

# 機械学習を資産価格モデルへ用いることの有効性と危険性について

東京都立大学  
経営学研究科経営学専攻  
ファイナンスプログラム  
峯大喜

# Summary

- ✓ 株価リターンの予測において、機械学習が線形モデルよりも有効であるか否かを網羅的に検証した
- ✓ 平均的には線形モデルと機械学習の予測精度は変わらないことが分かった
- ✓ 一方、極端に高いパフォーマンスの出現割合を検証したところ、機械学習においてはその出現頻度が高く、偶然やサンプルのバラツキでは説明できないことが分かった

# Previous Research for Developed Equity Market

- ✓ Gu et al. (2020) は、パネルデータを用いて様々な機械学習手法の株式リターン予測力を検証した結果、非線形なモデルの予測力が高いことを報告
- ✓ Moritz and Zimmermann (2016)
- ✓ Heaton et al. (2016)


# Previous Research for Japanese Equity Market

- ✓ 内藤・西内 (2020)
- ✓ 清水・内山 (2020)では、機械学習を用いることで、伝統的な株価リターン予測を上回ることができるのかについて検証したが、機械学習による有意なパフォーマンスの向上は観測されなかったと報告

# Assumptions


$$r_{i,t+1} = E_t(r_{i,t+1}) + \epsilon_{i,t+1} \quad (1)$$

$$E_t(r_{i,t+1}) = g^*(z_{i,t}) \quad (2)$$




# Problem : Unconscious multiple comparisons(1)


✓分析に用いる説明変数の採用方法は統一的な手法が定まっておらず、分析者の判断に委ねられている



Try1




Try2

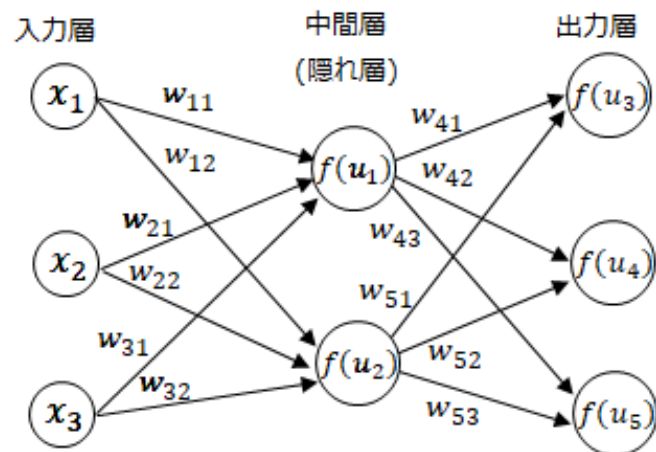


# Problem : Unconscious multiple comparisons(2)

✓  $g^*(\cdot)$  のチューニング方法についても統一的な手法が確立されておらず、複数の方法があるため、前頁と同様のことがいえる。

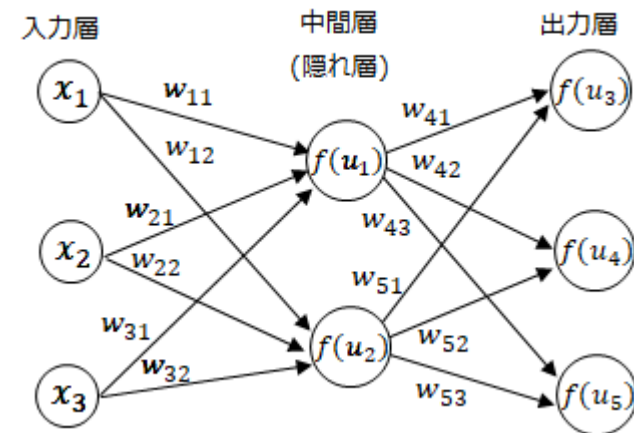


Try1



$$f(u_1) = \frac{1}{1 + e^{-u_1}}$$

Try2



$$f(u_1) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases}$$

# Data and Methodology

- ✓ 個別株式のクロスセクションのリターン予測問題で比較。ユニバーズはTOPIX500（除く金融）、123個の企業特性を用いる
- ✓ 2002年1月～2014年12月をインサンプル(モデルを推定するための期間)とし、2015年1月～2022年6月のデータをアウトオブサンプルとする
- ✓ 毎月、各モデルの出力で5分位ポートフォリオを構築し、第5分位をロング、第1分位をショートするポートフォリオのリターンをモデルのパフォーマンスとする



