年間の財務データ6項目の各平均値

4.2. 分析方法

本研究では、Case1 から Case4 の各ケースについて、説明変数 6 項目を入力とし、Target1 または Target2 を目的変数として XGBoost による回帰モデルを構築した。XGBoost は、決定木を逐次的に組み合わせる勾配ブースティング型の機械学習アルゴリズムであり、説明変数と目的変数の間に存在する非線形な関係や、複数の変数間の相互作用を表現することが可能である。そのため、財務データと株価指数との複雑な関係を捉える手法として有効であると考えられる。各ケースに学習済みモデルを作成し、同一データに対する予測値を算出した。そして、実測値と予測値との一致度を確認するために、決定係数 (R^2)、二乗平均平方根誤差 (RMSE)、平均絶対誤差 (MAE) を算出した。これらの指標により、各ケースにおけるモデルの当てはまりの程度を比較した。なお、本研究におけるこれらの指標は、同一データ上で学習と評価を行った結果に基づくものであり、未知データに対する厳密な予測性能そのものを示すものではない。

さらに、各ケースについて、実測値、予測値、誤差の分布を確認した。これにより、モデルが平均的な傾向をどの程度捉えているか、また、予測値のばらつきが実測値に比べてどのような特徴を持つかを検討した。

そして、企業ごとの予測構造を把握するために、ICE (Individual Conditional Expectation) を用いた。ICE では、対象企業について一つの説明変数のみを一定範囲で変化させ、他の説明変数を当該企業の値に固定したまま、モデルの予測値がどのように変化するかを確認することができる。これを用いて、各企業の株価指数がどの財務指標に対して比較的大きく反応するのか、また、その反応の仕方がどのような形をとるのかを確認し、企業ごとの特徴を考察する。また、各企業・各説明変数について ICE 曲線を作成するとともに、予測値の最大値と最小値の差を求め、これを ICE 変動幅とした。ICE 変動幅が大きいほど、その企業において当該説明変数が予測値に与える影響が相対的に大きいと解釈できる。

4.3 予測精度と分布の特徴

まず、XGBoost による各ケースの予測精度を確認する。各ケースにおけるモデル評価指標 (R^2 , RMSE, MAE) を表 3 に示す。表 3 より、Case1 から Case4 のいずれにおいても、同一データ上では比較的高い決定係数が得られていることが分かる。具体的には、Case1 は約 0.97、Case2 は約 0.98、Case3 は約 0.97、Case4 は約 0.97 であり、財務指標と株価指数

との間に一定の対応関係が存在していることが示唆される。

表3：各ケースにおけるモデル評価指標 (R^2 、RMSE、MAE)

case	label	target	R^2	RMSE	MAE
case1	Case1: Target1 × Ave5	Target1	0.974641	0.011575	0.009219
case2	Case2: Target1 × Ave10	Target1	0.982601	0.009588	0.007295
case3	Case3: Target2 × Ave5	Target2	0.969154	0.034906	0.026484
case4	Case4: Target2 × Ave10	Target2	0.966101	0.036593	0.027571

また、RMSE および MAE を比較すると、Target1 を目的変数とした Case1 および Case2 では比較的小さい値を示し、Target2 を目的変数とした Case3 および Case4 ではこれより大きい値となった。このことから、短期的な株価変動を表す Target1 の方が、中期的な株価変動を表す Target2 よりも、財務指標との対応関係を捉えやすい可能性がある。また、Target1、Target2 とともに、5 年間平均の説明変数を用いたケースよりも、10 年間平均の説明変数を用いたケースの方が、わずかに高い決定係数を示した。これは、企業の中長期的な財務構造を表す指標の方が、株価指数との対応関係をより安定的に示している可能性があるためである。

次に、各ケースにおける実測値、予測値、誤差の分布をヒストグラムにより確認する (図 1~4)。これらを見ると、いずれのケースにおいても、予測値の分布は実測値の分布よりもやや狭くなる傾向が確認された。特に、Target2 を目的変数とした Case3 および Case4 では、その傾向が比較的顕著であった。

