

博士論文

オルタナティブデータとレジームスイッチ  
を用いた資産配分法の研究

田口 怜

# 目次

図一覧	vii
表一覧	ix
<b>第1章 はじめに</b>	<b>1</b>
1.1 本研究の背景	1
1.2 投資戦略におけるオルタナティブデータの活用と課題	2
1.3 投資戦略におけるレジームスイッチの活用と課題	2
1.4 オルタナティブデータとレジームスイッチ活用の鍵	3
1.5 本研究の目的	4
1.6 本研究における新規性	4
1.7 本研究論文の構成	5
<b>第2章 先行研究</b>	<b>7</b>
2.1 伝統的なアセットアロケーション	7
2.2 機械学習を用いたアセットアロケーション	7
2.3 テキストマイニングを用いた経済指標の作成	8
2.4 Transformer ベースの時系列予測	8
2.5 因果推論とその応用	8
2.6 時系列変化点検知とその応用	9
<b>第3章 提案手法</b>	<b>10</b>
3.1 提案手法の概要	10

3.2	提案手法のアーキテクチャ . . . . .	11
3.2.1	ヒストリカルデータの抽出 . . . . .	13
3.2.2	極性指標の作成 . . . . .	13
3.2.3	先行効果の実証 . . . . .	14
3.2.4	変化点検知 . . . . .	15
3.2.5	ポートフォリオ最適化 . . . . .	15
<b>第4章</b>	<b>テキストデータを用いた株式アセットアロケーション戦略</b>	<b>16</b>
4.1	はじめに . . . . .	16
4.1.1	背景 . . . . .	16
4.1.2	仮説 . . . . .	16
4.1.3	貢献 . . . . .	17
4.2	提案手法 . . . . .	17
4.2.1	ヒストリカルデータの抽出 . . . . .	19
4.2.2	極性指標の作成 . . . . .	19
4.2.3	先行効果の実証 . . . . .	20
4.2.4	変化点検知 . . . . .	20
4.2.5	ポートフォリオ最適化 . . . . .	22
4.3	実験と結果 . . . . .	23
4.3.1	データセットの概説 . . . . .	23
4.3.2	バックテストの準備 . . . . .	24
4.3.3	バックテストのシナリオ . . . . .	27
4.3.4	バックテストの評価 . . . . .	29
4.3.5	バックテストの結果 . . . . .	29
4.4	考察 . . . . .	32

4.5	まとめ	33
<b>第5章</b>	<b>テキストデータを用いた多クラス資産アセットアロケーション戦略</b>	<b>34</b>
5.1	はじめに	34
5.1.1	背景	34
5.1.2	仮説	34
5.1.3	貢献	35
5.2	提案手法	35
5.2.1	ヒストリカルデータの抽出	37
5.2.2	極性指標の作成	37
5.2.3	先行効果の実証	38
5.2.4	変化点検知	39
5.2.5	最適化アルゴリズム	39
5.3	実験と結果	43
5.3.1	データセットの概説	43
5.3.2	バックテストの準備	44
5.3.3	バックテストのシナリオ	50
5.3.4	バックテストの評価	51
5.3.5	バックテストの結果	53
5.4	考察	59
5.5	まとめ	60
<b>第6章</b>	<b>テキストデータと予測ベースの極性指標を用いた暗号資産アセットアロケーション戦略</b>	<b>61</b>
6.1	はじめに	61
6.1.1	背景	61

6.1.2	仮説	62
6.1.3	貢献	62
6.2	提案手法	62
6.2.1	ヒストリカルデータの抽出	64
6.2.2	テキストデータのスコアリング	64
6.2.3	極性指標の予測	64
6.2.4	先行効果の実証	65
6.2.5	変化点検知	66
6.2.6	最適化アルゴリズム	67
6.3	実験と結果	70
6.3.1	データセットの概説	70
6.3.2	バックテストの準備	70
6.3.3	バックテストのシナリオ	75
6.3.4	バックテストの評価	76
6.3.5	バックテストの結果	77
6.4	考察	80
6.5	まとめ	81
<b>第7章</b>	<b>おわりに</b>	<b>82</b>
7.1	目的の振り返り	82
7.2	全体の考察	82
7.3	今後の展望	84
	<b>参考文献</b>	<b>86</b>
	<b>補遺</b>	<b>96</b>



## 図一覽

3.1	提案手法の概要	12
4.1	SSAAM の概要	18
4.2	変化点検知 (5 レジーム)	26
4.3	変化点検知 (10 レジーム)	27
4.4	ポートフォリオ価値 (30 日リバランスかつ 5 レジーム)	31
5.1	MA-SSAAM の概要	36
5.2	センチメントシグナルと因果情報の関係	42
5.3	極性指標の相関係数	45
5.4	変化点検知 (CNN)	49
5.5	変化点検知 (HFN)	49
5.6	変化点検知 (ONI)	49
5.7	Total Return	54
5.8	ベンチマークに対する各手法の比較	58
6.1	CA-SSAAM の概要	63
6.2	informer	65
6.3	センチメントシグナルと因果情報の関係	69
6.4	極性指標の相関係数	71
6.5	変化点検知 (AKBR)	74

6.6	変化点検知 (HFN) . . . . .	74
6.7	変化点検知 (ONI) . . . . .	74
6.8	Total Return . . . . .	79



# 表一覧

3.1 極性分類の方法 . . . . .	13
4.1 極性分類の方法 . . . . .	19
4.2 Augmented Dickey-Fuller test . . . . .	24
4.3 VAR-LiNGAM による因果推論 . . . . .	24
4.4 変化点検知の評価 . . . . .	26
4.5 アルゴリズムの選択 (5 レジーム) . . . . .	28
4.6 アルゴリズムの選択 (10 レジーム) . . . . .	28
4.7 バックテスト (SSAAM) . . . . .	29
4.8 バックテスト (Comparison) . . . . .	30
5.1 極性分類の方法 . . . . .	38
5.2 データの概要 . . . . .	44
5.3 Augmented Dickey-Fuller test . . . . .	45
5.4 VAR-LiNGAM による因果推論 (CNN) . . . . .	46
5.5 VAR-LiNGAM による因果推論 (HFN) . . . . .	47
5.6 VAR-LiNGAM による因果推論 (ONI) . . . . .	47
5.7 変化点検知の評価 . . . . .	48
5.8 バックテスト (MA-SSAAM) . . . . .	56
6.1 極性分類の方法 . . . . .	65

6.2	データの概要 . . . . .	71
6.3	Augmented Dickey-Fuller test . . . . .	72
6.4	VAR-LiNGAM による因果推論 (AKBR) . . . . .	72
6.5	VAR-LiNGAM による因果推論 (HFN) . . . . .	72
6.6	VAR-LiNGAM による因果推論 (ONI) . . . . .	73
6.7	変化点検知の評価 . . . . .	74
6.8	バックテスト (CA-SSAAM) . . . . .	78

# 第1章 はじめに

## 1.1 本研究の背景

金融領域におけるポートフォリオとは、分散投資を目的とした金融資産の組み合わせを指す。ポートフォリオのアセットアロケーションとは、投資家の目標やリスク許容度などに応じて最適な資産の配分を決定することを指す。

アセットアロケーションの研究は、伝統的に数理最適化の文脈で活発に行われてきた。例えば、ポートフォリオ収益率の平均と分散を考慮する平均-分散モデル [1] や、リスク指標 Conditional Value at Risk (CVaR) を用いた CVaR 最適化モデル [2] などがある。

このような先行研究においては、以下の課題が存在する。

- 伝統的なアセットアロケーションのアルゴリズムは、数理的には美しいが、現実世界のリーマンショックやコロナショックなど急激な市場の変化に必ずしも耐えられていない。
- 伝統的なアセットアロケーションでは、資産運用の全期間同じアルゴリズムが使われていて、必ずしも現実の市況に適するアーキテクチャとはなっていない。

上記の課題に対処するため、本研究では、オルタナティブデータとレジームスイッチという2つの技術に着目した。オルタナティブデータを選択した理由は、伝統的な金融経済データからは得られない情報が引き出せるからである。レジームスイッチを選択した理由は、時系列データの急激な変動を捉えることができるからである。1.2章-1.4章では、2つの技術の定義づけから出発し、実際に投資戦略に組み込んだ場合に考えられる課題について議論していく。

## 1.2 投資戦略におけるオルタナティブデータの活用と課題

オルタナティブデータとは、投資判断に使われるデータのうち、伝統的に用いられる財務諸表などの一般的な公開情報「以外」のデータ群の総称である。POS データ、経済ニュースの記事、クレジットカードの利用データ、SNS の投稿、衛星画像、ウェブサイトのトラフィック、携帯端末の利用ログ、などが挙げられる。近年、機械学習や自然言語処理の技術が急速に普及し、ビッグデータの利用が加速した。また、アルゴリズム取引の導入が進んだことにより、オルタナティブデータの活用が世界的に注目されることになった。

オルタナティブデータの活用の研究としては次のようなものがある。Yamamoto ら [3] は、景気ウォッチャー調査を Long Short Term Memory (LSTM) で学習し、極性指標を作成している。また、Suzuki ら [4] は、LSTM 等を用いてアナリストレポートから意見文と非意見文を抽出、純利益と株価の予測を行っている。Ueda ら [5] は、GPS 型人流データと、Variational Autoencoder (VAE) をはじめとする複数の深層学習アルゴリズムを用いて、自動車サプライチェーン異常指数を作成した。Suimon ら [6] は、衛星観測データと、Elastic Net などを使用し、消費動向の計測モデルを作成した。Taguchi ら [7] は、極性指標が既存の経済指標よりも先行性を持つことを実証している。

投資戦略にオルタナティブデータを用いる際の課題として次の2点がある。

- そもそもオルタナティブデータをアセットアロケーションの文脈で使用した先行研究がほとんど存在しないこと。
- アセットアロケーションでは金融時系列データを組み合わせる際の投資比率を計算するので、オルタナティブデータを何らかの方法で最適化アルゴリズムの外からフレームワークに組み込む工夫が必要であること。

## 1.3 投資戦略におけるレジームスイッチの活用と課題

経済・金融情報を含む時系列データの中には、各国の景気や経済政策、または国際情勢の変化に応じて、傾向が大きく変化しているようなものが多い。例えば、コロナショック後は、各国の経済活動が回復しつつあるが、ロックダウンなどで物理的な供給制約が発生したため、インフレ率の上昇を招いた。経済・金融情報を含む時系列データは、経済変

数間の関係に応じて少なからず変化するため、好況や不況、強気や弱気などといった「背後にある市場の見えざる状態」が存在している。このような状態をレジーム (Regime) と呼び、状態の変化をレジームスイッチ (Regime Switch) と呼ぶ。加えて、この状態の変化を数理的に表現したモデルをレジームスイッチングモデル (Regime Switching Model) と呼ぶ。

レジームスイッチングモデルを考える際のポイントは状態をどのように定義するかである。レジームスイッチングモデルにおいて、状態を定義するには2つの方法がある。1つ目は、状態が観測可能な変数によって決まるモデルである。その代表的なものとして閾値モデル (Tong [8] を参照) や平滑推移モデル (Franses & van Dijk [9] を参照) が有名である。2つ目は、状態が観測不可能な変数によって決まるモデルである。その代表的なものは Markov Switching Model である。後者は Hamilton [10] によって景気循環の構造がうまく分析できるようになったため、経済・金融分野での応用が広がった。近年, Komatsu & Makimoto [11] や Komatsu & Makimoto [12] など、レジームの変化を投資戦略に組み込むことで、より多くのリターンを獲得しようとする研究もある。

投資戦略にレジームスイッチを用いる際の課題としては次の2点がある。

- 先行研究において、算出された市況の変化点が、投資戦略の中に効果的に織り込まれていないこと。
- 先行研究において、他のポートフォリオ最適化戦略と比べて、レジームスイッチを織り込んだ投資戦略の有用性が十分に実証できていないこと。

本研究では、上記の課題に対処するため、レジームスイッチを用いた投資戦略とオルタナティブデータを融合させた新たなアプローチを開発する。

## 1.4 オルタナティブデータとレジームスイッチ活用の鍵

本研究では、1.2 章と 1.3 章で明らかになった問題点を克服するため、以下の先行研究に着目した。

- Ito ら [13] の、市場環境に応じて投資戦略を切り替える手法に関する研究。

- Taguchi ら [7] の, テキストデータから作成した極性指標が, 既存の経済指標に対してグレンジャー因果性を持つことを実証した研究.
- Taguchi ら [14] の, 極性指標とレジームスイッチングモデルが, 株式のペアトレーディングシミュレーションに有効であることを示した研究.

Ito ら [13] では, 状況に応じてアルゴリズムをスイッチする手法についてのユースケースを得た. Taguchi ら [7] では, 作成した極性指標が, 既存のいくつかの経済指標に対して先行するという示唆を得た. Taguchi ら [14] では, 極性指標の変化点をリバランス (構成銘柄における投資比率変更) のシグナルとして使用できるという示唆を得た. 本研究では Taguchi ら [14] の研究をより実践的に拡張し, 機動的かつ効果的なアセットアロケーション戦略を構築することを目指す.

## 1.5 本研究の目的

本研究の目的は以下の通りである.

1. オルタナティブデータから算出した変化点 (レジームスイッチの転換点) が, リバランスのシグナルとして有効であることを示すこと.
2. 本研究で提案するフレームワークが, 多期間において, 下方リスクを動的に最小化するフレームワークになっていることを示すこと.
3. 因果推論の結果が, アセットアロケーションに対して一定の効果があることを示すこと.

## 1.6 本研究における新規性

本研究における新規性は以下の通りである.

1. オルタナティブデータを利用した新たな経済指標を開発したこと.
2. レジームスイッチを利用した投資シグナルを開発したこと.
3. 因果推論を用いた新しい銘柄選択技術を開発したこと.

## 1.7 本研究論文の構成

1章では、本研究の動機と位置づけを述べている。1.1章では、伝統的なアセットアロケーションにおける課題と着目した技術について述べた。1.2章では、オルタナティブデータの定義づけと、投資戦略に適用する際の課題について述べた。1.3章では、レジームスイッチの定義づけと、投資戦略に適用する際の課題について述べた。1.4章では、先行研究からオルタナティブデータとレジームスイッチを投資戦略に適用する際のアイデアを提示した。1.5章では、本研究の目的について述べた。1.6章では、本研究の新規性について述べた。1.7章では、本研究論文の構成を述べた。

2章では、本研究と密接にかかわる先行研究について述べた。2.1章では伝統的なアセットアロケーション、2.2章では機械学習を用いたアセットアロケーション、2.3章ではテキストマイニングを用いた経済指標の作成、2.4章ではTransformerベースの時系列予測、2.5章では因果推論とその応用、2.6章では時系列変化点検知とその応用、に分けて記載している。

3章では、提案手法について述べた。3.1章では、本研究のベースとなるフレームワークを5つのステップに分けて記載した。3.2章では、本研究のアーキテクチャを図示した。本フレームワークの派生形については、4章、5章、6章で述べている。

4章では、株式ポートフォリオのアセットアロケーション戦略を構築した。4.1章では、本章の研究背景、仮説、貢献について述べている。4.2章では、極性指標の作成からポートフォリオの最適化まで実装手順を記載した。4.3章では、ポートフォリオのバックテストを行った。本研究のバックテストとは、過去のデータを用いて、売買ルールがどの程度のパフォーマンスを発揮するかをシミュレーションすることであり、データセット、前提条件、提案手法及び比較手法の説明、評価方法の定義、結果、まで記載した。4.4章では、結果の考察を行い、4.5章では、まとめを行った。

5章では、4章の株式ポートフォリオのアセットアロケーション戦略を多クラス資産（株や債券、金などの金融資産の組み合わせ）に拡張した。5.1章では、本章の研究背景、仮説、貢献について述べた。5.2章では、極性指標の作成からポートフォリオの最適化まで実装手順を記載した。5.3章では、ポートフォリオのバックテストを行った。データセット、前提条件、提案手法及び比較手法の説明、評価方法の定義、結果、まで記載した。5.4章では、結果の考察を行った。5.5章では、まとめを行った。

6章では、暗号資産を用いたアセットアロケーション戦略を構築した。近年では、フィンテック (FinTech) 技術の発展により、暗号資産を新たな資産クラスとして扱い、価格予測や最適流動化戦略などをターゲットにする研究が盛んになってきている [15, 16]。本研究では、暗号資産でポートフォリオを作成し、提案戦略の有効性を実証した。6.1章では、本章の研究背景、仮説、貢献について述べた。6.2章では、極性指標の作成からポートフォリオの最適化まで実装手順を記載している。6.3章では、ポートフォリオのバックテストを行った。データセット、前提条件、提案手法及び比較手法の説明、評価方法の定義、結果、まで記載した。6.4章では、結果の考察を行い、6.5章でまとめを行った。

7章では、本研究における全体の総括と今後の発展の方向性について述べた。7.1章では目的の振り返り、7.2章では全体を通しての考察、7.3章では今後の展望を述べている。



## 第2章 先行研究

### 2.1 伝統的なアセットアロケーション

伝統的なアセットアロケーションの研究には以下のようなものがある。平均-分散モデル [1] は、ポートフォリオ収益率の平均と分散のみを考慮する最適化モデルである。CVaR 最適化 [2] は、リスク指標 CVaR を用いた最適化モデルである。CVaR はある確率水準におけるポートフォリオの平均的な損失を表すリスク指標である。Entropic Value at Risk (EVaR) 最適化 [17] は、リスク指標 EVaR を用いた最適化モデルである。EVaR は VaR と CVaR の上限を示すリスク指標である。Conditional Drawdown at Risk (CDaR) 最適化 [18] は、リスク指標 CDaR を用いた最適化モデルである。CDaR はドローダウン（最大資産からの下落率）に基づくリスク指標である。

### 2.2 機械学習を用いたアセットアロケーション

機械学習を用いたアセットアロケーションの研究には、以下のようなものがある。2 段階深層学習モデルを用いた予測に基づく上場投資信託（Exchange Traded Funds, ETF）ポートフォリオ管理手法 [19], XGBoost と改良型ホタルアルゴリズム（Improved Firefly Algorithm, IFA）を用いたポートフォリオ最適化モデル [20], 平均-分散モデルと深層学習を組み合わせたフレームワーク [21, 22] などが代表的である。また、リターンの残差項の分布を予測するネットワークを構築し、予測分布の情報をもとにポートフォリオを設計する手法 [23] や、Trader-Company 法と呼ばれるトレーダーの役割を模倣した進化的計算モデル [24] などもある。また、Liu ら [25] により、Deep Deterministic Policy Gradient (DDPG) [26], Advantage Actor-Critic (A2C) [27], Proximal Policy Optimization (PPO) [28], Soft Actor-Critic (SAC) [29–31] などの強化学習を使ったアセットアロケーションフレームワークが提案されている。本研究では、アセットアロケーションの枠組みでオルタナティブデー

タとレジームスイッチを使用している点に新規性がある。

## 2.3 テキストマイニングを用いた経済指標の作成

テキストマイニングを用いた経済指標の作成の研究には, EcoRevs や Long Short-Term Memory (LSTM) を用いた新しいアーキテクチャ [32] の研究, 新聞記事及び景気動向調査と双方向 LSTM を用いた極性指標作成の研究 [33], テキストデータから景況感指数を開発した研究 [33, 34], などがある。また, アナリストレポートのレート情報を用いた経済指標作成に関する研究も行われている [4, 7, 14, 35]。本研究では, Masked Language Modeling (MLM) Score (3.2.2 章を参照) を用いて極性指標を作成し, テキストデータのトーンを指標化している点に新規性がある。

## 2.4 Transformer ベースの時系列予測

初期における Transformer ベースの時系列予測の研究 [36–38] は, 普遍的な Transformer を使用していたため, 長期時系列予測 (Long Sequence Time-series Forecasting, LSTF) の文脈では精度が不十分であった。一方で, 本研究の 6 章で用いる informer [39] は, self-attention におけるスパース性に注目し, LSTF 問題を克服している。

## 2.5 因果推論とその応用

因果推論の研究は次の 3 つのアプローチに分類できる。1 つ目は, 2 つのノード間のエッジの存在を確立するために条件付き独立性検定を用いる制約ベースのアプローチである [40, 41]。2 つ目は, 特定のスコア関数を最適化するためにいくつかの探索工程を使用するスコアベースのアプローチである [42–44]。3 つ目は, 特定のノードの変数を親関数として表現する構造的因果モデルベースのアプローチである [45–49]。金融分野においては, 因果チェーンとも呼ばれる, 企業間の業績に関する因果関係を結びつけるネットワークに関する研究が行われている [50, 51]。本研究では, Vector Autoregression Linear Non-Gaussian

Acyclic Model (VAR-LiNGAM) を用いて, テキストデータから作成された極性指標とポートフォリオとの間のリード・ラグ関係<sup>1</sup>を分析するという点に新規性がある.

## 2.6 時系列変化点検知とその応用

変化点検知とは, 時系列に並んだ信号の変化点を見つけることであり, 工業的な品質管理を目的として研究が開始された [52, 53]. 現在では, 信号処理 [54–56] だけでなく, 音声認識 [57–60], バイオインフォマティクス [61–63], 気候学 [64, 65] などの様々な分野に応用されている. 一方で, 金融時系列分析に変化点検知アルゴリズムを適用した研究がいくつかある [66–69]. 本研究では経済レジームの推定に3つのアルゴリズムを用いた. 4章では Binary Segmentation Search, 5章では Window Sliding Segmentation, 6章では ChangeFinder [70] を用いた.

---

<sup>1</sup>時系列データの間に時間差において相関関係が現れる現象を指す.

## 第3章 提案手法

### 3.1 提案手法の概要

本章ではアーキテクチャの基本形を示し, 3.2 章ではアーキテクチャの詳細を示す. 加えて, 4 章, 5 章, 6 章において, 各目的に応じて改良したアーキテクチャを示す.

本研究では, 以下のステップで投資戦略を構築した.