# Setting

- ✓ Yan and Zheng (2017)などを参考に、 **I ~ III**の手順を実施する
- I.** 123の変数からランダムにn個の説明変数を選択
- II.** **I**で得られた変数を説明変数、対応する月次リターンを被説明変数として、モデルをそれぞれ推定する。機械学習モデルにはニューラルネットワーク と LightGBM 、 Lasso を使用。
- III.** アウトオブサンプル期間のデータで、各モデルについて、翌月リターンの予測値の高低にもとづいてロング・ショートポートフォリオを構築し、そのリターンを計算する
- ✓ **I ~ III**を1000回繰り返すことで、1000個の比較サンプルをモデル毎に生成する。

# Evaluation

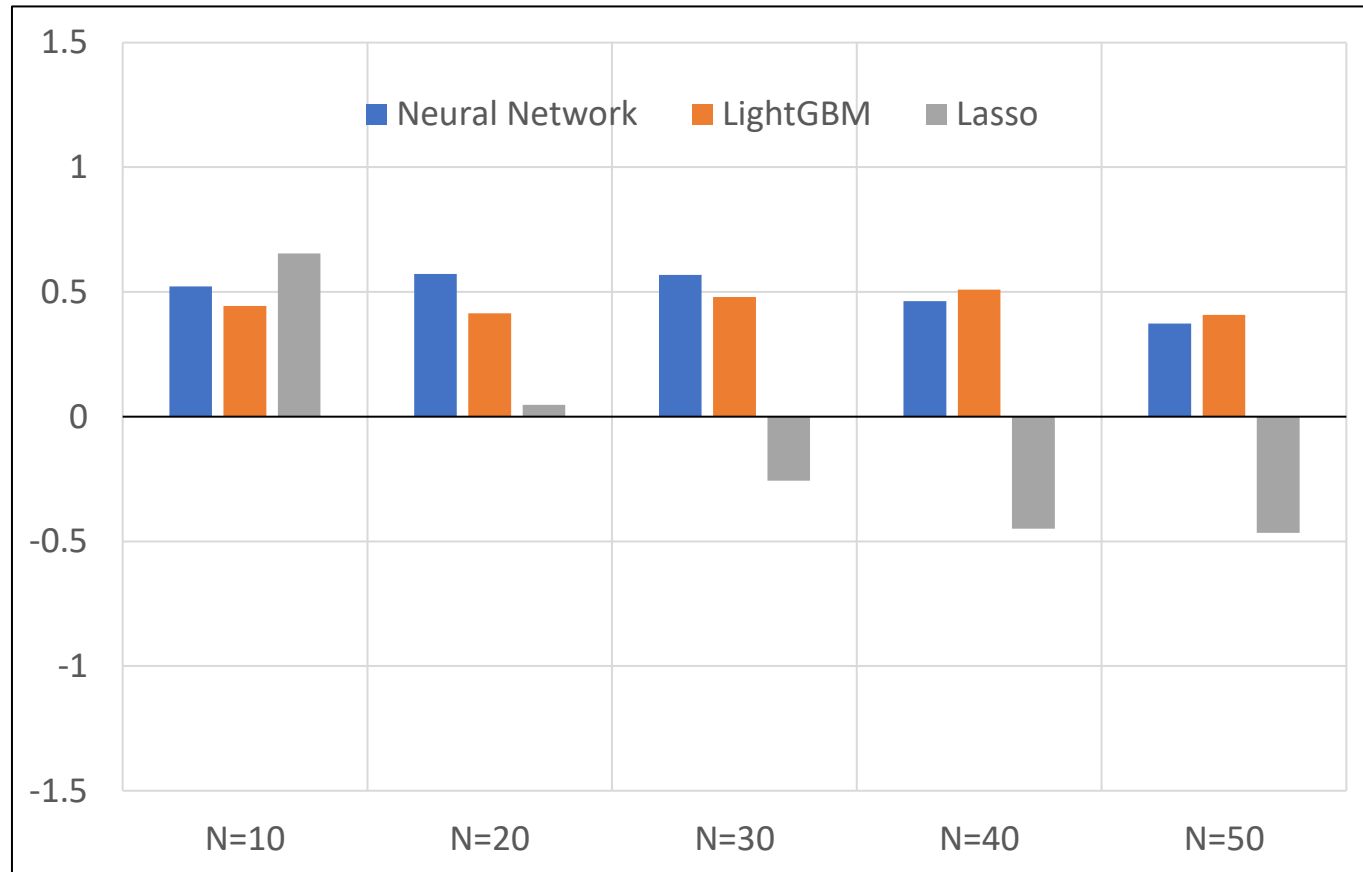
✓シミュレーションで得た90000個(=90カ月×1000回)の機械学習モデルのリターンと線形モデルのリターンの差(以下、 $LS_{j,t}^M - LS_{j,t}^{LM} = D_{j,t}^M$ )を検定

