

Explaining Cross-Sectional Stock Returns Using SHAP and Other Machine Learning Interpretation

平木一浩^{1 2} 篠 潤之介³

日本銀行金融研究所 ファイナンス・ワークショップ

機械学習・AI のファイナンス分析への応用

2025 年 11 月 28 日

¹ 国際通貨基金 (khiraki@imf.org)

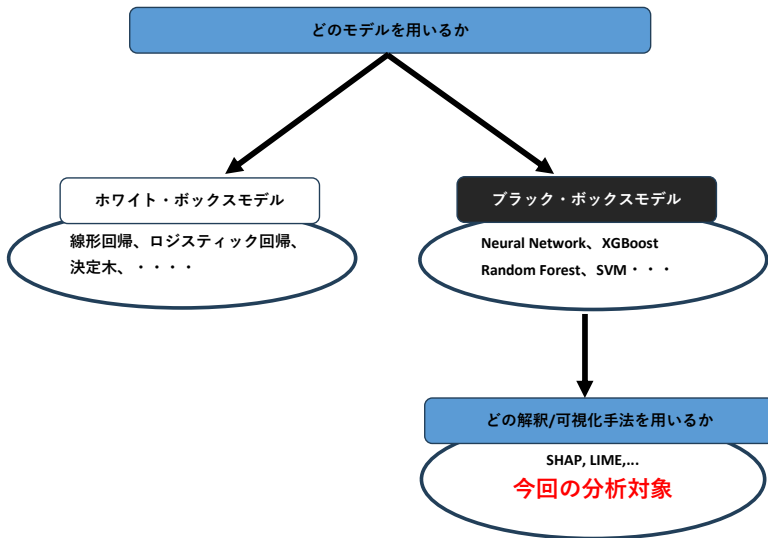
² 本稿の内容と意見は筆者ら個人に属するものであり, 日本銀行, 国際通貨基金, 同理事会, 同マネジメントの公式見解を示すものではない.

³ 早稲田大学国際学術院 (junnosuke.shino@waseda.jp)

1. はじめに
2. 理論編: SHAP とその代替的 AFA の紹介
3. 実証編: Cross-Sectional Stock Returns への適用

1. はじめに

本分析の位置づけ



AFA とは

- ▶ **Additive Feature Attribution (AFA)** : 高度に複雑な学習モデル (Neural Net, Tree Ensemble,...) を用いて計算されたデータの理論値・予測値を, 解釈可能な形に要因分解する手法. **Explainable AI** の 1 つ.

<線形回帰モデル>

$$y = f(x_1, x_2, x_3) = \alpha + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3$$



β を用いて要因分解できる

<複雑な機械学習モデル>

$$y = ML(x_1, x_2, x_3)$$



複雑な非線形モデルであり
線形回帰のようには要因分解できない



要因分解の手法 : AFA

- ▶ 代表的な手法として, 協力ゲーム理論の解概念であるシャープレイ値を用いた **SHAP** がある (Lundberg and Lee [18], 以下 **LL 論文**).

SHAP とは

協力ゲーム理論と機械学習（特にそのなかの AFA）は本来, 全く異なる学術分野. にもかかわらず, **両者が扱う問題は, 構造的に同じ.**

- ▶ **協力ゲーム** : **人々 (=プレイヤー)** の間で, 全体提携値 (=一定の大きさの「パイ」) をどのように配分するかという問題.
⇒ 協力ゲームにおける代表的な解概念: シャープレイ値 [22]
- ▶ **AFA** : **特徴量** の間で, すべての特徴量が既知の時の予測値に対する貢献度をどのように配分するかという問題.
⇒ シャープレイ値が適用できる! = SHAP

最近の AFA/SHAP 研究の動向 (1)

2020 年代以降, SHAP を用いた分析は, 世界的に急ピッチで進展.

- ▶ **LL 論文** (Lundberg and Lee [18]): NeurIPS の proceeding, 引用件数は **45,000** 件超 (2025 年 11 月時点).
- ▶ SHAP を用いた典型的な分析フロー: 「Random Forest, XGBoost, Neural Net といった**複雑で非線形な学習モデル**が導き出す予測値を, SHAP を用いて**可視化**し, **解釈性を与える**.」
- ▶ SHAP のメリットの 1 つ: どんな学習モデルにも適用できる.
 - ▶ 理論的分析 SHAP [18], LIME [21], Interval Shapley Value [20],...
 - ▶ 計算の高速化 FastSHAP [13], TreeSHAP [18],...
 - ▶ 実際のデータへの適用 医療 [19], ヘルスケア [17],...
 - ▶ 金融・経済データへの適用については次のページ

