

東京大学大学院
工学系研究科 システム創成学専攻
博士論文

拡張トピックモデルを用いた金融テキストに対
する指標構築、およびマーケット分析

指導教員: 和泉潔

余野京登

37-167282

2020年6月1日 提出

目次

第 1 章	はじめに	13
1.1	金融分野における人工知能技術の応用	13
1.1.1	人工知能技術の金融サービス業への影響	13
1.1.2	オルタナティブデータの台頭	14
1.2	自然言語処理技術の金融分野への応用	15
1.2.1	情報処理の自動化	15
1.2.2	資産運用への応用	15
1.2.3	伝統的ファイナンス理論との関連性	16
1.3	テキストデータの数値化	17
1.3.1	テキストデータに含まれる情報	17
1.3.2	テキストデータの特徴	18
1.3.3	トピックモデルによる数値化	18
1.3.4	トピックモデルの拡張、および金融テキストへの適応	19
1.4	本研究の目的	21
1.5	本研究の対象と手法	22
第 2 章	中央銀行の経済や物価に対する個別のセンチメントの可視化	25
2.1	中央銀行のコミュニケーション	25
2.2	金融政策におけるテキスト	26
2.3	中央銀行の発行するテキストを対象にした先行研究	27
2.3.1	中央銀行のテキスト自体に対する分析	27
2.3.2	市場でどのような影響を及ぼしているかについての分析	29
2.3.3	先行研究における課題	29
2.4	本章の目的	30
2.5	データセット	30
2.5.1	金融経済月報	30

2.5.2	景気ウォッチャー調査	31
2.6	モデル	33
2.6.1	深層学習によるセンチメント付与	33
2.6.2	トピックモデルによるトピック分類	35
2.6.3	トピック別センチメント指数の構築	38
2.7	トピック別センチメント指数の結果	38
2.7.1	全体のセンチメント推移	38
2.7.2	トピック分類の結果	39
2.7.3	トピック別のセンチメント推移	41
2.7.4	考察	54
2.7.5	マクロ指標との関連性	56
2.8	本章のまとめ	59
第3章	拡張したトピックモデルによる不確実性指数の構築	61
3.1	不確実性指数	61
3.1.1	不確実性とは	61
3.1.2	不確実性指数に関する先行研究	62
3.1.3	先行研究における課題点	66
3.1.4	拡張したトピックモデルを用いた不確実性指数構築の試み	68
3.2	データセット	68
3.2.1	テキストデータ	68
3.2.2	数値データ	70
3.3	提案手法による指数構築	71
3.3.1	指数構築の全体構成	71
3.3.2	テキストデータに対する前処理	71
3.3.3	数値データに対する前処理	73
3.3.4	supervised LDA を用いたトピック分類	74
3.3.5	指数構築	78
3.4	不確実性指数を用いた分析	78
3.4.1	トピック別不確実性指数	78
3.4.2	マクロ経済不確実性指数の推移	81
3.4.3	Baker らのモデルとの比較	85

目次	5
3.4.4 他の指標との相関分析	87
3.4.5 インパルス応答分析	92
3.5 本章のまとめ	94
第4章 市場センチメント指数を用いた為替市場変動の方向性の予想	95
4.1 はじめに	95
4.1.1 為替の決定要因	95
4.1.2 金融市場の価格予想に関する先行研究	96
4.1.3 先行研究における課題	98
4.1.4 本章の目的	99
4.2 トピックモデルの拡張	99
4.2.1 JST	100
4.2.2 sJST	101
4.2.3 推論法	104
4.3 データセット	105
4.3.1 為替レートの数値データ	105
4.3.2 為替ニューステキスト	107
4.4 モデル	108
4.4.1 モデルの全体像	108
4.4.2 テキストデータに対する前処理	109
4.4.3 数値データに対する前処理	109
4.4.4 LDA モデルによる特徴量抽出	110
4.4.5 機械学習による予測変動	110
4.5 結果	112
4.5.1 各トピックモデルによるトピック分類の結果	112
4.5.2 為替予想の結果	119
4.6 本章のまとめ	124
第5章 結論	127
付録A 不確実性指数の可視化ツール	131
A.1 全体構成図	131
A.1.1 分析	132

A.1.2	データベース	132
A.1.3	WEB アプリ	133
A.2	フロント画面	133
A.2.1	トピックの選択	135
A.2.2	トピックの関連単語	135
A.2.3	トピックの時系列推移	136
A.2.4	日付の指定	137
A.2.5	記事の描写	138
A.3	ユースケース	139
文献		141
謝辞		149

表目次

1	各章の対象とするマクロ経済ファクター・心理的な要因と適用するトピックモデル . . .	23
2	日本銀行が発行しているテキストの一覧	26
3	取得した景気判断のデータ数と割合	32
4	LDA のノーテーション	37
5	各トピック k の単語分布 φ_k における上位単語	40
6	各トピックのセンチメント指数とマクロ経済指標との相関	56
7	Baker らのモデルにおける特定キーワード (米国の経済政策不確実性指数)	63
8	Baker らのモデルにおける特定キーワード (日本の経済政策不確実性指数)	67
9	不確実性に関する単語群	72
10	sLDA の定義	75
11	各トピック k の単語分布 φ_k における上位 10 単語	79
12	全部トピック	80
13	Baker らの手法による日本の経済政策不確実性指数の各時点における出現単語上位 10 単語	86
14	Baker らの手法、提案手法による日本の不確実性指数のピーク時における単語割合 . . .	87
15	トピック別不確実性指数と各市場指数のボラティリティとの相関係数。なお $\bar{\eta}$ は、モデル で推論された正規化 VIX の期待値	88
16	トピック別不確実性指数と Baker らの不確実性指数との相関係数。なお $\bar{\eta}$ は、モデル で推論された正規化 VIX の期待値	91
17	単位根検定。P 値の値が 0.05 より大きい場合、有意水準 5%のもとで単位根過程である といえる。	93
18	為替の決定要因	96
19	各トピックモデルにおいて考慮されている要因	99
20	JST の定義	101
21	sJST の定義	103
22	通貨ペア一覧	106

23	各外国為替市場の取引時間 (グリニッジ標準時)	108
24	特徴量、予測モデル、予測対象のまとめ	109
25	予測モデルで用いた特徴量	111
26	データ期間	111
27	モデルの予測した値と実際の値の組み合わせ表	112
28	LDA による各トピック k の単語分布 φ_k における上位単語	113
29	sLDA による各トピック k の単語分布 φ_k における上位単語	114
30	JST による各トピック k 、センチメント l の単語分布 $\varphi_{k,l}$ における上位単語	116
31	sJST による各トピック k 、センチメント l の単語分布 $\varphi_{k,l}$ における上位単語	118
32	予測モデルごとの平均予測精度	119
33	特徴量、モデルごとの予測精度	120
34	トピックモデルの違いによる精度の違いに対する t 検定	122

図目次

1	AI・ビッグデータ活用による金融サービス業の本質の変化 (関・佐藤, 2017)	14
2	トピックモデルによる各トピック事への分類 (Zubiaga et al., 2018)	19
3	supervised LDA モデルによる映画レビューとそのスコアに基づくトピック事分類 (Mcauliffe & Blei, 2008)。横軸はスコアの大きさ。各トピックがレビューのスコアとレビューのテキストの話題の両方が影響されたトピック分類となっている	20
4	Joint Sentiment/Topic Model による各トピック事への分類 (Lin & He, 2009)。トピックとともにセンチメントも同時に推定される。	21
5	テキストの公開タイミング	27
6	景気ウォッチャー調査の深層学習を用いた金融レポートの指数 (山本・松尾, 2016)	28
7	景気ウォッチャー調査 景気判断 理由集	32
8	トピック別センチメント構築の全体像	33
9	LSTM モデル	34
10	LSTM のグラフィカルモデル図	35
11	LDA model	36
12	全センチメント推移。なお縦線より「ゼロ金利政策以前」、「ゼロ金利政策」、「ゼロ金利政策解除後」、「包括的な金融緩和政策」、「量的・質的金融緩和」に時期を区分けした	39
13	「個人消費」トピックの時系列推移	42
14	「公共投資」トピックの時系列推移	43
15	「在庫」トピックの時系列推移	44
16	「設備投資」トピックの時系列推移	45
17	「物価」トピックの時系列推移	46
18	「マネーサプライ」トピックの時系列推移	47
19	「鉱工業生産」トピックの時系列推移	48
20	「企業金融」トピックの時系列推移	49
21	「マーケット」トピックの時系列推移	50
22	「貿易」トピックの時系列推移	51

23	「資金供給」トピックの時系列推移	52
24	「企業収益」トピックの時系列推移	53
25	個人消費のセンチメントと消費者信頼感指数の推移	56
26	企業収益のセンチメントと Markit 製造業 PMI の推移	57
27	鉱工業生産センチメントと鉱工業生産前年比の推移	57
28	資金供給センチメントと日銀マネタリーベース前年比の推移	58
29	物価センチメントと CPI 前年比の推移	58
30	Baker らの構築した政策不確実性指数 (Baker et al., 2016)	64
31	Arbatli らの構築した日本の政策不確実性指数 (Arbatli, 2017)	65
32	Rauh らの構築した地域別政策不確実性指数 (Rauh, 2019)	66
33	ロイターの日本語ウェブサイト (マクロ経済動向のカテゴリー)	69
34	VIX 指数の過去推移	70
35	処理の全体像	71
36	形態素解析の流れ	73
37	Bag-of-words 表現による Word Embedding	74
38	正規化した VIX 指数の推移	75
39	sLDA モデルのグラフィカルモデル	76
40	トピック数と perplexity の関係性	77
41	各ドキュメント d ごとのトピック分布の月次平均値の時系列推移	81
42	トピック 1 国際的な経済イベントに係る不確実性指数の時系列推移	82
43	トピック 3 米国の財政政策に係る不確実性指数の時系列推移	82
44	トピック 4 新興国をはじめとする世界経済に係る不確実性指数の時系列推移	83
45	トピック 5 ユーロ圏における金融危機に係る不確実性指数の時系列推移	84
46	トピック 6 日本の金融政策に係る不確実性	84
47	ロイターニュースに対する Baker らの手法による日本の経済政策不確実性指数の時系列推移	86
48	各トピックの正規化 VIX の期待値 $\bar{\eta}$ および金融市場指数のボラティリティとの相関係数。正規化 VIX の期待値 $\bar{\eta}$ が大きいトピックほど、各市場のボラティリティと正の相関が強い。	90

49	インパルス応答関数による各変数に対し1標準偏差分のショックを与えたときの日本の 鉱工業生産指数の変動の時間変化。左上がVIXに対してショックを与えた場合。右上が Bakerらのモデルにより構築した日本の不確実性指数に対してショックを与えた場合。 左下がトピック4である新興国をはじめとする世界経済に係る不確実性指数に対して ショックを与えた場合。右下がトピック6である日本の金融政策に係る不確実性指数に 対してショックを与えた場合。	93
50	JST model	100
51	sJST model	102
52	モデルの全体像	108
53	各通貨ペアの取引量とトピックモデルのよる特徴量に起因する Accuracy の精度向上	124
54	システム構成図	132
55	フロント画面	134
56	トピックの選択	135
57	トピックの関連単語の出力	136
58	トピックの時系列推移の出力	137
59	日付の選択	138
60	記事の描写	139
61	使用例	140

第1章 はじめに

1.1 金融分野における人工知能技術の応用

1.1.1 人工知能技術の金融サービス業への影響

第3次人工知能ブームの台頭により、人工知能技術が社会の様々な領域で活用されている。従来では数年かかるとされる演算が、高速にできるようになったという大規模並列計算機技術の発展と、人間の脳神経のネットワークを模倣した深層学習の技術や大規模データから有意なパターンを認識する機械学習技術の発展が背景にある。象徴的な出来事として、Google が買収した企業 DeepMind の開発した AlphaGo が囲碁の対戦において、人間の世界最強候補の棋士に勝利したことが挙げられる。金融分野においても、人工知能技術の適応は例外ではなく、従来では扱えなかった大量データに対し、機械学習、深層学習や自然言語処理等の技術を応用した金融サービスへの取り組みが近年なされている。(関・佐藤, 2017) によると、人工知能技術の金融分野への応用は3つの軸でなされる(図1)。1つ目がパーソナライズ化の方向である。ロボアドバイザーのような顧客(一般投資家)のリスクリターン特性に合わせた銘柄を推奨するような活用である。これまで、人間の営業職員が個々の顧客にヒアリングして、個別に対応していた業務に対して、ロボアドバイザーが顧客の入力したリスク特性を問う質問に対して、顧客のリスク特性を自動的に把握し、顧客満足度を最大化させる形で、顧客のリスク特性似合う銘柄を推薦する。この背景には、機械学習や自然言語処理等の技術が役立っている。2つ目が金融サービス業のミドル・バックオフィスにおいて、行われていた情報処理の自動化の方向である。例えば、エコノミストやアナリストがかかわっていたレポートの執筆を自動的に執筆する方向である。定型的な数値を自動的に入力するなど業務効率の最大化が期待される。3つ目が金融市場の価格の動きの予測である。これは機械学習や深層学習を通じて、過去の価格のパターンから今後の動きを予測することや、これまでには活用されてこなかった新たなデータセット(オルタナティブデータ)を活用し、特定企業の価格の予想に役立っている。