図 1 : Case1 における実測値・予測値・誤差のヒストグラム




図 2 : Case2 における実測値・予測値・誤差のヒストグラム




図 3 : Case3 における実測値・予測値・誤差のヒストグラム





図 4 : Case4 における実測値・予測値・誤差のヒストグラム



このことは、モデルが全体として平均的な傾向を捉えている一方で、実測値が大きく上昇あるいは下落した企業については、その変動を十分に再現できていないことを意味する。すなわち、予測値は実測値よりも平均方向に寄る傾向があり、モデルが極端な変動をやや抑制的に表現していると考えられる。したがって、本研究のモデルは、個別企業の株価指数を精密に予測するというよりも、全体的な傾向や企業間の相対的な違いを把握するための手法として理解する方が適切である。

4.4 企業別 ICE 応答の分析

次に、ICE を用いて企業ごとの予測応答を確認する。各ケースにおいて、ICE 変動幅の最大値が比較的大きい代表的企業を取り上げ、その 6 説明変数に対する ICE 変動幅を表 4-1 から表 4-4 に示す。これらの表より、各ケースにおいて、同一企業の中でも反応の大きい説明変数が異なることが分かる。例えば、ある企業では売上高関連の指標に対する ICE 変動幅が比較的大きい一方で、別の企業では在庫比率や利益率に対する反応が大きといった違いがみられた。このことは、株価指数の予測に対して、企業ごとに異なる財務構造が関与している可能性を示している。

表 4-1 : Case1 における代表的企業の ICE 変動幅

Company Name English	Actual Target	Predicted_At_Original	Prediction_Error	(Ave5) NS	(Ave5) NI	(Ave5) IVT	(Ave5) T FA	(Ave5) ROA	(Ave5) ROE
HINO MOTORS	0.67	0.69	-0.03	0.21	0.06	0.05	0.16	0.09	0.05
NISSAN SHATAI	0.85	0.86	-0.01	0.20	0.03	0.04	0.13	0.06	0.03
MITSUBISHI MOTORS	1.10	1.09	0.01	0.20	0.04	0.03	0.11	0.14	0.05

表 4-2 : Case2 における代表的企業の ICE 変動幅

Company Name English	Actual Target	Predicted_At_Original	Prediction_Error	(Ave10) NS	(Ave10) NI	(Ave10) IVT	(Ave10) T FA	(Ave10) ROA	(Ave10) ROE
HINO MOTORS	0.67	0.68	-0.02	0.22	0.06	0.06	0.15	0.10	0.09
SUBARU	1.03	1.02	0.01	0.21	0.04	0.05	0.03	0.04	0.05
WEDS	1.01	1.00	0.01	0.20	0.03	0.05	0.04	0.04	0.07

表 4-3 : Case3 における代表的企業の ICE 変動幅

Company Name English	Actual Target	Predicted_At_Original	Prediction_Error	(Ave5) NS	(Ave5) NI	(Ave5) IVT	(Ave5) T FA	(Ave5) ROA	(Ave5) ROE
T.RA D	1.22	1.14	0.08	0.12	0.18	0.13	0.08	0.10	0.55
TOY ODA GOSE I	0.70	0.73	-0.04	0.06	0.14	0.17	0.07	0.06	0.54
TOY OTA MOT OR	0.26	0.32	-0.06	0.10	0.16	0.32	0.07	0.25	0.54

表 4-4 : Case4 における代表的企業の ICE 変動幅

Company Name English	Actual Target	Predicted_At_Original	Prediction_Error	(Ave10) NS	(Ave10) NI	(Ave10) IVT	(Ave10) T FA	(Ave10) ROA	(Ave10) ROE
TOY OTA MOT OR	0.26	0.32	-0.06	0.15	0.62	0.16	0.08	0.09	0.08
ISUZ U MOT ORS	1.34	1.27	0.07	0.21	0.56	0.14	0.12	0.09	0.16
MAZ DA MOT OR	1.01	0.98	0.02	0.20	0.55	0.14	0.12	0.16	0.17

さらに、代表的企業の ICE 曲線については、Case1 の日野自動車および Case3 のトヨタ自動車の結果を示す。日野自動車は短期株価変動を対象とする Case1 において、トヨタ自動車は中期株価変動を対象とする Case3 において、それぞれ ICE 変動幅が比較的大きく、企業ごとの予測応答の特徴が表れている事例である。

図 5：Case1 における代表的企業の ICE 曲線（日野自動車）

ICE Analysis for HINO MOTORS (HINO)
Code: T7205 / Industry: VEHICLES / Case1: Target1 × Ave5