最近の AFA/SHAP 研究の動向 (2)


SHAP を用いた機械学習モデルの可視化は、各国の中央銀行によるリサーチを中心に、経済・ファイナンス分野へも広がりつつある。

- ▶ Buckmann and Joseph [3] (*International Journal of Central Banking* 2023): BOE の WP. 米失業率を対象に、機械学習モデルの予測精度の比較評価, SHAP による要因分解, 変数間の非線形関係の可視化等, SHAP を核とする機械学習モデルを用いた分析ワークフローを提示.
- ▶ Bluwstein et al. [1] (*Journal of International Economics* 2023): ECB の WP. SHAP を用いて金融危機の予測に有用な金融経済変数を特定・可視化.
- ▶ Jabeur et al. [12] (*Annals of Operations Research* 2024): 金価格を 6 つの学習モデルを用いて予測, SHAP を適用. XGBoost モデルとそれに対する SHAP の適用が分析上有効であることを主張.
- ▶ 鷲見 [26]: SHAP を用いて通貨オプション市場における投資家センチメントを分析.
- ▶ 森ほか [25]: 125 か国の新規感染者数および 36 種類の特徴量からなるパネルデータにランダムフォレストモデルを適用, SHAP を用いて特徴量の重要度を計測.
- ▶ その他, デフォルト確率 [2], 信用リスク管理 [4], [10], M&A [7], ...

LL 論文の概要: SHAP の定式化と特徴づけ

LL 論文 [18] では, SHAP を以下の 2 つの主定理によって特徴づけた:


1. SHAP とは, 協力ゲームの解概念をベースとした概念である (Theorem 1).
2. SHAP とは, LIME (Local Interpretable Model-agnostic Explanations, XAI の 1 つの手法) の最適化問題において, ある特定のカーネル関数を用いた場合の最適解である (Theorem 2).



HIS 論文の概要: SHAP と代替的な手法の定式化

HIS 論文 [11][24] では, SHAP と代替的な AFA を, 以下の 2 つのアプローチから提示した:

1. **Approach 1**: シャープレイ値以外の協力ゲームの解概念を用いて AFA を導出.
2. **Approach 2**: より望ましい性質を有するカーネルを用いて AFA を導出.



以下では, (1) SHAP および **Approach 1** に基づく AFA を紹介したあと, (2) これらを **株式クロスセクション・リターン** に適用し, AFA 間の違いを比較 & 結果を解釈する.

2. 理論編

SHAP とその代替的 AFA の紹介

シャープレイ値以外の解概念を用いた AFA

- ▶ 学習モデル f , 特徴量 A, B, C の 3 つ.
- ▶ AFA が解くべき問題: $f(ABC) - f(\emptyset)$ を, A, B, C の「予測の貢献度」に応じて分配.

シャープレイ値(SHAP)の場合

$$\begin{array}{l} [1] \ f(?, ?, ?) \xrightarrow{A} f(A, ?, ?) \xrightarrow{B} f(A, B, ?) \xrightarrow{C} f(A, B, C) \\ [2] \ f(?, ?, ?) \xrightarrow{A} f(A, ?, ?) \xrightarrow{C} f(A, ?, C) \xrightarrow{B} f(A, B, C) \\ \quad \dots \dots \dots \\ [6] \ f(?, ?, ?) \xrightarrow{C} f(?, ?, C) \xrightarrow{B} f(?, B, C) \xrightarrow{A} f(A, B, C) \end{array}$$

(STEP 1) 各順列における
A, B, C の「**限界貢献度**」を計算

(STEP 2) 限界貢献度の平均 = **SHAP**

シャープレイ値以外の解概念を用いた AFA

- ▶ 学習モデル f , 特徴量 A, B, C の 3 つ.
- ▶ AFA が解くべき問題: $f(ABC) - f(\emptyset)$ を, A, B, C の「予測の貢献度」に応じて分配.

残余均等配分 (ES: Equal Surplus solution) の場合

$$[1] f(?, ?, ?) \xrightarrow{A} f(A, ?, ?)$$

$$[2] f(?, ?, ?) \xrightarrow{B} f(?, B, ?)$$

$$[3] f(?, ?, ?) \xrightarrow{C} f(?, ?, C)$$

(STEP 1) $f(A, ?, ?) - f(?, ?, ?)$ を, 特徴量 A が自分の分として「キープ」
(特徴量 B, C も同様)

(STEP 2) $f(A, B, C) - f(?, ?, ?)$ (全体のパイ)のうち,

(STEP 1)で配分した残りを3等分して足し合わせる = ES

シャープレイ値以外の解概念を用いた AFA

- ▶ 学習モデル f , 特徴量 A, B, C の 3 つ.
- ▶ AFA が解くべき問題: $f(ABC) - f(\emptyset)$ を, A, B, C の「予測の貢献度」に応じて分配.