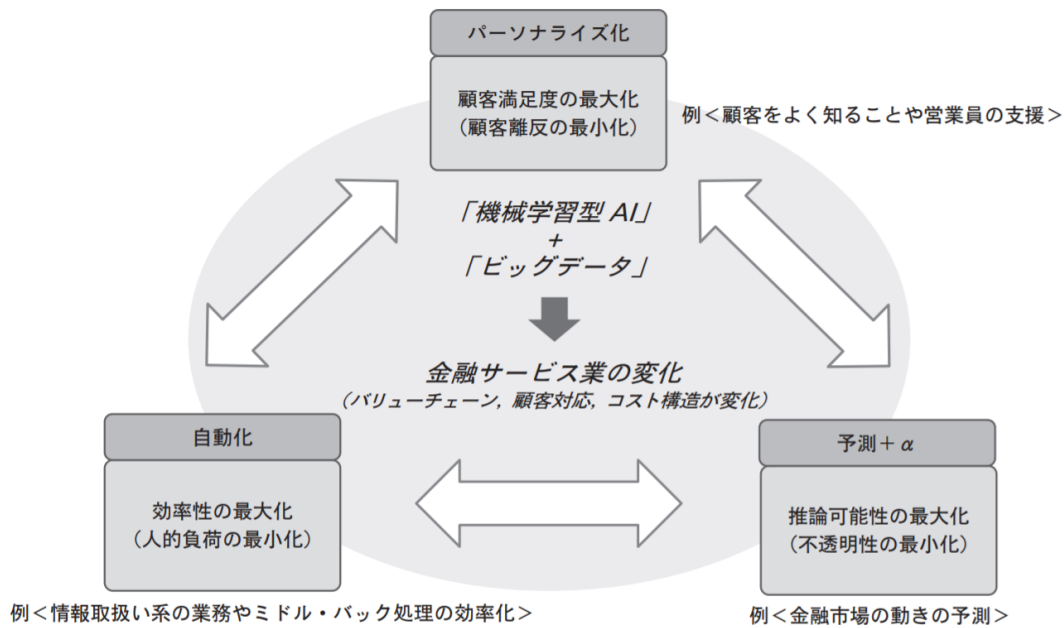


図 1: AI・ビッグデータ活用による金融サービス業の本質の変化 (関・佐藤, 2017)

1.1.2 オルタナティブデータの台頭

オルタナティブデータとは、従来の投資で使用されてきたマクロ経済指標や個別企業の決算数値などのデータの代替となるデータであり、衛星画像データ、POS データやクレジットカードなどの購買データ、さらには SNS データなどのテキストデータのことを指す。近年、人工知能技術の発展に伴い、オルタナティブデータを投資に活用するファンドが増加しており、オルタナティブデータ市場規模は、年々増加していく見込みである。

衛星画像データの活用では、米国のオービタルインサイト社が画像認識技術を使い、スーパーの駐車場に停車している車の数をカウントし、小売業の企業の業績を決算よりも早いタイミングで予測を行ったり、石油の貯蔵タンクの衛星画像からどの程度の石油がタンク内に入っているかを推定し、石油市場の価格の予想を行ったりしている。こうしたオルタナティブデータをヘッジファンド向けに販売しており、莫大な利益をもたらしている。例えば、米国のテルアスラボ社では、気象データや衛星画像データから作物の生産予想を行い、先物市場の価格予想に役立てている。

POS データを活用した事例では、日本のベンチャー企業であるノウキャスト社が、POS データやクレジットカードデータから、各企業ごとの売り上げを集計し、業績予想に役立てたりしている。こうした購買データからは個別企業の売り上げ以外にも、物価上昇率や小売りの状況などのマクロ統計の代替ともなっており、海外のヘッジファンドのみならず、国内エコノミストや政府関係者にも需要が

ある。

1.2 自然言語処理技術の金融分野への応用

先に述べた人工知能技術の発展とオルタナティブデータの台頭を踏まえ、自然言語処理技術がどのようなようにして、金融分野において、応用されているかについて目的別に俯瞰する。

1.2.1 情報処理の自動化

アナリストは大量の個別株の決算短信や経済ニュースから担当している企業に関する情報を集め、分析レポートを執筆している。また、エコノミストは、国内外問わず、経済ニュースや他のアナリストのレポートを読み、自身のレポートに役立てる。彼らの仕事において、自然言語処理技術による情報抽出や文章生成などの技術が役立っている。(酒井他, 2015) においては、決算短信から業績要因の抽出を行っており、この技術より、大量の決算短信からアナリストにとって有益な情報抽出が可能となる。また、(Izumi & Sakaji, 2019b) において、決算短信から抽出した複数の因果情報から因果チェーンを構築し、これにより、経済イベントの個別企業への連続的な波及効果が可視化され、アナリストのレポート作成等に活用できる。ゼノデータ・ラボ社が同様の技術を使用し、コロナウィルスの拡大など特定のリスク事象が発生した際に個別企業への影響の分析ツールを提供している。

また、自然言語処理技術を利用して、実際に文章生成を行う研究もある。(Murakami et al., 2017) において、深層学習を使い、実際の株価の動きをテキストデータに変換する研究がなされたり、(磯沼他, 2016) において、機械学習を用いて、決算短信の業績変動の係る重要文抽出を行ったりしており、この技術を用いて日経新聞社は決算サマリーを自動配信するサービスを提供している。

さらには銘柄選択に自然言語処理を取り入れた研究も進められている。(Hirano et al., 2019) において、キーワード間の similarity を図る手法を開発し、特定キーワードと関連度の高い銘柄を抽出することに成功している。このような技術を用いることで、投資家は大量の銘柄コーパスから自身の投資したい銘柄を効率よく選ぶことができる。

1.2.2 資産運用への応用

自然言語処理を金融テキストに適用し、市場の動きを予想する研究は盛んに行われている。(和泉他, 2010) において、日本銀行の金融経済月報を用いて、国債、株、為替の値動きの予想を行った。彼らの研究では、形態素解析を行い、さらに単語間の共起関係を使い、主要な要素を抽出し、市場の動きに回帰をさせている。

(Bollen et al., 2011a) において、SNS データであるツイッター・データを収集し、Calm, Alert, Sure, Vital, Kind, Happy の 6 つの心理状態を時系列で定量化し、米国株式指数との関係性を分析した。その結果、非常に高い精度で翌日の株価変動の方向性を予測することができた。

そのほかにも、市場のセンチメントから株価を予測する研究はほかにも複数存在する (Heston & Sinha, 2013; Tetlock, 2007)。

また、市場のセンチメントを実際に投資家に提供している会社も存在する。大手情報企業であるトムソンロイター社は、ソーシャルメディアから大手のニュース記事まで日々数百万件のニュースを収集し、自然言語処理技術を用いて、センチメント指数を構築している (Thomson Reuters MarketPsych Indices)。この指数は、日本株、米国株、原油、為替などのアセット別に加え、感情のベクトル (楽観、悲観、恐怖) 別にも算出している。このトムソンロイターの指数を用いて、例えばボラティリティの予測モデルを構築する研究がある (チェ, 2017)。市場のセンチメントではなく、中央銀行のセンチメント (金融引き締めか金融緩和か) の度合いを算出する企業も存在する。米国のベンチャー企業であるプラトル社は、日本銀行や米国の中央銀行にあたる FOMC の各審議員の講演やインタビューのテキストからセンチメントを計算し、これを定量化し、国ごとに時系列データとして比較できるようにし、投資家向けに提供している。

また、センチメントを各個別企業レベルで計測し、提供している企業もある。米国のベンチャー企業である TruValue Labs 社が開発・サポートする Insight360 というシステムでは、8000 社以上の上場企業に対して、テキストデータをはじめ様々な ESG に係る情報を収集・分析し、そのセンチメントをスコアリングを行っている。これにより投資家は、ESG という軸で保有企業を評価したり、新規投資先を選定することが可能である。

投資家は、こうした様々なテキストデータから数値化されたセンチメントを運用モデルに組み込むことができる。

1.2.3 伝統的ファイナンス理論との関連性

金融経済学において、「効率的市場仮説」という考え方があり、市場は効率的で一瞬のうちに価格に織り込まれてしまい、価格予想による超過収益を得ることはできないとする仮説である。「ウィーク型」、「セミストロング」、「ストロング型」の3つのレベルに分かれる。「ウィーク型」は、過去の価格データの推移から将来の価格予想はできないとし、価格データのみを使った予想はできないとする仮説である。「セミストロング」は、過去の価格データのみならず、公開情報も即時に価格に反映されることから、価格データ、公開情報を使った将来予測はできないとする仮説である。「ストロング型」は、過去の価格データと、内部情報 (インサイダー情報) を含む情報も即時に価格に反映されることから、すべての情報を使用しても将来予測はできないとする仮説である。

自然言語処理による価格予想による先行研究においては、テキスト情報による価格予想を可能としており、セミストロング型、およびストロング型の効率的市場仮説に反する結果が出ている。その理由は、理由は以下のように考えられる。効率的市場仮説をはじめとする伝統的ファイナンス理論は投資家

は合理的に行動することを前提にした理論である。しかし、近年、プロスペクト理論をはじめとする行動経済学の観点から、人間の行動は非論理的な場合があることが示されている。投資家の心理が投資行動に影響し、その結果、数多くのアノマリー（効率的市場仮説では説明できない特定の手法により超過リターンを得ることができる現象）が存在することが示されている。（岡田・羽室, 2011）において、日経記事から作成したセンチメント指数と株価指数の間に強い相関関係があり、投資家の気分が資産価格に影響していることを示唆している。他のいくつかのテキストからセンチメント指数を抽出する研究においても、株価の動向をテキストを基に予測することができるとされている（Bollen et al., 2011a; Heston & Sinha, 2013; Tetlock, 2007）このように、テキストデータによる超過収益の獲得は、「効率的市場仮説」からは説明ができない一つのアノマリーであると解釈することが可能である。

1.3 テキストデータの数値化

1.3.1 テキストデータに含まれる情報

金融テキストを分析する意義は、数値データに含まれていない要因を内包しているためである。また、数値データとして、公表されるまでの時間がかかるため、それより以前に公表されるテキストデータを用いてその数値を予想することで速報性を得ることができるという利点もある。数値データには含まれず、金融テキストデータにのみ含まれる要因には以下のようなものがある。

市場の投資家心理（センチメント）

市場参加者が今のマーケットの状況に対して、強気なのか、弱気なのか、といった心理的なスタンスは数値データとして直接的に存在しない。すべての市場参加者の心理状態を測定し、定量的に算出することは不可能である。しかし、テキストデータを用いて、その市場の投資家心理（センチメント）は複数存在し、twitterなどのソーシャルメディアのテキストに市場参加者のセンチメントが現れるという仮定の下で、テキストから抽出、スコア化を行っている。

経済見通しの不確実性

不確実性とは経済の先行きの見通しの予測不可能の度合いを表す。これは、エコノミストなどの見通しがばらつきなどの数値データでも表されるが、概念的なものであり、ニューステキストから上の「不確実性」の言及回数で代替する方法が存在している。

中央銀行の経済見通しや利上げ利下げのトーン

金融政策をつかさどる中央銀行が足元の金利を上げるべきか、否かを示す重要なチャートにFOMC参加メンバー全員が政策金利のあるべき数値を投票したドットチャートがある。これは会合が開かれるごとに各メンバーにより投票が実施され、足元の金利政策に深く関わっている。しかし、金融政策

を決める足元の経済状況は時々刻々と変化しており、市場関係者にとって、こうした中央銀行の経済や金融政策に対する見通しを会合以前にリアルタイムで知りたい。会合以前のメンバーの講演テキストには各メンバーの経済見通しや利上げ利下げのトーンが表れており、市場関係者は講演のテキストから事前に会合で決定される金融政策を予想する。

1.3.2 テキストデータの特徴

これまで、資産運用においてファンドマネージャーは国内総生産や雇用統計などマクロ経済データや、個別銘柄の株価や財務諸表の数値などのミクロ経済データを用いて、売買判断を行ったり、運用モデル開発を行ったりしていた。これらのデータは主に数値の時系列データである場合が多く、非常に扱いやすくモデルに組み込みやすいのが特徴である。一方で、テキストデータは数値データと異なり「非構造化」されたデータである。データ量が膨大であり、かつ必要な情報の抽出が難しい。数値データと異なり、テキストデータをそのまま分析の対象とすることは難しい。そのため、テキストデータを分析に使用する場合には、非構造化データから構造化データに変換する必要がある。文章を構造化データに変換する方法は、文章を形態素解析し、単語単位に分解したのち、その単語の頻度のベクトルとすることである。これを BoW (Bag of Words) 表現を呼ぶ。例えば、「自然言語処理」、「金融分野」、「応用」という 3 単語を含む文章を BoW を一つのベクトルとして、(1,1,1) で表す方法であり、ベクトルの成分はそれぞれ「自然言語処理」、「金融分野」、「応用」の出現頻度を示している。しかし、この BoW 表現をそのまま運用モデルに用いることも難しい。なぜなら、BoW の次元数は単語の種類数に等しく、次元の呪いにより、モデルが効率よく回帰または分類ができなくなる。そのため、非構造化データであるテキストを利用するためには、次元を落とすうえで、数値化することが必要となる。かつ次元を落とす際に情報の欠落をできるだけ防ぐ必要がある。

1.3.3 トピックモデルによる数値化

トピックモデルは、(Blei et al., 2003) にて、開発された言語モデルであり、単語の共起に基づくトピック（潜在的な意味）を仮定したモデルである。通常の言語モデルは各単語の生成確率を記述したモデルであるが、トピックモデルは、文中における単語の生成確率ではなく、トピックの生成確率、および各トピックにおける単語の生成確率の 2 段階の生成モデルで記述される。トピックモデルを用いることで、BoW 形式の高次元で表されたテキストデータをトピック数分の低次元のベクトルに次元圧縮することが可能である。次元圧縮する際には、単語間の共起性から推定される潜在的な意味合い（トピックと呼んでいる）を持つ内部変数を介しているため、情報の欠如が少ない。例えば、図 2 は、トピックモデルによる各トピック事の上位単語を可視化した図であるが、各トピックごとに共起性の高い単語が一つのトピックとして求められることがわかる。このトピックの占める割合が文中にどれくらいあるか（トピックウェイト）がその文章を示す「構造化データ」となる。このようにして、ト

ピックモデルを通じて、情報の欠落の少ない次元圧縮が可能となる。



図 2: トピックモデルによる各トピック事への分類 (Zubiaga et al., 2018)