- **Step 1 (ヒストリカルデータの抽出):** データソースから過去の時系列データを日次で抽出する.
- **Step 2 (極性指標の作成):** MLM Score を用いてテキストデータを採点する. さらに, 同じデータから四分位数を算出し, 四分位数範囲に応じてポジティブ, ネガティブ, ニュートラルの 3 値分類を行う. 算出された値は日次集計される. 6 章では極性分類の前に informer による時系列予測を行う.
- **Step 3 (先行効果の実証):** 統計的因果推論を用いて, テキストデータが各資産に対して先行性を持つかを実証する. ここでは, Step 2 で作成した極性指標を使用し, 各銘柄と極性指標を用いて因果推論を行う. アルゴリズムは VAR-LiNGAM を使用する.
- **Step 4 (変化点検知):** 変化点検知アルゴリズムを用いて極性指標のレジーム変化点を計算する.
- **Step 5 (ポートフォリオ最適化):** ポートフォリオのリバランスは, 定期リバランスに加え Step 3 で作成された変化点に基づいて実行される.

## 3.2 提案手法のアーキテクチャ

本研究で使⽤したアーキテクチャは図 3.1 に示すとおりである.

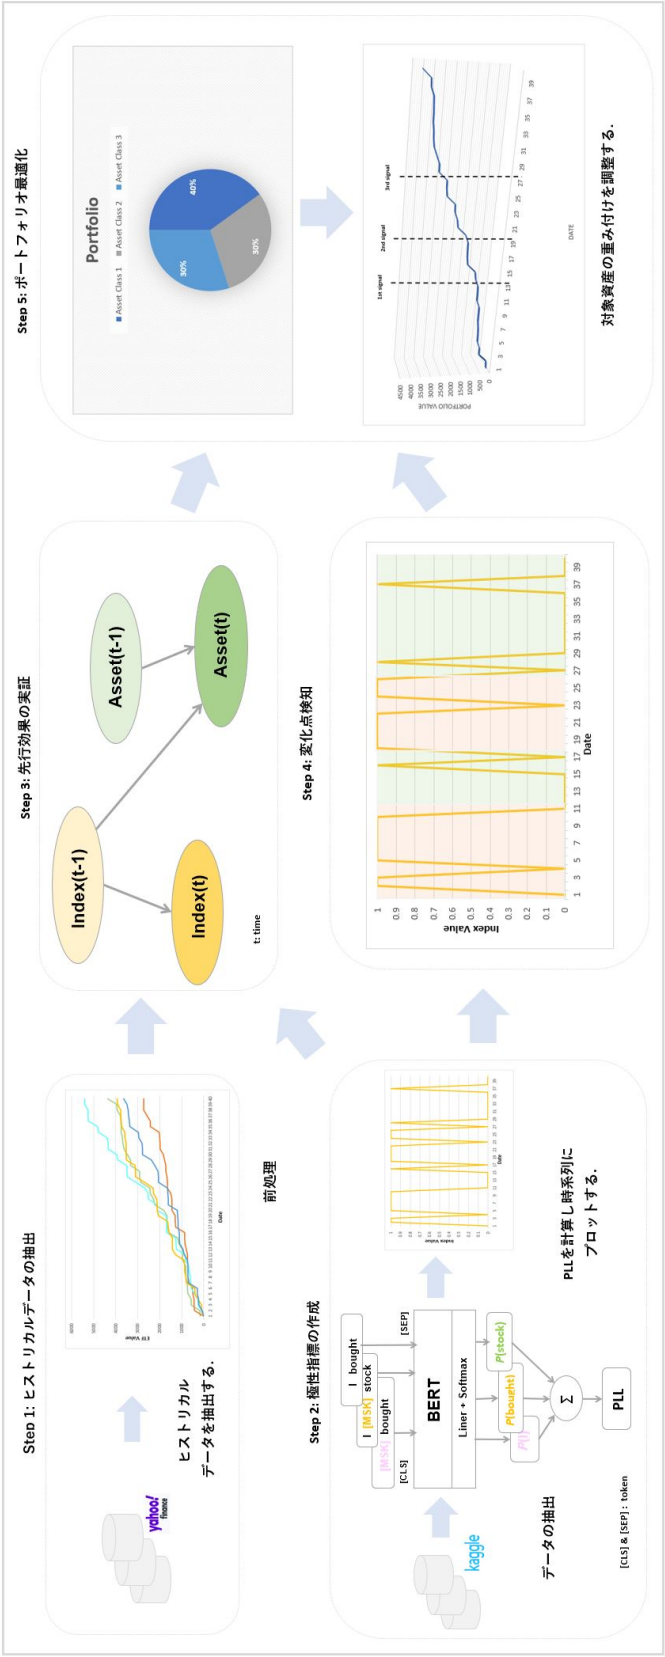


図 3.1: 提案手法の概要

本研究で使用するアルゴリズムの概要を以下に述べる.

### 3.2.1 ヒストリカルデータの抽出

データソースから過去の時系列データを日次で入手する. 使用するデータソースの詳細は後述するが, 本研究における多クラス資産の配分については, 複数の金融商品データを使用した.

### 3.2.2 極性指標の作成

極性指標の作成には Pseudo-Log-Likelihood scores (PLL) を用いた. PLL は Salazar ら [71] が提案した Masked Language Models (MLM) に相当する確率論的言語モデルである. MLM は両方向の単語を予測することで事前学習が行われるため, 従来の確率的言語モデルでは扱えない. これに対し, PLL は各単語をマスクして予測したときの条件付き確率の対数尤度の和で表されるため, 文の自然さを高いレベルで判定することができる. トークン  $\psi_t$  を [MASK] と置き換え, 過去と現在のトークン  $\Psi_{\setminus t} = [\psi_1, \psi_2, \dots, \psi_t]$  が予測される.  $t$  は時間,  $\Theta$  はモデルパラメータ,  $P_{MLM}(\cdot)$  は各文章トークンの確率を表す. MLM には Devlin ら [72] が提案した BERT を選択した.

$$\text{PLL}(\Psi) := \sum_{t=1}^{|\Psi|} \log_2 P_{MLM}(\psi_t | \Psi_{\setminus t}; \Theta) \quad (3.1)$$

前処理を行ったテキストデータを1文ずつPLLでスコアリングする. 1文ずつスコアリングしたデータに対して, 四分位範囲を算出する. 極性分類の方法は下図を参照.

表 3.1: 極性分類の方法

Classification Method	Sentiment Score
3rd quartile < PLLs	1 (positive)
1st quartile $\leq$ PLLs $\leq$ 3rd quartile	0 (neutral)
1st quartile > PLLs	-1 (negative)

極性を付与したスコアを時系列に集計する.

### 3.2.3 先行効果の実証

先行効果の実証には Hyvärinen ら [73] によって提案された統計的因果推論モデルである VAR-LiNGAM を使用する.

VAR-LiNGAM は以下の手順で実施される. まず, ラグタイムから現在までの変数間の因果関係に対して, VAR モデルを適用する. 次に, 現在時刻の変数間の因果関係については, 上記の VAR モデルの残差を用いて LiNGAM 推論を行う. 詳細は Algorithm1 を参照. 表記法は Hyvärinen ら [73] 及び Ciarli ら [74] に基づく. 最後に, 極性指標がポートフォリオに対し先行性を持つかを確認する.

---

#### Algorithm 1 VAR-LiNGAM

---

- 1: VAR モデルから行列  $\mathbf{D}$  の推定値  $\hat{\mathbf{D}}$  を求める.
  - 2:  $\hat{\mathbf{V}} = \mathbf{P}\hat{\mathbf{E}}$  を求める.  $\hat{\mathbf{V}}$  は推定 VAR 誤差項の行列,  $\mathbf{P}$  は係数行列である.  $\hat{\mathbf{E}}$  の成分が  $\hat{\mathbf{V}}$  の推定独立成分となる. ここで, 非ガウス性と統計的独立性を検証する.
  - 3: 行列  $\mathbf{Q}$  を  $\mathbf{Q} = \mathbf{P}^{-1}$  と定義する.  $\sum_i 1/|\mathbf{Q}_{ii}|$  を最小化する  $\mathbf{Q}$  の置換行列  $\tilde{\mathbf{Q}}$  を求める. また  $i$  は整数である.
  - 4:  $\tilde{\mathbf{Q}}$  の各行を対角要素で割り, 対角成分がすべて 1 の行列  $\hat{\mathbf{Q}}$  を得る.
  - 5: 因果関係を表す係数行列  $\mathbf{B}$  の推定値  $\hat{\mathbf{B}}$  を求める.  $\hat{\mathbf{B}}$  は,  $\hat{\mathbf{B}} = \mathbf{I} - \hat{\mathbf{Q}}$  と定義できる.  $\mathbf{I}$  は単位行列で,  $\hat{\mathbf{Q}}$  は同時および遅行係数を表す行列である.
  - 6:  $\mathbf{Z}\tilde{\mathbf{B}}\mathbf{Z}^\top$  を下三角形に近似する置換行列  $\mathbf{Z}$  を求める.
  - 7: 最後に,  $\hat{\mathbf{Q}}$  の推定値を計算し,  $\hat{\mathbf{Q}} = (\mathbf{I} - \hat{\mathbf{B}})\hat{\mathbf{D}}$  を用いて遅効性の推定を行う.
- 

VAR-LiNGAM によって推論される因果グラフの式は以下の通りである.

$$\mathbf{x}(t) = \sum_{\tau=1}^T \mathbf{B}_\tau \mathbf{x}(t - \tau) + \mathbf{e}(t) \quad (3.2)$$

ここで  $\mathbf{x}(t)$  は時刻  $t$  における変数のベクトル,  $\tau$  は遅延時間である.  $T$  は満期日を表す. また,  $\mathbf{B}_\tau$  は変数  $\mathbf{x}(t - \tau)$  の因果関係を表す係数行列であり,  $\mathbf{e}(t)$  は外的影響を示す擾乱項である.  $\mathbf{B}_\tau$  を推定する際, 従来の推定原理では独立になる変数を推定できず, モデルを



一意に同定することができなかったが, VAR-LiNGAMでは非ガウス性を仮定することで,  $e(t)$  の要素が互いに独立であることを示せるため, モデルを一意に同定することができる.

本章における「先行性がある状態」とは, テキストから生成した極性指標から金融時系列への方向に因果関係があり, かつ因果推論の総合効果<sup>2</sup>のスコアがプラスであることを指す. この場合, 先行する時間スケールは1ポイント先(直近の未来)である.

### 3.2.4 変化点検知

変化点検知について, 4章では Binary Segmentation Search, 5章では Window Sliding Segmentation, 6章では, ChangeFinder [70] を用いた. 詳細説明は各章に譲る.

### 3.2.5 ポートフォリオ最適化

ポートフォリオ最適化については, 4章では EVaR 最適化アルゴリズム, 5章と6章では リスク・パリティ・ポートフォリオ (RPP) 最適化アルゴリズムを使用する. 詳細説明は各章に譲る.

---

<sup>2</sup>因果推論において, 原因が結果に対してもたらす全体の因果関係の強さを指す.

## 第4章 テキストデータを用いた株式アセットアロケーション戦略

### 4.1 はじめに

#### 4.1.1 背景

本章では、テキストデータが株式を用いた戦術的アセットアロケーションに有用であることを実証する。これは自然言語処理と統計的因果推論を用いて投資シグナルを作成することで実現できる。機械学習を用いた投資手法については、数多くの研究が行われている。特に、投資シグナルの導出や投資比率の算出 [20, 23, 24] など、アセットアロケーションに関する研究が活発化している。本章では、外的要因によって株価やポートフォリオ価格が急変するポイント、すなわちレジームスイッチの転換点に注目する。ファイナンス理論では、レジームは拡大、後退、強気、弱気といった目に見えない市場の状態を指すが、この変化を投資戦略に組み込み、マーケットの  $\alpha^3$  を獲得しようとする研究もある [11, 12, 14]。

#### 4.1.2 仮説

近年、人工知能（AI）の爆発的な発展を背景に、特に金融・経済分野で従来のデータとともに経済予測や投資戦略に広く活用され始めたオルタナティブデータが、世界的に注目されている。その中でもテキストデータの汎用性は高く、自然言語処理による経済極性指標の作成に関する研究 [7, 33] や、テキストデータからの因果関係情報の抽出 [75] が注目されている。このような背景から、今後のレジームの変化点を算出するために、以下の仮説を立てる。

---

<sup>3</sup>市場平均に対して得られた超過リターンを指す。

- テキストデータから計算される極性指標には、株式などの従来の金融時系列データに先行する情報が含まれている。
- テキストデータから計算される極性指標は、ポートフォリオをリバランスするためのシグナルとなり、このシグナルによりポートフォリオのパフォーマンスを向上させることができる。
- 極性指標によって作成された変化点に従って、リスク最小化最適化戦略とリターン最大化最適化戦略を切り替えることで、ポートフォリオのパフォーマンスを向上させることができる。

### 4.1.3 貢献

テキストデータを用いた投資戦略は、比較戦略よりも優れたパフォーマンスを生み出すことが期待される。これは、自然言語処理技術を用いてテキストデータから極性指標を生成し、統計的因果推論を用いて極性指標の先行性を実証し、変化点検知技術を用いて極性指標のレジーム変化点を算出し、変化点に従って複数の数理最適化モデルを用いたポートフォリオのリバランスを行うことで実現可能である。本章の貢献は以下の通りである。

- テキストマイニング技術を用いた汎用性の高いアセットアロケーションフレームワークを提案した。
- テキストデータを用いたレジームスイッチの変化点推定が、アクティブ運用<sup>4</sup>にとって重要であることを実証した。
- 因果推論の結果が資産運用のパフォーマンス向上の一助になることを実証した。

## 4.2 提案手法

本稿では提案手法を Sentiment Signal-based Asset Allocation Method with Causality Information (SSAAM) と呼称する。

---

<sup>4</sup>目安となる指数（ベンチマーク）を上回る投資収益を目指すスタイル。

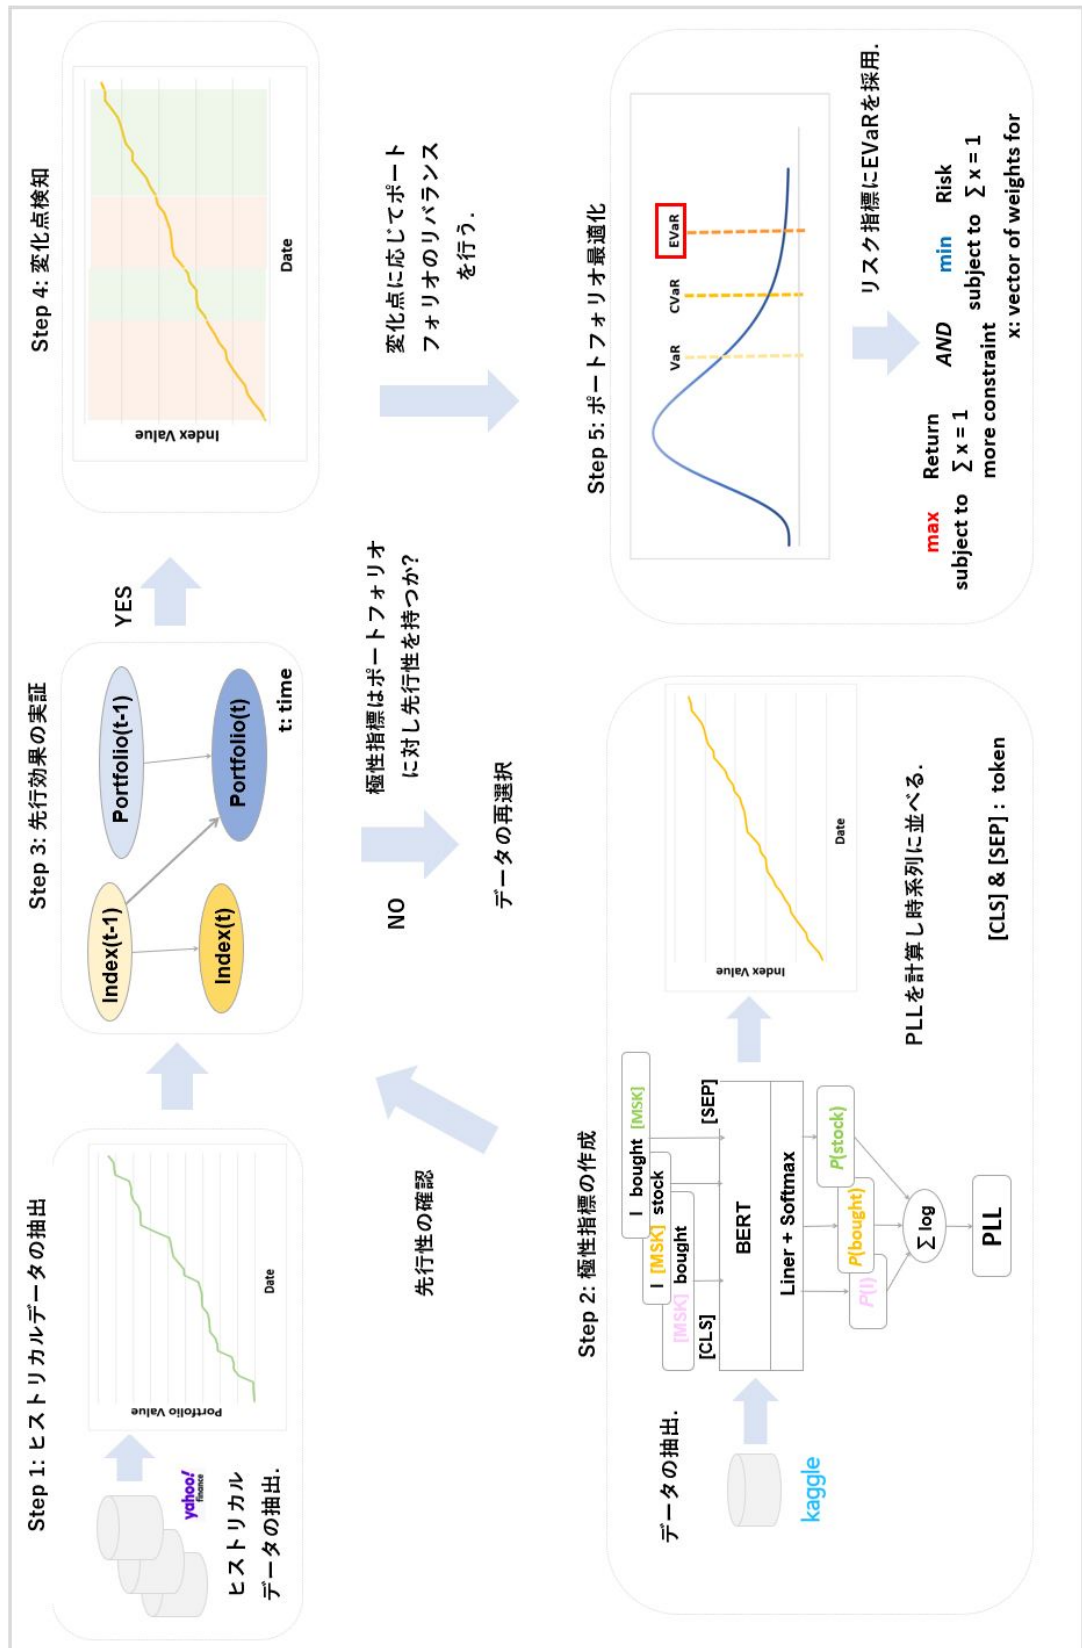


図 4.1: SSAAM の概要

本章で使⽤したアーキテクチャは図 4.1 に示すとおりである.

### 4.2.1 ヒストリカルデータの抽出

データソースから過去の時系列データを⽇次で⼊⼿した. ⽤するデータソースの詳細は後述するが, 本章における資産配分については, 複数の⾦融商品データを使⽤した.

### 4.2.2 極性指標の作成

極性指標の作成には Pseudo-Log-Likelihood scores (PLL) を⽤いている. PLL は Salazar ら [71] が提案した Masked Language Models (MLM) に相当する確率論的⾔語モデルである. MLM は両⽅向の単語を予測することで事前学習が⾏われるため, 従来の確率的⾔語モデルでは扱えない. これに対し, PLL は各単語をマスクして予測したときの条件付き確率の対数尤度の和で表されるため, 文の⾃然さを⾼いレベルで判定することができる. トークン  $\psi_t$  を [MASK] と置き換え, 過去と現在のトークン  $\Psi_{\setminus t} = [\psi_1, \psi_2, \dots, \psi_t]$  が予測される.  $t$  は時間,  $\Theta$  はモデルパラメータ,  $P_{MLM}(\cdot)$  は各⽂章トークンの確率を表す. MLM には Devlin ら [72] が提案した BERT を選択した.

$$\text{PLL}(\Psi) := \sum_{t=1}^{|\Psi|} \log_2 P_{MLM}(\psi_t | \Psi_{\setminus t}; \Theta) \quad (4.1)$$

前処理を⾏ったテキストデータを 1 文ずつ PLL でスコアリングする. 1 文ずつスコアリングしたデータに対して, 四分位範囲を算出する. 極性分類の方法は下図を参照.

表 4.1: 極性分類の方法

Classification Method	Sentiment Score
3rd quartile < PLLs	1 (positive)
1st quartile $\leq$ PLLs $\leq$ 3rd quartile	0 (neutral)
1st quartile > PLLs	-1 (negative)

極性を付与したスコアを時系列に集計する.

### 4.2.3 先行効果の実証

先行効果の実証には Hyvärinen ら [73] によって提案された統計的因果推論モデルである VAR-LiNGAM を使用する. 表記法は Hyvärinen ら [73] に従う. VAR-LiNGAM によって推論される因果グラフの式は以下の通りである.

$$\mathbf{x}(t) = \sum_{\tau=1}^T \mathbf{B}_{\tau} \mathbf{x}(t - \tau) + \mathbf{e}(t) \quad (4.2)$$

ここで  $\mathbf{x}(t)$  は時刻  $t$  における変数のベクトル,  $\tau$  は遅延時間である.  $T$  は満期日を表す. また,  $\mathbf{B}_{\tau}$  は変数  $\mathbf{x}(t - \tau)$  の因果関係を表す係数行列であり,  $\mathbf{e}(t)$  は擾乱項である. VAR-LiNGAM は以下の手順で実施される. まず, ラグタイムから現在までの変数間の因果関係に対して, VAR モデルを適用する. 次に, 現在時刻の変数間の因果関係については, 上記の VAR モデルの残差を用いて LiNGAM 推論を行う. 最後に, 極性指標がポートフォリオに対し先行性を持つかを確認する.