逆残余均等配分 (ENSC: Egalitarian Non-Separable Contribution value) の場合

$$[1] \quad f(?, B, C) \xrightarrow{A} f(A, B, C)$$

$$[2] \quad f(A, ?, C) \xrightarrow{B} f(A, B, C)$$

$$[3] \quad f(A, B, ?) \xrightarrow{C} f(A, B, C)$$

(STEP 1) $f(A, B, C) - f(?, B, C)$ を, 特徴量 A が自分の分として「キープ」
(特徴量 B, C も同様)

(STEP 2) $f(A, B, C) - f(?, ?, ?)$ (全体のパイ)のうち,
(STEP 1)で配分した残りを3等分して足し合わせる = **ENSC**

- ▶ **HIS 論文**では, SHAP に加え, (1) **ES**, (2) **ENSC**, および両者を按分した (3) **ES-ENSC** を用いた AFA を提示した.

AFA としての SHAP, ES, ENSC, ES-ENSC

- ▶ **SHAP** の正確な表現以下の通り.

$$\Psi_{\tau,j}^{SHAP} = \sum_{S \subseteq N \setminus j} \frac{|S|!(n - |S| - 1)!}{n!} (v_{\tau}(S \cup \{j\}) - v_{\tau}(S))$$

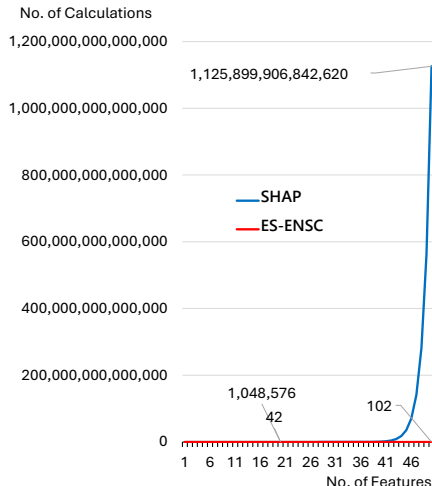
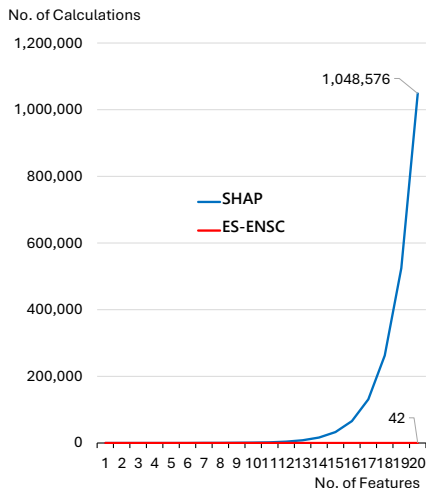
- ▶ SHAP とは (N, v_{τ}) におけるシャープレイ値そのもの.
- ▶ 残余均等配分解 (**ES**) 型 AFA は, 以下の通り (**ENSC** および **ハーフ&ハーフ** は省略).

$$\Psi_{\tau,j}^{ES} = v_{\tau}(\{j\}) + \frac{(v_{\tau}(N) - v_{\tau}(\emptyset)) - \sum_{i \in N} v_{\tau}(\{i\})}{n} \quad (1)$$

- ▶ Ψ_{τ}^{SHAP} の計算コスト: 全ての S について $v(S)$ を計算する必要があるため, 特徴量が n 個の時の計算コストは 2^n と, **計算コストが非常に大きい**.
 - ▶ 多くの特徴量からなるデータで Ψ_{τ}^{SHAP} を求める際には, 計算コストの大きさが問題となる.
- ▶ $\Psi_{\tau,j}^{ES}$ の計算コスト: n 個の $v(\{i\})$ と $v(\emptyset)$ と $v(n)$ を計算するだけなので, 計算コストは $n + 2$. ES-ENSC の計算コストは $2n + 2$ と, **計算コストは小さい**.