1.3.4 トピックモデルの拡張、および金融テキストへの適応

トピックモデルには様々な拡張したモデルが存在する。(Mcauliffe & Blei, 2008) において、通常のトピックモデルに教師信号となる変数を加えた supervised LDA モデルを構築している。通常のトピックモデルは、単語の共起性からトピック分類されるが、supervised LDA モデルにおいては、単語の共起性に加えて教師信号の値にも影響された潜在変数（トピック）の推定となり、分類される各トピックが教師信号の値の大きさごとに分かれる。例えば、レビューのスコア（数値）とレビューの文章がセツ

トとなったデータセットに対して、supervised LDA モデルによって、レビューのスコアとレビューのテキストのトピックの両方が影響されたトピック分類の結果となる (図 3)。

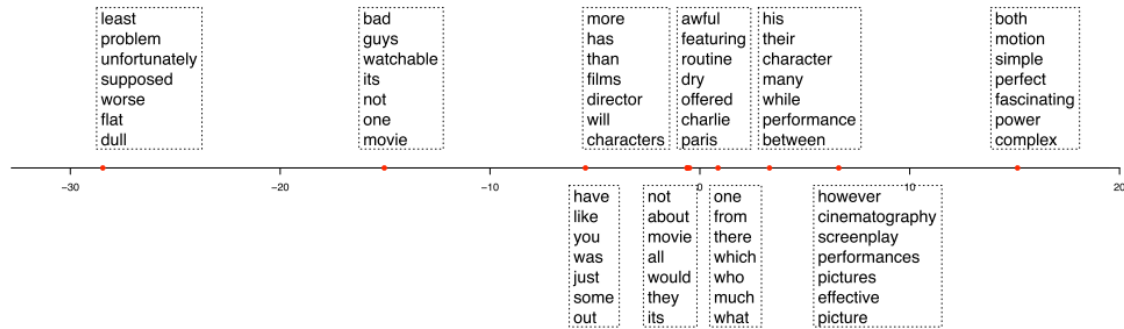


図 3: supervised LDA モデルによる映画レビューとそのスコアに基づくトピック事分類 (Mcauliffe & Blei, 2008)。横軸はスコアの大きさ。各トピックがレビューのスコアとレビューのテキストの話題の両方が影響されたトピック分類となっている

金融テキストにおいても、数値とテキストがセットとなったデータセットが多く存在する。例えば、市場の値動きとその市場のニュースのセットであったり、マクロ経済指数と経済ニュースや経済分析レポートのセットなどである。

supervised LDA を金融テキストとそれに対応する数値に適応することで、通常のトピックモデルで分類した結果と比較して、トピック分類が対応する数値の影響も受けることで、数値の強弱に基づいたトピック分類となる。この利点を生かして、第 2 章において、通常のトピックモデルではなく、supervised LDA モデルにより、不確実性指数の構築を実施した。先行研究において、トピックモデルを用いて、不確実性指数を構築した研究は存在するが、複数あるトピックうち、どのトピックの不確実性数がよりマーケット変動に影響を及ぼすか不確実性指数かは、通常のトピックモデルでは判断できない。第 2 章の提案モデルでは、supervised LDA を用いることで、テキストから不確実性指数を構築する際に、どの不確実性指数がより市場変動に影響を及ぼすかと同時に推計し判別できるようにした。

また、(Lin & He, 2009) において、通常のトピックモデルに、センチメントを示す潜在変数を加えた Joint Sentiment/Topic Model モデルを構築している。通常のトピックモデルでは推論されない各文書のセンチメントを単語の共起性から推論することができる。このモデルにより、文章のセンチメントを求める際にドメインに特化したセンチメント分析を教師なしで可能となる (図 4)。

Positive sentiment label						Negative sentiment label					
Topic 1		Topic 2		Topic 3		Topic 1		Topic 2		Topic 3	
w	$P(w z, l)$	w	$P(w z, l)$	w	$P(w z, l)$	w	$P(w z, l)$	w	$P(w z, l)$	w	$P(w z, l)$
good	0.084708	tom	0.035175	ship	0.059020	bad	0.079132	sex	0.065904	prison	0.073208
realli	0.046559	ryan	0.030281	titan	0.031586	worst	0.035402	scene	0.053660	evil	0.032196
plai	0.044174	hank	0.025388	crew	0.024439	plot	0.033687	sexual	0.031693	guard	0.031755
great	0.036645	comedi	0.021718	cameron	0.024439	stupid	0.029767	women	0.026291	green	0.029109
just	0.028990	star	0.020800	alien	0.022826	act	0.025602	rate	0.023770	hank	0.028227
perform	0.028362	drama	0.016519	jack	0.020751	suppos	0.025480	act	0.023230	wonder	0.027345
nice	0.026354	meg	0.015601	water	0.019137	script	0.024500	offens	0.018728	excute	0.026904
fun	0.025978	joe	0.014378	stori	0.017984	wast	0.024500	credict	0.016027	secret	0.025581
lot	0.025853	relationship	0.014072	rise	0.016601	dialogu	0.023643	porn	0.014587	mile	0.022936
act	0.022715	mail	0.013766	rose	0.013835	bore	0.022908	rape	0.013867	death	0.022495
direct	0.021586	blond	0.013460	boat	0.013374	poor	0.022908	femal	0.013686	base	0.022054
best	0.020331	run	0.012543	deep	0.013143	complet	0.020825	cut	0.013686	tom	0.019849
get	0.020331	phone	0.012237	ocean	0.012451	line	0.019968	gril	0.013506	convict	0.018967
entertain	0.018198	date	0.011931	board	0.011990	terribl	0.018988	parti	0.012426	return	0.018526
better	0.017445	got	0.011625	sink	0.011299	mess	0.015313	male	0.011886	franklin	0.016762
job	0.016692	busi	0.011319	sea	0.010838	wors	0.014333	bad	0.011346	happen	0.016321
talent	0.016064	cute	0.011013	rain	0.010838	dull	0.013598	nuditi	0.011166	power	0.014116
pretti	0.016064	sister	0.010708	dicaprio	0.010607	actor	0.012986	woman	0.010986	known	0.012352
try	0.015688	children	0.010096	storm	0.010377	total	0.012986	peopl	0.010986	instinct	0.011470
want	0.015186	dog	0.009790	disast	0.010146	isn	0.012863	nake	0.010625	inmat	0.011470

図 4: Joint Sentiment/Topic Model による各トピック事への分類 (Lin & He, 2009)。トピックとともにセンチメントも同時に推定される。

金融テキストにおいてもセンチメント分析は広く用いられており、株価指数や個別株価の予測にはテキストのセンチメントが予測力を持つことを示す研究結果が多い (Bollen et al., 2011a; Schumaker et al., 2012; 岡田・羽室, 2011)。これらの研究では、ドメイン特化したセンチメント辞書を用いたアプローチや、機械学習を用いたアプローチを用いている。ただし、これらのアプローチにはそれぞれ事前に金融分野のセンチメント辞書を定義することや、機械学習用の学習データを用意する必要があり、事前に準備コストがかかることが課題である。これに対して、Joint Sentiment/Topic Model では、トピックとセンチメントをそれぞれ別の潜在変数として定義し、単語の共起性から同時に定義している。第 3 章の提案モデルでは、このセンチメントの潜在変数も取り入れた拡張したトピックモデルを用いることで、為替概況ニュースから為替の決定要因であるマクロ経済のトピックとそのセンチメントを同時に推定し、為替変動の予測の特徴量としてモデルに取り入れた。

1.4 本研究の目的

金融経済分野において、これまでには数値データとして観測されにくく、分析することが困難であるが、金融市場へ影響を与えるマクロ経済ファクター・心理的な要因をテキストデータを用いて、分析することにより、資産運用への活用を試みることである。

個々の要因に大きく関係する非構造化データであるテキストデータに対して、拡張したトピックモデルを用いて、その潜在的な意味を踏まえ、要素ごとに抽出し数値化することにより、金融市場システムに対する変動要因を解析する。

具体的には分析の対象とするマクロ経済ファクター・心理的な要因は、中央銀行の経済や物価に対

するセンチメント、経済の先行きに対する不確実性、金融市場における市場参加者センチメントの3つである。

1.5 本研究の対象と手法

本論文ではまず初めに、日本銀行が発行しているテキストを対象に中央銀行の経済や物価に対する個別のセンチメントをモデルから計算し、時系列推移として可視化した。加えて、マクロ経済との関連性について考察を行った(2章)。次に、ロイターの経済ニュース、および不確実性の代替指標であるVIX指数を用いて、複数の経済要因ごとの不確実性指数の構築し、不確定指数が鉱工業生産指数へ影響を分析した(3章)。そして、為替概況ニュースを用いて、各経済要因、およびそれに対する市場関係者のセンチメントをモデルから抽出し、それらを特徴量として、ニュース発行後の為替市場の変動の方向性の予想を行った(第4章)。加えて、第3章で作成した不確実性指数の可視化ツールの紹介を行う(付録A)。第2~4章まで、すべて金融経済テキストから数値データを抽出することが中心となった研究であるが、その抽出される数値データの利用目的や頻度が異なる。第2章、第3章は、これまで数値データとしては存在していないマクロ経済ファクター・心理的な要因をテキストから抽出し、それを指数化・可視化することに目的がある。そのため、構築した指数が妥当かを実際のマクロ経済イベントと比較したり、影響のある他のマクロ経済ファクターとの関連性を分析している。ファンダメンタル分析を行う投資家にとって、新たなファンダメンタルズ(基礎的な要因)を提供することにつながる。また、データの頻度は月次と長期間である。第4章は、テキストから抽出した数値データを資産運用モデルへの応用することに重点を置いており、テキストから抽出した特徴量を基に短期的な(6時間後)の為替変動の方向性予測を行う。

また、本論文において、分析の対象とするテキストやその背景になるマクロ経済ファクターや心理的な要因の対象は異なるが、金融経済テキストからトピックモデルを用いて、要素ごとに数値化するという点では、一貫している。ただし、用いるモデルは個々のマクロ経済ファクターや心理的な要因に合わせて、拡張を行っている。本研究の各章の対象とするマクロ経済ファクター・心理的な要因と適用するトピックモデルについて、表1にまとめた。

通常のとピックモデルであるLDAモデルは、潜在変数としてトピックのみを仮定している。通常のとピックモデルを拡張した教師ありのとピックモデルであるsupervisedLDAでは、各トピックごとにその教師信号に当たる変数が加わる。また、sJSTモデルでは、通常のとピックモデルの潜在変数に加え、センチメントを示す潜在変数がモデル内に加わる。

第2章では、通常のとピックモデルであるLDAモデルを基いている。これは、トピックモデルを用いる理由が、中央銀行のテキストを単純にとピック事に分けるためだけに使用しているからである。トピックモデルに加えて、深層学習モデルによるセンチメントの付与を行っており、深層学習モデル

とトピックモデルの2つのモデルを適応させて、最終的な中央銀行の経済や物価に対する個別のセンチメントを計算している。一方、第3章では、マクロ経済の先行き不確実性を分析するにあたり、通常のトピックモデルを拡張した教師ありのトピックモデルである supervised LDA を使用した。拡張したモデルを使用した理由としては、「不確実性」の代理変数として VIX 指数があり、これを教師信号として使用することをモデル内に取り込むためである。これにより、市場変動の大きさごとのマクロに要因を分解することができ、それぞれの推移を可視化することができる。第4章では、金融市場における市場参加者のセンチメントを構築し、為替変動の予測の特徴量として使用するにあたり、複数のトピックモデルでそれぞれ特徴量を抽出し、比較を行っている。市場変動が個々のマクロ経済ファクターの変化だけでなく、加えて心理的な要因の変化から影響を受けるという仮定の下、モデル内にセンチメントの潜在変数を組み込んだトピックモデルを用いている。

表 1: 各章の対象とするマクロ経済ファクター・心理的な要因と適用するトピックモデル

章	分析の対象とするマクロ経済ファクター・心理的な要因		モデル	
	概要	対象テキスト	トピックモデル	モデル拡張
2	中央銀行の 経済や物価に対するセンチメント	日本銀行の金融経済月報	LDA	拡張なし
3	経済の先行きに対する 不確実性	ロイターニュース	supervised LDA	教師信号を加味
4	金融市場における 市場参加者のセンチメント	為替概況ニュース	sJST 等	センチメント の潜在変数を加味

第2章 中央銀行の経済や物価に対する個別のセンチメントの可視化

この章では、投資家が今までファンダメンタルズ分析等を行う際に中央銀行の経済に対する見通しを定性的にしかテキストから捉えられないという課題に対し、日本銀行のテキストに用いて、定量化されなかった日本銀行の各マクロ経済要因ごとの見通しを数値として算出するモデルを構築する。具体的には、トピックモデルと深層学習モデルを日本銀行の金融経済月報に適用することで、「物価」や「個人消費」、「企業収益」などの複数のマクロ要因ごとにセンチメント指数を構築する。そして、構築したセンチメント指数を用いて、日本銀行の政策との関連性やマクロ経済指標との相関について論じる。

2.1 中央銀行のコミュニケーション

中央銀行が決める金融政策は市場参加者にとって、非常に重要である。中央銀行が決定する政策金利や金融引き締め、金融緩和の方向性を変更すると、どのアセットクラスにも大きな影響を与える。近年、中央銀行の政策としての「コミュニケーション」が着目されている。政策としての「コミュニケーション」とは、中央銀行が足元の経済や今後の政策に対する考え方を記者会見や講演メディア経由で投資家に述べることや、政策決定会合後の議事録を通じて、投資家に伝えることである。特に金融市場において、中央銀行と市場とのコミュニケーションは日々重要になっている。日本銀行の白井さゆり審議委員は、かつて講演で日本銀行のコミュニケーションについて、その重要性の理由を以下のように述べた(白井, 2014)。