$$D_{j,t}^M = \alpha_j^M + \epsilon_{j,t}^M \quad (3)$$

$$D_{j,t}^M = \alpha_j^M + \beta_{mkt,j}^M R_{Mt} + \beta_{SMB,j}^M SMB_t + \beta_{HML,j} HML_t + \epsilon_{j,t}^M \quad (4)$$

# Empirical Results


✓リターン格差 $D_{j,t}^M$ について、リスク調整済みリターンの $t$ 値を算出した




# Focus on the tail of the distribution

- ✓ 仮に真の期待リターン  $E_t(r_{i,t+1})$  が企業特性  $z_{i,t}$  の非線形関数であるならば、適切な  $z_{i,t}$  を用いてモデリングした場合、高い  $\alpha$  を生み出す可能性がある。
- ✓ Kosowski et al. (2006) や Fama and French (2010)、Yan and Zheng (2017) の方法にしたがって、クロスセクショナルブートストラップ法を用いて、高い  $\alpha$  の出現頻度について分析する

真の  $\alpha$  が 0 であるというセッティングでサンプリングした分布



実際のロング・ショートのリターンから算出した分布



# Cross Sectional Bootstrap

✓ ロング・ショートポートフォリオのリターンの時系列から、真の $\alpha$ が0であるというセッティングもとで疑似分布を発生させ、実際のデータの分布と比較する

$$LS_{j,t}^M = \alpha_j^M + \beta_{mkt,j}^M R_{Mt} + \beta_{SMB,j}^M SMB_t + \beta_{HML,j}^M HML_t + \epsilon_{j,t}^M \quad (5)$$

$$LS_{j,t}^{M,b} := \beta_{mkt,j}^M R_{Mt} + \beta_{SMB,j}^M SMB_t + \beta_{HML,j}^M HML_t + \epsilon_{j,t}^{M,b} \quad (6)$$

