

機械学習による経営者バイアスの予測

大阪公立大学大学院
博士後期課程 (D3)
鄭 民雋 (チョン ミンジュン)

1はじめに

背景

大阪公立大学
Osaka Metropolitan University

予想利益は、投資家の期待形成に影響を及ぼす投資意思決定の基礎

ただし、予想利益にバイアスが内在する可能性

決算短信の公表

経営者バイアス

投資家が反映

過大・過少 反映

日本では損失報告が米国よりも強力な否定的シグナル(Suda and Shuto 2007)
経営者のバイアスの大きさと方向は持続的 (Ota 2006; 清水 2007)
経営者の初期予測は楽観的だが、否定的サプライズを回避するため期中に下方修正 (Kato et al. 2009)

機械学習による経営者バイアスの予測

1はじめに

背景

大阪公立大学
Osaka Metropolitan University

「予測可能な」バイアスが存在すれば、**超過リターンを得られる**

Lakonishok et al. (1994): 投資家はナイーブに悲観・楽観的な期待を抱き、それが株価の過剰な歪み

La Porta (1996): バリューストックの超過リターンはリスク要因ではなく、アナリストの過剰予測から起因

So (2013): アナリスト予想の体系的な楽観性を利用することで、超過リターンを得ることが可能

Kothari et al. (2016): アナリスト予想には体系的なバイアスが存在し、市場はこれに過小反応しており、予想情報は投資戦略およびICCの推定に重要な影響を与えると論じる。

一方、「予測可能な」バイアスなら既に市場は反映し、**超過リターンは得られない**

Hughes et al. (2008): 一貫した予想バイアスの存在を実証しつつも、市場はその誤差を既に織り込んでおり、予測誤差に基づく投資では超過収益を得られないと主張

Zhang et al. (2024): 機械学習によってアナリスト予想のバイアスを予測しポートフォリオを構築しても、有意なアルファは得られないことを提示

機械学習による経営者バイアスの予測

2リサーチデザイン

リサーチデザインの概要

大阪公立大学
Osaka Metropolitan University

予測モデルの構築

1機械学習モデル

2出力変数定義

3入力変数定義

4モデル訓練

実証分析

バイアスの予測

予測可能性と予測精度

MAE, MDAE, MSE

バイアスの分布

経済的有用性

市場調整済み異常リターン

回帰分析

ロング・ショート ポートフォリオ

解釈可能性

PFIとSHAPを活用した変数の重要度

線形近似

機械学習による経営者バイアスの予測

3分析結果

図表 2 バイアスの基本統計と予測精度

大阪公立大学
Osaka Metropolitan University

Panel A: 基本統計量

	N	Mean	SD	Min	P25	Median	P75	Max
$F_bias_{ind_XGB}$	13,867	0.132	2.399	-10.016	-0.663	-0.035	0.694	21.428
$F_bias_{d_XGB}$	13,867	-0.019	1.523	-6.391	-0.628	-0.081	0.505	9.045
$F_bias_{ind_RF}$	13,867	0.301	6.560	-22.371	-1.690	0.028	1.247	55.503
$F_bias_{d_RF}$	13,867	3.470	6.364	-3.207	0.258	1.045	3.769	58.346
MF_bias	13,867	0.005	7.162	-30.495	-2.171	-0.392	1.202	64.695

Panel B: 予測精度

	N	MAE	MDAE	MSE
$F_bias_{ind_XGB}$	13,867	4.129	1.874	0.628
$F_bias_{d_XGB}$	13,867	3.939	1.818	0.568
$F_bias_{ind_RF}$	13,867	5.423	2.417	1.099
$F_bias_{d_RF}$	13,867	6.206	2.960	1.193
MF_bias	13,867	10.314	8.176	1.810

(注) 予測精度のMAE, MDAE, MSEは、100を乗じてパーセンテージで表記としている。

機械学習による経営者バイアスの予測

3分析結果

図表 5 回帰分析

大阪公立大学
Osaka Metropolitan University

図表 5 回帰分析

	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6	Model 7
$F_bias_{i,t}$	-4.540*** (-27.513)	-6.394*** (-32.915)	-5.001*** (-27.609)	-3.414*** (-17.943)	-1.944*** (-10.564)	-1.821*** (-7.703)	-1.821*** (-7.703)
$bias_{i,t}$						-0.284*** (-7.575)	-0.055 (-1.141)
$size_{i,t}$			-0.301*** (-31.194)	-0.355*** (-36.576)	-0.261*** (-27.484)	-0.265*** (-27.523)	-0.264*** (-27.498)
$B/P_{i,t}$			0.070*** (7.654)	0.061*** (6.781)	0.032*** (3.736)	0.034*** (3.926)	0.030*** (3.537)
$O/B_{i,t}$				0.660*** (17.461)	0.183*** (4.824)	0.170*** (4.262)	0.165*** (4.157)
$A_G_{i,t}$				0.343*** (12.818)	0.287*** (11.319)	0.278*** (10.836)	0.276*** (10.793)
$MF/P_{i,t}$					2.686*** (37.661)	2.750*** (38.587)	2.667*** (37.097)
Year	X	O	O	O	O	O	O
Firm	X	O	O	O	O	O	O
N	13,867	13,867	13,867	13,867	13,867	13,867	13,867
R ²	0.052	0.084	0.236	0.271	0.349	0.344	0.347
Adj R ²	0.052	-0.073	0.105	0.146	0.237	0.230	0.234