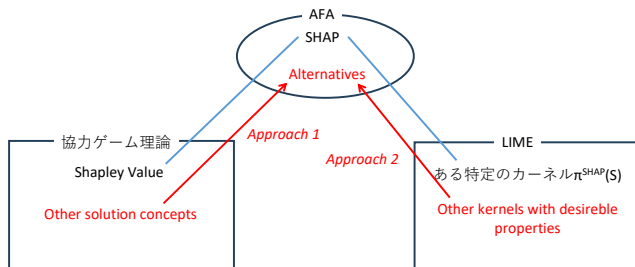
計算コスト: SHAP vs ES-ENSC

SHAP と残余均等配分関連 AFA との計算量の差は, 指数関数的に拡大していく.



再掲: 理論編の分析の枠組み

- ▶ 以下の2つのアプローチから, SHAP と代替的な AFA 手法を提示した.
 1. シャープレイ値以外の協力ゲームの解概念を用いて AFA を導出する (Approach 1).
 2. SHAP 以外のカーネルを用いて AFA を導出する (Approach 2).



- ▶ Approach 2 については HIS 論文 [11][24] を参照.

SHAP およびその代替的な AFA 一覧 (HIS 論文より)

番号	記号	協力ゲームとしての特徴	カーネルとしての特徴
[1]	$\Psi_{\tau,j}^{SHAP}$	シャーププレイ値	$ S $ に関して U 字型
[2]	$\Psi_{\tau,j}^{PNucl}$	LS プレ仁	$ S $ に関して一定
[3]	$\Psi_{\tau,j}^{ES}$	残余均等配分解	$ S $ に関して減少
[4]	$\Psi_{\tau,j}^{ENSC}$	逆残余均等配分解	$ S $ に関して増加
[5]	$\Psi_{\tau,j}^{ES-ENSC}$	ES と ENSC を按分	$ S $ に関して U 字型
[6]	$\Psi_{\tau,j}^{LnK}$	－ 未解決 －	$ S $ に関して線形に増加
[7]	$\Psi_{\tau,j}^{ExK}$	－ 未解決 －	$ S $ に関して指数関数的に増加
[8]	$\Psi_{\tau,j}^{CvK}$	－ 未解決 －	$ S $ に関して対数関数的に増加

- ▶ 次ページ以降, これらの AFA をわが国の株価リターン (Cross-Sectional Stock Returns) に適用して, それぞれの AFA がどの程度の違いをもたらすのかを考察する.

3. 実証編

SHAP およびその代替的 AFA の Cross-Sectional Stock Returns への適用

- ▶ Part I はじめに
- ▶ Part II ML モデルのパフォーマンス & AFA 間の比較
- ▶ Part III 結果の解釈

Part I

はじめに

既存研究: ML Analysis of Cross-Sectional Returns

- ▶ ML を Cross Sectional Stock Returns に適用 →いくつかの既存研究が存在
 - ▶ Gu et al. ([9], RFS): 機械学習を用いた資産価格モデルの最も代表的な研究の一つ. 株価リターンに複数の機械学習モデルを適用し, これらの予測精度が従来の回帰ベースの予測を大きくアウトパフォームすることを実証. 特徴量の重要度は global XAI の手法で検証.
 - ▶ Chen et al. ([5], MS): Deep Neural Networks を用いて, 資産価格モデルの因子構造をデータから自動的に学習させ, 株式超過リターンを予測. Gu らの ML モデルよりアウトパフォームすることを示した. 特徴量の重要度は global XAI の手法で検証.
 - ▶ Leippold et al. ([15], JFE). Gu et al. の中国市場バージョン. 特徴量の重要度は Feature Importance 等 (global な手法) で計測.
- ▶ さらに XAI で可視化 → 未だ限定的
 - ▶ Goswami and Uddin ([8], AOR): 166 種類の特徴量を対象に, 機械学習 (ML) モデルと SHAP を用いて「どの特徴量が株式リターンの予測に重要か」を検証. モメンタム関連や取引量関連の SHAP 値が大きい.
 - ▶ Li et al. ([16], WP): LIME によって得られる係数を「moderation effect」とし, 企業変数との交互作用がリターンにどう影響するかを検証 (LIME-adjusted moderation regression). WP 段階 (202510 時点)
 - ▶ Demirbaga and Xu ([6], WP): 米国株式を対象に LIME と SHAP を用いて特徴量の影響度を可視化. WP 段階 (202510 時点)

やること：

- ▶ 日本の株価リターンに ML モデル (XGBoost) で学習・予測させ、その後 SHAP & その代替的手法を適用
- ▶ ML モデル自体のパフォーマンス: Gu et al. [9] との比較
- ▶ SHAP およびその代替的手法の比較 (I) 計算コスト
- ▶ SHAP およびその代替的手法の比較 (II) SHAP 値とのギャップ
- ▶ 結果の解釈例: ETF 買入れ効果の可視化 (ドメイン知識の活用)