# Results(1)

## $\alpha$ の検定(線形モデル)

LM_10			LM_20			LM_30			LM_40			LM_50		
Percentiles	Actual	p-value	Percentiles	Actual	p-value	Percentiles	Actual	p-value	Percentiles	Actual	p-value	Percentiles	Actual	p-value
100	3.26	0.10	100	2.98	0.23	100	3.03	0.21	100	2.96	0.19	100	3.12	0.10
99	2.33	1.19	99	2.32	1.28	99	2.17	1.84	99	2.32	1.12	99	2.26	1.12
98	2.07	2.15	98	1.88	3.39	98	1.83	3.81	98	1.94	2.74	98	2.02	2.00 *
97	1.82	3.77	97	1.68	5.09	97	1.71	4.86	97	1.74	4.23	97	1.81	3.18
96	1.66	5.13	96	1.60	5.86	96	1.58	6.24	96	1.63	5.24	96	1.68	4.20
95	1.52	6.71	95	1.49	7.24	95	1.46	7.76	95	1.52	6.49	95	1.56	5.37
90	1.10	13.72	90	1.02	16.00	90	1.09	14.29	90	1.12	13.13	90	1.22	10.19
10	-1.50	6.81	10	-1.31	9.18	10	-1.24	11.46 *	10	-1.22	11.25 *	10	-1.07	14.93 *
9	-1.58	5.79	9	-1.39	7.82	9	-1.27	10.85 *	9	-1.27	10.20 *	9	-1.12	13.87 *
8	-1.64	5.18	8	-1.45	7.02	8	-1.36	9.38 *	8	-1.35	8.85 *	8	-1.18	12.52 *
7	-1.70	4.59	7	-1.53	5.96	7	-1.41	8.64 *	7	-1.41	8.01 *	7	-1.25	11.12 *
6	-1.77	3.97	6	-1.58	5.46	6	-1.45	7.97 *	6	-1.47	7.10 *	6	-1.31	10.08 *
5	-1.88	3.12	5	-1.62	4.96	5	-1.59	6.18 *	5	-1.55	6.04 *	5	-1.38	8.79 *
0	-3.74	0.01 *	0	-3.20	0.08 *	0	-3.62	0.02 *	0	-2.90	0.22 *	0	-2.78	0.35 *

PercentilesとActualはそれぞれ実際の $t(\alpha_j^M)$ の分布におけるパーセンタイルとそれに対応する $t(\alpha_j^M)$ の値を示し、 $p$ 値は疑似分布において各 $t(\alpha_j^M)$ を上回ったサンプルの割合を示す。 $p$ 値は100倍した値を掲載している。任意のパーセンタイルについて疑似分布よりも実際の分布の $t$ 値の方が高かった場合アスタリスクを記している

# Results(2)

## $\alpha$ の検定(ニューラルネットワーク)

ML_10			ML_20			ML_30			ML_40			ML_50		
Percentiles	Actual	p-value	Percentiles	Actual	p-value	Percentiles	Actual	p-value	Percentiles	Actual	p-value	Percentiles	Actual	p-value
100	2.78	0.36	100	2.89	0.28	100	3.62	0.03	100	3.48	0.05	100	4.80	0.00
99	2.27	1.33	99	2.47	0.86 *	99	2.71	0.42 *	99	2.55	0.66 *	99	2.75	0.39 *
98	1.93	2.95	98	2.24	1.49 *	98	2.34	1.09 *	98	2.19	1.61 *	98	2.43	0.92 *
97	1.72	4.58	97	1.98	2.72 *	97	2.14	1.79 *	97	2.08	2.06 *	97	2.26	1.38 *
96	1.64	5.31	96	1.82	3.76 *	96	1.93	2.89 *	96	1.93	2.91 *	96	2.03	2.37 *
95	1.51	6.85	95	1.74	4.47 *	95	1.83	3.60 *	95	1.86	3.41 *	95	1.88	3.29 *
90	1.11	13.66	90	1.36	9.08 *	90	1.42	7.97 *	90	1.44	7.75 *	90	1.52	6.84 *
10	-1.35	8.96	10	-1.21	11.63 *	10	-1.16	12.55 *	10	-1.13	13.04 *	10	-0.94	17.28 *
9	-1.43	7.75	9	-1.25	10.76 *	9	-1.21	11.57 *	9	-1.19	11.80 *	9	-1.01	15.74 *
8	-1.49	6.98	8	-1.33	9.37 *	8	-1.27	10.41 *	8	-1.24	10.87 *	8	-1.07	14.30 *
7	-1.54	6.29	7	-1.42	7.93 *	7	-1.32	9.54 *	7	-1.29	9.99 *	7	-1.16	12.40 *
6	-1.63	5.33	6	-1.50	6.84 *	6	-1.38	8.54 *	6	-1.36	8.91 *	6	-1.25	10.62 *
5	-1.79	3.76	5	-1.58	5.94 *	5	-1.47	7.29 *	5	-1.43	7.73 *	5	-1.35	8.93 *
0	-4.81	0.00 *	0	-3.13	0.13 *	0	-2.78	0.32 *	0	-3.80	0.01 *	0	-3.35	0.06 *