1. 中央銀行には自らが独立して決定する金融政策について対外的な説明責任を果たす義務がある。
2. コミュニケーションの有効活用によって金融政策の効果を高めようとする見方が浸透しつつある。
3. ゼロ金利制約下の中央銀行が非伝統的な金融緩和政策手段としてコミュニケーションを積極的に活用しようという意識が高まっている。

また、米国の連邦準備制度理事会前議長であるベン・バーナンキは、「金融政策は98%が話すことであり、2%が行動である」と述べている。このように中央銀行は金融政策の方向性や、各マクロ経済の見通しを市場に伝えるすることで、金融政策の効果の向上を図ってきたが、その有効性について、様々な実証研究が行われてきた。(Campbell et al., 2012; Blinder et al., 2008)

日本銀行において、黒田総裁は2013年4月に国債の買い入れ額の増加等を盛り込んだ異次元緩和を開始した。2014年10月には長期国債の買い入れを30兆円増やす追加緩和を打ち出し、2016年1月にはさらなる追加緩和として、マイナス金利の導入を発表した。このような様々な金融政策を実行してきた日本銀行についても、そのコミュニケーションの有効性についても様々な実証研究が行われてきた(翁邦雄・白塚重典, 2003; 黒木祥弘, 2001; 中島上智・服部正純, 2010)。

近年、自然言語処理の発展に伴い、中央銀行の発行する様々な公表資料に対して、テキストマイニングを行い、中央銀行のコミュニケーションについての定量的な分析を行う研究が盛んになっている。

2.2 金融政策におけるテキスト

日本銀行が発行している金融政策やマクロ経済に対する日本銀行の見通しに関するテキストデータは複数存在する(表2)。これらのテキストの発行する順番と日本銀行が行っている金融政策決定会合

表 2: 日本銀行が発行しているテキストの一覧

テキストの種類	タイミング	頻度	分量	フォーマット
金融政策決定会合議事要旨	1～2ヶ月後	月次	20-30	定形
主な意見	1週間後	月次	5	定形
総裁定例記者会見要旨	翌営業日	月次	20	不定形
経済・物価情勢の展望	翌営業日	四半期毎	10/100	定形
金融経済月報	翌営業日	月次	20-30	定形
講演	不定	月1回程度	10~20	不定形
記者会見	不定	月3回前後	1～2	不定形

との関係は次のようになっている(図5)。決定会合の翌営業日にまず、「総裁定例記者会見要旨」が発行される。これは決定会合が行われた日に日本銀行総裁が記者会見を行うが、その記者会見の要旨である。同じタイミングで「経済・物価 情勢の展望」が発行される。これは四半期毎に日本銀行のマクロ経済に対する現状、および将来のビューが掲載されており、定型なフォーマットで書かれている。決定会合の1週間後には、「主な意見」が発行される。これは決定会合で行われた審議委員の主な意見についてまとめられており、定形的なフォーマットとなっている。そして、決定会合から1、2か月ほど後に、「金融政策決定会合議事要旨」が発行され、審議委員の議論や日本銀行執行部からの報告が

定形的なフォーマットでまとめられている。また、不定期に総裁や各審議員の講演や記者会見が掲示される。なお、金融経済月報については、既に廃止されおり、現在は発行されていない。

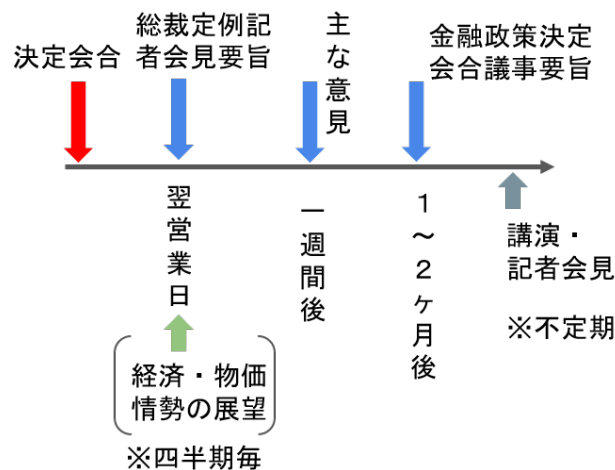


図 5: テキストの公開タイミング

2.3 中央銀行の発行するテキストを対象にした先行研究

中央銀行総裁の顔の画像からその感情を数値化し、それを用いて金融政策決定の関連性を分析する研究(水門・勇, 2017)など、中央銀行に関する様々なデータを対象とした先行研究がある中で、中央銀行の発行するテキストに対する研究を大別すると以下の2つのテーマとなる。

1. 中央銀行のテキストが含む情報の分類などテキスト自身の内容に関する分析
2. 中央銀行のテキストが市場でどのような影響を及ぼしているか等のテキストと市場との関連性に関する分析

前者に関しては、テキストから中央銀行の金融政策のセンチメントやトピックなどの特徴量を如何に抽出するかに着目しており、後者に関しては抽出した特徴量から市場に関連する指数の価格や価格変動などへの影響を分析している。

2.3.1 中央銀行のテキスト自体に対する分析

中央銀行の発行するテキストから抽出できる特徴量として、まず中央銀行のセンチメントがあげられる。中央銀行が足元の景気動向をポジティブにとらえているか、ネガティブにとらえているかを定量的にテキストから抽出する研究は複数ある。

最も一般的なセンチメントを抽出する方法として、極性辞書を用いて抽出する手法が挙げられる。(Kawamura et al., 2019b) では、本章で用いるテキストと同じ日本銀行の金融経済月報に対して、事前に単語ごとポジネガを定義した極性辞書を用いて、景気ごとのセンチメントを計算し、景気動向指数との相関を確認している。

日本銀行以外の中央銀行のテキストに対して、同様の極性辞書を用いたセンチメントの算出方法をベースにしている研究は複数存在する (Hüning, 2017; Jegadeesh & Wu, 2017; Hubert & Fabien, 2017; Schmeling & Wagner, 2019; Picault & Renault, 2017)。

これらの極性辞書を用いたアプローチの課題としては、極性辞書の構築が非常に困難であることがあげられる。なぜなら金融経済分野に特化した文脈で使われる単語の極性と一般的な文脈で使われる単語の極性は異なるからである。

一方で、極性辞書ではなく、深層学習モデルを用いて、センチメントを抽出するアプローチも存在する。

(山本・松尾, 2016) では、日本銀行の金融経済月報に対して、深層学習を用いて、日本銀行のセンチメントを特徴量として抽出し、日経平均株価指数等との相関を計算した (図 6)。




図 6: 景気ウォッチャー調査の深層学習を用いた金融レポートの指数 (山本・松尾, 2016)

また、(風戸他, 2019) では、日本銀行の総裁記者会見の冒頭のテキストに対して、深層学習を用いて、日本銀行のセンチメントを特徴量として抽出し、景気動向指数との相関を確認している。

その他にも、単語の頻度に基づくアプローチ (Galardo & Guerrieri, 2017) や有識者の主観に基づくアプローチ (Cieslak & Vissing-Jorgensen, 2020) により、中央銀行のテキストからセンチメントを算出している研究もある。

2.3.2 市場でどのような影響を及ぼしているかについての分析

中央銀行のテキストを利用し、中央銀行の政策金利を予測できるか、について分析した研究が複数ある (Hubert & Fabien, 2017; Schmeling & Wagner, 2019; Picault & Renault, 2017; Cieslak & Vissing-Jorgensen, 2020)。これらの研究から中央銀行のテキストに、中央銀行のスタンスの追加的な情報が含まれており、この情報により政策金利の予測可能性の向上に寄与していることが示唆される。また、政策金利のみならず、市中金利への影響を分析した事例もあり、中央銀行のテキストの特徴量が変動した際に、金利に与える変動の大きさを算出しているもの (Hubert & Fabien, 2017; Schmeling & Wagner, 2019; Galardo & Guerrieri, 2017; Berger et al., 2011; Gertler & Horvath, 2018) や、テキストの変化が将来の金利の不確実性に影響するという仮定の下、金利のボラティリティへの影響を分析したものが存在する (Ehrmann & Talmi, 2019; Jegadeesh & Wu, 2017)。

その他にも、中央銀行の緩和・引き締めスタンスが株式市場へ影響を与えるという背景のもとに、中央銀行のテキストの変化から株価の水準やボラティリティへの影響を分析した研究 (Picault & Renault, 2017; Schmeling & Wagner, 2019; Gertler & Horvath, 2018; Jegadeesh & Wu, 2017; Hansen & McMahon, 2016b; Hüning, 2017) や、政策金利の変化が内外金利差へ影響するという考えのもと、中央銀行のテキストの変化から為替レートの影響を分析した研究 (Hansen & McMahon, 2016b; Gertler & Horvath, 2018; Hüning, 2017) もある。

2.3.3 先行研究における課題

(山本・松尾, 2016) では、日本銀行の金融経済月報に対して、深層学習を用いて、日本銀行のセンチメントの指数化を行い、指数と日経平均との強い相関を示した。しかし、彼らの研究では、日本銀行のセンチメントを一つの指数としており、より詳細に個別のマクロ経済要素ごとに分解した分析は行われていない。本章の提案手法では、彼らの研究手法を拡張し、各トピックごとの指数化を目指した。

トピック別の指数化を行う必要な理由としては、以下である。

先行研究としては、金融経済月報の全文に対して、深層学習を用いて、月次の一つの指数として、計算しているが、実際の日銀の一時点におけるセンチメントはトピックごとに存在する。例えば、2015年12月の金融経済月報において、以下の記述がなされている。

公共投資は、高水準ながら緩やかな減少傾向にある。工事の進捗を反映する公共工事出来高をみると、7～9月に前期比で小幅に減少したあと、10月の7～9月対比もマイナスとなっている。

(中略)

実質輸出は、一部に鈍さを残しつつも、持ち直している（図表6 (1)、7）。中国をはじめとする新興国・資源国経済の減速の影響が残るも、資本財で弱めの動きが続いているものの、IT関連は、スマートフォンの新商品発売の影響から、このところ持ち直しているほか、自動車関連も、米欧向けを中心に、堅調に推移している。

上記太字で始まる文章の通り、公共経済に対するセンチメントはネガティブである一方、実質輸出に対するセンチメントはポジティブとなっている。日銀のセンチメントはトピック事に存在し、それぞれで別々のトーンを持つが、先行研究においては一つのセンチメント指数に集計している。

もう一つの要因としては、日銀の政策目標が特定のトピックに偏っていることが、挙げられる。日銀は、2013年1月に2%の物価の前年比上昇率を早期達成を目標に挙げている。物価の安定があらゆる経済活動の基盤であると考えており、他のトピックよりも物価の安定を最優先に考えている。そのため、日銀のセンチメントをトピックごとの算出することにより、日銀がより重視しているトピックのセンチメントに着目することが可能となる。また、米国の中央銀行にあたるFOMCは、物価の安定に加え、雇用の最大化を政策の目標としており、中央銀行により重要視するトピックが異なる。

2.4 本章の目的

投資家が中央銀行の政策や経済見通しを把握できるようにするために、日本銀行の物価、個人消費、マネーサプライなどの各経済要素に対するセンチメントを数値する手法を構築することが目的である。そのため、日本銀行の発行しているテキストデータに対し、先行研究(山本・松尾, 2016)で行われた深層学習によるセンチメント指数構築手法をトピックモデルを用いて拡張し、個別トピックごとのセンチメント指数の構築を行う。構築した指数を基に既存のマクロ指標との比較を行い、日本銀行のトピック事のセンチメント推移について論じる。

2.5 データセット

2.5.1 金融経済月報

今回の分析では、日本銀行の景気に対するセンチメントを知るために分析の対象となるテキストとして金融経済月報を対象とする。2016年以降、金融経済月報は「経済・物価情勢の展望」(展望レポート)に集約されたため、分析の期間は1998年1月から2015年12月までの18年間である。金融経済月報は前述のように、決定会合が行われたあとに日本銀行が公開しているドキュメントであり、日本銀行が金融政策を決める前提とする足元の経済や今後の見通しについて述べている。海外経済、米国経済、欧州経済、中国経済、新興国経済と海外の情勢について始まり、わが国の景気として、輸出、設備投資、雇用・所得環境、個人消費、住宅投資、鉱工業生産、物価面と国内マクロ環境について述べ、最後にわが国の金融環境についてと、海外要因、国内経済、国内金融という順番の一定の形

式に従って記述されている。下記に 2015 年 12 月の金融経済月報の冒頭部分を記す。全体の要約を一番始めに述べており、「海外要因」、「国内経済」について順番に記述されている。

わが国の景気は、輸出・生産面に新興国経済の減速の影響がみられるものの、緩やかな回復を続けている。

海外経済は、新興国が減速しているが、先進国を中心とした緩やかな成長が続いている。そうしたもとで、輸出は、一部に鈍さを残しつつも、持ち直している。国内需要の面では、設備投資は、企業収益が明確な改善を続けるなかで、緩やかな増加基調にある。また、雇用・所得環境の着実な改善を背景に、個人消費は底堅く推移しているほか、住宅投資も持ち直している。公共投資は、高水準ながら緩やかな減少傾向にある。鉱工業生産は、横ばい圏内の動きが続いている。この間、企業の業況感は、一部にやや慎重な動きもみられるが、総じて良好な水準を維持している。

2.5.2 景気ウォッチャー調査

まず、深層学習によるセンチメント付与モデルを構築した。そのモデルの学習データとして、景気ウォッチャー調査のテキストを用いた。景気ウォッチャー調査は内閣府が公表しているデータセットであり、業種ごとにおける景気判断（良い、やや良い、変わらない、やや悪い、悪いの 5 段階評価）とその理由となるテキストがセットとなっている (図 7)。