やらないこと：

- ▶ ML モデルの選定 (ML モデルは XGBoost で固定).
- ▶ 特徴量の選定 (既存研究に基づき 10 個弱に固定 ← Exact SHAP との比較のため)

ベンチマーク推計

- ▶ 被説明変数: JPX400 全構成銘柄の対 TOPIX 超過リターン (月次)
- ▶ 学習データ: 2010 年 1 月から 2015 年 12 月まで
- ▶ テストデータ: (i) 2016 年 1 月から 2016 年 12 月まで, (ii) 2016 年 1 月から 2017 年 12 月まで, の 2 パターン.
- ▶ 特徴量: Gu et al. [9] の特徴量選定などを参考に, 以下の通りとした.
 - ▶ **marval_lag**: 時価総額 (1 か月ラグ)
 - ▶ **volume_lag**: 売買高 (1 か月ラグ)
 - ▶ **momentum_1m_lag1**: 株価モメンタム (1 か月, 1 か月ラグ)
 - ▶ **momentum_6m_lag1**: 株価モメンタム (6 か月, 1 か月ラグ)
 - ▶ **chmom_6m_lag1**: 株価モメンタム変化幅 (6 か月モメンタム前月差, 1 か月ラグ)
 - ▶ **asset_growth_lag1**: 総資産伸び率 (年次データ, 1 年前ラグ)
 - ▶ **BOJETF**: 銘柄レベル日銀 ETF 買入額 (月次, 時価総額対比)
- ▶ ベンチマーク推計からの拡張として, 他の特徴量 (PER など) を加えるケースも考える.
- ▶ ベンチマーク推計では, 特徴量はすべて平均ゼロ, 標準偏差 1 に標準化.

Part II

ML モデルのパフォーマンス & AFA 間の比較

ML モデルのパフォーマンス: Gu et al. [9] との比較

	[1] Gu et al. OLS	[2] Gu et al. RF	[3] Gu et al. GBRT	[4] Gu et al. NN3	[5] Benchmark XGBoost	[6] Benchmark XGBoost without BOJETF	[7] Benchmark In-sample (2010-2017)
R^2_{Oos}	-3.46	0.33	0.34	0.40	0.4396	0.3052	0.9510

Table: Monthly out-of-sample stock-level prediction performance (percentage R^2_{Oos})

- ▶ 我々のベンチマーク推計の予測精度（列 [5]）は Gu et al.（列 [2][3][4]）と同程度.
 - ▶ 特徴量の数を絞ることによる影響は限定的と考えられる.
- ▶ BOJETF の説明力は相応に高い.
 - ▶ 同変数を除くと予測パフォーマンスがはっきりと低下（列 [6]）.
- ▶ In-sample (2010 年 1 月-2017 年 12 月) の R^2 は 0.95%程度（列 [7]）.

SHAP およびその代替的手法の比較 (I) 計算コスト

	[1] Benchmark (i) 1 年予測	[2] Benchmark (ii) 2 年予測	[3] [2]+ 特徴量 1 個追加	[4] [2]+ 特徴量 2 個追加	[5] [2]+ 特徴量 3 個追加
ES	111.28	443.04	529.84	611.18	718.24
ENSC	187.02	464.79	544.34	653.13	723.22
ES-ENSC	186.12	447.81	508.36	653.96	726.43
Exact SHAP	696.06	2370.84	4523.32	8696.46	16625.90
Permutation SHAP	2744.94	9815.22	10540.60	9780.20	10562.40
Kernel SHAP	523.48	1839.84	3847.89	6899.20	14009.34

Table: 各 AFA および SHAP 近似計算アルゴリズムの計算コスト (秒)

- ▶ 我々の提示した ES, ENSC, ES-ENSC の計算速度は、厳密な SHAP 計算 (Exact SHAP) のみならず、Python の SHAP パッケージに実装されている近似計算アルゴリズム (Permutation SHAP, Kernel SHAP) と比べても大幅に速い。
- ▶ 特徴量の増加に対する計算時間の増加ペースも、SHAP に比べて大幅に抑制されているように見える。

異なる AFA/近似計算アルゴリズムとの値の違い

左下: XGBoost 右上: Linear Model

	SHAP	ES	ENSC	ES-ENSC	Permutation SHAP	Kernel SHAP
SHAP	—	0.0000000	0.0000000	0.0000000	0.0000000	0.0000000
ES	0.0172193	—	0.0000000	0.0000000	0.0000000	0.0000000
ENSC	0.0172193	0.0344390	—	0.0000000	0.0000000	0.0000000
ES-ENSC	0.0000000	0.0172190	0.0172190	—	0.0000000	0.0000000
Permutation SHAP	0.0000000	0.0172193	0.0172193	0.0000000	—	0.0000000
Kernel SHAP	0.0011640	0.0171040	0.0174180	0.0011640	0.0011640	—