### 4.2.4 変化点検知

Binary Segmentation Search [76, 77] は, 貪欲な逐次計算アルゴリズムである. 表記法は Truong ら [78] に従う. 最初の変化点の位置で信号を2つに分割し, 得られた部分信号に対して, 停止基準に達するまで同様の操作を繰り返す. 詳細は Algorithm 2 のように表される. 多変量で非定常<sup>5</sup>な確率過程に従う信号  $y = \{y_s\}_{s=1}^S$  を定義する. これは  $S$  個のサンプルを持つ.  $L$  は変化点のリストを指す.  $s$  は変化点の値を指す.  $G$  は順序付き変化点のリストを指す. 信号  $y$  が与えられた場合の  $(b-a)$ -sample long sub-signal  $\{y_s\}_{s=a+1}^b$ ,  $(1 \leq a < b \leq S)$  をシンプルに  $y_{a,b}$  と表記する. 記号ハットが付いた文字は計算された値を指す. その他の表記はアルゴリズム中のコメントに記す.

<sup>5</sup>時系列における確率過程で, 時間に依存せずどの時点でも性質が同じことを定常といい, それ以外を非定常という.

---

**Algorithm 2** Binary Segmentation Search

---

**Input:** signal  $y = \{y_s\}_{s=1}^S$ , cost function  $c(\cdot)$ , stopping criterion.Initialize  $L \leftarrow \{\}$ .

▷ Estimated breakpoints

**Repeat** $k \leftarrow |L|$ .

▷ Number of breakpoints

 $s_0 \leftarrow 0$  and  $s_{k+1} \leftarrow S$ 

▷ Dummy variables

**if**  $k > 0$  **then**Denote by  $s_i (i = 1, \dots, k)$  the elements (in ascending order) of  $L$ , ie  $L = \{s_1, \dots, s_k\}$ .**end if**Initialize  $G$  a  $(k+1)$ -long array.

▷ List of gains

**for**  $i = 0, \dots, k$  **do** $G[i] \leftarrow c(y_{s_i, s_{i+1}}) - \min_{s_i < s < s_{i+1}} [c(y_{s_i, s}) + c(y_{s, s_{i+1}})]$ .**end for** $\hat{i} \leftarrow \arg \max_i G[i]$  $\hat{s} \leftarrow \arg \min_{s_i < s < s_{i+1}} [c(y_{s_i, t}) + c(y_{s, s_{i+1}})]$ .

▷ Estimated change points

 $L \leftarrow L \cup \{\hat{s}\}$ **Until** stopping criterion is met.**Output:** set  $L$  of estimated breakpoint indexes.

---

### 4.2.5 ポートフォリオ最適化

Entropic Value at Risk (EVaR) は, チェルノフの不等式から導かれる Value at Risk (VaR) と Conditional Value at Risk (CVaR) の上界<sup>6</sup>にあるリスク尺度である [79, 80]. EVaR は, 確率最適化問題に組み込んだ場合, CVaR などの他のリスク指標と比較して計算がしやすいという利点がある [80]. EVaR の定義は以下の通りである.

$$\mathbf{EVaR}_\alpha(X) := \min_{z>0} \left\{ z \ln \left( \frac{1}{\alpha} M_X \left( \frac{1}{z} \right) \right) \right\} \quad (4.3)$$

$X$  は確率変数,  $M_X$  はモーメント母関数,  $\alpha$  は有意水準,  $z$  は変数である. Cajas [17] は EVaR のための一般的な凸計画法のフレームワークを提案した. 4.2.4 章で分類された領域に応じて, 以下の2つの最適化戦略をスイッチする.

- **Minimize risk optimization:** ある  $\mu$  ( $\hat{\mu}$ ) が与えられたとき, EVaR を最小化する制約が課された凸最適化問題である.

$$\begin{aligned} & \text{minimize} && q + z \log_e \left( \frac{1}{T\alpha} \right) \\ & \text{subject to} && \mu w \geq \hat{\mu} \\ & && \sum_{i=1}^N w_i = 1 \\ & && z \geq \sum_{j=1}^T u_j \\ & && (-r_j w^\top - q, z, u_j) \in K_{exp} \quad (\forall j = 1, \dots, T) \\ & && w_i = 0 \quad (\forall i = 1, \dots, N) \end{aligned} \quad (4.4)$$

- **Maximize return optimization:** ある  $EVaR(\widehat{EVaR})$  が与えられたときに, 期待リターンを最大化する制約が課された凸最適化問題である.

<sup>6</sup>実数全体からなる集合の部分集合に対し, その部分集合のどんな元 (集合を構成する個々の数学的対象) よりも大きい等しい実数が存在するとき, その実数のことを上界と呼ぶ.



$$\begin{aligned}
& \text{maximize} && \mu w^\top \\
& \text{subject to} && q + z \log_e \left( \frac{1}{T\alpha} \right) \geq \widehat{EVaR} \\
& && \sum_{i=1}^N w_i = 1 \\
& && z \geq \sum_{j=1}^T u_j \\
& && (-r_j w^\top - q, z, u_j) \in K_{exp} \quad (\forall j = 1, \dots, T) \\
& && w_i = 0 \quad (\forall i = 1, \dots, N)
\end{aligned} \tag{4.5}$$

ここで,  $q, z, u$  は変数,  $K_{exp}$  は Exponential Cone,  $T$  は観測数である.  $w$  は  $N$  個の資産における重みベクトル,  $r$  はリターン行列,  $\mu$  は資産における平均ベクトルとして定義される. 表記法は Cajas [17] に従う.

## 4.3 実験と結果

### 4.3.1 データセットの概説

本章のデータは2種類使用した.

- **Stock Data:** Yahoo!Finance<sup>7</sup>が提供する日次株価データを使用した. 使用した銘柄は NYSE FANG+ 指数の構成銘柄である: Facebook, Apple, Amazon, Netflix, Google, Microsoft, Alibaba, Baidu, NVIDIA, Tesla が選ばれた. これらのデータには, 調整後の終値が使用されている. このデータの期間は2015年1月から2019年12月までである.
- **Financial News Data:** データ分析プラットフォームである Kaggle<sup>8</sup>が提供する日次の金融ニュースアーカイブを使用した. このデータは, NYSE/NASDAQ に上場し

<sup>7</sup><https://finance.yahoo.com/>

<sup>8</sup><https://www.kaggle.com/>

ている米国株の過去 12 年間のニュースアーカイブである。このデータは 10 銘柄の  
情報を含むことが確認されている。また、このデータは 9 つの列と 221,513 行で構成  
されており、本章ではタイトルとリリース日の列を使用した。期間は 2015 年 1 月か  
ら 2019 年 12 月までである。

### 4.3.2 バックテストの準備

実験はサンプル内検証である。すべてのデータは、極性指標, VAR-LiNGAM, 変化点の  
推定に使用される。

極性指標の作成は 4.2.2 章に従って行う。Stock Data も Financial News Data も日単位  
であるが、期間を合わせるため、どちらかに空白がある場合は空白を含む行を削除する。

4.2.2 章により極性指標を作成したら、次は 10 銘柄の調整後の終値を合計して株式ポ  
ートフォリオを作成する。ポートフォリオの投資比率は全銘柄一律とした。次に、4.2.3 章の  
VAR-LiNGAM を用いて因果推論を行う。

ここでは、データの定常性を確認するために、Augmented Dickey-Fuller test (ADF) [81]  
を用いる。表 4.2 によると、検定統計量は 0.05 より小さいので、帰無仮説は棄却されるた  
め、データは定常であると言える。

表 4.2: Augmented Dickey-Fuller test

Data	Test Statistic
Financial News Data	-5.09
Stock Data	-0.73

定常性が検証されたので、データは VAR-LiNGAM の入力として使用される。

因果推論の結果は以下のように表される。

表 4.3: VAR-LiNGAM による因果推論

From	To	Causal Graph Value
Index(t-1)	Index(t)	0.39
Index(t-1)	Portfolio(t)	<b>0.11</b>
Portfolio(t-1)	Portfolio(t)	1.00

表 4.3 の値は隣接行列の要素を示す. 下限は 0.05 とした. 結果は, 極性指標が株式ポートフォリオよりも優位にあることを示している. バックテストには Python ライブラリの LiNGAM [73] を用いる.

変化点検知の性能を評価するために, 以下の指標を使用する.

- **Precision:** Precision とは, 正のクラスと予測されたサンプルにどれだけ正しい値が含まれているかの比率である. 変化点検知の文脈では, Precision は以下のように定義される.

$$\text{Precision} := | \text{TP} | / | \{ \hat{s}_l \}_l | \quad (4.6)$$

- **Hausdorff Metric (HM):** HM は最悪の予測誤差を推定する. 変化点検知に関連する研究としては, Boysen ら [82] や Harchaoui & Lévy-Leduc [83] がある.

$$\text{HM} := \max \left\{ \max_m \min_l | s_m - \hat{s}_l |, \max_m \min_l | \hat{s}_m - s_l | \right\} \quad (4.7)$$

$l$  と  $m$  を変数とする. TP は真陽性であり,  $\text{TP} := \{ s_m \mid \exists s_l \text{ s.t. } | s_l - \hat{s}_m < \text{Mar} | \}$  と定義できる.  $\text{Mar}$  はマージンである. 各指標を用いて計算した結果を表 4.4 に示す. BSS は Binary Segmentation Search (4.2.4 章を参照), WSS は Window Sliding Segmentation (5.2.4 章を参照), CF は ChangeFinder (6.2.5 章を参照) を指す. なお, 評価に必要な正しいラベルは著者が手動で付与した.

表 4.4 の結果より, 本章のデータについては Binary Segmentation Search の方が比較優位となるため, Binary Segmentation Search を選択する.

変化点検知の結果得られたレジームを図 4.2 と 4.3 に示す. ポートフォリオの変化点は上昇と下降の 2 種類しかないため, Binomial Segmentation Search のような逐次的な手法を極性指標に用いて作成したシグナルは, ポートフォリオのリバランスに有効であるといえる. 実装には Python ライブラリの ruptures (Truong ら [78]) が使用される. 本章では, レジームを 5 と 10 に分類した結果を使用する.

表 4.4: 変化点検知の評価

Model	Regime	Precision	HM
BSS (Proposed)	5	0.50	<b>45.00</b>
	10	<b>0.78</b>	<b>45.00</b>
WSS (Comparison)	5	0.00	260.00
	10	0.44	155.00
CF (Comparison)	5	0.00	426.00
	10	0.00	626.00




図 4.2: 変化点検知 (5 レジーム)

図 4.2 について、レジームの変化点は、2016 年のパナマ文書の出版、2018 年に起きたトルコによるシリアへの軍事攻撃、2019 年におけるベネズエラ大統領危機、などの重要イベントにそれぞれ重なった。




図 4.3: 変化点検知 (10 レジーム)

図 4.3 について、レジームの変化点は、図 4.2 のイベントに加え、2017 年の核兵器禁止条約の採択、2017 年の米国のユネスコ脱退、などの重要イベントとそれぞれ重なった。

### 4.3.3 バックテストのシナリオ

バックテストの戦略は以下である。バックテストには Python のライブラリ `vectorbt` [84] と `Riskfolio-Lib` [85] を使用した。最適化アルゴリズムとしては、EVaR 最適化のほか、CVaR 最適化、平均-分散モデルも比較対象として使用した。レジーム数は 5 と 10 とした。リバランスのタイミングは、30 日、90 日、180 日とした。バックテスト方法は以下の通りである。CPD-EVaR++ を提案戦略、CPD-EVaR+ を次点戦略として位置づけた。

- **CPD-EVaR++ (Proposed):** リスク最小化・リターン最大化 EVaR 最適化による変化点リバランス＋一定間隔リバランス戦略

- **CPD-EVaR+**: リスク最小化と無制限 EVaR 最適化による変化点リバランス＋一定間隔リバランス戦略
- **EVaR**: 定期 EVaR 最適化リバランス戦略
- **CVaR**: 定期 CVaR 最適化リバランス戦略
- **MV**: 定期平均-分散最適化リバランス戦略

各レジームにおいて、極性指標が上昇トレンドを示すか下降トレンドを示すかの判断は、表 4.2 と表 4.3 を見て行う。SSAAM バックテストに使用したアルゴリズムの一覧は表 4.5 と表 4.6 を参照。

表 4.5: アルゴリズムの選択 (5 レジーム)

Regime	Selected Model	Formula
1	MinRiskOpt	4.2.5 章 - 式 (4.4)
2	MaxReturnOpt	4.2.5 章 - 式 (4.5)
3	MinRiskOpt	4.2.5 章 - 式 (4.4)
4	MaxReturnOpt	4.2.5 章 - 式 (4.5)
5	MinRiskOpt	4.2.5 章 - 式 (4.4)

表 4.6: アルゴリズムの選択 (10 レジーム)

Regime	Selected Model	Formula
1	MinRiskOpt	4.2.5 章 - 式 (4.4)
2	MaxReturnOpt	4.2.5 章 - 式 (4.5)
3	MinRiskOpt	4.2.5 章 - 式 (4.4)
4	MaxReturnOpt	4.2.5 章 - 式 (4.5)
5	MinRiskOpt	4.2.5 章 - 式 (4.4)
6	MaxReturnOpt	4.2.5 章 - 式 (4.5)
7	MinRiskOpt	4.2.5 章 - 式 (4.4)
8	MaxReturnOpt	4.2.5 章 - 式 (4.5)
9	MinRiskOpt	4.2.5 章 - 式 (4.4)
10	MaxReturnOpt	4.2.5 章 - 式 (4.5)

#### 4.3.4 バックテストの評価

ポートフォリオのパフォーマンスを評価するために以下の指標を採用した.

- **Total Return (TR):** TR とは, ある投資商品への投資から一定期間内に得られる総リターンのことである. TR の計算式は以下の通り:  $TR = \text{Valuation Amount} + \text{Cumulative Distribution Amount Received} + \text{Cumulative Amount Sold} - \text{Cumulative Amount Bought}$ . 本章では, incorporate tax amounts や trading commissions は織り込んでいない.
- **Maximum Drawdown (MDD):** MDD とは, 最大資産からの下落率を指す. MDD の計算式は以下の通り:  $MDD = (\text{Trough Value} - \text{Peak Value}) / \text{Peak Value}$ .

#### 4.3.5 バックテストの結果

バックテストの結果を以下に示す. 表 4.7 は提案手法の結果をまとめたものであり, 表 4.8 は比較手法の結果をまとめたものである.

表 4.7: バックテスト (SSAAM)

Rebalance	Regime	Algorithm	TR [%]	MDD [%]
30 days	5	CPD-EVaR++	<b>810.9915</b>	26.8629
		CPD-EVaR+	594.7410	26.8629
	10	CPD-EVaR++	485.5201	45.0235
		CPD-EVaR+	392.1392	42.4803
90 days	5	CPD-EVaR++	535.7349	27.6386
		CPD-EVaR+	410.8530	27.6386
	10	CPD-EVaR++	417.8354	27.7646
		CPD-EVaR+	373.5849	27.7646
180 days	5	CPD-EVaR++	152.0988	27.3924
		CPD-EVaR+	131.2210	27.3924
	10	CPD-EVaR++	169.2992	<b>25.3050</b>
		CPD-EVaR+	232.4513	<b>25.3050</b>

表 4.8: バックテスト (Comparison)

Rebalance	Algorithm	TR [%]	MDD [%]
30 days	EVaR	<b>587.9630</b>	46.6651
	CVaR	558.7446	44.4532
	MV	527.2827	42.9851
90 days	EVaR	500.1421	44.9860
	CVaR	496.7423	44.0592
	MV	459.1195	42.7358
180 days	EVaR	353.2412	44.7714
	CVaR	382.9451	44.2525
	MV	360.4298	<b>42.8165</b>

SSAAM (CPD-EVaR++, CPD-EVaR+) の共分散行列と期待リターンはヒストリカルデータに基づいて推定した. 比較手法 (MV, CVaR, EVaR) についても同様である. また, Turnover Deviation の Limit は 0.05 に固定されている.

例として, 各ポートフォリオの価値を図 4.4 に示す. これらは, 初期値を 100 とし, 30 日ごとに定期リバランスを行うと仮定している. SSAAM については, 5 つのレジームで戦略を切り替えた場合について計算されている.






図 4.4: ポートフォリオ価値 (30 日リバランスかつ 5 レジーム)

## 4.4 考察

表 4.7 によると、定期的なリバランスの回数が多いほど、TR は高くなる。また、MDD は 25% から 45% の間で推移しており、平均的なシステムトレーダーが許容できる MDD の範囲内であると考えられる。実験は、レジーム 5 と 10 の場合に分けて実施した。MDD はどちらのレジームでもほぼ同じであった。さらに、仮説 (4.1.2 章) の通り、リスク最小化とリターン最大化を組み合わせた CPD-EVaR++ は、他の手法よりも優れたパフォーマンスを示した。したがって、この方法を用いて株式ポートフォリオを運用する際のベストプラクティスは、CPD-EVaR++ を用い、30 日ごとの定期的なリバランスに加え、レジーム 5 で不定期にリバランスを行うことである。

表 4.8 を、表 4.7 と同じパラメータで行った。その結果、アルゴリズムについては、Cajas [17] の結果と同様に、EVaR 最適化が他よりも良い結果を示した。これは、最適化における EVaR の計算効率が、CVaR のような他のリスク尺度を用いた場合よりも高いためと考えられる。表 4.7 のように、リバランスの回数が増えるほど、TR は高くなる傾向がある。MDD は 43% から 47% の範囲にあり、平均して高いままである。

表 4.7 と表 4.8 を比較した。両者を比較すると、表 4.7 の TR は、リバランス 30、レジーム 5 の戦略がリスク評価、リターン評価ともにハイパフォーマンスであることがわかった。逆に、リバランスが 180 の戦略はパフォーマンスが低いことがわかった。これは、定期リバランスの間隔が広い戦略では、テキストに含まれる情報の利点を十分に活用できていないと解釈できる。

リバランスのタイミングの組み合わせについて議論する。4.4 章の評価指標に示すように、レジーム 5 よりレジーム 10 の方が変化点検知の評価が高い。一方、バックテストの結果、レジームを 10 とした場合の不定期リバランスと、30 日、90 日、180 日といった周期的リバランスの組み合わせは相性が悪いことがわかる。これより、本手法は短期的な戦術的アセットアロケーションには有効であるが、長期的な戦略的アセットアロケーションに対して必ずしも有効ではないことが示唆された。

レジームのトレンドの決定について述べる。変化点は Binary Segmentation Search によって自動計算されているが、各レジームにおけるトレンドが上昇であるか下降であるかの判断は、本フレームワークのユーザー（ファンドマネージャー）に依存する。クオンツ運用に携わるファンドマネージャーにとって、完全自動化されたモデルを投資運用に利用することはあまり現実的ではないが、この点でさらなる高度化と説明力が求められているこ

とは確かである。

この方法が実際の取引で使われた場合について述べる。テキストデータにはニュースが用いられることが多いが、それらは必ずしも必要なタイミングで入手できるとは限らない。不定期に発表される四半期ごとの決算報告書やアナリストレポートから個々の極性指標を作成する場合や、これらの文章を組み合わせて極性指標を作成する場合には、一度極性指標を予測してから利用する方法がある程度有効であると考えられる。

米国市場以外でのこの方法の有効性について議論する。極性指標の作成には、テキストのトーンを計算する MLM Score を使用した。テキストのトーン、感情の表現方法、言語システムは各国で異なると考えられる。米国市場だけでなく、欧州やアジア諸国の市場でもこの方法を検証し、テキスト情報の寄与度を測定することは興味深いかもしれない。

## 4.5 まとめ

本章は、株式ポートフォリオのアセットアロケーションにおけるテキストデータの有用性を実証するものである。これは、自然言語処理技術と変化点検知技術を用いて、リバランスのシグナルとなる極性指標を作成することで実現した。将来的には、オプションのヘッジ戦略やクレジット・デリバティブを含むポートフォリオ管理になどにも応用し、このフレームワークをさらに強化したいと考える。加えて、中央銀行が公表している報告書や財務諸表など、入手可能なテキストデータを検証することで、この手法の有効性を確認したい。

## 第5章 テキストデータを用いた多クラス 資産アセットアロケーション戦略

### 5.1 はじめに

#### 5.1.1 背景

本章では, 多クラス資産を用いたアセットアロケーションにテキストデータが有用であることを提案する. これは, 自然言語処理と統計的因果推論を用いてリバランスのシグナルを作成することで実現できる. 機械学習を用いた投資手法については, 数多くの研究が行われている. 特に, 投資シグナルの導出や投資比率の算出 [23, 24]. など, アセットアロケーションに関する研究が活発化している. 本章でも, 外的要因によってポートフォリオ価格が急変するポイント, すなわちレジームスイッチの転換点に注目する. ファイナンス理論では, レジームは拡大, 後退, 強気, 弱気といった目に見えない市場の状態を指すが, この変化を投資戦略に組み込み, マーケットの  $\alpha$  を獲得しようとする研究 [12, 14] もある. 本章では, 特に Taguchi ら [86] の研究を参考にした. 本章では, さらに一歩踏み込んで, 将来のレジームの変化を測定することに焦点を当てる. 将来のレジーム変化 (将来の市場環境の変化) の情報が分かれば, より自由度の高いアクティブ運用が可能になる. しかし, 伝統的な金融時系列データだけでは将来レジームの算出に一定の限界があるため, 多クラス資産の金融時系列データに加え, 近年注目されているオルタナティブデータを組み合わせる投資戦略を構築する.

#### 5.1.2 仮説

5.1.1 章を考慮し, 将来レジームの変化点を算出するために以下の仮説を立てる.

- 多クラス資産のポートフォリオは, 極性指標の変化点に応じて戦略を切り替えることで, リスクをヘッジしながら高いリターンを確保することができる.

### 5.1.3 貢献

本章で提案するテキストデータを用いた投資戦略は, 比較戦略よりも優れたパフォーマンスを生み出すことが期待される. これは, 自然言語処理技術を用いてテキストデータから極性指標を生成し, 統計的因果推論を用いて生成された極性指標の先行性を特定し, 変化点検知技術を用いて極性指標のレジーム変化点を算出し, 変化点に従い最適化モデルを用いてポートフォリオのリバランスを行うことで実現される. 本章の貢献は以下の通りである.