1. 北海道（地域別調査機関：株式会社北海道二十一世紀総合研究所）

（－：回答が存在しない、○：主だった回答等が存在しない）

分野	景気の現状判断	業種・職種	判断の理由	追加説明及び具体的状況の説明
家計 動向 関連 (北海道)	良くなっている	百貨店（販売促進担当）	それ以外	・閉店を控えているという特殊要因が店舗来店への動機づけの後押しとなり、来客数の増加、購買率の上昇がみられる。ただ、地方都市の小売販売全体として、プラスアルファの需要が喚起されるほどの力強さがあるとはいえない。
	やや良くなっている	百貨店（販売促進担当）	販売量の動き	・夏のセールのスタート以後、客の購買力が高まっている。外国人観光客の売上は相変わらずマイナス傾向だが、来客数が増加しているため、客単価が下げ止まればマイナス幅も縮小してくる。
		衣料品専門店（経営者）	販売量の動き	・初夏を迎えてイベントが開催されていることから、外国人観光客や一般市民が街を歩いており、それに伴い店舗への来店も増えている。売上は前年から12%のアップとなった。例年よりも気温が低いなか、浴衣などの単価の低い商材が動いている。
		衣料品専門店（店長）	販売量の動き	・例年、この時期は低単価商材の販売が中心となるが、今年はオーダースーツが好調である。夏のボーナスが影響しているとみられる。
		乗用車販売店（従業員）	来客数の動き	・前年と比べてわずかではあるが来場者数が増えている。例年であれば、暑い日が続くと外出を控える客が増える傾向にあるが、今年は涼を求めてショールームに来院する客が増えている。そのため、これから売上が伸びることを期待している。
		その他専門店〔医薬品〕（経営者）	それ以外	・来客数、客単価がようやく上向きになってきた。地道な積み重ねもあり、目先のチラシ、特売などに左右されるのではなく、安心できる軽医療機関として当店が少しずつ認められてきたようだ。

図 7: 景気ウォッチャー調査 景気判断 理由集

過去約 8 年間 (2010 年～2017 年) の景気ウォッチャー調査を取得し、景気判断のデータ数と割合は表 3 のとおりである。

表 3: 取得した景気判断のデータ数と割合

景気判断（数値）	件数（割合）
良くなっている	4172 (2%)
やや良くなっている	50120 (22%)
変わらない	108747 (48%)
やや悪くなっている	48714 (22%)
悪くなっている	14084 (6%)

20 万件以上のテキストと評価のデータセットにあり、これを用いて深層学習の学習データに使用する。景気ウォッチャー調査のテキストと数値データは、多くの研究で用いられており (近藤他, 2019; 参木他, 2018; 青嶋・中川, 2019)、経済分野におけるテキストに特化しているという点においても、本提案手法において、日銀のテキストを対象とするセンチメント付与モデルの構築に使用することは妥当である。

2.6 モデル

日本銀行のトピック別のセンチメント指数を構築するにあたり、モデルは図8の通り4つのパートとなる。

1. センチメント指数の算出を行うため、景気ウォッチャー調査を学習データとして、テキストからセンチメントを算出する深層学習モデル (LSTM) を構築する。
2. 各月の日本銀行の金融経済月報の一文ごとに対して、トピックモデル (LDA) を用いて、文章のトピックを判定する。
3. 各月の日本銀行の金融経済月報の一文ごとに対して、学習した深層学習モデルを用いて、センチメントを算出する。
4. 各月の日本銀行の金融経済月報に対して、各トピックごとのセンチメントの平均値を算出する。

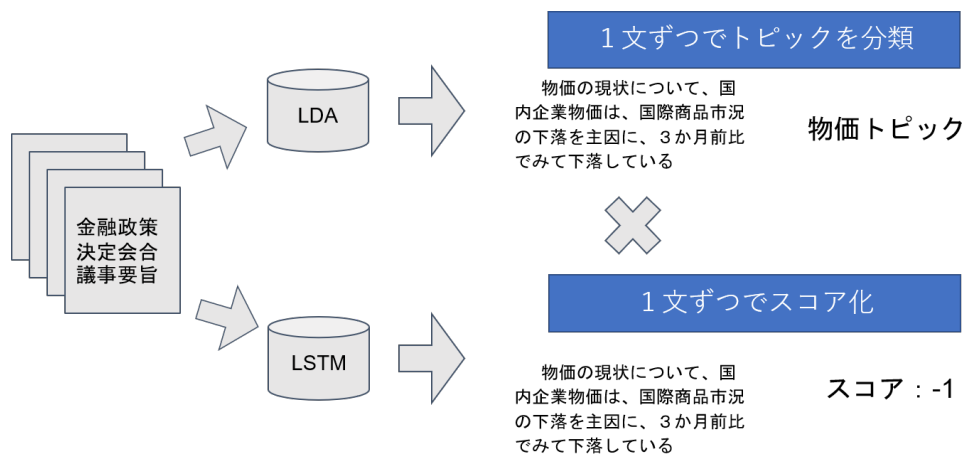


図 8: トピック別センチメント構築の全体像

2.6.1 深層学習によるセンチメント付与

各文章に対するセンチメント付与は先行研究(山本・松尾, 2016)と同じく、景気ウォッチャーを用いてテキストからセンチメントとして5値分類を行う分類器を深層学習を用いて構築した。景気ウォッチャーの各テキストに対して、Mecabを用いて形態素解析を行い、名詞、動詞、副詞、形容詞を抽出、また、景気判断を2値(ポジティブ・ネガティブ)に変換を行った。次にLSTMネットワークの構築を図9の通り構築を行った。インプット層には各形態素解析後の各単語に対応したIDをインプットとし、そこから中間層として、単語の250次元の分散表現を組み込んで、その後LSTM層を介して、ア

ウトプット層には景気判断の2値分類となるようにネットワークを組んでいる。モデルの学習は、各景気判断の割合が不均一であるため、均一となるようにオーバーサンプリングをしており、エポック数は15、バッチサイズは64である。景気ウォッチャー調査を用いたLSTMモデルによりテキストを数値に変換することができる。

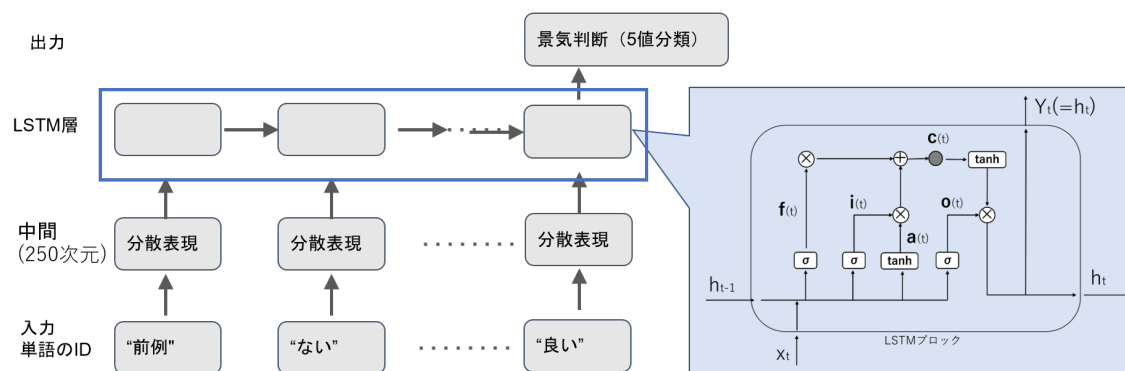


図 9: LSTM モデル

長短期記憶 (LSTM)

再帰ニューラルネットワーク (recurrent neural networks; RNN) は、一つ前の隠れ状態 h_{t-1}^l 、および現在の $l-1$ 層目の隠れ状態 h_t^{l-1} を使い、現在の l 層目の隠れ状態 h_t^l を更新する鋼構造となっており、音声や言語、動画などの可変長の入力列を扱うことに適したネットワーク構造である。以下のような形式の関数により更新される。

$$\text{RNN} : h_t^{l-1}, h_{t-1}^l \rightarrow h_t^l$$

最も基礎的な RNN の場合、パラメータ行列 $T_{n,n}$ を用いて、以下の式を用いて更新される。

$$h_t^l = f(T_{n,n}h_t^{l-1} + T_{n,n}h_{t-1}^l), \text{ where } f \in \{\text{sigm}, \text{tanh}\}$$

これに対して、LSTM(Hochreiter & Schmidhuber, 1997) は、複雑な構造のネットワークをしており、状態を記憶するセルを用いることで、状態を記憶し、通常の RNN が階層が深くなった場合に起こる勾配消失の問題を解決している。この長期記憶はメモリーセル c_t^l に保存される。LSTM のグラフィカルモデル図を図 10 に示す。

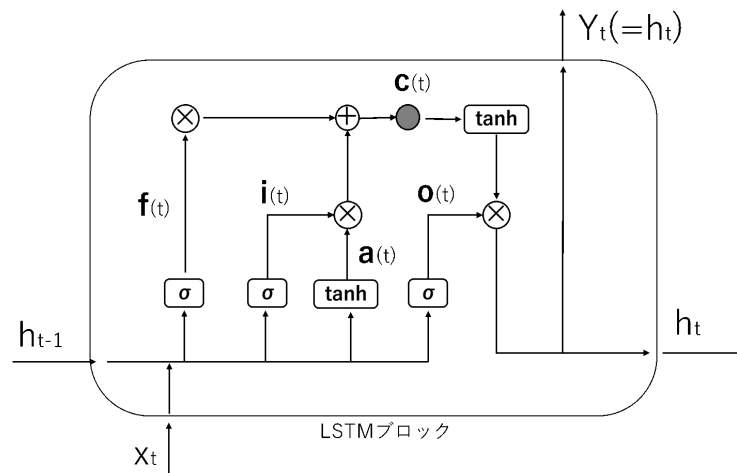


図 10: LSTM のグラフィカルモデル図

LSTM は、このメモリーセルを更新、値の取得、または何もせずに次の状態へ移行するのいずれかを行うことができる、LSTM はメモリーセル c_t^l 、入力ゲート i_t^l 、出力ゲート o_t^l 、忘却ゲート f_t^l の 4 つの要素からなる。状態遷移の式は以下の通りとなる (Graves et al., 2013)。なお、 $T_{2n,4n}$ はパラメータ行列である。

$$\text{LSTM} : h_t^{l-1}, h_{t-1}^l, c_{t-1}^l \rightarrow h_t^l, c_t^l$$

$$\begin{pmatrix} i \\ f \\ o \\ g \end{pmatrix} = \begin{pmatrix} \text{sigm} \\ \text{sigm} \\ \text{sigm} \\ \text{tanh} \end{pmatrix} T_{2n,4n} \begin{pmatrix} h_t^{l-1} \\ h_{t-1}^l \end{pmatrix}$$

$$c_t^l = f \odot c_{t-1}^l + i \odot g$$

$$h_t^l = o \odot \tanh(c_t^l)$$

2.6.2 トピックモデルによるトピック分類

トピックモデルである LDA を用いて、金融経済月報の各文章のトピック分類を行った。金融経済月報のテキストデータに対し、形態素解析を行い、名詞を抽出した。抽出した名詞に対して、文章における出現頻度を基にしたベクトル (BoW 形式) をモデルのインプットとし、LDA モデルの各文章 d に対するトピック分布 θ_d 、および、各トピック k に対する単語分布 φ_k を推定した。なお、LDA

モデルのパラメーターは、それぞれ $\alpha = 0.1, \beta = 0.0001$, トピック数 N を 12 とした。 α, β は単語分布 φ_k を散らばりぐらいを基に定性的に判断し決定し、トピック数については、金融経済月報に含まれるマクロ経済等のトピック数を基に決定した。

LDA

LDA は非常によく知られたトピックモデルであり、各ドキュメント d が複数の潜在変数 Z_d を有しており、ドキュメント中の各単語 $w_{d,i}$ は潜在変数の確率分布から生成されるという考えがベースとなっている (Blei et al., 2003)。例えば、 $D = \{d_1, d_2, \dots, d_M\}$ と表される全金融経済月報に対して、各金融経済月報 d は複数のマクロ経済トピック (物価、企業収益、マネーサプライ等) から成り立っており、記事に含まれる各単語 $d = \{w_1, w_2, \dots, w_{N_d}\}$ はそのトピックから生成されることを仮定したモデルである。例えば、「デフレ」という単語が物価トピックの確率分布から生成される。図 11 に LDA のグラフィカルモデル、表 4 にそのノーテーションを示す。




図 11: LDA model

表 4: LDA のノーテーション

定義	
α, β	ハイパーパラメーター
φ	各トピックの単語分布
K	トピック数
θ	各ドキュメントのトピック分布
Z	トピックの潜在変数
w	単語
N	単語数
M	ドキュメント数

LDA の生成プロセスについて以下の通りとなる。

- ドキュメント d のトピック分布 θ_d が以下の数式 1 により生成される。なお、ここで α はディリクレ分布のハイパーパラメータである。

$$\theta_d \sim \text{Dirichlet}(\alpha) \quad (1)$$

- 各トピック k に対して、単語分布 φ_k が以下の数式 (2) により生成される。なお、ここで β はディリクレ分布のハイパーパラメータである。

$$\varphi_k \sim \text{Dirichlet}(\beta) \quad (2)$$

- ドキュメント d における、各単語 $w_{i,d}$ に対して
 - トピック $z_{d,i}$ が数式 (3) の分布よりからサンプリングされる。

$$z_{d,i} \sim \text{Multinomial}(\theta_d) \quad (3)$$

- 単語 $w_{d,i}$ が数式 (4) の分布よりからサンプリングされる。

$$w_{d,i} \sim \text{Multinomial}(\varphi_{z_{d,i}}) \quad (4)$$

ディリクレ分布は以下の式 (5) により定式化される。なお、式中の Γ はガンマ関数、 α はハイパーパラメーターである。

$$Dirichlet(x|\alpha) = \frac{\Gamma(\sum_{i=1}^k \alpha_i)}{\prod_{i=1}^k \Gamma(\alpha_i)} \prod_{i=1}^k x_i^{\alpha_i-1} \quad (5)$$