(注) ***, **, * はそれぞれ1%, 5%, 10%水準で統計的に有意であることを示している。

機械学習による経営者バイアスの予測

3分析結果

図表 7 MF/Pを調整した予測バイアスに基づくポートフォリオ

大阪公立大学
Osaka Metropolitan University

図表 7 MF/Pを調整した予測バイアスに基づくポートフォリオ

	Low_F_bias	Q2	Q3	Q4	High_F_bias	All	Low_F_bias - High_F_bias
Small_MF/P	-2.08 (200)	-2.26 (344)	-5.22 (595)	-12.16 (691)	-10.85 (947)	-8.27 (2,777)	8.77*** [4.66]
Q2	3.29 (256)	3.99 (526)	0.27 (744)	-7.03 (750)	-10.77 (499)	-2.70 (2,775)	14.06*** [7.38]
Q3	6.76 (409)	5.80 (669)	1.71 (646)	-3.17 (578)	-9.35 (473)	0.54 (2,775)	16.11*** [6.81]
Q4	12.14 (635)	12.28 (740)	6.65 (510)	-1.47 (459)	-3.99 (428)	6.42 (2,772)	16.13*** [10.74]
Large_MF/P	27.65 (1277)	16.29 (496)	12.83 (279)	7.66 (294)	9.17 (422)	19.20 (2,768)	18.48*** [7.45]
ALL	16.60 (2,777)	8.06 (2,775)	1.87 (2,774)	-5.03 (2,772)	-6.47 (2,769)	3.02 (13,867)	
Small_MF/P - Large_MF/P	29.73*** [9.44]	18.55*** [5.53]	18.05*** [5.14]	19.82*** [5.00]	20.02*** [9.37]		

(注) 12ヶ月間の市場調整済み異常リターンは100倍し、パーセンテージで表記している。Pは前年度の6月末の時価総額である。ヘッジリターンは年度別にFama-MacBeth回帰を用いて有意性と括弧内に t値を算出している。その他の括弧内の値はグループ別の観測値である。***, **, * はそれぞれ1%, 5%, 10%水準で統計的に有意であることを示している。

機械学習による経営者バイアスの予測

3分析結果

図表 8

大阪公立大学
Osaka Metropolitan University

Panel A: Variable Importance

feature	PFI mean	std	feature	SHAP mean	std
MFS	0.150	0.015	MFS	1313.198	0.015
MFS_dif	0.029	0.013	MF_dif	281.283	0.013
MF_dif	0.027	0.006	MFS_dif	190.541	0.006
XRD	0.023	0.021	E	96.791	0.021
E	0.018	0.008	IVA_dif	58.775	0.008
MFAE	0.011	0.008	RE_dif	54.310	0.008
RE_dif	0.011	0.005	XINT_dif	50.830	0.005
SALE_dif	0.011	0.003	bias_lag	49.814	0.003
COGS_dif	0.010	0.004	XRD	49.603	0.004
bias_lag	0.009	0.006	INVT_dif	48.627	0.006

Panel B: Group Importance

Group	N	mean PFI	sum PFI	mean SHAP	sum SHAP
MF	12	0.021	0.255	167.876	2014.516
PL	45	0.005	0.223	17.647	794.108
BS	48	0.004	0.193	15.293	734.050
CF	12	0.003	0.037	11.691	140.291

(注) Panel Aは各年度の重要度を平均・標準偏差で集計したものである。Panel Bは各グループ内の変数の平均および合計の重要度を示したものである。

機械学習による経営者バイアスの予測

3分析結果

図表 9 決定係数

大阪公立大学
Osaka Metropolitan University

図表 9 決定係数

Yearly Adjusted R²: Linear, LASSO, LASSO Interaction

YEAR	linear 1	linear 7	Lasso 116	Lasso 116 + I
2013	0.122	0.442	0.754	0.765
2014	0.001	0.477	0.735	0.738
2015	0.001	0.622	0.791	0.830
2016	0.020	0.646	0.881	0.929
2017	0.000	0.555	0.622	0.625
2018	0.001	0.613	0.691	0.840
2019	0.063	0.607	0.681	0.708
2020	0.074	0.572	0.885	0.951
2021	0.196	0.748	0.879	0.911

Mean R²

Variables	1	7	116	6,786
Mean R ²	0.053	0.587	0.769	0.811

機械学習による経営者バイアスの予測

4おわりに

主な発見

大阪公立大学
Osaka Metropolitan University

バイアスの予測可能性

機械学習による予測バイアスは、バイアスの持続性に基づく当期バイアスを用いた予測よりも高い精度を示した。

企業規模や過去のバイアスなどに応じて、機械学習の予測がバイアスのパターンをある程度に捉えており、一貫性のある傾向が確認された。

経済的有用性

予測バイアスは市場調整済み異常リターンと有意な負の関係を示し、リスク要因を統制しても説明力が維持された。

予測バイアスに基づくロング・ショート戦略は、年次別や3ヶ月単位でも安定して超過リターンを生み、MF/Pを調整してもその傾向が持続した。

解釈可能性

バイアス予測に最も大きな影響を与えるのは経営者予想に関する変数グループ

機械学習によるバイアス予測は、説明変数の線形結合によって相当程度を説明可能

機械学習による経営者バイアスの予測