PercentilesとActualはそれぞれ実際の $t(\alpha_j^M)$ の分布におけるパーセンタイルとそれに対応する $t(\alpha_j^M)$ の値を示し、 $p$ 値は疑似分布において各 $t(\alpha_j^M)$ を上回ったサンプルの割合を示す。 $p$ 値は100倍した値を掲載している。任意のパーセンタイルについて疑似分布よりも実際の分布の $t$ 値の方が高かった場合アスタリスクを記している

# Which explanatory variables boosted machine learning?

✓線形モデルと機械学習モデルのリターン格差を、使用した説明変数の組み合わせで説明する

$$\bar{D}_j^{NN} := \frac{1}{T} \sum_{t=1}^T LS_{j,t}^{NN} - LS_{j,t}^{LM} \quad (7)$$

$$\bar{D}_j^{NN} = \bar{\alpha}^{NN} + \boldsymbol{\beta}^{NN} \mathbf{I}_j + \epsilon_j \quad (8)$$

✓ $\mathbf{I}_j = (I_{j,1}, \dots, I_{j,123})^T$  であり、 $I_{j,1}$  は本分析で使用した123個の説明変数に1~123の番号を振り、1番目の説明変数がサンプル $j$ に含まれていれば1、そうでなければ0を取る指示関数



# Results

✓  $n \in \{10, 20, 30, 40, 50\}$ のそれぞれについて回帰係数を推定し、 $t$ 値の平均が上位10の変数について掲載した

✓ 出来高、ボラティリティ、指数ウェイトなどが、機械学習の予測性能を高めると解釈できる

Variable	Type	N=10	N=20	N=30	N=40	N=50	AVG
売買代金	TURNOVER	0.16	2.73	3.22	1.33	2.35	1.96
HV (3ヵ月)	VOL	2.95	2.08	1.15	0.77	1.31	1.65
HV (1年)	VOL	1.98	3.60	-0.58	0.85	0.70	1.31
受取利息・割引料	PL_ACT	1.64	1.37	0.10	0.73	1.83	1.13
対ドル円レート感応度(月次・36ヵ月)	BETA	1.24	1.09	1.47	1.41	0.09	1.06
予想売上高伸び率(今期-本決-Qコンセンサス-連優)	PL_EST	0.92	0.58	2.45	-0.56	1.81	1.04
予想営業利益(来期-本決-Qコンセンサス-連優)	PL_EST	0.28	0.25	0.54	0.66	3.27	1.00
予想売上高(来期-本決-Qコンセンサス-連優)	PL_EST	0.56	1.75	0.30	1.80	0.52	0.99
予想売上高税引利益率(来期-本決-Qコンセンサス-連優)	PL_EST	-1.48	0.55	0.48	1.42	3.60	0.92
対日経公社債インデックス(長期)感応度(月次・60ヵ月)	BETA	-0.47	2.03	0.09	1.13	1.70	1.90

# Interpretation

- ✓ Wang et al (2017)では、含み益を抱える銘柄においてはリスクとリターンの関係が正であった一方で、含み損を抱える銘柄においてはリスクとリターンの関係が負であったことが確認されている
- ✓ 臼井(2022)では含み損益の定義として、Grinblatt and Han (2005)によるキャピタルゲイン・オーバーハングが使用されており、算出においては、一定期間における個別銘柄の株価リターンと売買回転率が使用されている。
- ✓ 指数ウェイトはサイズと関連しており、小型と大型でファクターリターンの効果が異なるとの先行研究が多い。Alquist et al. (2018)では、モメンタムやバリュー、低ベータ効果は小型株で顕著となることを示した。