- テキストデータを用いたレジームの転換点の推定がアクティブ運用に有効であることを実証し, 多クラス資産に対する汎用性の高いアセットアロケーションのフレームワークを提案する.

## 5.2 提案手法

本稿では提案手法を Sentiment Signal-based Asset Allocation Method with Causal Information using Multi-asset Class (MA-SSAAM) と呼称する. このフレームワークのベースとなる研究は, Taguchi ら [86] で紹介されている. 本章では, この研究を多クラス資産ポートフォリオ最適化のケースに拡張する.

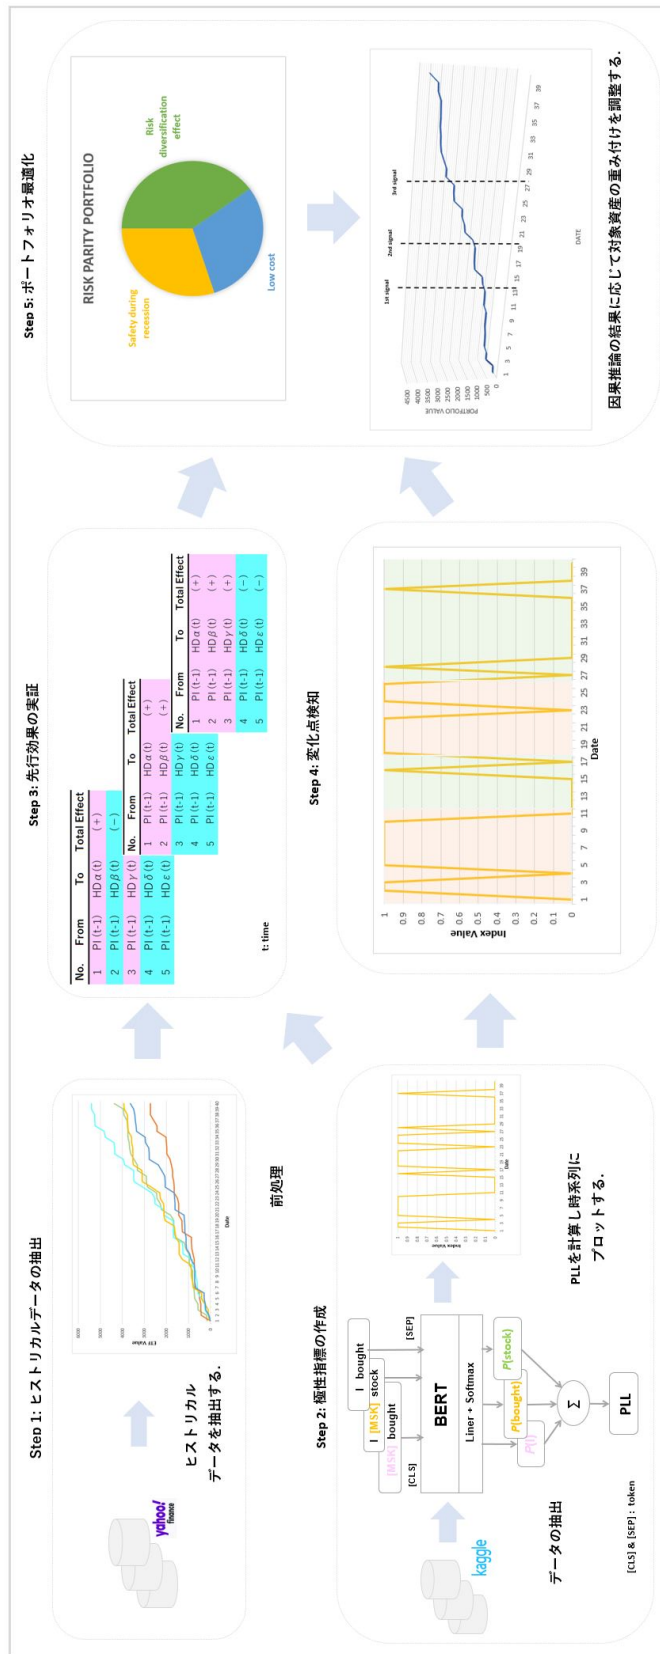


図 5.1: MA-SSAAM の概要

図 5.1 で MA-SSAAM の概要を示す.

### 5.2.1 ヒストリカルデータの抽出

データソースから過去の時系列データを日次で入手する. 使用するデータソースの詳細は後述するが, 本章における多クラス資産の配分については, 複数の金融商品データを使用した.

### 5.2.2 極性指標の作成

MLM Score を用いてテキストデータタイトルを採点する. さらに, 同じデータから四分位数を算出し, 四分位数範囲に応じてポジティブ, ネガティブ, ニュートラルの3値分類を行う. 算出された値は毎日集計される. 本章では, Pseudo-Log-Likelihood scores (PLL) を用いて極性指標を作成した. PLL は, Salazar ら [71] によって提案された MLM に相当する確率的言語モデルである. MLM は両方向の単語を予測することで事前学習が行われるため, 従来の確率的言語モデルでは扱えない. しかし, PLL は各単語をマスクして予測したときの条件付き確率の対数尤度の和で表現されるため, 文の自然度を高いレベルで判定することができる. トークン  $\psi_t$  を [MASK] で置き換え, 過去と現在のトークン  $\Psi_{\setminus t} = (\psi_1, \psi_2, \dots, \psi_{|\Psi|})$  を予測する.  $Psi$  は文を表し,  $t$  は時間を表し,  $\Theta$  はモデルパラメータを表し,  $P_{\text{MLM}}(\cdot)$  は各文トークンの確率を表す. MLM には BERT [72] を用いた.

$$\text{PLL}(\Psi) := \sum_{t=1}^{|\Psi|} \log_2 P_{\text{MLM}}(\psi_t | \Psi_{\setminus t}; \Theta) \quad (5.1)$$

前処理としてストップワード<sup>9</sup>を除去した (Bird ら [87] を参照). 同じセンテンスを含む行については, 1 センテンスを削除した. PLL を含むテキストを前処理後に1文ずつスコアリングした. スコアは1文ずつ採点されたデータについて毎日合計された. スコアの合計について四分位範囲を算出した. 表 5.1 に極性分類の方法を示す.

<sup>9</sup> 自然言語処理を実行する際, 役に立たない等の理由で処理の対象外とする単語.

表 5.1: 極性分類の方法

Classification Method	Sentiment Score
3rd quartile > PLL	1 (positive)
1st quartile $\leq$ PLL $\leq$ 3rd quartile	0 (neutral)
1st quartile < PLL	-1 (negative)

ここで作成された極性指標を次のステップで金融時系列データと共に使用する場合は、金融時系列データの日付に合わせる必要がある。極性指標側に欠落した日付がある場合、極性指標は中央値で穴埋めされる。

### 5.2.3 先行効果の実証

統計的因果推論を用いて、テキストデータが多クラス資産ポートフォリオに先行効果をもたらすかどうかを、作成した極性指標を使って実証する。本章では、VAR-LiNGAM [73] を用いて先行性を実証した。表記法は Hyvärinen ら [73] に従う。VAR-LiNGAM によって推定される因果グラフは以下の通りである。

$$\mathbf{x}(t) = \sum_{\tau=0}^T \mathbf{B}_{\tau} \mathbf{x}(t - \tau) + \mathbf{e}(t) \quad (5.2)$$

ここで  $\mathbf{x}(t) = (x_1(t), \dots, x_n(t))^{\top}$  は時刻  $t$  における変数のベクトル、 $\tau$  は時間遅れを表す。 $\top$  は転置、 $n$  は係数数、 $T$  は満期日を表す。また、 $\mathbf{B}_{\tau}$  は変数間の因果関係を表す係数行列  $\mathbf{x}(t - \tau) = (x_1(t - \tau), \dots, x_n(t - \tau))^{\top}$  であり、 $\mathbf{e}(t) = (e_1(t), \dots, e_n(t))^{\top}$  は擾乱項を表す。VAR-LiNGAM は以下の手順で実装した。

- まず、ラグタイムから現在までの変数間の因果関係については、Vector Autoregressive (VAR) モデルを適用した。
- 次に、現在時刻における変数間の因果関係については、上記の VAR モデルの残差を用いて LiNGAM 推論を行った。



### 5.2.4 変化点検知

極性指標に先行効果があることを確認する。変化点検知アルゴリズムを用いて、極性指標のレジーム変化点を計算する。ここでは、Window Sliding Segmentation アルゴリズムを用いる。Window Sliding Segmentation [88,89] は、信号  $y$  に沿ってスライドする隣接する2つのウィンドウ間の不一致を計算する高速な近似アルゴリズムである。アルゴリズムの表記は Algorithm 3 の通り。表記法は Truong ら [78] に従う。Window Sliding Segmentation は、直近の過去 (left window) と直近の未来 (right window) の間の不一致を測定する。不一致曲線が計算されると、変化点インデックスを決定するためにピーク探索が実行される。5.2.4 章では、Window Sliding Segmentation の完全なアルゴリズムを示す。 $Z$  はスコアリストであり、PKSearch ( $Z$ ) はピーク探索手順である。Window Sliding Segmentation の主な利点は、その複雑性の低さと実装の容易さである。

---

#### Algorithm 3 Window Sliding Segmentation

---

**Input:** signal  $y = \{y_t\}_{t=1}^T$  ( $1 \leq t \leq T$ ), cost function  $c(\cdot)$ , half window width  $w_h$ , peak search procedure PKSearch.

**Initialize:**  $Z \leftarrow [0, 0, \dots]$  a  $T$ -long array filled with 0.

**for**  $t = w_h, \dots, T - w_h$  **do**

$p \leftarrow (t - w_h)..t$

$q \leftarrow t..(t + w_h)$

$r \leftarrow (t - w_h)..(t + w_h)$

$Z[t] \leftarrow c(y_p) + c(y_q)$

**end for**

$L \leftarrow \text{PKSearch}(Z)$

**Output:** set  $L$  of estimated breakpoint indexes.

---

### 5.2.5 最適化アルゴリズム

作成された変化点に基づいてポートフォリオの最適化が実行される。ポートフォリオの最適化には、制約付きリスク・パリティ・アプローチが使用される。リスク・パリティ・ポートフォリオ (RPP) は、総リスクを資産に均等に配分する。本章では、Kolm ら [90] で提案された対数バリア関数を用いる。最適化問題は以下のように定式化される。

$$\min_{w>0} f(w) = w^\top \Sigma w - \sum_{i=1}^n \ln w_i \quad (5.3)$$

この最適化問題は、 $-\sum_{i=1}^n \ln w_i$  という項があることから、対数ペナルティ定式化と呼ばれることもある。 $\ln w_i$  は対数バリア関数である。 $n$  を投資リスク資産とする。ここで、 $w_i$  は総投資資産に対する資産  $i$  の比率を表し、ポートフォリオを  $n$  次元ベクトル  $w = (w_1, w_2, \dots, w_n)$  と定義する。記号  $\top$  は転置を表す。資産  $i$  の収益率の標準偏差を  $\sigma_i$ 、資産  $i$  と資産  $j$  の収益率の相関係数を  $\rho_{ij}$ 、全資産の収益率の共分散行列を次式とする。資産  $i$  と資産  $j$  の共分散  $\sigma_{ij}$  は、 $\sigma_{ij} = \sigma_i \sigma_j \rho_{ij} (i \neq j)$  で与えられる。

$$\Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & & \sigma_{2n} \\ \vdots & & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_{nn} \end{pmatrix} \quad (5.4)$$

最適化問題の最適化条件は以下の通りである。

$$\nabla f(x) = 2\Sigma w - w^{-1} = 0 \quad (5.5)$$

$w^{-1} = (\frac{1}{w_1}, \frac{1}{w_2}, \dots, \frac{1}{w_n})$  はベクトル  $w$  の逆ベクトルを表す。

Relative Risk Contribution (RRC) は、ポートフォリオ全体のリスクに対する対象資産のリスク寄与度の比率として定義される。これは以下のように与えられる。

$$RRC_i = \frac{w_i(\Sigma w)_i}{w^\top \Sigma w} \quad (5.6)$$

なお、最適性条件の各要素は以下のように等価な形で書くことができる。

$$2(\Sigma w)_i - \frac{1}{w_i} = 0 \Leftrightarrow w_i(\Sigma w)_i = \frac{1}{2}, i = 1, \dots, n \quad (5.7)$$

これらの条件が成立すれば以下ようになる。

$$RRC_i = \frac{w_i(\Sigma w)_i}{w^\top \Sigma w} = \frac{1/2}{n/2} = \frac{1}{n} \quad (5.8)$$

本章では、センチメント・シグナルと因果情報をリスク・パリティ・ポートフォリオに統合することを試みる。VAR-LiNGAMによって計算された因果情報は、リスク・パリティ・ポートフォリオに反映される。本章では、シグナルに挟まれた領域をレジームと呼び、レジームの切れ目をセンチメントシグナルと呼称する。センチメントシグナルと因果情報の関係を図5.2に示す。




図 5.2: センチメントシグナルと因果情報の関係

VAR-LiNGAM の総合効果の符号 (+または-) に基づいて, リスク・パリティ・ポートフォリオの対象資産のウェイトを調整する. 本章では, これをセンチメントレジームアプローチと呼ぶ. これは以下のステップで行われる.  $n$  は資産の数を表す. さらに,  $n$  は  $n = l + m$  で表される.

- **Step 1:** スタートから最初のセンチメントシグナルに到達するまでのアルゴリズムは, 重み付けを調整しないリスク・パリティ・ポートフォリオである. この場合, 重みベクトルは  $w = (w_1, w_2, \dots, w_n)$  である.
- **Step 2:** 景気が上向き, つまり極性指標の値が 1 の割合が高いレジームでは, 2 段階の重み付け調整が行われる. この場合, まずベクトル  $w = (w_1, w_2, \dots, w_l)$  を用いてリスク・パリティ・ポートフォリオを作成し, 次に因果推論の結果に基づいて追加ウェイト・ベクトル  $w^{adj} = (w_1^{adj}, \dots, w_m^{adj})$  を調整する. このとき,  $w^{adj}$  の全成分が同じ比率になるようにする.
- **Step 3:** 景気が下向き, つまり極性指標が -1 の値の割合が高いレジームでは, 重み付けを調整しないリスク・パリティ・ポートフォリオとなる. この場合, ウェイト・ベクトルは  $w = (w_1, w_2, \dots, w_n)$  となる.

5.2.5 章の一連の最適化手法をセンチメントレジームアプローチ (投資比率調整型) と呼称する.

## 5.3 実験と結果

### 5.3.1 データセットの概説

本章のデータは2種類使用した. これらのデータの期間は2017年1月から2019年12月までである.

- **News:** データ分析プラットフォームである Kaggle<sup>10</sup>が提供する日次の過去のテキストデータアーカイブを使用した.

---

<sup>10</sup><https://www.kaggle.com/>

- **ETF:** Yahoo! Finance<sup>11</sup>が提供する日次ETF ヒストリカルデータアーカイブを使用した。

本章で使用したデータの概要を表 5.2 に示す。

表 5.2: データの概要

Type	Name	Details
News	CNN	CNN News Headlines
	HFN	Historical Financial News Titles
	ONI	Onion Article Titles
ETF	SPY	SPDR S&P 500 ETF
	QQQ	PowerShares QQQ ETF
	GLD	SPDR Gold Shares
	EMB	iShares JP Morgan USD Em Mkts Bd ETF
	AGG	iShares Core US Aggregate Bond ETF

### 5.3.2 バックテストの準備

極性指標の作成方法は 5.2.2 章に示されている。テキストデータは、極性指標を作成する前に前処理を行った。テキストデータも ETF データも日単位であるが、期間を合わせるため、どちらかに空白がある場合は空白を含む行を削除している。5.2.2 章に従って極性指標を作成し、次に ETF の調整後の終値を加えて多クラス資産ポートフォリオを作成する。次に 5.2.3 章の VAR-LiNGAM を用いて因果推論を行う。VAR-LiNGAM の結果は、極性指標が多クラス資産ポートフォリオにおいて先行性があることを示している。変化点検知の実装には、Python ライブラリ ruptures [78] を用いた。バックテストの実装には Python ライブラリ vectorbt [84], Riskfolio-Lib [85], PyPortfolioOpt [91], FinRL [25] を用いた。

作成された極性指標同士の相関を図 5.3 に示す。

結果から、HFN と ONI のペアについて正の相関がやや高いことがわかる。

ここでは、データの定常性を確認するために、Augmented Dickey-Fuller test (ADF) [81] を用いる。前処理として ETF については差分をとる。表 5.3 によると、検定統計量は 0.05 より小さいので、帰無仮説は棄却されるため、データは定常であると言える。

<sup>11</sup><https://finance.yahoo.com/>




図 5.3: 極性指標の相関係数

表 5.3: Augmented Dickey-Fuller test

Type	Name	Test Statistic
News	CNN	-4.07
	HFN	-3.33
	ONI	-5.69
ETF	SPY	-1.82
	QQQ	-20.07
	GLD	-28.53
	EMB	-1.08
	AGG	-1.03

定常性が検証されたので, データは VAR-LiNGAM の入力として使用される.

因果推論の結果は以下のように表される.

表 5.4: VAR-LiNGAM による因果推論 (CNN)

Data Coverage	From	To	Total Effect	Remarks
Start-CP2	CNN(t-1)	SPY(t)	-0.52	-
Start-CP2	CNN(t-1)	GLD(t)	-0.50	-
Start-CP2	CNN(t-1)	EMB(t)	-0.03	-
Start-CP2	CNN(t-1)	QQQ(t)	0.07	Increase the ratio of QQQ
Start-CP2	CNN(t-1)	AGG(t)	0.12	Increase the ratio of AGG
Start-CP3	CNN(t-1)	GLD(t)	-0.39	-
Start-CP3	CNN(t-1)	EMB(t)	-0.10	-
Start-CP3	CNN(t-1)	AGG(t)	-0.07	-
Start-CP3	CNN(t-1)	QQQ(t)	0.38	-
Start-CP3	CNN(t-1)	SPY(t)	0.42	-
Start-CP4	CNN(t-1)	AGG(t)	-0.06	-
Start-CP4	CNN(t-1)	EMB(t)	-0.10	-
Start-CP4	CNN(t-1)	GLD(t)	-0.41	-
Start-CP4	CNN(t-1)	QQQ(t)	0.44	Increase the ratio of QQQ
Start-CP4	CNN(t-1)	SPY(t)	0.40	Increase the ratio of SPY

表 5.4-5.6 の Total Effect の値は因果推論の総合効果を示す. 考慮するパス係数<sup>12</sup>の最小値は 0.01 とした.

変化点検知の性能を評価するために, 以下の指標を使用する.

- **Precision:** Precision とは, 正のクラスと予測されたサンプルにどれだけ正しい値が含まれているかの比率である. 変化点検知の文脈では, Precision は以下のように定義される.

$$\text{Precision} := | \text{TP} | / | \{ \hat{s}_l \}_l | \quad (5.9)$$

<sup>12</sup>変数間の関係性の強さを指す値.



表 5.5: VAR-LiNGAM による因果推論 (HFN)

Data Coverage	From	To	Total Effect	Remarks
Start-CP2	HFN(t-1)	AGG(t)	0.13	Increase the ratio of AGG
Start-CP2	HFN(t-1)	EMB(t)	-0.19	-
Start-CP2	HFN(t-1)	QQQ(t)	-0.43	-
Start-CP2	HFN(t-1)	GLD(t)	-0.56	-
Start-CP3	HFN(t-1)	SPY(t)	-0.71	-
Start-CP3	HFN(t-1)	AGG(t)	0.04	-
Start-CP3	HFN(t-1)	EMB(t)	-0.09	-
Start-CP3	HFN(t-1)	GLD(t)	0.26	-
Start-CP3	HFN(t-1)	QQQ(t)	-0.35	-
Start-CP3	HFN(t-1)	SPY(t)	-0.40	-

表 5.6: VAR-LiNGAM による因果推論 (ONI)

Data Coverage	From	To	Total Effect	Remarks
Start-CP2	ONI(t-1)	AGG(t)	0.05	Increase the ratio of AGG
Start-CP2	ONI(t-1)	QQQ(t)	0.19	Increase the ratio of QQQ
Start-CP2	ONI(t-1)	GLD(t)	-0.58	-
Start-CP2	ONI(t-1)	EMB(t)	-0.13	-
Start-CP2	ONI(t-1)	SPY(t)	0.32	Increase the ratio of SPY
Start-CP3	ONI(t-1)	GLD(t)	-0.11	-
Start-CP3	ONI(t-1)	EMB(t)	-0.03	-
Start-CP3	ONI(t-1)	SPY(t)	-0.10	-
Start-CP3	ONI(t-1)	QQQ(t)	-0.20	-
Start-CP4	ONI(t-1)	GLD(t)	-0.07	-
Start-CP4	ONI(t-1)	SPY(t)	0.22	Increase the ratio of SPY
Start-CP4	ONI(t-1)	QQQ(t)	0.22	Increase the ratio of QQQ

- **Hausdorff Metric (HM):** HM は最悪の予測誤差を推定する. 変化点検知に関連する研究としては, Boysen ら [82] や Harchaoui & Lévy-Leduc [83] がある.

$$\mathbf{HM} := \max\left\{\max_m \min_l |s_m - \hat{s}_l|, \max_m \min_l |\hat{s}_m - s_l|\right\} \quad (5.10)$$

$l$  と  $m$  を変数とする. TP は真陽性であり,  $\text{TP} := \{s_m \mid \exists s_l \text{ s.t. } |s_l - \hat{s}_m| < \text{Mar}\}$  と定義できる.  $\text{Mar}$  はマージンである. 各指標を用いて計算した結果を表 5.7 に示す. BSS は Binary Segmentation Search (4.2.4 章を参照), WSS は Window Sliding Segmentation (5.2.4 章を参照), CF は ChangeFinder (6.2.5 章を参照) を指す. なお, 評価に必要な正しいラベルは著者が手動で付与した.