- ▶ それぞれの AFA または近似計算アルゴリズムの組み合わせについて、平均絶対差 (ある観測値におけるある特徴量について、2 つの AFA の差の絶対値を計算し、それを全ての特徴量およびすべての観測値について平均したもの) を表示。
 - ▶ 線形モデルの場合は、これらに違いは生じない。かつ、回帰パラメータを用いた分解と一致する (以上は数学的に証明済)。
- ▶ ES-ENSC は、既存の SHAP 近似計算アルゴリズムと比較して、計算速度が速いだけでなく、SHAP との近似度も優れている。

Part III

結果の解釈


- ▶ (注) 期間全体の政策効果をみるのが目的のため, 以下では 2010 年 1 月から 2017 年 12 月までの In-sample 推計に基づいて考察する.

各特徴量の SHAP 値: 平均的な貢献度の大きさ



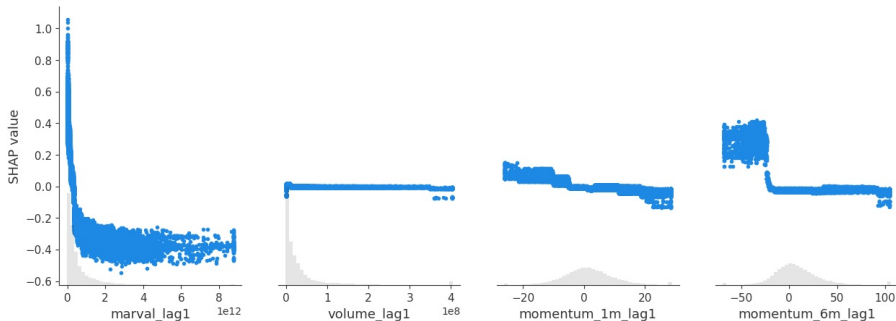
- ▶ 期間中における個別銘柄レベルの平均的な SHAP 値の大きさ（絶対値）をみると、
時価総額, 日銀 ETF 買入れ, 総資産伸び率, の順に大きい。

各特徴量の SHAP 値: Beeswarm Plot



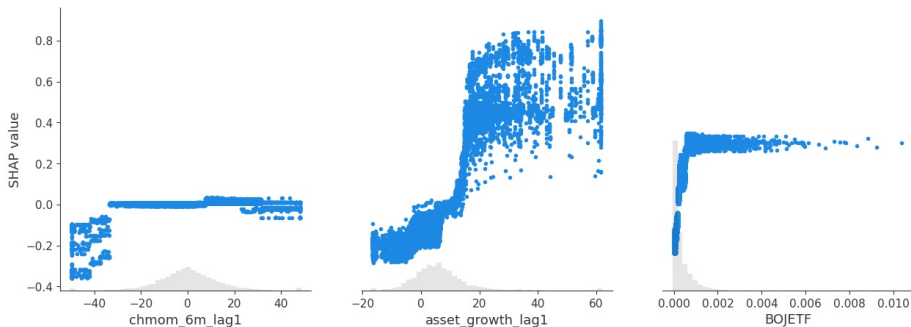
- ▶ 前期の時価総額が小さいほど/資産の伸びが高いほど/モメンタムが弱いほど, 期待リターンは高くなる.
- ▶ BOJETF が大きいほど, 当期リターンは高くなる.
 - ▶ ただし, 特徴量が大きくなる (グラフ上において赤くなる) に従い, SHAP 値は 0.3~0.4 程度でクラスター化しており, 買入効果が「頭打ち」になっているようにも見える.

各特徴量の分布と SHAP 値 (1)




- ▶ (i) 各特徴量と SHAP 値の関係（青点の散布図）と, (ii) 特徴量自体の分布（灰色のヒストグラム）を示したもの（特徴量の分布は標準化前の raw data を表示）。
 - ▶ 左から時価総額, 売買高, モメンタム (1M), モメンタム (6M).
- ▶ 特徴量の変化に対する SHAP 値の反応は均一ではない (非線形性).
- ▶ 特徴量の大きさに対する SHAP 値の反応は対称ではない (非対称性) .