また、 n 回試行における Multinomial 分布は以下の式 (6) により定式化される。前述の式 (3)、(4) において、1 回ごとの試行であるため $n = 1$ 、また p はパラメーター θ 、および φ に当たる。

$$Multinomial(x|n, p) = \frac{n!}{n_1! \dots n_k!} p_1^{n_1} \dots p_k^{n_k} \quad (6)$$

2.6.3 トピック別センチメント指数の構築

LDA モデルにより、トピック分類を行った後、文章 d においてトピック k が出現する確率である $\theta_{d=1..M, k=1..K}$ が推論される。ここで、 M は総ドキュメント数で、 K は総トピック数を表す。文章 d のトピック d_k はその文章のトピック分布 $\theta_{d,k}$ が最大であるトピックとした。また、LSTM モデルにより、各文章のポジネガスコア $score_d$ が算出される。最後に以下の式 7 を用いて、月 t のトピック k の金融経済月報におけるセンチメント値を求められる。

$$TotalScore_{t=1..T, k=1..K} = \frac{1}{n_{t,k}} \sum_{d_i \in D_{t,k}} score_{d_i} \quad (7)$$

ここで、 $n_{t,k}$ は月 t に属する金融経済月報のうちトピックが k である文章の数、 $D_{t,k}$ は月 t かつトピック k に属するドキュメントを示す。

2.7 トピック別センチメント指数の結果

2.7.1 全体のセンチメント推移

まず、LSTM モデルのみを使い、トピック分類を行う前の各月の金融経済月報の全テキストに対して、センチメント付与を行い、その推移を以下の図 12 に示す。




図 12: 全センチメント推移。なお縦線より「ゼロ金利政策以前」、「ゼロ金利政策」、「ゼロ金利政策解除後」、「包括的な金融緩和政策」、「量的・質的金融緩和」に時期を区分けした

先行研究である(山本・松尾, 2016)と同様の手法とテキストを用いているため、先行研究の時系列推移(図 6)と同様に、2001年のITバブルの崩壊や2008年から2009年にかけてのリーマンショックによる落ち込み、さらには2011年の東日本大震災時の低下を確認できた。

2.7.2 トピック分類の結果

トピック分類の結果として、各トピック k の単語分布 φ_k における上位単語を表 5 に示す。

表 5: 各トピック k の単語分布 φ_k における上位単語

個人消費	公共投資	在庫	設備投資
個人消費	公共投資	資本財	機械投資
住宅投資	公共工事請負金額	部品	実質
海外経済	実質輸出	財別	船舶
所得環境	所得環境	情報関連	輸送機械
設備投資	公共工事出来高	実質輸入	設備投資
景気	有効求人倍率	自動車関連	電力
公共投資	完全失業率	電子部品	機械受注
鉱工業生産	労働需給	中間財	全国百貨店売上高
物価	マネーサプライ	鉱工業生産	企業金融
消費者物価	マネーサプライ	在庫調整	金融機関
物価	電子部品	鉱工業生産	貸出態度
国内企業物価	C D	実質輸出	企業金融
国際商品市況	デバイス	最終需要	設備投資
ターム物金利	輸送機械	素材	資金供給面
生鮮食品	マネタリーベース	情報関連財	資金調達コスト
短期金融市場	業種別	鉄鋼	信用力
輸入物価	在庫バランス	海外経済	製造業
マーケット	貿易	資金供給	企業収益
株価	実質貿易収支	C P	製造業
国債	実質ベース	社債	企業収益
流通利回りスプレッド	サービス収支	民間銀行貸出	設備投資
為替相場	世帯	発行環境	雇用者所得
社債	海外経済	発行残高	中小企業
対米ドル相場	黒字幅	資金調達	賃金
流通利回り	二人以上	資金需要面	常用労働者数
日経平均株価	消費財	資金需要	所定外給与

各トピックのテーマは、個人消費、公共投資、在庫、設備投資、物価、マネーサプライ、鉱工業生

産、企業金融、マーケット、貿易、資金供給、企業収益の 12 個のトピックに分類とした。

2.7.3 トピック別のセンチメント推移

各 k トピックに関して、その全体に占める割合の推移 W_k 、センチメントの推移 S_k 、および、全体のセンチメントに対するそのトピックの影響度 $E_k (=W_k \times S_k)$ を図 13 から図 24 に示す。

個人消費




図 13: 「個人消費」トピックの時系列推移

公共投資

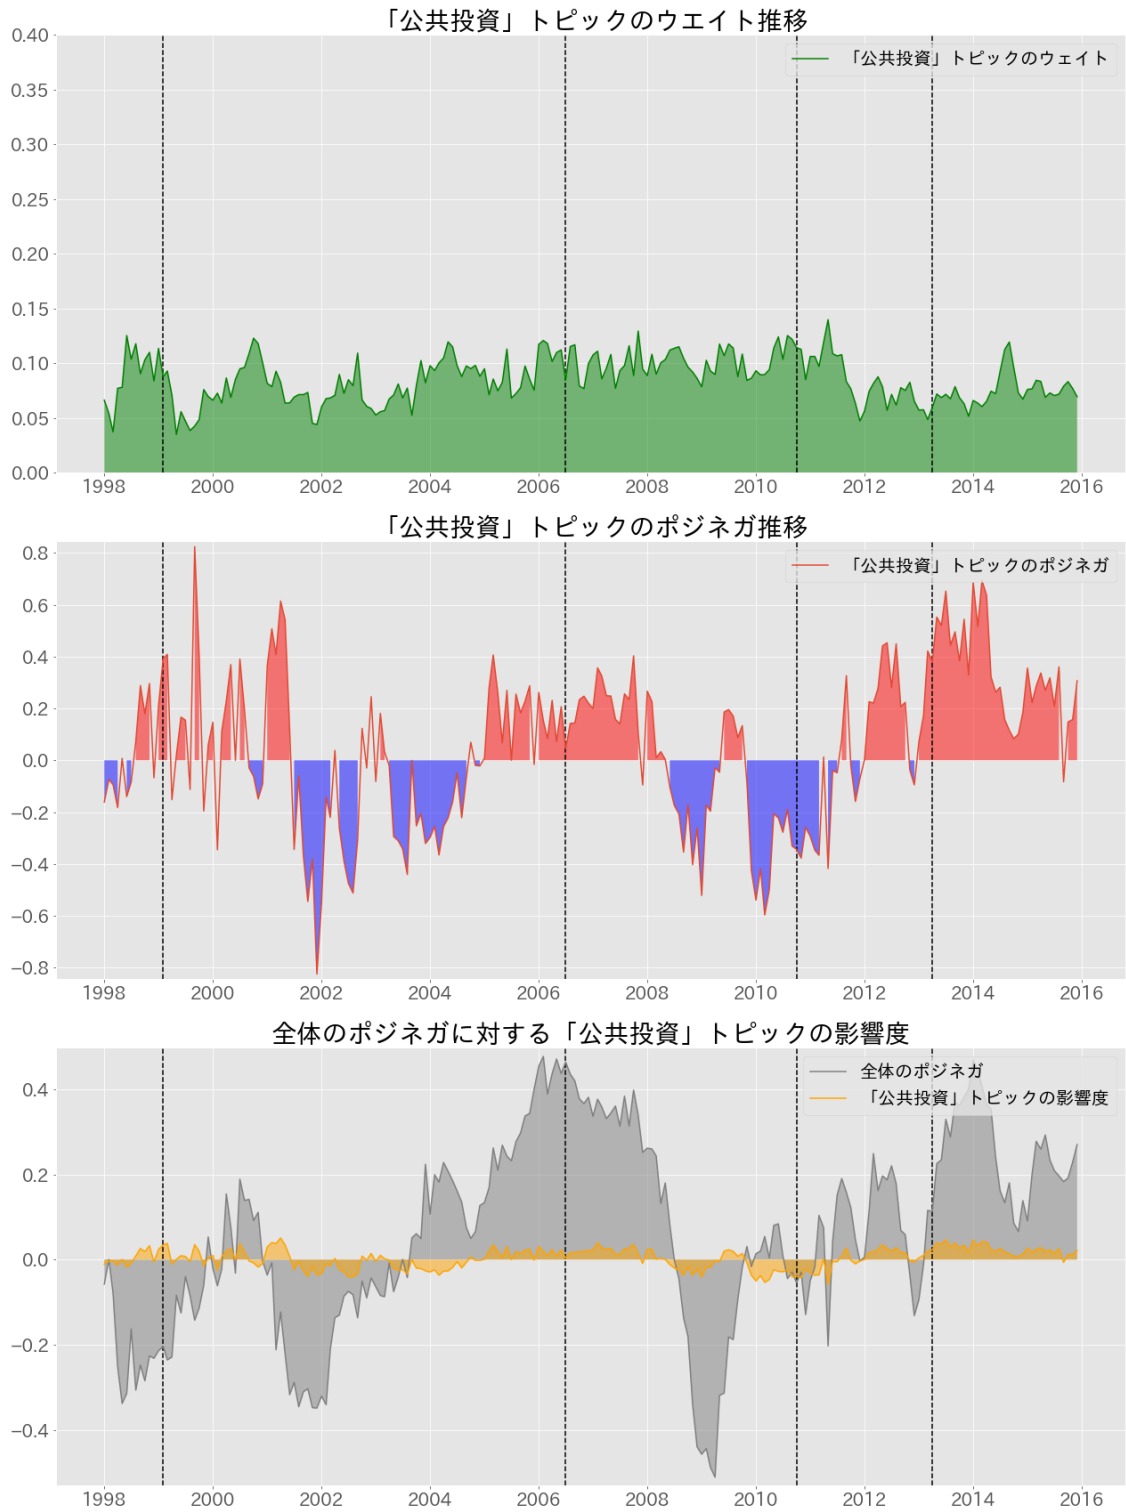


図 14: 「公共投資」トピックの時系列推移

在庫




図 15: 「在庫」トピックの時系列推移

設備投資




図 16: 「設備投資」トピックの時系列推移

物価




図 17: 「物価」トピックの時系列推移

マネーサプライ




図 18: 「マネーサプライ」トピックの時系列推移

鉱工業生産




図 19: 「鉱工業生産」トピックの時系列推移

企業金融




図 20: 「企業金融」トピックの時系列推移

マーケット




図 21: 「マーケット」トピックの時系列推移

貿易




図 22: 「貿易」トピックの時系列推移

資金供給




図 23: 「資金供給」トピックの時系列推移

企業収益




図 24: 「企業収益」トピックの時系列推移

2.7.4 考察

本セクションにおいて、前述したトピック別のセンチメント推移に対して、各種マクロ経済イベント、および日銀の金融政策の変遷と合わせて考察を行う。日銀の金融政策の違いにより、「ゼロ金利政策以前」、「ゼロ金利政策」、「ゼロ金利政策後」、「包括的な金融緩和政策」、「量的・質的金融緩和」の5つの時期に分けた。

ゼロ金利政策以前

バブル崩壊後、1998年に長銀が破綻するなど戦後最悪の景気の中、日銀は段階的に政策金利を引き下げていった。この間の各トピック別のセンチメントを見ると(図13～図24の1999年前後)、すべてのセンチメントがマイナスに推移していったことがわかる。日銀が段階的に政策金利を引き下げていった中で、ほぼすべてのマクロ経済の見通しに対して非常にネガティブなセンチメントを有していたことがわかる。

ゼロ金利政策

日銀は1999年2月以降、当時の政策金利である無担保コール翌日物金利を0.15%とすること決めた。これにより2006年3月に解除されるまで、ゼロ金利政策が続いた。一時的にITバブルにより、2000年8月に一時解除されるものの、ITバブル崩壊により、2001年2月に再度復活した。この間の各トピック別のセンチメントを見ると、1999年以降、ゼロ金利政策のおかげで徐々に各センチメントが回復していき、2000年以降、ITバブルを通じて「個人消費」や「貿易」、「鉱工業生産」など企業活動から多少離れた経済要因については、ややポジティブに転じた程度にとどまる(図13、図22、図19の2000年前後)。一方で、「企業収益」、「在庫」、「設備投資」といった企業活動や雇用に関連したトピックが大きくポジティブになり、日銀センチメントの回復をけん引していることがわかる(図24、図15、図16の2000年前後)。その後ITバブル崩壊により、再び各トピックにおいて、マイナスのセンチメントとなる(図13～図24の2002年前後)。

2004年ごろから「個人消費」、「設備投資」、「企業収益」、「貿易」などのセンチメントがポジティブに回復し(図13、図16、図22、図22の2004年前後)、それに遅れて2005年～2006年頃から「マネーサプライ」、「資金供給」といった資金に係るセンチメントがプラスに転じた(図18、図23の2005年頃)。このことから、ゼロ金利政策の中、量的緩和政策も行っていた日銀が様々なマクロファクターが回復していった後、量的緩和策の効果を確信し、資金に係るセンチメントもプラスに転じたと考えることができる。

また、ひときわ物価のトピックのマイナスが継続しており、日本銀行のセンチメントを押し下げている一因となっている(図17の1999年～2005年)。その理由として、1999年～2005年間の物価上昇率がマイナス推移をしていことが挙げられる。

その後、ほとんどのトピックのセンチメントが大きくプラスに転じた後(図13～図24の2006年頃)、2006年にゼロ金利政策を解除した。

ゼロ金利政策解除後

ゼロ金利政策解除後、好景気が継続し、各トピック別の日銀センチメントがプラスに推移していきながら、2008年9月のリーマンショックにより、すべてのセンチメントがマイナスに転じた(図13～図24の2007年～2008年)。2008年～2009年とマイナスの推移をたどり、2010年に「個人消費」や企業活動に係る「設備投資」、「在庫」、「企業収益」はポジティブに転じている(図13、図15、図15、図23の2010年頃)。しかし、「公共投資」はリーマンショック後の財政出動の反動からマイナスとなる一方で(図14の2010年頃)、「マネーサプライ」、「資金供給」といった資金に係るにセンチメントは以前とマイナスのままである(図18、図23の2010年以降)。資金に係るにセンチメントがマイナスであることは、市場への資金供給に対して、日銀が不足と捉えていることを示唆しており、2010年10月に包括的な金融緩和政策をとることを決定している。