表 5.7: 変化点検知の評価

Model	Data	Precision	HM
WSS (Proposed)	CNN	0.33	<b>80.00</b>
	HFN	<b>0.50</b>	145.00
	ONI	0.00	105.00
BSS (Comparison)	CNN	0.00	205.00
	HFN	0.33	100.00
	ONI	0.00	185.00
CF (Comparison)	CNN	0.00	550.00
	HFN	0.00	684.00
	ONI	0.00	468.00

表 5.7 の結果より, 本章のデータについては Window Sliding Segmentation の方が比較優位となるため, Window Sliding Segmentation を選択する.

変化点検知によって得られたレジームを図 5.4-5.6 に示す.

図 5.4-5.6 において検出された変化点は, CNN では 2017 年におけるイギリスの EU 離脱交渉開始, HFN では 2018 年のカナダの大麻合法化, ONI では 2019 年のカタールの OPEC 脱退, などの重大イベントと重なった.




図 5.4: 変化点検知 (CNN)




図 5.5: 変化点検知 (HFN)




図 5.6: 変化点検知 (ONI)

### 5.3.3 バックテストのシナリオ

バックテストの条件は以下の通りである。

- 定期的なリバランスは30日ごとに行われる。
- MA-SSAAM は、定期的なリバランスとセンチメントレジームを組み合わせた戦略である。センチメントレジームアプローチの開始は、定期的なバランスのポイントに合わせる。
- 変化点検知の検知数<sup>13</sup>は3とした。

この研究で提案された主なアルゴリズムは以下の通りである。

- **MA-SSAAM:** これは、本章で提案する方法である。本章では、テキストデータやパラメータを変化させたいいくつかの結果を述べる。

ベンチマークモデルは以下の通りである。

- **BM (RPP):** このアルゴリズムは、RPP [90] である。これは、MA-SSAAM から5.2.3章の因果推論と5.2.4章の変化点検知の影響を取り除いたベンチマークモデルである。
- **BM (RPP+MV):** このアルゴリズムは、RPP と平均-分散モデル (MV) [1] を組み合わせたものである。センチメントシグナルが下降トレンドの場合はRPPを、上昇トレンドの場合は平均-分散モデルを用いる。このベンチマークモデルは、MA-SSAAM から5.2.3章における因果推論の影響を取り除いたものである。

ポートフォリオ理論に基づく方法は以下の通りである。

- **MV:** このアルゴリズムは、平均-分散モデル [1] に基づいている。MV は、ポートフォリオ収益率の平均と分散のみを考慮する。

<sup>13</sup>変化点の数 は ruptures であらかじめ設定されているパラメータである。必ずしも設定した変化点数が検知されるとは限らず、より少ない変化点が検知される場合もあることに注意。

- **CVaR:** このアルゴリズムは, Conditional Value at Risk (CVaR) [2] に基づいている. CVaR はある確率水準におけるポートフォリオの平均的な損失を表すリスク指標である. 最適化の条件として期待損失 (リスクによる損失の期待値) を最小化する必要がある.
- **EVaR:** このアルゴリズムは, Entropic Value at Risk (EVaR) [17] に基づいている. EVaR は VaR と CVaR の上限を示すリスク指標である.
- **CDaR:** このアルゴリズムは, Conditional Drawdown at Risk (CDaR) [18] に基づいている. CDaR はドローダウンに基づくリスク指標である. その最適化の枠組みは CVaR 最適化と同様である.

強化学習を用いた手法は以下の通りである.

- **DDPG:** 本アルゴリズム [25] は Deep Deterministic Policy Gradient (DDPG) [26] に基づいている. DDPG はモデルフリーの深層強化学習アルゴリズムである. 行動空間の次元が高い複雑なタスクにおいて, より少ない試行回数でより高い報酬量を得ることができる.
- **A2C:** 本アルゴリズム [25] は Advantage Actor-Critic (A2C) [27] に基づいている. A2C は Actor-Critic<sup>14</sup>に基づく分散深層強化学習アルゴリズムである. A2C は同期処理を採用しており, GPU の負荷を分散させることができる.
- **PPO:** 本アルゴリズム [25] は Proximal Policy Optimization (PPO) [28] に基づいている. PPO は従来の強化学習アルゴリズムに clip [28] という手法を用いて計算効率を高めたアルゴリズムである.
- **SAC:** 本アルゴリズム [25] は Soft Actor-Critic (SAC) [29–31] に基づいている. SAC は従来の目的関数に方策エントロピー項を追加したことで, 学習をより安定化させた手法である.

#### 5.3.4 バックテストの評価

評価指標は以下のように定義される.

<sup>14</sup>行動を選択する Actor と, Actor が選択した行動を評価する Critic で構成される強化学習フレームワーク.

- **TR:** Total Return (TR) とは, ある金融資産への投資から一定期間内に得られたリターンの合計を指す. ここで,  $P_{Start}$  は開始時の価格,  $P_{End}$  は終了時の価格,  $D_{Period}$  は期間中の受取配当金である.

$$\mathbf{TR} = \frac{P_{Start} - P_{End} + D_{Period}}{P_{Start}} \quad (5.11)$$

- **AR:** Annualized Return (AR) とは, 1 年間に発生した投資収益率である.  $n$  は期間中の日数である.

$$\mathbf{AR} = (\mathbf{TR} + 1)^{\frac{252}{n}} - 1 \quad (5.12)$$

- **AV:** Annualized Volatility (AV) は, 1 年間に発生した金融資産の価格変動率を表す. ここで,  $N$  は要素数,  $R_i$  は  $i$  番目のリターン,  $\hat{R}$  は平均リターンである.

$$\mathbf{AV} = \sqrt{252} \times \sqrt{\frac{\sum_{i=1}^N (R_i - \hat{R})^2}{N - 1}} \quad (5.13)$$

- **MDD:** Maximum Drawdown (MDD) とは, 最大資産からの下落率を指す. ここで,  $V_{Peak}$  は最大下落前のピーク値,  $V_{Lowest}$  は最大下落前の最低値である.

$$\mathbf{MDD} = \frac{V_{Peak} - V_{Lowest}}{V_{Peak}} \quad (5.14)$$

- **SR:** Sharpe Ratio (SR) は, 投資対象が取ったリスクに見合ったリターンを上げたかどうかを測る指標である. ここで  $R_f$  はリスク・フリー・レート<sup>15</sup>である. 本章では  $R_f = 0$  と仮定する.

$$\mathbf{SR} = \frac{\mathbf{AR} - R_f}{\mathbf{AV}} \quad (5.15)$$

- **CR:** Calmar Ratio (CR) は, 高リターンが高リスクと関連しているかどうかを示す指標である.

$$\mathbf{CR} = \frac{\mathbf{AR} - R_f}{\mathbf{MDD}} \quad (5.16)$$

- **TE:** Tracking Error (TE) は, ポートフォリオ・リターンとベンチマーク・リターンの差を表す. ここで,  $Var(\cdot)$  は分散,  $R_p$  はポートフォリオ・リターン,  $R_b$  はベンチマーク・リターンを表す.

$$\mathbf{TE} = \sqrt{252} \times \sqrt{Var(R_p - R_b)} \quad (5.17)$$

<sup>15</sup> リスクがほとんどないもしくは皆無の商品から得られる利回り.

- **IR:** Information Ratio (IR) は, TE で考慮されるリスクに対して, どれだけ多くのリターンが得られるかを表す. ここで,  $N$  は要素数,  $R_p$  はポートフォリオ・リターン,  $R_b$  はベンチマーク・リターンを表す.

$$\mathbf{IR} = \frac{R_p - R_b}{\mathbf{TE}} \quad (5.18)$$

### 5.3.5 バックテストの結果

各月末の Total Return の時系列プロットを図 5.7 に示す.




図 5.7: Total Return



バックテストの結果を表 5.8 に示す.<sup>16</sup>

---

<sup>16</sup>強化学習を用いた手法では, 2008 年 1 月から 2016 年 12 月までの ETF データを学習データとして追加使用した.

Type	Name	Parameter	AR [%]	AV [%]	MDD [%]	SR	CR
Proposed Method	MA-SSAAM #1	news = cnn, adj-weight = 0.3	<b>9.97</b>	6.65	5.52	1.50	1.81
	MA-SSAAM #2	news = hfn, adj-weight = 0.3	7.90	<b>4.87</b>	4.90	1.62	1.61
	MA-SSAAM #3	news = oni, adj-weight = 0.3	8.72	6.42	7.05	1.36	1.24
	MA-SSAAM #4	news = cnn, adj-weight = 0.2	8.57	5.69	6.14	1.40	1.51
	MA-SSAAM #5	news = hfn, adj-weight = 0.2	8.18	5.31	5.43	1.54	1.51
	MA-SSAAM #6	news = oni, adj-weight = 0.2	8.54	5.94	6.60	1.44	1.29
Benchmark	BM (RPP)	weight_bounds = (0.01, 1)	8.56	5.03	6.24	<b>1.70</b>	1.37
Method	BM (RPP+MV)	weight_bounds = (0.01, 1)	7.85	4.69	<b>4.21</b>	1.67	<b>1.86</b>
Portfolio Theory	MV	significance_level = 0.05	8.65	10.84	17.11	0.80	0.51
	CVaR	significance_level = 0.05	5.59	9.59	17.13	0.58	0.33
	EVaR	significance_level = 0.05	8.56	8.20	13.02	1.04	0.66
	CDaR	significance_level = 0.05	8.53	10.67	17.07	0.80	0.50
Reinforcement Learning	DDPG	batch_size = 128, learning_rate = 0.001	8.53	6.35	11.16	1.34	0.76
	A2C	batch_size = 128, learning_rate = 0.0002	9.36	6.50	10.53	1.44	0.89
	PPO	batch_size = 128, learning_rate = 0.001	9.24	6.67	10.58	1.39	0.87
	SAC	batch_size = 128, learning_rate = 0.0003	8.36	6.39	10.46	1.31	0.80

表 5.8: バックテスト (MA-SSAAM)

図 5.8a は BM (RPP) に対する TE, 図 5.8b は BM (RPP+MV) に対する TE, 図 5.8c は BM (RPP) に対する IR, 図 5.8d は BM (RPP+MV) に対する IR, である.

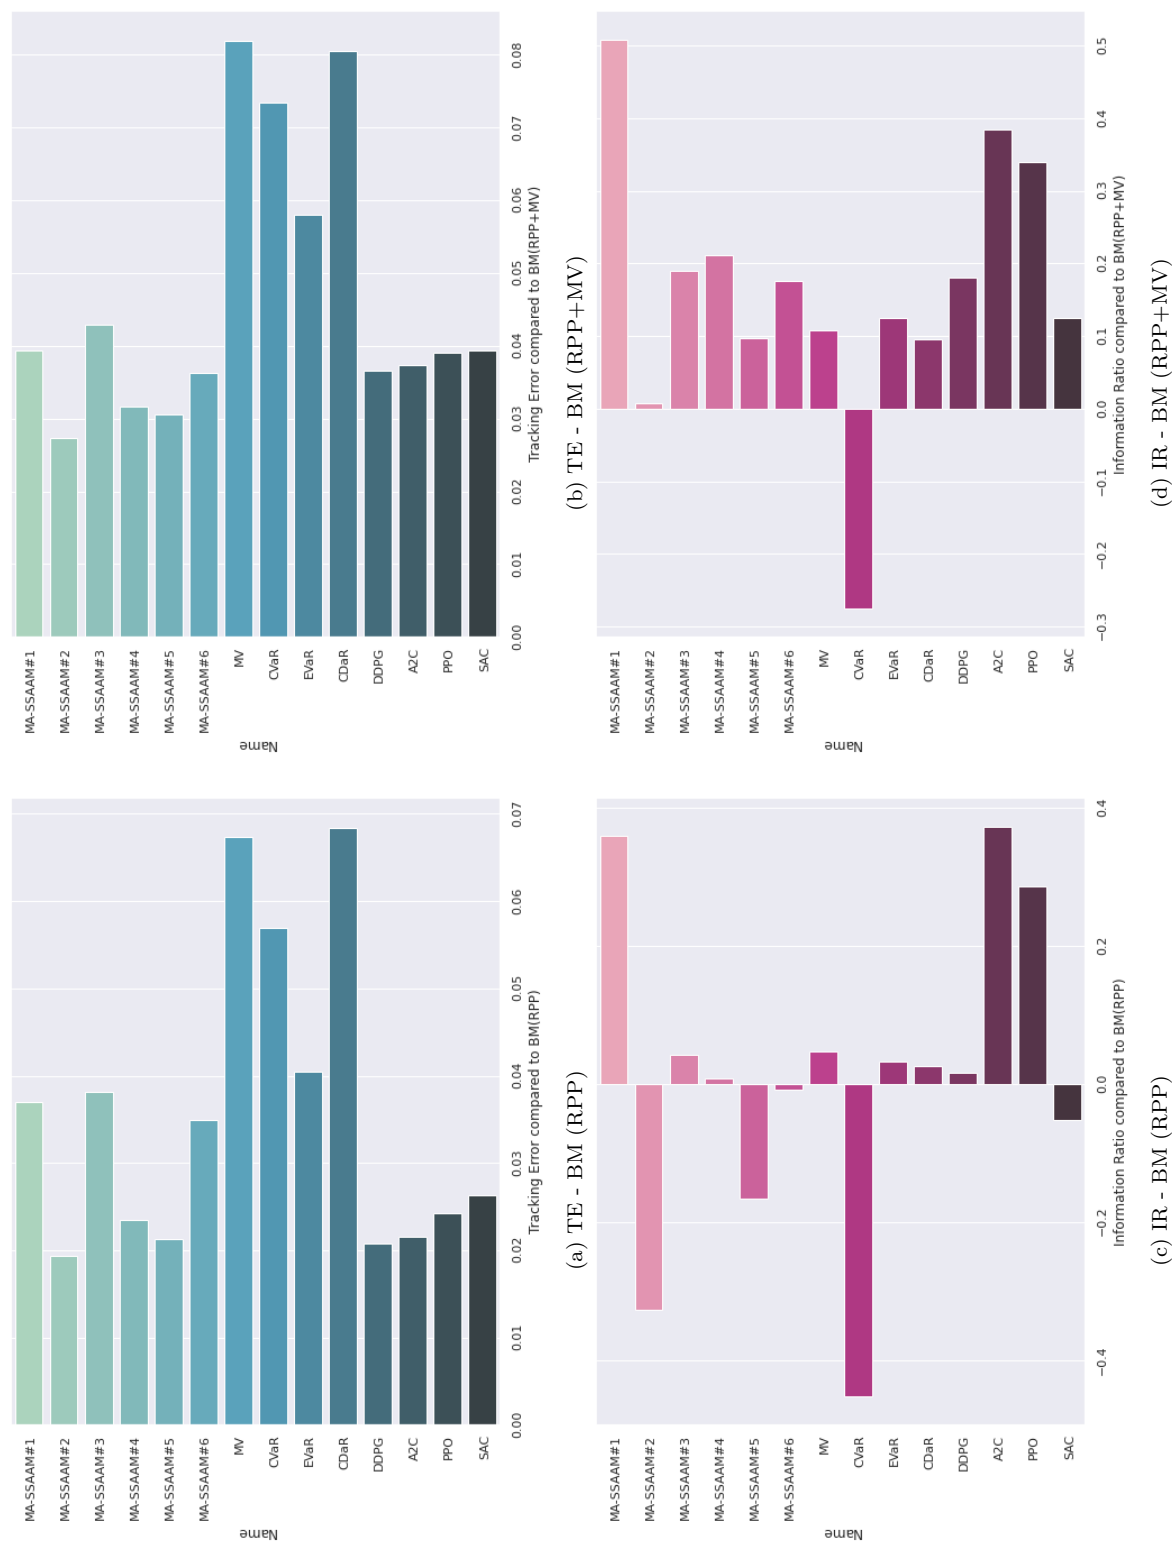


図 5.8: ベンチマークに対する各手法の比較

## 5.4 考察

表 5.8 中の提案手法の全体的な傾向は, AR, SR, CR の値が高く, バランスが取れている. 特に CR の値が高く, 安定した運用戦略であることがわかる. また, CNN を用いた手法である MA-SSAAM #1 と #3 は, 特に AR と CR が安定している. これは, より形式的なテキストソースを用いることで, 本手法の性能が向上することを示している.

提案手法をベンチマーク手法と比較した. BM (RPP) と MA-SSAAM を比較すると, SR は BM (RPP) の方が高く, AR は MA-SSAAM の方が相対的に高い傾向がある. BM (RPP) は, 多クラス資産の配分によく用いられるリスク・パリティ・ポートフォリオ戦略であるが, CR 値は MA-SSAAM の方が相対的に高い. BM (RPP+MV) と MA-SSAAM を比較すると, MDD は BM (RPP+MV) の方が低い. BM (RPP+MV) は因果推論効果のない MA-SSAAM と解釈できるが, MA-SSAAM の AR は BM (RPP+MV) を上回るため, 因果推論効果はリターンを高める効果がある. BM (RPP) と MA-SSAAM の比較では, BM (RPP+MV) と同じ傾向を示した. ここで, BM (RPP) は MA-SSAAM から変化点検知効果と因果推論効果を落としたと解釈できる. 逆に, BM (RPP+MV) と BM (RPP) を比較すると, BM (RPP+MV) の方が MDD と AR が低かった. この結果は, 変化点検知の導入が市場に対するリスクヘッジ効果を持つことを示しており, 本章の仮説 (5.1.2 章) と矛盾しない.

提案手法をポートフォリオ理論と比較した. 全体として, MA-SSAAM の指標はポートフォリオ理論を上回る. MDD は特にポートフォリオ理論の方が高く, 多クラス資産のアセットアロケーションの戦略としては相対的にハイリスクである. しかし, AR については MA-SSAAM とポートフォリオ理論は同様の結果を示した. また, CVaR の AR は低く, MDD は高く, 他の運用結果と比べて相対的に劣っている. 特に MDD は MA-SSAAM#1 の 3 倍近く大きい. この点は, 本章の副次的な成果として今後検討すべきである.

提案手法を強化学習を用いた手法と比較した. 全体的に, AR と MDD は強化学習を用いた手法が高かった. 強化学習を用いた手法は, MA-SSAAM と比較してハイリスク・ハイリターンである. 余談だが, 教師データの量によって強化学習法の性能が変化する可能性があるため, 今後, 強化学習を用いた手法のベストプラクティスを模索する必要がある. MA-SSAAM の最大の特徴は, MDD を最小化できることである. しかし, リターンの最大化についてはさらなる研究の余地がある. 今後の研究では, この点を考慮し, MA-SSAAM のフレームワークをより堅牢なものにしていきたいと考えている.

図 5.8 中の 2 つのベンチマークに対する各手法の比較誤差を考慮すると、MA-SSAAM は、図 5.8a と図 5.8b で同様の傾向を示している。これは、変化点検知と因果推論がリターンの乖離に大きな影響を与えないことを示している。しかし、MA-SSAAM の IR は、図 5.8c と図 5.8d で異なる傾向を示している。図 5.8c 中、MA-SSAAM の IR は低く、MA-SSAAM の IR がマイナスのものもある。これに対し、図 5.8d では、MA-SSAAM の IR は全てプラスである。これは、BM (RPP+MV) や変化点検知を含めると値が改善することを示しており、変化点検知効果を含むアクティブ運用の効率が高くなることを示している。

## 5.5 まとめ

本章では、多クラスの資産で構成されるポートフォリオのアセットアロケーションにテキストデータが有用であることを実証した。これは、リバランスのシグナルとなる極性指標を作成するために、自然言語処理技術と変化点検知を用いて達成された。将来的には、ボラティリティの高い商品、不動産、オプション、クレジット・デリバティブを用いたヘッジ戦略など、ポートフォリオ管理においてこのフレームワークをさらに強化する予定である。また、中央銀行が公表している報告書や財務諸表など、入手可能なテキストデータを調べることで、このアプローチの有効性を確認したい。

## 第6章 テキストデータと予測ベースの極性指標を用いた暗号資産アセットアロケーション戦略

### 6.1 はじめに

#### 6.1.1 背景

本章では、暗号資産を用いた戦術的なアセットアロケーションにテキストデータが有用であることを実証する。これは、自然言語処理と統計的因果推論を用いてリバランスのシグナルを作成することで実現できる。機械学習を用いた投資手法に関する研究は数多く行われている。特に、投資シグナルの導出や投資比率の算出 [23, 24] など、アセットアロケーションに関する研究が進んでいる。本章では、外的要因によりポートフォリオ価格が急変するポイント、すなわちレジームスイッチの転換点に注目する。ファイナンス理論では、レジームは拡大、後退、強気、弱気といった目に見えない市場の状態を指すが、この変化を投資戦略に組み込み、マーケットの  $\alpha$  を獲得しようとする研究 [12, 14] もある。本章ではさらに一歩進めて、将来のレジーム変化を測定することに焦点を当てる。本章でも、特に Taguchi ら [86] の研究を参考にする。将来のレジーム変化、すなわち市場環境の変化、の情報が分かれば、より自由度の高いアクティブ運用が可能となる。しかし、伝統的な金融時系列データのみで将来のレジームを算出することには一定の限界があるため、金融時系列データに加え、近年注目されているオルタナティブデータを組み合わせて投資戦略を構築する。

### 6.1.2 仮説

6.1.1 を考慮し, 将来レジームの変化点を算出するために以下の仮説を立てる.

- 極性指標の変化点に応じて運用戦略を切り替えることで, 暗号資産ポートフォリオは, ある程度のリスクヘッジをしながら高いリターンを確保することができる.

### 6.1.3 貢献

本章で提案するテキストデータを用いた投資戦略は, 比較戦略よりも優れたパフォーマンスを生み出すことが期待される. 本章の貢献は以下の通りである.

- テキストマイニング技術を用いた極性指標の変化点推定がアクティブ運用に有効であることを実証し, 暗号資産に対する汎用性の高いアセットアロケーションのフレームワークを提案する.

## 6.2 提案手法

本稿では提案手法を Sentiment Signal-based Asset Allocation Method with Causal Information using Crypto Assets (CA-SSAAM) と呼称する. このフレームワークのベースとなる研究は Taguchi ら [86] で紹介されている. この研究で使用されたアーキテクチャは図 6.1 に示されている.