各特徴量の大きさと SHAP 値 (2)




- ▶ 左からモメンタム (6M) の変化, 総資産伸び率, BOJ の ETF 買入額
- ▶ BOJETF: 全銘柄/全期間で見ると, 追加的な買入れが超過リターンに与える影響は逓減しているように見える (買入れ効果の非線形性). このこと自体は既存研究とも整合的 (例えば Katagiri et al. [14])
 - ▶ BOJETF と SHAP 値の関係を銘柄別・期間別にみる (次ページ以降)

BOJETF と SHAP 値の関係: 個別銘柄 (1)




- ▶ 銘柄別にみても, 買入額が増加するにしたいが, SHAP 値はフラット化する傾向にある.
- ▶ ごく大まかにいって, BOJETF が 0.001 (=月次買入額の対時価総額対比 0.1%) 弱の水準で境界があり, そこを超えると急激にフラット化している.

BOJETF と SHAP 値の関係: 個別銘柄 (2)




- ▶ 他の銘柄をみても、買入額が増加するにしたいが、SHAP 値はフラット化する傾向にある。
- ▶ 前ページの散布図と横軸の目盛幅が異なっている点に注意. SHAP 値がフラット化するタイミングは BOJETF が 0.001 弱のときであり、前ページで見た関係性と概ね同じ。

BOJETF と SHAP 値の関係: 通時的な変化 (1)



- ▶ 2011 年 1 月 (左パネル), 2013 年 5 月 (右パネル): ETF 買入れ政策導入直後や, QQE 導入時の買入れ増額の際には, 「買入額が増えるに従い, SHAP 値が増加する」という関係性が明確に見られた
 - ▶ あるいは, 「こうした関係性が維持される範囲内で ETF 買入れを行っていた」ともいえる。

BOJETF と SHAP 値の関係: 通時的な変化 (2)



- ▶ 2014 年 10 月 (左パネル) , 2016 年 8 月 (右パネル) : ETF 買入れを増額するに
したがって, SHAP 値のフラット化が明確になっていった.
- ▶ 「買入れの超過リターンに対する追加的な効果は限定的だった」ともいえる.

まとめ & 今後の課題

- ▶ (I) 協力ゲーム理論の解概念, (II) 望ましいカーネル条件, の2つのアプローチから, **SHAP の代替案を理論的に導出した** (HIS 論文).
- ▶ それらの手法を, **わが国の Cross-sectional stock returns** に適用し, 以下の点を明らかにした.
 - ▶ **AFA 間の比較**という観点からは, ES-ENSC 型の AFA は, SHAP および既存の近似計算アルゴリズムよりも計算コストが大幅に小さく, かつ厳密な SHAP 値を精緻に近似している.
 - ▶ **SHAP を用いることの最大の障壁は計算コストの大きさ**であることから, この点は ES-ENSC の有用性を強く示唆するものといえる.
 - ▶ **日本銀行の ETF 買入の効果**という観点では, **買入効果の非線形性や異なる銘柄や局面に共通のパターン**が示唆された. こうした点は, **実際の政策運営の観点からも有用な知見である**といえる.
 - ▶ こうした「示唆」をもとに, 次のステップとして, 精緻な統計的因果推論を行っていくことが重要 (和泉 [23]).
- ▶ 今後取り組むべき課題としては, (1) 特徴量を増やした場合の学習・予測と AFA 間の計算コストの比較, (2) 理論的により望ましい性質を持った AFA の開発, (3) さまざまなタイプのデータへの適用, 等が挙げられる.

参考文献 I

- [1] Kristina Bluwstein, Marcus Buckmann, Andreas Joseph, Sujit Kapadia, and Özgür Şimşek.
Credit growth, the yield curve and financial crisis prediction: Evidence from a machine learning approach.
Journal of International Economics, 145:103773, 2023.
- [2] Philipp Bracke, Anindya Datta, Christopher Jung, and Sougata Sen.
Machine learning explainability in finance: an application to default risk analysis.
Staff Working Paper 816, Bank of England, 2021.
Bank of England Staff Working Paper No.816.
- [3] Marcus Buckmann and Andreas Joseph.
An interpretable machine learning workflow with an application to economic forecasting.
International Journal of Central Banking, 19–4:449–522, October 2023.
- [4] Niklas Bussmann, Paolo Giudici, Daniele Marinelli, and Jochen Papenbrock.
Explainable machine learning in credit risk management.
Computational Economics, 57:203–216, 2021.
- [5] Luyang Chen, Markus Pelger, and Jason Zhu.
Deep learning in asset pricing.
Management Science, 70(2):714–750, 2024.
- [6] Umit Demirbaga and Yue Xu.
Empirical asset pricing using explainable artificial intelligence.
SSRN Working Paper, 2024.
- [7] Kazuhiro Futagami, Yuji Fukazawa, Neha Kapoor, and Takahiro Kito.
Pairwise acquisition prediction with shap value interpretation.
The Journal of Finance and Data Science, 7:22–44, 2021.
- [8] Bhaskar Goswami and Ajim Uddin.
Significance of predictors: revisiting stock return predictions using explainable ai.
Annals of Operational Research, 2025.
- [9] Shihao Gu, Bryan Kelly, and Dacheng Xiu.
Empirical asset pricing via machine learning.
Review of Financial Studies, 33:2223–2273, 2020.