包括的な金融緩和政策

包括的な金融緩和政策以前から「個人消費」や企業活動に係る「設備投資」、「在庫」、「企業収益」はプラスに転じており、包括的な金融緩和政策がとられている間も、プラスに推移している(図13、図15、図15、図23の2010年～2013年)。しかし、日銀は金融緩和を継続しており、その後2013年4月には量的・質的金融緩和を決定している。また、資金に係るセンチメントである「資金供給」、「マネーサプライ」についても、2012年以降のアベノミクス開始後にはプラスに転じている(図18、図23の2012年以降)。これらのトピックに係るセンチメントがポジティブにもかかわらず、金融緩和を継続している理由として、「物価」のトピックがマイナスに推移していることが挙げられる(図17の2011年～2013年)。包括的な金融緩和政策において、日銀は「物価の安定が展望できる情勢になったと判断するまで、実質ゼロ金利政策を継続する」としており、「物価」トピックのセンチメントが一つの金融緩和を継続する判断軸としており、「物価」のセンチメントがマイナスが続く限り、金融緩和を継続することが読み取れる。

量的・質的金融緩和

量的・質的金融緩和により、日銀は「2013年以降の2年程度をメドに2%の物価上昇率を目指す」とした。アベノミクス経済により、ほとんどマクロ経済のトピックがプラスに推移していく中、以前として、金融緩和が続いている。金融緩和を継続している理由として、「物価」のトピックの推移をみるに、2013年以降ほぼニュートラルに推移していく中、2015年には再びマイナスに転じている(図17の2013年～2015年)。このことから、日銀ははじめ「2013年以降の2年程度をメドに2%の物価上

昇率」の達成を目指していたが、それに対する可能性が低くなり、弱気なセンチメントに転落したことがうかがえる。

2.7.5 マクロ指標との関連性

本セクションにおいては、各トピックのセンチメント推移と実際のマクロ経済指標との相関について述べる。

各トピックのセンチメント推移のうち、個人消費、企業収益、鉱工業生産指数、資金供給、物価とそれに対応するマクロ経済指標との相関係数を計算した。なお、データの関係上期間は、2007年2月～2015年12月までの間である。相関係数を表6に示す。

表 6: 各トピックのセンチメント指数とマクロ経済指標との相関

センチメント	マクロ経済統計	相関係数
個人消費	消費者信頼感指数 (Consumer Confidence Index)	0.729
企業収益	Markit 製造業 PMI	0.500
鉱工業生産	鉱工業生産前年比	0.417
資金供給	日銀マネタリーベース前年比	0.392
物価	CPI 前年比	-0.147

また、各全トピックのセンチメントと対応するマクロ経済指標の推移を図 25～図 28 に示した。




図 25: 個人消費のセンチメントと消費者信頼感指数の推移




図 26: 企業収益のセンチメントと Markit 製造業 PMI の推移




図 27: 鋁工業生産センチメントと鋁工業生産前年比の推移




図 28: 資金供給センチメントと日銀マネタリーベース前年比の推移




図 29: 物価センチメントと CPI 前年比の推移

表 6 から個人消費、企業収益、鉱工業生産指数のセンチメントについては、マクロ経済統計の間に非常に強い相関がある。これは、日銀のセンチメントがマクロ経済統計を既存のマクロ経済統計の強弱をそのまま反映していることが言える。一方で、「資金供給」については、比較的弱い相関に留まる。「資金供給」と日銀マネタリーベース前年比との gap は、2008 年のリーマンショック前の一年間である(図 29)。リーマンショック前の 1 年間については、金融緩和前の状態であり、マネタリーベースの増加はなく、かつ日銀としても金融緩和の必要がないと考えており、センチメント的にもポジティブで

あったため、ギャップが生じたと考えられる。

一方で、物価センチメントとCPI前年比とはほぼ無相関であると言える。図29の時系列推移をみると、CPIがマイナスで推移していく中、物価のセンチメントもネガティブに推移。2014年に物価が+2%の上昇をしており、その際のセンチメントに変化はなく、これがセンチメントとマクロ指標との大きな乖離となり、全体を通じて、無相関となっている。この原因としては、2014年4月に消費税が5%から8%に引き上げられてことが挙げられる。そのため、2015年4月以降には、消費税上昇分が剥落し、再び前年比ほぼ横ばいとなった。その間の日銀センチメントを見ると、物価が上昇している時期においても、センチメントはほぼマイナスのままである。日銀センチメントは消費税増税の影響を取り除いた結果が反映されており、「2013年以降の2年程度をメドに2%の物価上昇率を目指す」目標と実際の物価の乖離が日銀センチメントのマイナスに表れていると言える。

以上の経済指標と個別トピックの日銀センチメントとの相関分析から、各センチメントが現行の経済指標をそのまま反映したものか、あるいは、将来的な見通しを考慮したものかを分類することができる。経済指標と無相関の物価についての日銀センチメントは、経済指標から予想することが困難であり、本論文で示したテキストから構築したセンチメント指数からのみ把握することができ、日銀の動向を把握するニーズを有しているエコノミスト等にとっては非常に有用である。

2.8 本章のまとめ

本章では、今まで一つの指数として構築されていた日本銀行のセンチメント指数に対して、日銀のセンチメントの全体感しか定量化することができず、要因ごとの影響度合いや日銀の重要視している特定の要因の推移について、より精緻に中央銀行の政策動向や経済見通しを定量化したいという投資家のニーズを満たすべく、トピックモデルと深層学習モデルを用いて、トピック別に指数化を行うモデルを開発し、「個人消費」、「企業収益」、「資金供給」、「物価」等の12個の各マクロ経済の要因ごとの日本銀行のセンチメント指数を構築した。

「ゼロ金利政策」、「包括的な金融緩和政策」、「量的・質的金融緩和」等の日銀の異なる金融政策を行った期間ごとに各要因ごとの時系列推移がどのように推移したかについて、考察を加え、トピック別のセンチメントの変化と金融政策の実施への影響について論じた。

また、複数のトピック別センチメントとそれに対応するマクロ経済指標との相関関係を分析し、多くのトピックにおいて、正の相関がみられた一方で、物価トピックについては、量的・質的金融緩和以降の日銀の政策固有の影響と、消費税増税の影響により、センチメントとマクロ経済指標との乖離が存在することがわかった。

本章において、日本銀行のセンチメントを計算する対象として、「金融経済月報」を用いたが、これは日銀が発行しているテキストデータの一部に過ぎない。総裁の講演や記者会見などのテキストを取

り込んだセンチメント指数の構築が必要することで、より即時性のあるセンチメント指数を構築することができる。また、現状では、金融緩和を終了したというケースが非常に少なく、予想モデルを組むためには学習データが足りないが、構築したトピック別のセンチメント時系列データから金融政策の予想を行うことを考えている。金融緩和が続いている中、日銀はどのタイミングで緩和策を解除し、政策金利を上げていくか、事前に予測できれば投資家のニーズは非常に高い。

第3章 拡張したトピックモデルによる不確実性 指数の構築

本章では、拡張したトピックモデルを用いてニュース記事から不確実性指数の構築を行う。不確実性指数とはマクロ経済の先行きの予測不可能性を定量的に示す数値である。テキストから不確実性指数を構築する研究では、Baker らの先行研究において特定単語を含む記事数をカウントするモデルがあり、既に多く国別の不確実性指数として構築されている (Baker et al., 2016)。

しかし、テキストから指数構築時に特定単語を事前に定義する必要があることや複数のマクロ経済要因による不確実性が一つの不確実性指数に混在していることなどの課題が挙げられる。

本章の提案モデルでは、不確実性指数の代替指標が将来の市場変動を示す VIX 指数であることに着目し、拡張したトピックモデルを用いて、VIX 指数を教師信号として使用し、マクロ経済要因ごとの不確実性指数を構築する。

その上で、Baker らのモデルで構築した不確実性指数との比較、および不確実性指数のマクロ経済指標への影響について、VAR モデルを用いたインパルス応答関数を用いた分析を行った。

3.1 不確実性指数

3.1.1 不確実性とは

不確実性 (uncertainty) とは、(Knight, 1921) によると、事象の起こる見込みを予測することができない特定の事象のことを指している。

Knight の著書「Risk, Uncertainty, and Profit」には以下のように記されている。

uncertainty must be taken in a sense radically distinct from the familiar notion of Risk, from which it has never been properly separated... **The essential fact is that ‘risk’ means in some cases a quantity susceptible of measurement, while at other times it is something distinctly not of this character;** and there are far-reaching and crucial differences in the bearings of the phenomena depending on which of the two

is really present and operating... It will appear that a measurable uncertainty, or 'risk' proper, as we shall use the term, is so far different from an unmeasurable one that it is not in effect an uncertainty at all.

事象の発生確率を予測できるものを「リスク」(risk)と呼び、事象の発生確率を予測できないものを「不確実性」(uncertainty)と呼んでいる。

例えば、コイントスで表と裏が出現する事象に関しては、事前に裏と表が出現する確率はそれぞれ50%であることを知ることができるため、これは「リスク」と言える。一方で、例えば、米国で発生した同時多発テロやコロナウイルスによる世界的なパンデミックの発生については、事前に発生確率を知ることができないため、このような事象は不確実性に該当する。

市場参加者にとって、マクロ経済の不確実性は、意思決定をする際に重要な役割を果たす。マクロ経済の不確実性の大小は、マクロ経済の今後の動きが不透明で予測が不可能な度合いを示している。その対象はマクロ経済の見通しから、各国の金融政策や財政政策、国家間の関係性など多岐にわたる。

あるマクロ経済の不確実性が増すと、投資家はそのマクロ経済に影響を受ける資産の売買の意思決定(買い増すべきか、あるいは、売るべきか)が難しくなる。マクロ経済の不確実性により将来の資産の価格の方向性が不透明になるからである。例えば、米国連邦公開市場委員会(FOMC)が今後利上げをするかどうか、どのタイミングで行うか、などに関する金融政策の不確実性が高まると、米国債を買うべきか売るべきか、様々な憶測が飛び交い、米国債のボラティリティが上昇する。

もしマクロ経済の不確実性を要因ごとに分類し、定量的に測定することが可能となれば、市場参加者にとって有意義なものとなるであろう。例えば、ヘッジ戦略やストレステスト等に活用が可能となるからだ。

マクロ経済の不確実性を測定することは、不確実性の性質から困難であり、これといった確立された測定方法があるわけではない。マクロ経済の不確実性は、消費者や政策決定者や市場参加者などの個々人の頭の中で考えている将来に対する見通しを反映するものであるからだ。

マクロ経済の不確実性を直接的に測定することは困難であるが、その代理となる指標はいくつかある。GDPや株式市場のボラティリティ、エコノミスト間における経済見通しの相違度合い、ニュース記事内における「不確実性」という単語の出現頻度等である。

3.1.2 不確実性指数に関する先行研究

マクロ経済の不確実性を測定する上で、その代理の指数として、ボラティリティが挙げられる。金融市場において、マクロ経済の不確実性と市場のヒストリカルボラティリティとの相関は大きく、マクロ経済の不確実性が高い場合には、市場のヒストリカルボラティリティも高い。金融市場におけるボラティリティに関する先行研究は多岐にわたるが、不確実性指数に関係する先行研究について言及

する。

(Chuliá et al., 2017b) では、株価データを用いて、金融市場における不確実性を測定し、日次の指数として構築した。彼らは、株価の変動を「リスク」(期待される変動)と「不確実性」(期待されない変動)に分離を行っている。株式市場のボラティリティ自身を検索データやテキストデータから予測する研究もあり、(Hamid, 2015) では、Google Trends を用いて、市場のボラティリティを予測するモデルを構築し、(Manela & Moreira, 2017) では、ニューステキストをもとに News implied volatility (NVIX) を構築している。この指数は、株式市場のクラッシュした時期や不確実性の高い時期とピークが一致している。彼らはニュース記事のキーワードの出現頻度を使い、VIX 指数にサポートベクターで回帰させ、指数を構築している。

政策不確実性指数をテキストを用いて構築した事例として (Baker et al., 2016) の研究が有名である。彼らは事前に定められた「政策」、「経済」、「不確実性」の3つのカテゴリでそれぞれ定義された単語群 (表 7) を用いて、ニュース記事でそれら3つのカテゴリに属する単語いずれかをすべてを含む記事の数をカウントする手法を用いた。記事数を月次で集計し、季節調整を施した上で政策不確実性指数としている (図 30)。

表 7: Baker らのモデルにおける特定キーワード (米国の経済政策不確実性指数)

カテゴリー	単語
不確実性	‘uncertainty’ または ‘uncertain’
経済	‘economic’ または ‘economy’
政策	‘congress’, ‘deficit’, ‘Federal Reserve’, ‘legislation’, ‘regulation’, ‘white house’

Baker らの研究に対して、多くの派生研究が存在する。

まず一つの派生の方向性としては、不確実性指数と金融市場との関連性を分析する研究の方向である。(Jin et al., 2019a) では、Baker らの手法を基に、中国語のニュース記事に適応させ、中国の政策不確実性指数を構築した。構築した政策不確実性指数と株価のクラッシュの関係性について分析をし、政策不確実性指数が株価のクラッシュに顕著な正の影響を与えていることを明らかにした。また、同様に (Pástor & Veronesi, 2013) においても、政策不確実性指数と株式のリスクプレミアムに関する議論を行っている。(Brogaard & Detzel, 2015) では、Baker らの指数が市場の超過リターンの予測に有意であることを示している。

他方、不確実性指数とマクロ経済との関連性についても多くの研究が進められている。(Gulen & Ion, 2016a) では、政策不確実性指数と企業投資との関係性について分析を行っており、(Bachmann et al., 2013) や (Fernández-Villaverde et al., 2015) では、政策不確実性指数と経済活動との関係性に