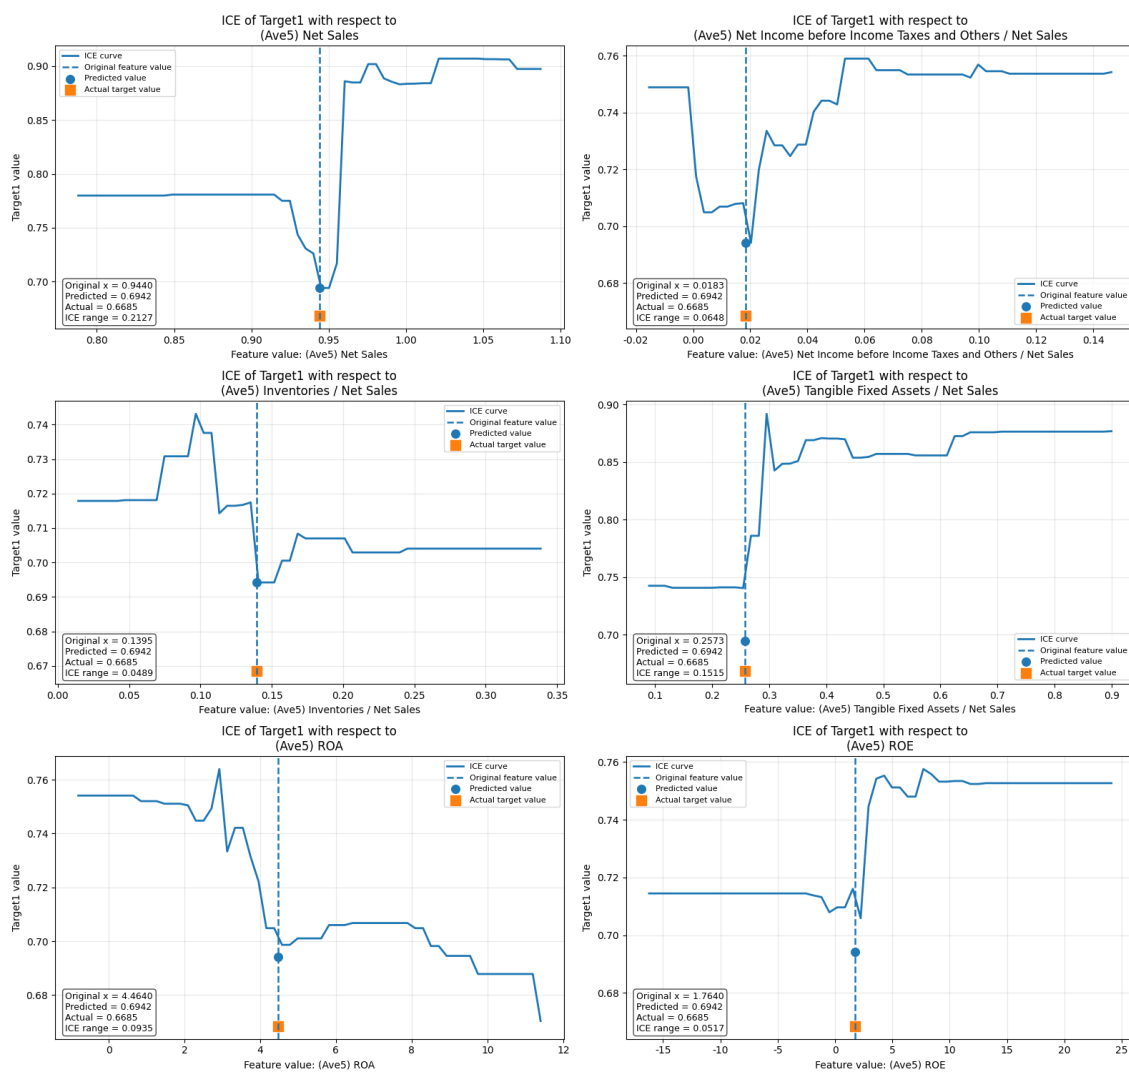


図 6：Case3 における代表的企業の ICE 曲線（トヨタ自動車）

ICE Analysis for TOYOTA MOTOR (TOYOTA)
Code: T7203 / Industry: VEHICLES / Case3: Target2 × Ave5