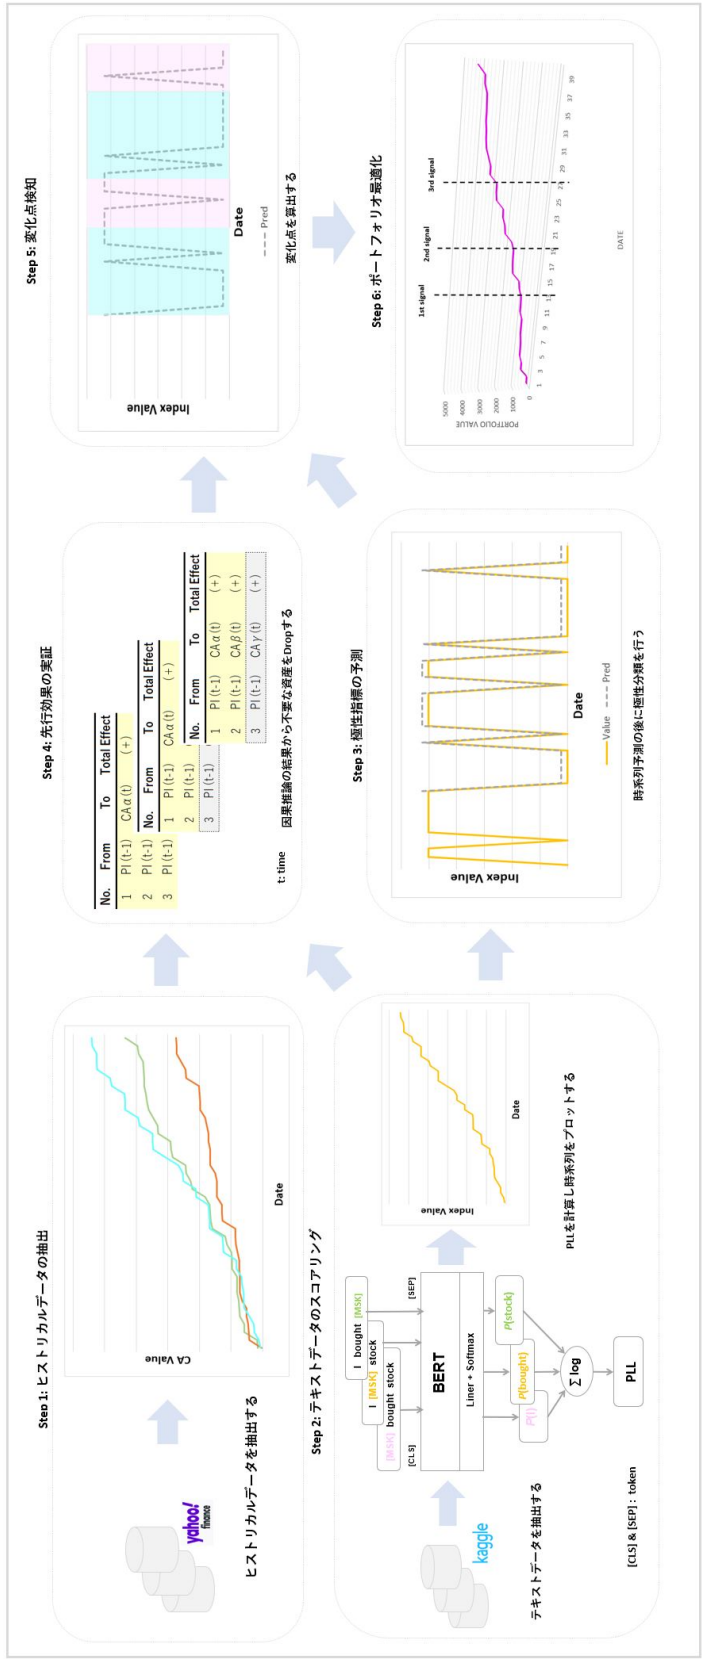


図 6.1: CA-SSAAM の概要

### 6.2.1 ヒストリカルデータの抽出

データソースの詳細は後述するが、本章においては日次暗号資産データを使用した。

### 6.2.2 テキストデータのスコアリング

MLM scoring を用いてテキストデータのタイトルをスコア化した。さらに、同じデータから四分位数を算出し、四分位数範囲に応じて positive, neutral, negative の三値分類を行う。本章では、pseudo-log-likelihood scores (PLL) を用いて極性指標を作成した。PLL は、Salazar ら [71] らが提案した確率的言語モデルである。PLL では、各単語をマスクして予測したときの条件付き確率の対数尤度の和で表されるため、文章の自然度を高いレベルで判定することができる。トークン  $\delta_\eta$  を [MASK] で置き換え、過去と現在のトークン  $\Delta_{\setminus\eta} = (\delta_1, \delta_2, \dots, \delta_{|\Delta|})$  を予測する。 $\Delta$  は文を表す。 $t$  は時間を表し、 $\Theta$  はモデルパラメータを表し、 $P_{\text{MLM}}(\cdot)$  は各文トークンの確率を表す。MLM には BERT [72] を用いた。

$$\mathcal{PLL}(\Delta) := \sum_{t=1}^{|\Delta|} \log_2 P_{\text{MLM}}(\delta_\eta | \Delta_{\setminus\eta}; \Theta) \quad (6.1)$$

前処理として、同じセンテンスを含む行については重複を削除した。前処理後に PLL を用いて 1 文ずつスコアリングした。算出されたスコアは日次で集計された。

### 6.2.3 極性指標の予測

本章では、LSTF 問題 (2.4 章を参照) を考慮して informer [39] を使用する。表記法は Zhou ら [39] に従う。Encoder は大量の入力情報を受け取る。次に、canonical self-attention を ProbSparse attention に置き換える。台形は、self-attention の蒸留操作であり、ネットワークサイズを大幅に縮小させる。一方、Decoder は入力情報を受け取り、ターゲットの要素を 0 にし、Feature Map の重み付き attention 構成を測定し、出力要素を即座に予測する。informer の概要は図 6.2 に示す。

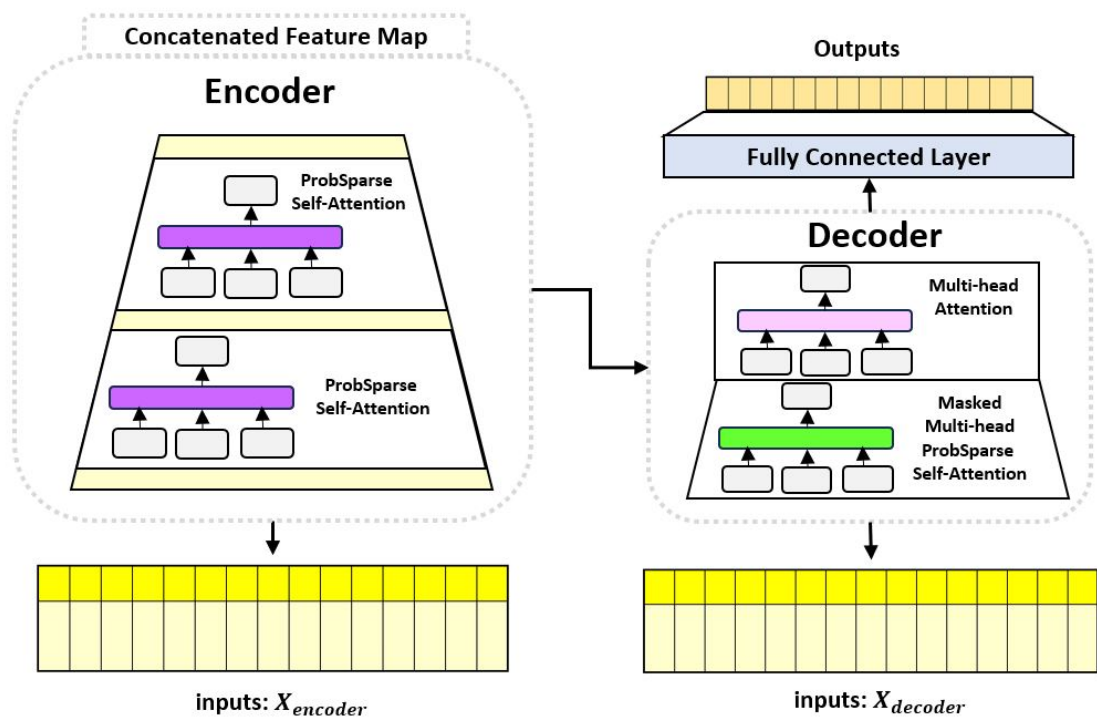


図 6.2: informer

informer でアウトプットされたスコア値に対し、極性を付与する。予測済スコア値について四分位範囲を計算した。極性分類の方法は表 6.1 に示す。

表 6.1: 極性分類の方法

分類条件	対応する値
3rd 四分位数 > PLL	1, {positive}
1st 四分位数 ≤ PLL ≤ 3rd 四分位数	0, {neutral}
1st 四分位数 < PLL	-1, {negative}

作成された極指標を金融時系列データと共に使用する場合は、金融時系列データの日付に合わせる。極性指標側に欠落した日付がある場合は中央値で穴埋めされる。

## 6.2.4 先行効果の実証

テキストデータが暗号資産ポートフォリオに先行効果をもたらすことを作成した極性指標を使って実証する。本章では、VAR-LiNGAM を用いた。VAR-LiNGAM は、Hyvärinen

ら [73] が提唱した統計的因果推論モデルである。表記法は Hyvärinen ら [73] に従う。VAR-LiNGAM の定式化は以下の通りである。

$$\mathcal{X}(t) = \sum_{\tau=0}^T \mathcal{B}_{\tau} \mathcal{X}(t - \tau) + \mathcal{E}(t) \quad (6.2)$$

ここで、 $\mathcal{X}(t)$  は時刻  $t$  における変数のベクトル、 $\tau$  は時間遅れを表す。  $T$  は満期日を表す。また、 $\mathcal{B}_{\tau}$  は変数  $\mathcal{X}(t - \tau)$  間の因果関係を表す係数行列である。  $\mathcal{E}(t)$  は擾乱項を表す。VAR-LiNGAM は以下の手順で実装した。

- 第1に、ラグタイムから現在までの変数間の因果関係に Vector Autoregressive (VAR) モデルを適用した。
- 第2に、現時点での変数間の因果関係については、上記の VAR モデルの残差を用いて LiNGAM 推論を行った。

### 6.2.5 変化点検知

ChangeFinder [70] は、Autoregressive (AR) モデルの学習に、オンライン学習と忘却機能を追加した Sequentially Discount-ing AutoRegressive (SDAR) モデルを利用した変化点検知手法である。ChangeFinder のメリットは、計算時間の短縮、非定常データへの対応、オンライン処理などが可能になる点である。ChangeFinder の流れを以下に示す。表記法は Takeuchi & Yamanishi [70] に従う。

- 第1に、入力されたデータから AR モデルを定義し、SDAR モデルでパラメータの学習を行い、外れ値スコアを算出する。外れ値スコアの計算式は以下に示す。

$$Score(x_{\gamma}) = -\log P_{\gamma-1}(x_{\gamma}|x^{\gamma-1}) \quad (6.3)$$

- 第2に、求めた外れ値スコアに対し、期間  $T$  ごとに平滑化処理を行う。平滑化処理の計算式を以下に示す。

$$\mathcal{Y}_\gamma = \frac{1}{\Gamma} \sum_{i=\gamma-\Gamma+1}^{\gamma} \text{Score}(x_i) \quad (6.4)$$

- 第3に, 平滑化後, 再度 SDAR アルゴリズムにより算出したスコアを変化点スコアとする. このスコアが一定の閾値を超えた時点を変化点と判断する.

$x_\gamma$  は  $\gamma$  番目の入力データである.  $P_\gamma$  は SDAR アルゴリズムから求めた確率密度関数で,  $P_\gamma$  が高いほど予測値に近づいていることを示す. また, 本章における変化点の判断基準は以下のように設定した.

- 変化点スコアの後半  $\frac{1}{2}$  を変化点検知の対象とする.
- 変化点スコアの閾値は 20 とする.
- 変化点スコアがなだらかな山状の分布を持つ場合, 山の頂上の値を変化点とみなす.

### 6.2.6 最適化アルゴリズム

作成された変化点に基づいてポートフォリオの最適化が実行される. 最適化には, 制約付きリスク・パリティ・アプローチが使用される. リスク・パリティ・ポートフォリオは, 総リスクを各資産に均等に配分する. 本章では, 対数バリア関数を使用した. 最適化問題は以下のように定式化される. 表記法は Kolm ら [90] に従う.

$$\min_{w>0} f(w) = w^\top \Sigma w - \sum_{i=1}^n \ln w_i \quad (6.5)$$

この最適化問題は, 対数ペナルティ関数  $-\sum_{i=1}^n \ln w_i$  という項があることから, 対数ペナルティ定式化と呼ばれる.  $n$  をリスク資産とする. ここで, 全資産の収益率の共分散行列を  $\Sigma$  とする. 最適化問題の最適化条件は以下の通りである.  $w^{-1}$  はベクトル  $w$  の逆ベクトルを表す.

$$\nabla f(x) = 2\Sigma w - w^{-1} = 0 \quad (6.6)$$

また, ある資産の相対リスク寄与度 (RRC) は, ポートフォリオ全体のリスクに対するその資産のリスク寄与度の比率として定義される. これは以下のように与えられる.

$$\mathcal{RRC}_i = \frac{w_i(\Sigma w)_i}{w^\top \Sigma w} \quad (6.7)$$

なお, 最適性条件の各要素は, 以下のように等価な形で書くことができる.

$$2(\Sigma w)_i - \frac{1}{w_i} = 0 \Leftrightarrow w_i(\Sigma w)_i = \frac{1}{2}, i = 1, \dots, n \quad (6.8)$$

これらの条件が成立する場合, 以下の形で書くことができる.

$$\mathcal{RRC}_i = \frac{w_i(\Sigma w)_i}{w^\top \Sigma w} = \frac{1/2}{n/2} = \frac{1}{n} \quad (6.9)$$

本章では, VAR-LiNGAM によって計算された因果情報をリスク・パリティ・ポートフォリオに統合することを試みる. 本章では, シグナルに挟まれた領域をレジームと呼称する. また, レジームの切れ目をセンチメントシグナルと呼ぶ. センチメントシグナルと因果情報の関係を以下に示す.

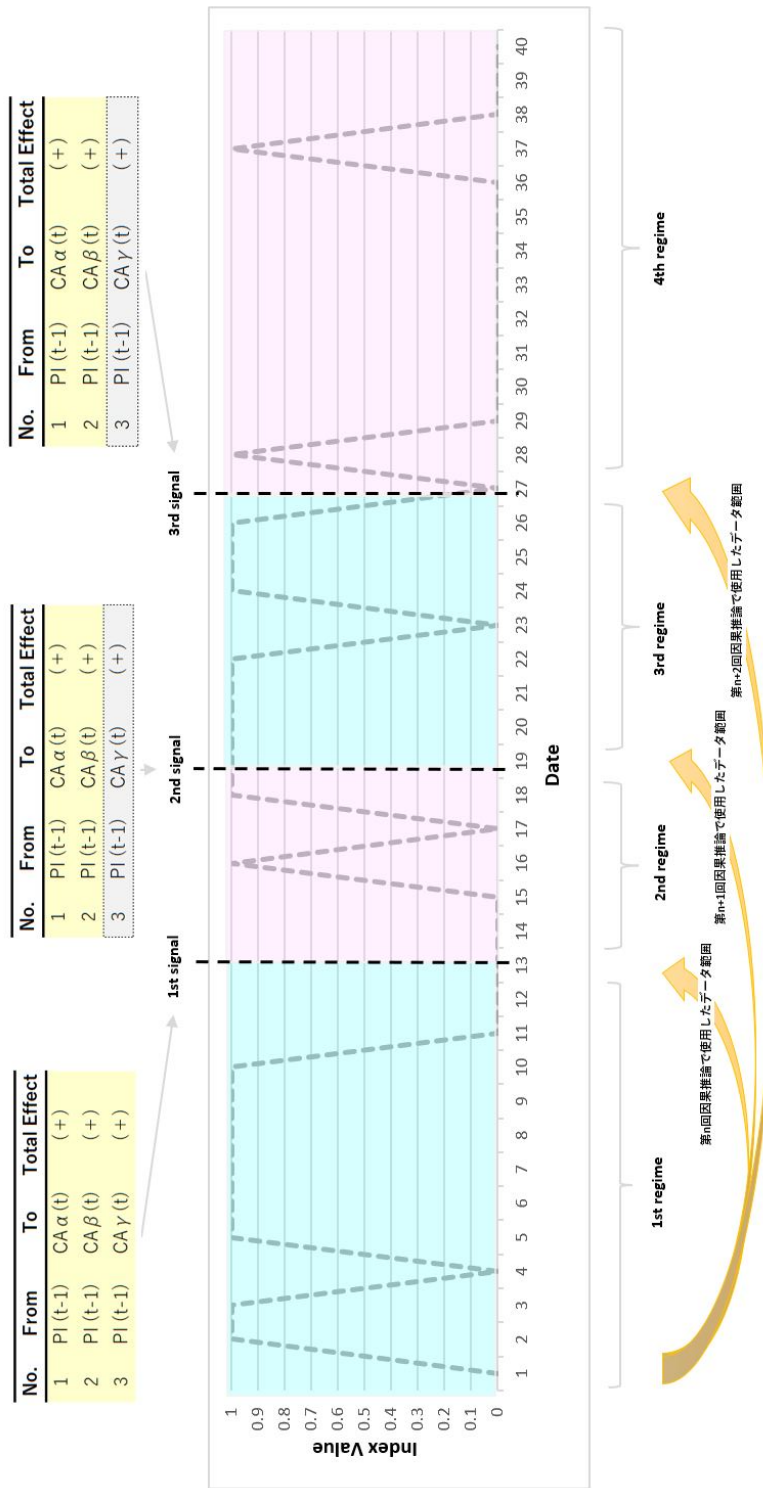


図 6.3: センチメントシグナルと因果情報の関係

VAR-LiNGAM の総合効果の符号に基づいて、リスク・パリティ・ポートフォリオの対象資産の入れ替えを行う。

- バックテスト開始直後は全資産を運用の対象とする。
- 総合効果がマイナスになった対象資産は、次のリバランスのタイミングでドロップする。

6.2.6 章の一連の最適化手法をセンチメントレジームアプローチ（銘柄限定型）と呼称する。

## 6.3 実験と結果

### 6.3.1 データセットの概説

本章では、テキストデータがポートフォリオに対し先行性を持つという仮定に基づき、ポートフォリオ・リバランスのシグナルを計算する。データは2種類使用し、期間は2016年1月から2018年12月までである。データの概要は表6.2に示す。

- **Text:** データ分析プラットフォームの Kaggle<sup>17</sup>が提供する日次テキストデータアーカイブを使用した。
- **CA:** Yahoo! Finance<sup>18</sup>が提供する暗号資産の日次ヒストリカルデータアーカイブを使用した。

### 6.3.2 バックテストの準備

テキストデータのスコアリング方法については、6.2.2 章で述べた。算出した PLL スコアを、極性判定する前に informer を用いて時系列予測を行う。予測結果を表6.1の通り極性分類する。informer の実装には PyTorch を用いた。6.2.4 章で VAR-LiNGAM を用いて

---

<sup>17</sup><https://www.kaggle.com/>

<sup>18</sup><https://finance.yahoo.com/>



表 6.2: データの概要

Type	Name	Details
News	AKBR	Amazon Kindle Book Review
	HFN	Historical Financial News Titles
	ONI	Onion Article Titles
CA	LTC	Litecoin
	NMC	Namecoin
	PPC	Peercoin

因果推論を行う。変化点検知の実装には changefinder [92] を用いた。バックテストの実装には vectorbt [84], Riskfolio-Lib [85], PyPortfolioOpt [91] を用いた。

作成された極性指標同士の相関を図 6.4 に示す。




図 6.4: 極性指標の相関係数

結果から, HFN と ONI のペア以外, 負の相関が高いことがわかる。

ここでは, データの定常性を確認するために, Augmented Dickey-Fuller test (ADF) [81] を用いる。前処理として CA については差分をとる。表 6.3 によると, 検定統計量は 0.05 より小さいので, 帰無仮説は棄却されるため, データは定常であると言える。

定常性が検証されたので, データは VAR-LiNGAM の入力として使用される。

表 6.3: Augmented Dickey-Fuller test

Type	Name	Test Statistic
News	AKBR	-2.73
	HFN	-2.80
	ONI	-4.50
CA	LTC	-6.89
	NMC	-6.28
	PPC	-5.67

因果推論の結果は以下のように表される.

表 6.4: VAR-LiNGAM による因果推論 (AKBR)

Data Coverage	From	To	Total Effect	Remarks
Start-CP2	AKBR(t-1)	LTC(t)	-0.04	-
Start-CP3	AKBR(t-1)	LTC(t)	0.91	Drop the target issue LTC
Start-CP3	AKBR(t-1)	NMC(t)	0.03	-
Start-CP3	AKBR(t-1)	PPC(t)	0.03	-

表 6.5: VAR-LiNGAM による因果推論 (HFN)

Data Coverage	From	To	Total Effect	Remarks
Start-CP2	HFN(t-1)	HFN(t)	-0.08	-
Start-CP2	HFN(t-1)	PPC(t)	-0.02	-
Start-CP2	HFN(t-1)	LTC(t)	0.44	Drop the target issue LTC
Start-CP3	HFN(t-1)	HFN(t)	-0.07	-
Start-CP3	HFN(t-1)	PPC(t)	-0.03	-

表 6.4-6.6 の値は因果推論の総合効果を示す. 考慮するパス係数 (Hyvärinen ら [73] を参照) の最小値は 0.01 とした.

変化点検知の性能を評価するために, 以下の指標を使用する.

- **Precision:** Precision とは, 正のクラスと予測されたサンプルにどれだけ正しい値が含まれているかの比率である. 変化点検知の文脈では, Precision は以下のように定義される.