参考文献 II

- [10] Biljana Hadji-Misheva, Joerg Osterrieder, Ali Hirsa, Omkar Kulkarni, and Simon Fung Lin.
Explainable ai in credit risk management.
arXiv Quantitative Finance, 2021.
- [11] Kazuhiro Hiraki, Shinichi Ishihara, and Junnosuke Shino.
Alternative methods to shap derived from properties of kernels: A note on theoretical analysis.
In Proceedings of the International Conference on Big Data, 2024.
- [12] Sami Ben Jabeur, Salma Mefteh-Wali, and Jean-Laurent Viviani.
Forecasting gold price with the xgboost algorithm and shap interaction values.
Annals of Operational Research, 334:679–699, 2024.
- [13] N. Jethani, M. Sudarshan, I. C. Covert, S.-I. Lee, and R. Ranganath.
Fastshap: Real-time shapley value estimation.
In International Conference on Learning Representations, 2021.
- [14] Mitsuru Katagiri, Junnosuke Shino, and Koji Takahashi.
To lend or not to lend: the bank of japan's etf purchase program and securities lending.
Review of Asset Pricing Studies, 2025.
- [15] Markus Leippold, Qian Wang, and Wenyu Zhou.
Machine learning in the chinese stock market.
Journal of Financial Economics, 145:64–82, 2022.
- [16] Zequn Li, Xiaoxia Lou, Ying Wu, and Steve Yang.
Interpreting cross-section returns of machine learning models: Firm characteristics and moderation effect through lime.
Working Paper, 2024.
- [17] Hui Wen Loh, Chui Ping Ooi, Silvia Seoni, Prabal Datta Barua, Filippo Molinari, and Rajendra Acharya.
Application of explainable artificial intelligence for healthcare: A systematic review of the last decade (2011 – 2022).
Computer Methods and Programs in Biomedicine, 226:107161, 2022.
- [18] Scott M. Lundberg and Su-In Lee.
A unified approach to interpreting model predictions.
In Advances in Neural Information Processing Systems, volume 30, 2016.
- [19] Scott M. Lundberg, Bala Nair, Monica S. Vavilala, Mayumi Horibe, Michael J. Eisses, Trevor Adams, David E. Liston, Daniel King-Wai Low, Shu-Fang Newman, Jerry Kim, and Su-In Lee.
Explainable machine-learning predictions for the prevention of hypoxaemia during surgery.
Nature Biomedical Engineering, 2:749–760, 2018.

参考文献 III

- [20] Davide Napolitano, Lorenzo Vaiani, and Luca Cagliero.
Efficient neural network-based estimation of interval shapley values.
IEEE Transactions on Knowledge and Data Engineering, 36:8108–8119, 2024.
- [21] M. T. Ribeiro, S. Singh, and C. Guestrin.
Why should i trust you?: Explaining the predictions of any classifier.
In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 1135–1144, New York, NY, USA, 2016. ACM.
- [22] L. S. Shapley.
A value for n-person games.
Annals of Mathematics Studies, 28:307–318, 1953.
- [23] 和泉潔.
金融分野における因果推論の展開 一統計的手法・因果AI・自然言語処理の三潮流とその展望一.
SBI Research Review, 8, 2025.
- [24] 平木一浩, 石原慎一, 篠潤之介.
Shap の代替的手法の検討：協力ゲーム理論を用いたアプローチ.
日本銀行金融研究所ディスカッションペーパー, 2025 年 12 月公表予定.
- [25] 森いづみ, 中村俊文, 乗政喜彦.
グローバルにみた感染症の家計等の行動への影響：機械学習によるアプローチ.
日銀レビュー, 2021-J-5, 2021.
- [26] 鷲見和昭.
通貨オプション市場における投資家センチメントの要因分析：機械学習アプローチ.
日本銀行ワーキングペーパー, No.20-J-8, 2020.