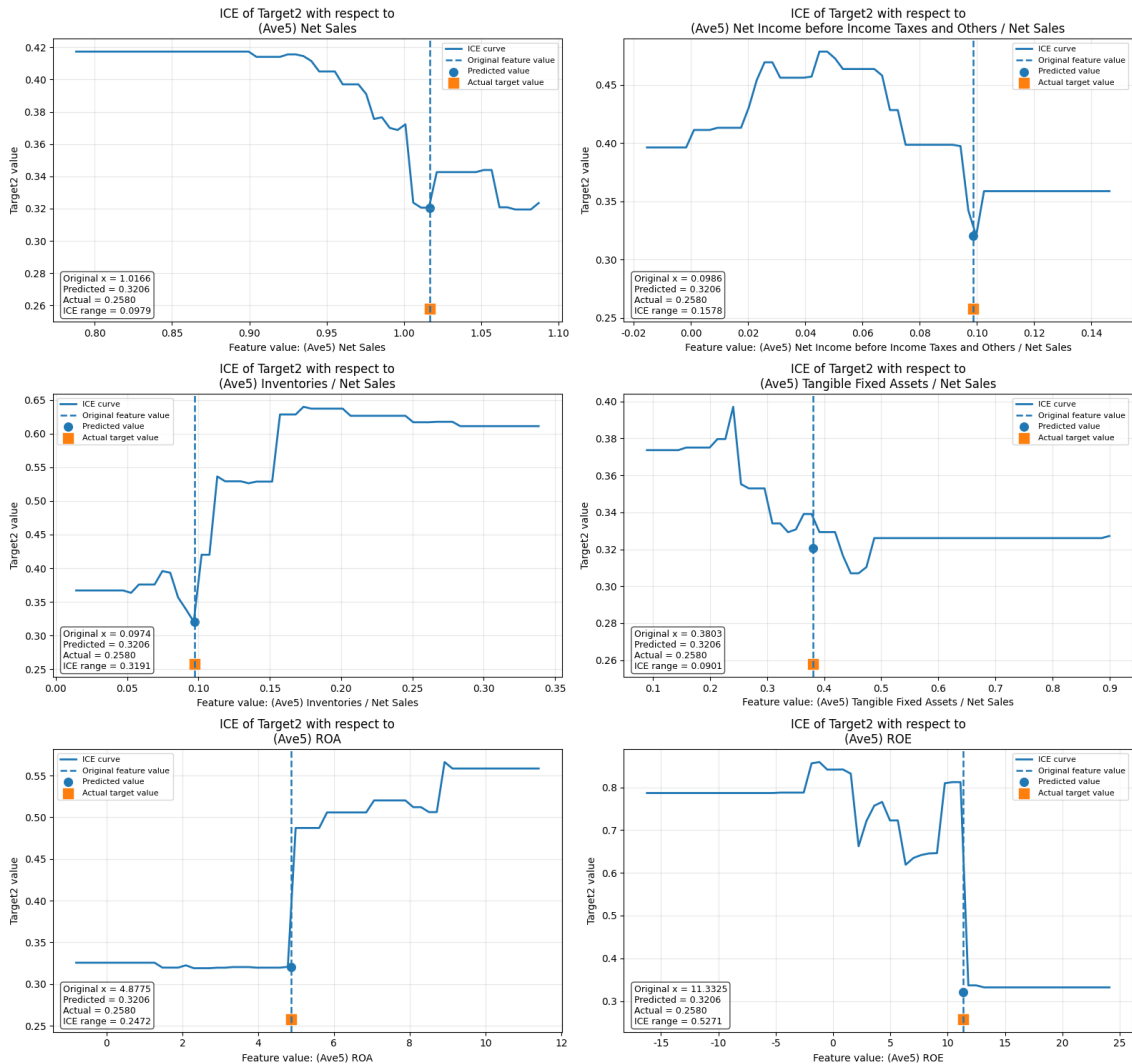


図 5、6 を見ると、いずれの企業においても、説明変数ごとに予測値の反応の大きさが異なっていることが分かる。ある説明変数では比較的大きな変動幅が見られる一方で、別の説明変数では応答が限定的である。また、曲線の形状は必ずしも単調ではなく、特定の値域で急激に変化するものや、一定範囲ではほとんど変化しないものも存在する。これは、財務指標と株価指数との関係が企業ごとに異なり、単純な線形関係としては捉えにくいことを示している。