# Conclusions

- ✓本研究では、線形モデルと機械学習の精度を比較するシミュレーションを多数繰り返すことで、両モデルの頑健な性能比較を行った。
- ✓その結果、説明変数を所与とすると、平均的には線形モデルと機械学習の予測精度は変わらないことが分かった。
- ✓一方、高い $\alpha$ の出現割合を比較したところ、機械学習においてはその出現頻度が高く、偶然やサンプルのバラツキでは説明できないことが分かった。
- ✓また、特定の変数を含めることで機械学習のパフォーマンスを押し上げることが分かった

## 参考文献

臼井健人 (2021), 「投資家の含み損益と低ボラティリティ・アノマリー」, 証券アナリストジャーナルVol.59 No.11 Nov. 2021 pp.90-102

内山朋規・清水康弘 (2017), 「クオリティファクターの有効性とアクティブファンドのパフォーマンス」, 日本ファイナンス学会第25回大会予稿集

清水康弘・内山朋規 (2020), 「機械学習はファクターの合成方法を学習できるか—リターン予測とオーバーフィッティング—」, 日本ファイナンス学会第28回大会予稿集

内藤誠・西内翔 (2020), 「日本株式市場における深層学習を用いたファクターモデルの構築とその有効性の検証」, 日本ファイナンス学会第28回大会予稿集

Alquist, R., Israel, R., & Moskowitz, T. (2018). Fact, fiction, and the size effect. *The Journal of Portfolio Management*, 45(1), 34–61.

Chinco, A., Clark - Joseph, A. D., & Ye, M. (2019). Sparse signals in the cross - section of returns. *The Journal of Finance*, 74(1), 449-492.

Fama, E. F., & French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of financial economics*, 33(1), 3-56.

Fama, E. F., & French, K. R. (2010). Luck versus skill in the cross - section of mutual fund returns. *The journal of finance*, 65(5), 1915-1947.

## 参考文献

Feng, G., Giglio, S., & Xiu, D. (2017). Taming the factor zoo. Fama-Miller Working Paper, 24070.

Freyberger, J., Neuhierl, A., & Weber, M. (2020). Dissecting characteristics nonparametrically.

*The Review of Financial Studies*, 33(5), 2326-2377.

Grinblatt, M., & Han, B. (2005). Prospect theory, mental accounting, and momentum. *Journal of financial economics*, 78(2), 311-339.

Gu, S., Kelly, B., & Xiu, D. (2020). Empirical asset pricing via machine learning. *The Review of Financial Studies*, 33(5), 2223-2273.

Gupta, T., & Kelly, B. (2019). Factor momentum everywhere. *The Journal of Portfolio Management*, 45(3), 13–36.

Harvey, C. R., Liu, Y., & Zhu, H. (2016). ... and the cross-section of expected returns. *The Review of Financial Studies*, 29(1), 5-68.

Heaton, J. B., Polson, N. G., & Witte, J. H. (2016). Deep learning in finance. arXiv preprint arXiv:1602.06561.

Kahneman, D., & Tversky, A. (2013). Prospect theory: An analysis of decision under risk. In *Handbook of the fundamentals of financial decision making: Part I* (pp. 99-127).

Kelly, B. T., Pruitt, S., & Su, Y. (2019). Characteristics are covariances: A unified model of risk and return. *Journal of Financial Economics*, 134(3), 501-524.

## 参考文献

- Kosowski, R., Timmermann, A., Wermers, R., & White, H. (2006). Can mutual fund “stars” really pick stocks? New evidence from a bootstrap analysis. *The Journal of finance*, 61(6), 2551-2595.
- Moritz, B., & Zimmermann, T. (2016). Tree-based conditional portfolio sorts: The relation between past and future stock returns. Available at SSRN 2740751.
- Petersen, M. A. (2009). Estimating standard errors in finance panel data sets: Comparing approaches. *The Review of financial studies*, 22(1), 435-480.
- Wang, H., Yan, J., & Yu, J. (2017). Reference-dependent preferences and the risk–return trade-off. *Journal of Financial Economics*, 123(2), 395-414.
- Yan, X. S., & Zheng, L. (2017). Fundamental analysis and the cross-section of stock returns: A data-mining approach. *The Review of Financial Studies*, 30(4), 1382-1423.