表 6.6: VAR-LiNGAM による因果推論 (ONI)

Data Coverage	From	To	Total Effect	Remarks
Start-CP2	ONI(t-1)	NMC(t)	0.02	-
Start-CP2	ONI(t-1)	PPC(t)	0.02	-
Start-CP3	ONI(t-1)	PPC(t)	0.03	-
Start-CP3	ONI(t-1)	LTC(t)	-1.42	-

$$\text{Precision} := | \text{TP} | / | \{ \hat{s}_l \}_l | \quad (6.10)$$

- **Hausdorff Metric (HM):** HM は最悪の予測誤差を推定する. 変化点検知に関連する研究としては, Boysen ら [82] や Harchaoui & Lévy-Leduc [83] がある.

$$\text{HM} := \max \left\{ \max_m \min_l | s_m - \hat{s}_l |, \max_m \min_l | \hat{s}_m - s_l | \right\} \quad (6.11)$$

$l$  と  $m$  を変数とする. TP は真陽性であり,  $\text{TP} := \{ s_m \mid \exists s_l \text{ s.t. } | s_l - \hat{s}_m < \text{Mar} | \}$  と定義できる.  $\text{Mar}$  はマージンである. 各指標を用いて計算した結果を表 6.7 に示す.

BSS は Binary Segmentation Search (4.2.4 章を参照), WSS は Window Sliding Segmentation (5.2.4 章を参照), CF は ChangeFinder (6.2.5 章を参照) を指す. なお, 評価に必要な正しいラベルは著者が手動で付与した.

表 6.7 の結果より, 本章のデータについては ChangeFinder の方が比較優位となるため, ChangeFinder を選択する.

変化点検知によって得られたレジームを図 6.5, 6.6, 6.7 に示す.

図 6.5-6.7 において検出された変化点は, AKBK では 2018 年における国連安全保障理事会の北朝鮮に対する経済制裁承認, HFN では 2018 年のインドネシア大地震, ONI では 2018 年におけるイスラム主義者によるフランスへのテロ攻撃, などの重大イベントと重なった.

表 6.7: 変化点検知の評価

Model	Data	Precision	HM
CF (Proposed)	AKBR	<b>1.00</b>	306.00
	HFN	0.50	106.00
	ONI	<b>1.00</b>	157.00
WSS (Comparison)	AKBR	0.33	<b>40.00</b>
	HFN	0.50	220.00
	ONI	0.33	225.00
BSS (Comparison)	AKBR	0.33	280.00
	HFN	0.33	325.00
	ONI	0.33	225.00




図 6.5: 変化点検知 (AKBR)




図 6.6: 変化点検知 (HFN)




図 6.7: 変化点検知 (ONI)

### 6.3.3 バックテストのシナリオ

バックテストの前提条件は以下の通りである。これらは Taguchi ら [86] である程度有効であることが確認されている。

- 定期リバランスは 30 日ごとに行われる。
- CA-SSAAM は、定期リバランスとセンチメントシグナルを組み合わせた戦略である。

本章で提案されたアルゴリズムは以下である。

- **CA-SSAAM:** 本章で提案する方法である。

本章で使用されたベンチマークモデルは以下である。

- **BM (RPP):** 本アルゴリズムは RPP [90] に基づいている。これは、CA-SSAAM から 6.2.4 章における因果推論と、6.2.5 章における変化点の検知の影響を取り除いたものである。

ポートフォリオ理論に基づくアルゴリズムは以下である。

- **MV:** このアルゴリズムは、平均-分散モデル [1] に基づいている。MV は、ポートフォリオ収益率の平均と分散のみを考慮する。
- **CVaR:** このアルゴリズムは、Conditional Value at Risk (CVaR) [2] に基づいている。CVaR はある確率水準におけるポートフォリオの平均的な損失を表すリスク指標である。最適化の条件として期待損失を最小化する必要がある。
- **EVaR:** このアルゴリズムは、Entropic Value at Risk (EVaR) [17] に基づいている。EVaR は VaR と CVaR の上限を示すリスク指標である。
- **CDaR:** この最適化は、Conditional Drawdown at Risk (CDaR) [18] に基づいている。

### 6.3.4 バックテストの評価

バックテストの評価指標は以下のように定義される.

- **TR** : Total Return とは, ある金融資産への投資から一定期間内に得られたリターンの合計を指す. ここで,  $\mathcal{P}_{Start}$  は開始時の価格,  $\mathcal{P}_{End}$  は終了時の価格,  $\mathcal{D}_{Period}$  は期間中の受取配当金である.

$$TR = \frac{\mathcal{P}_{Start} - \mathcal{P}_{End} + \mathcal{D}_{Period}}{\mathcal{P}_{Start}} \quad (6.12)$$

- **AR** : Annualized Return とは, 1 年間に発生した投資収益率である.  $n$  は期間中の日数である.

$$AR = (TR + 1)^{\frac{252}{n}} - 1 \quad (6.13)$$

- **AV** : Annualized Volatility は, 1 年間に発生した金融資産の価格変動率を表す. ここで,  $N$  は要素数,  $\mathcal{R}_i$  は  $i$  番目のリターン,  $\hat{\mathcal{R}}$  は平均リターンである.

$$AV = \sqrt{252} \times \sqrt{\frac{\sum_{i=1}^N (\mathcal{R}_i - \hat{\mathcal{R}})^2}{N - 1}} \quad (6.14)$$

- **MDD** : Maximum Drawdown とは, 最大資産からの下落率を指す. ここで,  $\mathcal{V}_{Peak}$  は最大下落前のピーク値,  $\mathcal{V}_{Lowest}$  は最大下落前の最低値である.

$$MDD = \frac{\mathcal{V}_{Peak} - \mathcal{V}_{Lowest}}{\mathcal{V}_{Peak}} \quad (6.15)$$

- **SR** : Sharpe Ratio は, 投資対象が取ったリスクに見合ったリターンを上げたかどうかを測る指標である. ここで  $\mathcal{R}_f$  はリスク・フリー・レートである. 本章では  $\mathcal{R}_f = 0$  と仮定する.

$$SR = \frac{AR - \mathcal{R}_f}{AV} \quad (6.16)$$

- **CR** : Calmar Ratio は, 高リターンが高リスクと関連しているかどうかを示す指標である.

$$CR = \frac{AR - \mathcal{R}_f}{MDD} \quad (6.17)$$

- $\text{TE}$  : Tracking Error は, ポートフォリオ・リターンとベンチマーク・リターンの差を表す. ここで,  $\text{Var}(\cdot)$  は分散,  $\mathcal{R}_p$  はポートフォリオ・リターン,  $\mathcal{R}_b$  はベンチマーク・リターンを表す.

$$\text{TE} = \sqrt{252} \times \sqrt{\text{Var}(\mathcal{R}_p - \mathcal{R}_b)} \quad (6.18)$$

- $\text{IR}$  : Information Ratio は,  $\text{TE}$  で考慮されるリスクに対して, どれだけ多くのリターンが得られるかを表す. ここで,  $N$  は要素数,  $\mathcal{R}_p$  はポートフォリオ・リターン,  $\mathcal{R}_b$  はベンチマーク・リターンを表す.

$$\text{IR} = \frac{\mathcal{R}_p - \mathcal{R}_b}{\text{TE}} \quad (6.19)$$

### 6.3.5 バックテストの結果

本章のバックテストの結果を表 6.8 に示す. また, 各月末の Total Return の時系列プロットを図 6.8 に示す.

Type	Name	Parameter	AR [%]	AV [%]	MDD [%]	SIR	CIR	TE	IIR
Proposed	CA-SSAAM #1	text = akbr	22.60	117.16	92.48	0.19	0.24	46.22	48.89
	CA-SSAAM #2	text = hfn	46.21	100.99	<b>90.79</b>	0.46	0.51	33.43	138.22
	CA-SSAAM #3	text = oni	<b>51.48</b>	95.32	91.25	<b>0.54</b>	<b>0.56</b>	22.16	<b>232.32</b>
Benchmark	BM (RPP)	weight_bounds = (0.01, 1)	47.09	96.95	91.22	0.49	0.52	-	-
Portfolio Theory	MV	significance_level = 0.05	39.73	<b>91.19</b>	92.67	0.44	0.43	48.18	82.47
	CVaR	significance_level = 0.05	31.78	93.01	93.16	0.34	0.34	<b>63.25</b>	50.25
	EVaR	significance_level = 0.05	43.92	92.36	92.54	0.48	0.47	57.95	75.80
	CDaR	significance_level = 0.05	39.42	96.49	93.53	0.41	0.42	60.00	65.69

表 6.8: バックテスト (CA-SSAAM)






図 6.8: Total Return

## 6.4 考察

表 6.8 において, CA-SSAAM の全体的な傾向として, MDD の値が低く, 比較的安定的な戦略であることがわかる. CA-SSAAM#2 と #3 では, SR, CR, IIR が他の手法より高く出ている.

CA-SSAAM#1 から #3 での比較では, テキストソースにおいて, 如実に運用パフォーマンスに差が出ることが分かった. CA-SSAAM#2 と #3 の比較では, 運用パフォーマンスに若干の差が出ている. Historical Financial News Titles を使用した CA-SSAAM#2 よりも, Onion Article Titles を使用した CA-SSAAM#3 の方が高いパフォーマンスを出している. これは暗号資産ポートフォリオの運用に限っては, 株価の情報よりもニュース記事のほうが有用だということが示された. 一方で, CA-SSAAM#1 に使われている Amazon Kindle Book Review は金融にほぼ関係がないソースなので, リバランスのシグナルとしては不適であるといえる.

CA-SSAAM を BM (RPP) と比較した. CA-SSAAM の乖離は, 他の手法と比較して小さいことがわかる. これはベースのアルゴリズムがどちらも RPP であることが影響していると考えられる. 特に, CA-SSAAM#3 と BM (RPP) を比較すると, SR, CR について, CA-SSAAM#3 の方が高くなる. 一方, BM (RPP) と CA-SSAAM#1 と #2 の比較では, BM (RPP) の方が高くなる.

CA-SSAAM を MV, CVaR, EVaR, CDaR と比較した. CA-SSAAM#3 との比較では, SR, CR, IIR について CA-SSAAM#3 の方が高くなる. CA-SSAAM#2 との比較では, SR, CR, IIR については CA-SSAAM#2 のほうが高いが, ほぼ変わらないことがわかる. CA-SSAAM#1 との比較では, MV, CVaR, EVaR, CDaR が優れている.

加えて, 図 6.8 について比較する. CA-SSAAM#2 と #3 は構成資産の急激な上昇と下落に対して, 堅調なリターンを出している. EVaR は, 上昇に対しては強いが, 下落に対しては CA-SSAAM#2 と #3 に劣る. BM (RPP) は安定しているが, リターンの伸びが CA-SSAAM#2 と #3 に比べて小さい. MV と CDaR は, BM (RPP) よりもさらにリターンの伸びが小さい. CA-SSAAM#1 はどの場面においても低いリターンを出すことが分かった. 特に, CA-SSAAM#2 と #3 においては, 因果推論の総合効果がマイナスの資産を抜いたタイミングでリターンが向上している. これより, CA-SSAAM のフレームワークは, 本章の最初に記載した仮説 (6.1.2 章) と貢献 (6.1.3 章) に対してある程度の実証ができたといえる.

また、本章では informer を用いることで時系列財務データとテキストデータの時間範囲を合わせることができたため、実証に使えるデータ範囲は保有するテキストデータの範囲より拡大した。本章において予測ベースの極性指標は有効であったが、手法の有効範囲については informer の予測性能に依存すると考えられる。

## 6.5 まとめ

本章では、暗号資産で構成されるポートフォリオのアセットアロケーションにテキストデータが有用であることを実証した。これは、自然言語処理と変化点検知技術を用い、センチメントシグナルを作成することで達成された。将来的には、不動産 ETF、オプション、クレジット・デリバティブなど、ポートフォリオ管理におけるこのフレームワークをさらに強化する予定である。加えて、中央銀行が公表している報告書や財務諸表など、入手可能なテキストデータを組み合わせることで、このアプローチの有効性を確認したい。

## 第7章 おわりに

本研究では、オルタナティブデータから作成した極性指標が既存の経済指標に対して先行性を持つ、すなわち既存の経済指標の数歩先を予測できるという仮説の下、変化点検知アルゴリズムを用い、レジームの変化点を記述し、ポートフォリオ最適化アルゴリズムを切り替えることで、新しい投資戦略を構築した。

### 7.1 目的の振り返り

ここでは、1.5章の目的が、本研究の成果を持って達成されたかどうかについて確認する。

目的1に関しては、レジームスイッチを考慮した3資産以上のポートフォリオ最適化戦略を構築することができた。

目的2に関しては、複数種類の資産で構成されたポートフォリオで8つの評価指標を導入し、多期間において高リスクヘッジ効果を維持できることを示した。

目的3に関しては、因果推論のスコアが銘柄選択に有効であることを示した。

これより、本研究の成果を持って目的は達成されたと言える。

### 7.2 全体の考察

ここでは、本研究を通しての全体の考察を述べる。

1つ目は、本研究におけるアセットアロケーションフレームワークの汎用性についての考察である。本研究では、株式ポートフォリオ、多クラス資産ポートフォリオ、暗号資産ポートフォリオについてそれぞれ実験を行い、提案フレームワークの汎用性を証明してきた。本結果をもとに、また新しい資産クラスのアセットアロケーションを行う場合、提案フ

レームワークは一定の汎用性を持つが、内包するテキストや各アルゴリズムの組み合わせは微調整する必要があると示唆される。テキストデータは個別銘柄の情報が必要な資産クラス（株式など）とそうでない資産クラス（暗号資産など）があるため、場合に応じて使い分けが必要になる。最適化アルゴリズムは、対象資産のボラティリティが高いか低いかによって最適な組み合わせが必要になる。低ボラティリティ資産で構成されたポートフォリオ（例えば債券多めのポートフォリオ）では $\alpha$ を取りに行くためリターン最大化 EVaR 最適化のようなアルゴリズムが必要となり、高ボラティリティ資産で構成されたポートフォリオ（例えば暗号資産中心のポートフォリオ）ではリスク・パリティ・ポートフォリオのようなアルゴリズムが必要となる。

2つ目は、レジームとイベントの関係についての考察である。本研究において極性指標作成の際には、個別の会社名、地名、IPO など経済関連用語、レストランや喫煙者といった市井での生活でよく目にする用語などが使われている。レジームが発生した時点でどのような単語が検知されているかの例を挙げる。ONIでは2018年にレジームが検知され、イスラム主義者によるフランスへのテロ攻撃と重なっているが、この付近では Failed や Decline といった否定を表す語が多く検出されている。本研究では記事のタイトルをテキストデータとして多用したが、今後本フレームワークを用いる際は、使用する時系列テキストデータの見出しに否定語が多く混じり始めたらレジームスイッチの前兆と考え、アセットアロケーションの準備を始めるのが賢明である。

3つ目は、レジームの数とファンドパフォーマンスの関係についての考察である。本フレームワークでは、定期リバランスと不定期リバランスのミックス戦略を推奨している。本研究の結果から1か月ごとの定期リバランスと年1回程度の不定期リバランスを行うミックス戦略が本手法のベストプラクティスであるという示唆を得た。本論文4章において、レジーム5とレジーム10の場合でレジーム変化点と（対応する）イベントを概観する。レジーム5ではパナマ文書の出版やトルコ軍が行ったシリア軍事攻撃、レジーム10の場合レジーム5のイベントに加え核兵器禁止条約の採択や米国のユネスコ脱退などのイベントが対応している。レジーム5は経済に即時影響を与えるイベント（戦争など）で、レジーム10には暫時影響を与えるイベント（条約採択など）が含まれている。経済に即時影響を与えるイベントは、起こった後の影響が比較的明確で、レジームスイッチのトリガーとして検出されやすいが、経済に暫時影響を与えるイベントは、その後の影響が比較的読みづらく、トリガーとして検出されにくいのではないかと考えられる。よって今後本フレームワークを用いる際は、経済に即時影響を与えるイベントの発生が見込まれた場合

は即リバランスを実行, 経済に暫時影響を与えるイベントが見込まれた場合は一度立ち止まり必要に応じてリバランスを行うことが賢明である.

## 7.3 今後の展望

今後は, 本研究の内容について以下の6つの観点から発展させていきたい.

1つ目は, 運用実務を考慮に入れたフレームワークの改良・簡易化である. 本研究のフレームワークの有用性は実証されたが, 作業工程が多い点は今後の課題である.

2つ目は, アセットアロケーションに対するより効果的なテキストソースの選択・開発である. 本研究では アセットアロケーションの対象資産クラスによって効果的なテキストソースに差があることが分かった. 各資産クラスに対応するテキストソースの整理および開発は, 本フレームワークを効率的に運用するために不可欠である.

3つ目は, 運用実務における規制・市況を考慮したアルゴリズム変更タイミング問題への対応である. 伝統的にアルゴリズムの変更タイミングはファンドマネージャーのビジネス・ジャッジにより行われてきた. 本研究においてレジームの変更タイミングを変更ポイントとするフレームワークは本問題に対する1つの解を提示した形になる. 今後は, さらに分析を重ね, 定量的かつ精度の高い解を提供していきたい.

4つ目は, 銘柄選択に対応できる経済因果推論アルゴリズムの研究・開発である. 今後, 経済分野の因果推論アルゴリズムの需要がますます高くなると予想され, 銘柄選択においてもより細分化されたケースに対応することが求められる. その中で, アセットアロケーションの見地から経済因果推論アルゴリズムの新規開発を行っていきたい.

5つ目は, レジームスイッチに柔軟に対応できる Transformer モデルの開発である. 時系列予測を行う際の難点は, やはりレジームスイッチである. はじめて Transformer が発表された直後はレジームスイッチに柔軟に対応できず, 古典的な時系列モデルよりパフォーマンスが劣ることもあった. 現在ではかなり改善されているが, 本研究のような産業応用の観点から基礎研究へのフィードバックを継続的に行っていきたい.

6つ目は, アセット・ライアビリティ・マネジメント (ALM)・エンタープライズ・リスク・マネジメント (ERM) への対応である. 本研究は資産運用リスクのヘッジを念頭に設計されているが, 保険リスクやクレジットリスクに関しては現時点で加味されていない.

今後は、総合的なリスク管理の観点から本フレームワークをアップデートしていきたい。

## 参考文献

- [1] Harry Markowitz. Portfolio Selection. *Journal of Finance*, Vol. 7, No. 1, pp. 77–91, March 1952.
- [2] Stanislav Uryasev and R Tyrrell Rockafellar. Conditional value-at-risk: optimization approach. In *Stochastic optimization: algorithms and applications*, pp. 411–435. Springer, 2001.
- [3] 山本裕樹, 松尾豊. 景気ウォッチャー調査を学習データに用いた金融レポートの指数化. 人工知能学会全国大会論文集, Vol. JSAI2016, pp. 3L3OS16a2–3L3OS16a2, 2016.
- [4] Masahiro Suzuki, Hiroki Sakaji, Kiyoshi Izumi, Hiroyasu Matsushima, and Yasushi Ishikawa. Forecasting net income estimate and stock price using text mining from economic reports. *Information*, Vol. 11, No. 6, 2020.
- [5] 上田翼, 和泉潔, 坂地泰紀. 人流データを用いた自動車サプライチェーン異常指数の構築. 人工知能学会第二種研究会資料, Vol. 2023, No. FIN-030, pp. 40–44, 2023.
- [6] 水門善之, 田邊洋人, 和泉潔. 人工衛星観測データを用いた  $\text{CO}_2$  濃度推計値に基づく消費動向の計測モデルの構築. 人工知能学会第二種研究会資料, Vol. 2022, No. FIN-028, p. 98, 2022.
- [7] Rei Taguchi, Hikaru Watanabe, Masanori Hirano, Masahiro Suzuki, Hiroki Sakaji, Kiyoshi Izumi, and Kenji Hiramatsu. Market trend analysis using polarity index generated from analyst reports. In *2021 IEEE International Conference on Big Data (Big Data)*, pp. 3486–3494, 2021.
- [8] H. TONG. Non-linear time series. *A dynamical system approach*, 1990.
- [9] Philip Hans Franses and Dick van Dijk. *Non-Linear Time Series Models in Empirical Finance*. Cambridge University Press, 2000.



- [10] James D. Hamilton. A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica*, Vol. 57, No. 2, pp. 357–384, 1989.
- [11] Takahiro Komatsu and Naoki Makimoto. Dynamic investment strategy with factor models under regime switches. *Asia-Pacific Financial Markets*, Vol. 22, No. 2, pp. 209–237, 2015.
- [12] Takahiro Komatsu and Naoki Makimoto. Linear rebalancing strategy for multi-period dynamic portfolio optimization under regime switches. *Journal of the Operations Research Society of Japan*, Vol. 61, No. 3, pp. 239–260, 2018.
- [13] Masatake Ito, Kabun Jo, and Norio Hibiki. Application of asset allocation models in practice and mutual fund design [in japanese]. *Operations research as a management science*, Vol. 66, No. 10, pp. 683–689, 2021.
- [14] Rei Taguchi, Hikaru Watanabe, Hiroki Sakaji, Kiyoshi Izumi, and Kenji Hiramatsu. Constructing equity investment strategies using analyst reports and regime switching models. *Frontiers in Artificial Intelligence*, Vol. 5, , 2022.
- [15] 山本寛史, 坂地泰紀, 松島裕康, 山下雄己, 大澤恭平, 和泉潔, 島田尚. インフルエンサーのツイートを用いた暗号資産の価格変化予測. 人工知能学会第二種研究会資料, Vol. 2019, No. FIN-022, p. 25, 2019.
- [16] 久保健治, 中川慧, 水上大樹. 確率制御を用いた暗号資産販売所における最適流動化戦略. 人工知能学会第二種研究会資料, Vol. 2022, No. FIN-029, pp. 23–27, 2022.
- [17] Dany Cajas. Entropic portfolio optimization: a disciplined convex programming framework. *Available at SSRN 3792520*, 2021.
- [18] Alexei Chekhlov, Stanislav Uryasev, and Michael Zabarankin. Portfolio optimization with drawdown constraints. In *Supply chain and finance*, pp. 209–228. World Scientific, 2004.
- [19] Hyungbin Yun, Minhyeok Lee, Yeong Seon Kang, and Junhee Seok. Portfolio management via two-stage deep learning with a joint cost. *Expert Systems with Applications*, Vol. 143, p. 113041, 2020.