特に、Case1 と Case3 を比較すると、短期株価変動と中期株価変動とでは、予測に強く関与する説明変数や、その応答の形状に違いがみられる。このことから、株価指数と財務データとの対応関係は、分析対象期間によっても異なる可能性がある。

4.5 考察

本研究では、63社の企業データを用いてモデルを学習し、その同じ63社について予測値を算出している。したがって、ここで確認しているのは、未知の企業に対する予測性能ではなく、学習に用いた企業群に対して、実際の株価指数と予測値とがどの程度一致しているかという意味での当てはまりである。その意味で、各ケースとも決定係数は比較的高い値を示しており、今回用いた財務指標群が株価指数の変動と一定の対応関係を持つことが示唆される。

一方で、予測値の分布が実測値よりも狭くなっていることから、今回のモデルは平均的な企業については比較的良好に予測できるが、株価指数が大きく上昇または下落している企業については、その変動を十分に再現できていないことが分かる。これは、株価が財務指標だけではなく、市場環境、為替、政策、投資家心理、個別イベントなど多様な要因によって動くためであると考えられる。

また、ICEによる分析からは、企業ごとに反応しやすい財務指標が異なることが確認された。従来の線形モデルでは全企業に共通する係数によって変数の影響を表現するが、本研究の結果は、予測構造が企業ごとに異なっていることを示している。さらに、ICE曲線の形状は必ずしも単調ではなく、説明変数の値域によって予測応答の仕方が異なることも示唆された。

5. まとめと今後の課題

本研究では、日本の自動車関連企業を対象として、企業の財務データと株価指数との関係を、XGBoostによる回帰分析とICEによって検討した。目的変数としては短期的な株価変動を表すTarget1と中期的な株価変動を表すTarget2を用い、説明変数としては売上高、利益率、棚卸資産比率、有形固定資産比率、ROA、ROEの6項目について、5年間平均値および10年間平均値を利用した。

分析の結果、各ケースにおいてXGBoost回帰モデルは同一データ上で比較的高い決定係数を示し、企業財務データと株価指数との間に一定の対応関係が存在することが確認された。一方で、予測値は実測値よりもばらつきが小さく、平均的な傾向を捉えているものの、極端な変動の再現には限界があることが分かった。また、ICEによって、企業ごとに予測値が大きく反応する財務指標が異なり、その応答の仕方も一様ではないことが示された。

今後の課題としては、第一に、学習用データと検証用データを分割したうえで、未知データに対する予測精度を確認することが挙げられる。第二に、説明変数を財務指標に限定せず、マクロ経済要因、市場全体の動向、為替、個別企業のイベントなども考慮する必要がある。第三に、分析対象企業や対象期間を拡張し、今回得られた結果の一般性を検討することも重

要である。

以上のように、本研究では、XGBoost と ICE を用いることによって、企業の財務指標と株価指数との関係を、企業ごとの予測応答として分析した。今後は、対象データや説明変数を拡張することにより、さらに検討を深める必要がある。

参考文献

- [1] 松井久勝、音川和久、『会計情報のファンダメンタル分析』、中央経済社、2013
- [2] 経済産業省、『「持続的成長への競争力とインセンティブ～企業と投資家の望ましい関係構築～」プロジェクト（伊藤レポート）最終報告書』、2014
- [3] 渡部敏明、佐々木浩、『ARCH 型モデルと Realized Volatility によるボラティリティ予測と Value-at-Risk』、日本銀行金融研究所、Discussion Paper No.2006-J-13、2006
- [4] 松井美樹、『サプライチェーン・マネジメント』、放送大学教育振興会、2021
- [5] 永島正康、『グローバル・サプライチェーンにおける新しい製販協働のかたち』、2021

Research Institute of Economic Science
College of Economics, Nihon University

1-3-2 Kandamisaki-cho, Chiyoda-ku, Toyko 101-8360 JAPAN
Phone: 03-3219-3309 Fax: 03-3219-3329
E-mail: keikaken.eco@nihon-u.ac.jp
<http://www.eco.nihon-u.ac.jp/research/economic/>