- [20] Wei Chen, Haoyu Zhang, Mukesh Kumar Mehlawat, and Lifan Jia. Mean–variance portfolio optimization using machine learning-based stock price prediction. *Applied Soft Computing*, Vol. 100, p. 106943, 2021.
- [21] Yilin Ma, Ruizhu Han, and Weizhong Wang. Portfolio optimization with return prediction using deep learning and machine learning. *Expert Systems with Applications*, Vol. 165, p. 113973, 2021.
- [22] Wuyu Wang, Weizi Li, Ning Zhang, and Kecheng Liu. Portfolio formation with preselection using deep learning from long-term financial data. *Expert Systems with Applications*, Vol. 143, p. 113042, 2020.
- [23] Kentaro Imajo, Kentaro Minami, Katsuya Ito, and Kei Nakagawa. Deep portfolio optimization via distributional prediction of residual factors. *Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 35, No. 1, pp. 213–222, May 2021.
- [24] Katsuya Ito, Kentaro Minami, Kentaro Imajo, and Kei Nakagawa. Trader-company method: A metaheuristics for interpretable stock price prediction. In *Proceedings of the 20th International Conference on Autonomous Agents and MultiAgent Systems*, AAMAS ’21, p. 656–664, Richland, SC, 2021. International Foundation for Autonomous Agents and Multiagent Systems.
- [25] Xiao-Yang Liu, Hongyang Yang, Qian Chen, Runjia Zhang, Liuqing Yang, Bowen Xiao, and Christina Dan Wang. Finrl: A deep reinforcement learning library for automated stock trading in quantitative finance. *arXiv preprint arXiv:2011.09607*, 2020.
- [26] Timothy P. Lillicrap, Jonathan J. Hunt, Alexander Pritzel, Nicolas Heess, Tom Erez, Yuval Tassa, David Silver, and Daan Wierstra. Continuous control with deep reinforcement learning, 2015.
- [27] Volodymyr Mnih, Adrià Puigdomènech Badia, Mehdi Mirza, Alex Graves, Timothy P. Lillicrap, Tim Harley, David Silver, and Koray Kavukcuoglu. Asynchronous methods for deep reinforcement learning, 2016.
- [28] John Schulman, Filip Wolski, Prafulla Dhariwal, Alec Radford, and Oleg Klimov. Proximal policy optimization algorithms, 2017.

- [29] Tuomas Haarnoja, Aurick Zhou, Pieter Abbeel, and Sergey Levine. Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor, 2018.
- [30] Tuomas Haarnoja, Aurick Zhou, Kristian Hartikainen, George Tucker, Sehoon Ha, Jie Tan, Vikash Kumar, Henry Zhu, Abhishek Gupta, Pieter Abbeel, and Sergey Levine. Soft actor-critic algorithms and applications, 2018.
- [31] Tuomas Haarnoja, Sehoon Ha, Aurick Zhou, Jie Tan, George Tucker, and Sergey Levine. Learning to walk via deep reinforcement learning, 2018.
- [32] Tomoki Ito, Kota Tsubouchi, Hiroki Sakaji, Tatsuo Yamashita, and Kiyoshi Izumi. Contextual sentiment neural network for document sentiment analysis. *Data Science and Engineering*, Vol. 5, No. 2, pp. 180–192, 2020.
- [33] Hiroki Sakaji, Ryota Kuramoto, Hiroyasu Matsushima, Kiyoshi Izumi, Takashi Shimada, and Keita Sunakawa. Financial text data analytics framework for business confidence indices and inter-industry relations. In *Proceedings of the First Workshop on Financial Technology and Natural Language Processing*, pp. 40–46, 2019.
- [34] Kyoto Yono, Hiroki Sakaji, Hiroyasu Matsushima, Takashi Shimada, and Kiyoshi Izumi. Construction of macroeconomic uncertainty indices for financial market analysis using a supervised topic model. *Journal of Risk and Financial Management*, Vol. 13, No. 4, 2020.
- [35] Masahiro Suzuki, Hiroki Sakaji, Kiyoshi Izumi, and Yasushi Ishikawa. Forecasting stock price trends by analyzing economic reports with analyst profiles. *Frontiers in Artificial Intelligence*, p. 103, 2022.
- [36] Yao Qin, Dongjin Song, Haifeng Chen, Wei Cheng, Guofei Jiang, and Garrison Cottrell. A dual-stage attention-based recurrent neural network for time series prediction, 2017.
- [37] Jiawei Ma, Zheng Shou, Alireza Zareian, Hassan Mansour, Anthony Vetro, and Shih-Fu Chang. Cdsa: Cross-dimensional self-attention for multivariate, geo-tagged time series imputation, 2019.

- [38] Shiyang Li, Xiaoyong Jin, Yao Xuan, Xiyu Zhou, Wenhui Chen, Yu-Xiang Wang, and Xifeng Yan. Enhancing the locality and breaking the memory bottleneck of transformer on time series forecasting, 2020.
- [39] Haoyi Zhou, Shanghang Zhang, Jieqi Peng, Shuai Zhang, Jianxin Li, Hui Xiong, and Wancai Zhang. Informer: Beyond efficient transformer for long sequence time-series forecasting, 2021.
- [40] Biwei Huang, Kun Zhang, Jiji Zhang, Joseph D Ramsey, Ruben Sanchez-Romero, Clark Glymour, and Bernhard Schölkopf. Causal discovery from heterogeneous/nonstationary data. *J. Mach. Learn. Res.*, Vol. 21, No. 89, pp. 1–53, 2020.
- [41] Peter Spirtes, Clark Glymour, and Richard Scheines. Causation, prediction, and search.
- [42] David Maxwell Chickering. Optimal structure identification with greedy search. *Journal of machine learning research*, Vol. 3, No. Nov, pp. 507–554, 2002.
- [43] David Heckerman, Dan Geiger, and David M Chickering. Learning bayesian networks: The combination of knowledge and statistical data. *Machine learning*, Vol. 20, No. 3, pp. 197–243, 1995.
- [44] Biwei Huang, Kun Zhang, Yizhu Lin, Bernhard Schölkopf, and Clark Glymour. Generalized score functions for causal discovery. In *Proceedings of the 24th ACM SIGKDD international conference on knowledge discovery & data mining*, pp. 1551–1560, 2018.
- [45] Peter Bühlmann, Jonas Peters, and Jan Ernest. Cam: Causal additive models, high-dimensional order search and penalized regression. *The Annals of Statistics*, Vol. 42, No. 6, pp. 2526–2556, 2014.
- [46] Patrik Hoyer, Dominik Janzing, Joris M Mooij, Jonas Peters, and Bernhard Schölkopf. Nonlinear causal discovery with additive noise models. *Advances in neural information processing systems*, Vol. 21, , 2008.
- [47] Jonas Peters, Joris M. Mooij, Dominik Janzing, and Bernhard Schölkopf. Causal discovery with continuous additive noise models. *Journal of Machine Learning Research*, Vol. 15, No. 58, pp. 2009–2053, 2014.

- [48] Shohei Shimizu, Patrik O Hoyer, Aapo Hyvärinen, Antti Kerminen, and Michael Jordan. A linear non-gaussian acyclic model for causal discovery. *Journal of Machine Learning Research*, Vol. 7, No. 10, 2006.
- [49] Shohei Shimizu, Takanori Inazumi, Yasuhiro Sogawa, Aapo Hyvärinen, Yoshinobu Kawahara, Takashi Washio, Patrik O Hoyer, and Kenneth Bollen. Directlingam: A direct method for learning a linear non-gaussian structural equation model. *The Journal of Machine Learning Research*, Vol. 12, pp. 1225–1248, 2011.
- [50] Kiyoshi Izumi, Hitomi Sano, and Hiroki Sakaji. Economic causal-chain search and economic indicator prediction using textual data. In *Proceedings of the 3rd Financial Narrative Processing Workshop*, pp. 19–25, 2021.
- [51] Kiyoshi Izumi and Hiroki Sakaji. Economic causal-chain search using text mining technology. In *International Joint Conference on Artificial Intelligence*, pp. 23–35. Springer, 2019.
- [52] Ewan S Page. Continuous inspection schemes. *Biometrika*, Vol. 41, No. 1/2, pp. 100–115, 1954.
- [53] ES Page. A test for a change in a parameter occurring at an unknown point. *Biometrika*, Vol. 42, No. 3/4, pp. 523–527, 1955.
- [54] Marc Lavielle and Gilles Teyssiere. Adaptive detection of multiple change-points in asset price volatility. In *Long memory in economics*, pp. 129–156. Springer, 2007.
- [55] Venkata Jandhyala, Stergios Fotopoulos, Ian MacNeill, and Pengyu Liu. Inference for single and multiple change-points in time series. *Journal of Time Series Analysis*, Vol. 34, No. 4, pp. 423–446, 2013.
- [56] Kaylea Haynes, Idris A Eckley, and Paul Fearnhead. Computationally efficient changepoint detection for a range of penalties. *Journal of Computational and Graphical Statistics*, Vol. 26, No. 1, pp. 134–143, 2017.
- [57] Frédéric Desobry, Manuel Davy, and Christian Doncarli. An online kernel change detection algorithm. *IEEE Transactions on Signal Processing*, Vol. 53, No. 8, pp. 2961–2974, 2005.

- [58] Zaid Harchaoui, Félicien Vallet, Alexandre Lung-Yut-Fong, and Olivier Cappé. A regularized kernel-based approach to unsupervised audio segmentation. In *2009 IEEE international conference on acoustics, speech and signal processing*, pp. 1665–1668. IEEE, 2009.
- [59] Daniele Angelosante and Georgios B Giannakis. Group lassoing change-points in piecewise-constant ar processes. *EURASIP Journal on Advances in Signal Processing*, Vol. 2012, No. 1, pp. 1–16, 2012.
- [60] Nicolas Seichepine, Slim Essid, Cédric Févotte, and Olivier Cappé. Piecewise constant nonnegative matrix factorization. In *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 6721–6725. IEEE, 2014.
- [61] Toby Dylan Hocking, Gudrun Schleiermacher, Isabelle Janoueix-Lerosey, Valentina Boeva, Julie Cappel, Olivier Delattre, Francis Bach, and Jean-Philippe Vert. Learning smoothing models of copy number profiles using breakpoint annotations. *BMC bioinformatics*, Vol. 14, pp. 1–15, 2013.
- [62] L Oudre, R Barrois-Müller, T Moreau, C Truong, R Dadashi, T Grégory, D Ricard, N Vayatis, C De Waele, A Yelnik, et al. Détection automatique des pas à partir de capteurs inertiels pour la quantification de la marche en consultation. *Neurophysiologie Clinique/Clinical Neurophysiology*, Vol. 45, No. 4-5, p. 394, 2015.
- [63] Siqi Liu, Adam Wright, and Milos Hauskrecht. Change-point detection method for clinical decision support system rule monitoring. *Artificial intelligence in medicine*, Vol. 91, pp. 49–56, 2018.
- [64] Jan Verbesselt, Rob Hyndman, Glenn Newnham, and Darius Culvenor. Detecting trend and seasonal changes in satellite image time series. *Remote sensing of Environment*, Vol. 114, No. 1, pp. 106–115, 2010.
- [65] Jaxk Reeves, Jien Chen, Xiaolan L Wang, Robert Lund, and Qi Qi Lu. A review and comparison of changepoint detection techniques for climate data. *Journal of applied meteorology and climatology*, Vol. 46, No. 6, pp. 900–915, 2007.
- [66] Sayantan Banerjee and Kousik Guhathakurta. Change-point analysis in financial networks. *Stat*, Vol. 9, No. 1, p. e269, 2020.

- [67] VASILE GEORGESCU. Online change-point detection in financial time series: challenges and experimental evidence with frequentist and bayesian setups. pp. 131–145, 2012.
- [68] Reza Habibi. Bayesian online change point detection in finance. *Financial Internet Quarterly*, Vol. 18, No. 1, pp. 27–34, 2022.
- [69] Kieran Wood, Stephen Roberts, and Stefan Zohren. Slow momentum with fast reversion: A trading strategy using deep learning and changepoint detection. *The Journal of Financial Data Science*, Vol. 4, No. 1, pp. 111–129, dec 2021.
- [70] J. Takeuchi and K. Yamanishi. A unifying framework for detecting outliers and change points from time series. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 18, No. 4, pp. 482–492, 2006.
- [71] Julian Salazar, Davis Liang, Toan Q. Nguyen, and Katrin Kirchhoff. Masked language model scoring. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, pp. 2699–2712, Online, July 2020. Association for Computational Linguistics.
- [72] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. Bert: Pre-training of deep bidirectional transformers for language understanding, 2019.
- [73] Aapo Hyvärinen, Kun Zhang, Shohei Shimizu, and Patrik O Hoyer. Estimation of a structural vector autoregression model using non-gaussianity. *Journal of Machine Learning Research*, Vol. 11, No. 5, 2010.
- [74] Tommaso Ciarli, Alexander Coad, and Alessio Moneta. Exporting and productivity as part of the growth process: Causal evidence from a data-driven structural var. Technical report, LEM Working Paper Series, 2019.
- [75] Kiyoshi Izumi and Hiroki Sakaji. Economic causal-chain search using text mining technology. In *Proceedings of the First Workshop on Financial Technology and Natural Language Processing*, pp. 61–65, Macao, China, August 2019.
- [76] Jushan Bai. Estimating multiple breaks one at a time. *Econometric theory*, Vol. 13, No. 3, pp. 315–352, 1997.

- [77] Piotr Fryzlewicz. Wild binary segmentation for multiple change-point detection. *The Annals of Statistics*, Vol. 42, No. 6, pp. 2243–2281, 2014.
- [78] Charles Truong, Laurent Oudre, and Nicolas Vayatis. Selective review of offline change point detection methods. *Signal Processing*, Vol. 167, p. 107299, 2020.
- [79] A. Ahmadi-Javid. An information-theoretic approach to constructing coherent risk measures. In *2011 IEEE International Symposium on Information Theory Proceedings*, pp. 2125–2127, 2011.
- [80] Amir Ahmadi-Javid. Entropic value-at-risk: A new coherent risk measure. *Journal of Optimization Theory and Applications*, Vol. 155, No. 3, pp. 1105–1123, 2012.
- [81] David A Dickey and Wayne A Fuller. Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*, Vol. 74, No. 366a, pp. 427–431, 1979.
- [82] Leif Boysen, Angela Kempe, Volkmar Liebscher, Axel Munk, and Olaf Wittich. Consistencies and rates of convergence of jump-penalized least squares estimators. *The Annals of Statistics*, Vol. 37, No. 1, feb 2009.
- [83] Z. Harchaoui and C. Lévy-Leduc. Multiple change-point estimation with a total variation penalty. *Journal of the American Statistical Association*, Vol. 105, No. 492, pp. 1480–1493, 2010.
- [84] Oleg Polakow. vectorbt (1.4.2). <https://github.com/polakowo/vectorbt/tree/master/vectorbt>, 2022.
- [85] Dany Cajas. Riskfolio-lib (3.0.0). <https://github.com/dcajasn/Riskfolio-Lib>, 2022.
- [86] Rei Taguchi, Hiroki Sakaji, and Kiyoshi Izumi. Ssaam: Sentiment signal-based asset allocation method with causality information. In *2022 IEEE International Conference on Big Data (Big Data)*, pp. 2363–2366, 2022.
- [87] Steven Bird, Ewan Klein, and Edward Loper. *Natural Language Processing with Python*, Juni 2009.



- [88] Alexandre Lung-Yut-Fong, Céline Lévy-Leduc, and Olivier Cappé. Distributed detection/localization of change-points in high-dimensional network traffic data. *Statistics and Computing*, Vol. 22, No. 2, pp. 485–496, 2012.
- [89] Céline Lévy-Leduc and François Roueff. Detection and localization of change-points in high-dimensional network traffic data. *The Annals of Applied Statistics*, pp. 637–662, 2009.
- [90] Petter N. Kolm, Reha Tütüncü, and Frank J. Fabozzi. 60 years of portfolio optimization: Practical challenges and current trends. *European Journal of Operational Research*, Vol. 234, No. 2, pp. 356–371, 2014. 60 years following Harry Markowitz ’ s contribution to portfolio theory and operations research.
- [91] Robert Andrew Martin. Pyportfoliopt: portfolio optimization in python. *Journal of Open Source Software*, Vol. 6, No. 61, p. 3066, 2021.
- [92] Shunsuke Aihara. changefinder (0.0.3). <https://github.com/shunsukeaihara/changefinder>, 2018.

# 補遺

本論文は，東京大学大学院工学系研究科システム創成学専攻博士後期課程在学中に行った以下の研究発表の内容に基づく．

## 1. 査読付き学術雑誌論文

- Rei Taguchi, Hiroki Sakaji, Kiyoshi Izumi, Yuri Murayama. Constructing Sentiment Signal-based Asset Allocation Method with Causality Information. *New Generation Computing*, vol.41, pp.777–794, Sep 11, 2023
- Rei Taguchi, Hiroki Sakaji, Kiyoshi Izumi, Yuri Murayama. Asset Allocation Method Based on Sentiment Signals and Causal Information using Multi-asset Classes. *International Journal of Smart Computing and Artificial Intelligence* vol.7, no.2, Dec 14, 2023
- Rei Taguchi, Hikaru Watanabe, Hiroki Sakaji, Kiyoshi Izumi, Kenji Hiramatsu. Constructing Equity Investment Strategies using Analyst Reports and Regime Switching Models. *Frontiers in Artificial Intelligence in Finance* (ISSN 2624-8212), 5, May 18, 2022

## 2. 査読付き国際会議論文

- Rei Taguchi, Hiroki Sakaji, Kiyoshi Izumi. SSAAM: Sentiment Signal-based Asset Allocation Method with Causality Information. 2022 IEEE International Conference on Big Data (Big Data), Dec 18, 2022
- Rei Taguchi, Hikaru Watanabe, Hiroki Sakajii, Kiyoshi Izumii, Kenji Hiramatsu. Proposal for Turning Point Detection Method using Financial Text and Transformer. The 36th Annual Conference of the Japanese Society for Artificial Intelligence, Jun 5, 2022

- Rei Taguchi, Hikaru Watanabe, Masanori Hirano, Masahiro Suzuki, Hiroki Sakaji, Kiyoshi Izumi, Kenji Hiramatsu. Market Trend Analysis Using Polarity Index Generated from Analyst Reports. 2021 IEEE International Conference on Big Data (Big Data), Dec 15, 2021

### 3. 国内学会発表

- 田口怜, 坂地泰紀, 和泉潔. 因果関係を考慮した感情シグナルに基づく資産配分法の提案. 2023 年度人工知能学会全国大会 (第 37 回) 2023 年 6 月 7 日
- 田口怜, 渡邊光, 坂地泰紀, 和泉潔, 平松賢士. Financial Text と Transformer を用いた転換点検出手法の提案. 人工知能学会第 28 回金融情報学研究会 2022 年 3 月 12 日
- 田口怜, 渡邊光, 坂地泰紀, 和泉潔, 平松賢士. アナリストレポートとレジームスイッチングモデルを用いた株式投資戦略の構築. 人工知能学会「社会における AI」研究会 第 41 回研究会 2021 年 11 月 27 日
- 田口怜, 渡邊光, 平野正徳, 鈴木雅弘, 坂地泰紀, 和泉潔, 平松賢士. アナリストレポートから生成した極性指標を用いた市場動向分析. 人工知能学会第 27 回金融情報学研究会 2021 年 10 月 9 日

# 謝辞

本論文は筆者が東京大学大学院工学系研究科システム創成学専攻在学時に和泉・坂地研究室で行った研究をまとめたものです。

本論文の作成にあたり、多くの方々にお力添えをいただきました。あらためて感謝申し上げます。

指導教員の和泉潔教授には、博士課程在学中に、熱心なご指導、多くの有益なご助言をいただきました。深く感謝いたします。また、研究室内でのご指導に加えて、国内外での学会活動においても、大変お世話になりました。加えて、今後のキャリアについて親身に相談に乗っていただき、誠にありがとうございました。

坂地泰紀特任講師には、論文の投稿にあたり、多くのきめ細かいアドバイスをいただきました。深く感謝いたします。他分野からの進学にも関わらず、情報系の論文特有の作法や、論文の投稿戦略についてのご指導、加えてゼミ勉強会以外での個別指導もいただき大変感謝しております。ありがとうございました。

中部大学の松井藤五郎教授、東京大学の陳 昱教授・島田尚准教授・安川和孝准教授には本論文の副査を担当していただきました。誠にありがとうございました。

和泉・坂地研究室の学生の皆様にも本研究を進めるにあたり大変お世話になりました。

博士課程の平野正徳氏には、研究のデザインから設計についてあらゆる面で建設的なご意見をいただきました。誠にありがとうございました。また、夏休み期間の有志勉強会などで進捗のフォローアップもいただき感謝に堪えません。

博士課程の鈴木雅弘氏には、筆者と同じくオルタナティブデータを用いた研究をされており、なおかつ資産運用会社に勤務されている視点から、研究デザインから詳細な評価方法に至るまで建設的なご意見をいただきました。誠にありがとうございました。

博士課程の皆川直人氏には、同じ社会人博士の立場から学業と仕事の両立について相談させていただきました。社会人の先輩として有益なアドバイスをいただきましてありがと

うございました。

修士課程の渡邊光氏には入学当時実装のアドバイスや共著論文の執筆など、研究の基礎的な部分をお手伝いいただきました。ありがとうございました。

筆者は、IBM Technology Expert Labs (Data & AI) の Data Scientist として業務をしながら研究を行ってきました。仕事と学業の両立を承諾し応援してくださった石井宏和氏をはじめとするマネジメントの皆様、後押ししてくださった同僚諸氏に深く感謝申し上げます。

そして、本学入学前から私の研究生生活を支えてくれた妻の有沙には日々の仕事、家庭、学生生活全般にわたりきめ細やかなサポートをいただきました。誠にありがとうございました。

最後に、秋田県から私の研究生生活を応援してくれた父の和彦、母の美保子、弟の慧、祖母の鈴木花子、祖父の鈴木倉司、この論文完成を目前に早逝した義父の丹治勇夫に心から感謝の意を表し、本論文の謝辞とさせていただきます。