Figure 1: Economic Policy Uncertainty Index for the US

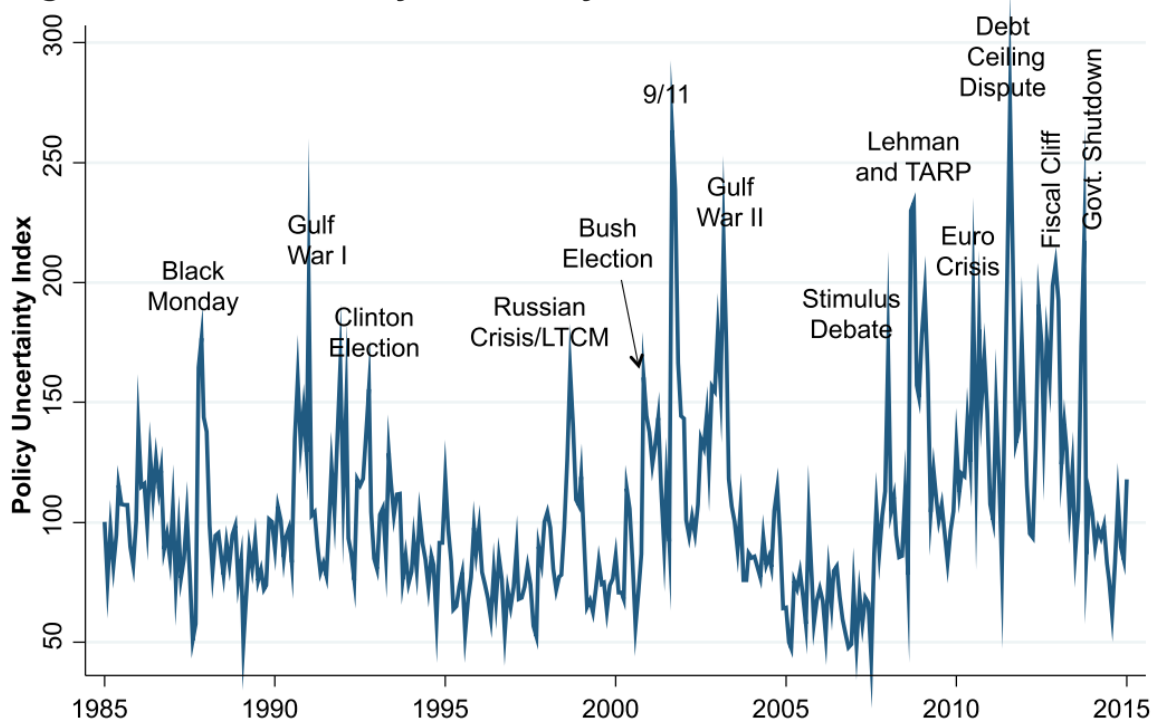


図 30: Baker らの構築した政策不確実性指数 (Baker et al., 2016)

についても分析を行った。さらには、(Bloom, 2014) では、不確実性指数の stylized facts について定義を行っている。

Baker らの手法をもとに各国の政策不確実性指数を構築する研究も盛んに行っている。(Arbatli, 2017) では、日本語のニューステキストデータに対して、Baker らの手法を適応し、日本の政策不確実性指数を構築した(図 31)。また、(Tobback et al., 2018) では、同様に、Baker らの手法を適応し、ベルギーにおける政策不確実性指数を構築した。(Azqueta-Gavaldon, 2017b) は、Baker らの手法を適応し、イギリスにおける政策不確実性指数を構築し、(Jin et al., 2019a) は中国の政策不確実性指数を構築した。

さらには、不確実性指数を構築するにあたり、他のテキストデータを用いて構築する研究も複数存在している。(Husted et al., 2019a) や (Saltzman & Yung, 2018) では、米国連邦公開市場委員会のページブックを対象にした不確実性指数を構築した。また、(Bloom, 2014) では、143 カ国のニューステキストを使い、世界の政策不確実性指数を構築した。(Castelnuovo & Tran, 2017a) では、Google 検索に基づくキーワードの盛り上がり具合を数値化するサービス「Google Trends」を活用し、Google Trends Uncertainty (GTU) indices を構築している。彼らは、米国の連邦準備理事会の発行物におい




図 31: Arbatli らの構築した日本の政策不確実性指数 (Arbatli, 2017)

て、不確実性と共起するキーワード（「bankruptcy」, 「stock market」, 「economic reforms」, 「debt stabilization」）を事前を選択し、これらのキーワードの Google Trends の頻度を基に不確実性指数を構築した。彼らの構築した指数は他の既存研究で示されたいくつかの不確実性を示す指数との相関が大きいことを示されている。(Baker et al., 2019) では、Equity Market Volatility tracker を構築した。

本章における提案モデルと非常に近い形で、トピックモデルを不確実性指数の構築に用いる研究も存在する。(Azqueta-Gavaldón, 2017a) ではトピックモデルを用いた不確実性指数の構築を試みた。彼の研究では、トピックモデルを用いて、ニュース記事を 30 のトピックに分割し、Baker らの構築した政策不確実性指数のカテゴリーに属するトピックのみを選択し、最終的な政策不確実性指数を構築した。彼らの手法では、Baker らの構築した政策不確実性指数をよりコストをかけずに柔軟な形で複製することを可能にした。(Rauh, 2019) では、地方版のニューステキストを用いて、国レベルではなく、地域レベルの不確実性指数を構築した。この研究では、トピックモデルを用いて、ニューステキストから 30 トピックを抽出し、そのうち 5 つのトピック（「Independence」, 「Energy」, 「Investment, Federal」, 「Government」）を不確実性指数として構築を行った (図 32)。

これらのトピックモデルを用いた不確実性指数の構築の先行研究と本章における提案モデルとの違いは、提案モデルでは、教師付きのトピックモデル (supervised LDA) を用いて、ニューステキスト

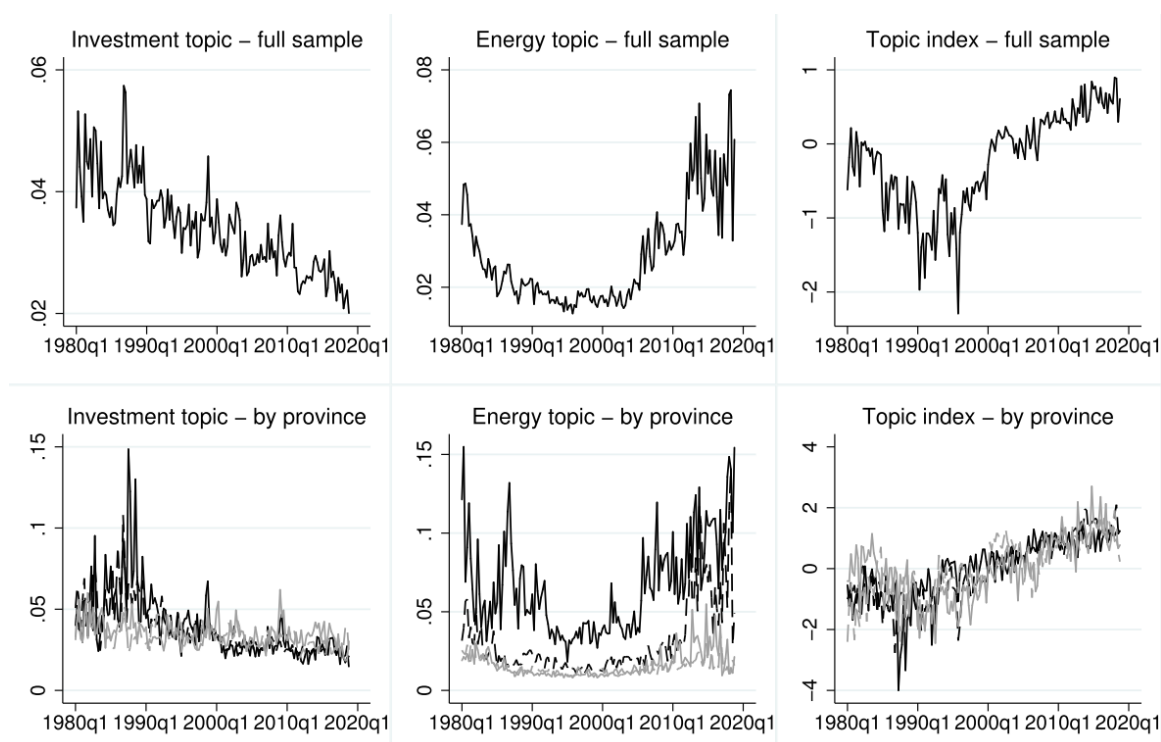


図 32: Rauh らの構築した地域別政策不確実性指数 (Rauh, 2019)

から複数の異なるトピックにかかる不確実性指数を構築している点にある。supervised LDA については、セクション 3.3.4 で詳細に解説を行う。supervised LDA を用いることにより、複数の異なるトピックの不確実性指数のうち、市場のボラティリティとの関連性の高いトピックを知ることが可能となる。

3.1.3 先行研究における課題点

先行研究における問題点について、述べる。

まず第 1 点目について経済政策不確実性指数を構築する際に Baker らのモデルでは、事前に指数に対応するキーワードを定義しておく必要がある。Baker らのモデルで、米国の経済政策不確実性指数を構築する際には、表 7 の 3 つグループのいずれかの単語をすべて含む記事の数をカウントしている。

一方で、(Arbatli, 2017) において、Baker らのモデルを日本の経済政策不確実性指数に適応した場合、指数を構築する場合には、以下のキーワードを含む記事をカウントしている。

国によってカウントするキーワードが多少異なっており、特に政策にかかる単語には大きな差異がある。例えば、中央銀行について、米国の場合には「Federal Reserve」であるが、日本の場合には「日本銀行」となる。

このように既存の政策不確実性指数の指数を構築する方法では、事前に多くのキーワードを定義し

表 8: Baker らのモデルにおける特定キーワード (日本の経済政策不確実性指数)

カテゴリー	単語
不確実性	不確実、不透明、不確定、不安
経済	経済 または 景気'
政策	税制、課税、歳出、政府債務、規制、日本銀行など政策に関する 31 用語

ておく必要があり、かつ、国によって異なるキーワードを選定する必要がある。事前にキーワードを定義しておくことは非常にコストがかかる作業である。また、政策不確実性指数を定義する単語が将来的に変化することもありうる。これについては、(Azqueta-Gavaldón, 2017a) においても言及されており、彼らは、トピックモデルによって、事前にキーワードを定めずに政策不確実指数を構築している。彼らは、トピック分類を行った後に、Baker のトピックと一致するトピックのみを選定することで、既存の Baker らの政策不確実性指数を再現している。

次に第 2 点目について、述べる。Baker らの手法を各国のニュース記事に適用し、国に限定した政策不確実性指数を構築した先行研究が多くの存在している ((Arbatli, 2017; Tobbyack et al., 2018; Azqueta-Gavaldon, 2017b; Jin et al., 2019a))。これらの多くの国限定の政策不確実性指数において、それぞれの国内のイベントに起因する不確実性のみならず、海外の経済要因や政治要因に起因する不確実性の影響を受けた指数となっている。例えば、図 31 において、(Arbatli, 2017) の日本の政策不確実性指数に関して、日本の政策不確実性指数であるにもかかわらず、D 時点における「Russian Crisis」、L 時点における「Greek Crisis」、M 時点における「US DownGrade」、「Eurozone Crisis」など日本国内ではなく海外で起きた経済イベントに起因する不確実性を示すピークが多く存在する。本来なら、国別の政策不確実性指数は、これらの海外に起因する不確実性は排除されるべきであるが、Baker らの手法ではその影響を取り除くことができていなく、グローバルな政策不確実性指数となっていると言える。

最後に第 3 点目について、述べる。トピックモデルを用いて政策不確実性指数を構築する先行研究である (Rauh, 2019) において、ニューステキストにトピックモデルを適用させ、各トピックごとの政策不確実性指数を構築しているが、その際にどのトピックを不確実性指数の対象にするか、トピックの選定について、著者らは恣意的に「Investment」、「Federal」、「Energy」、「Government」の 4 つのトピックと選定している (図 32)。トピックの選定に客観的な根拠がなく、なぜそのトピックを選んだかが不明確である。また、各トピックの金融市場への影響がどの程度か、トピック分類を行った時点では知ることはできない。

3.1.4 拡張したトピックモデルを用いた不確実性指数構築の試み

本章では、Baker らの構築してきたニューステキストを基にした政策不確実性指数の構築を拡張したトピックモデルを活用し、構築を行う。既に (Azqueta-Gavaldón, 2017a; Rauh, 2019) において、Baker らのモデルにおける問題点であるキーワードを事前に定義する必要があることを克服するためトピックモデルを不確実性指数の構築に応用する研究は存在している。本章では、さらに拡張したトピックモデルを導入した。具体的には教師付きトピックモデルである supervised LDA を用いる。supervised LDA については、セクション 3.3.4 で詳細に解説を行う。教師信号には VIX 指数を用いる。VIX 指数は次項で詳しく述べるが、VIX 指数の高まりは投資家が相場の先行きに不透明感を示しており、不確実性指数の proxy(代理指標) となるため、教師信号としている。教師付きトピックモデルを用いてトピック別の不確実性指数を構築することにより、どのトピックの不確実性指数がより強く VIX と関連度が高いかがパラメーター推定により求めることができ、市場変動の影響度ごとにトピック別の不確実性指数を構築することが可能となる。

以下のセクションにおいて、まず、データセット、および提案モデルについて説明を行う。次に、提案モデルで構築した不確実性指数に対して、以下の分析を行った。

1. 構築したトピック別の不確実性指数の推移が実際のヒストリカルなマクロ経済イベントを捉えているかの検証
2. Baker らのモデルとの定量的な比較を通じて、モデルの精度を比較
3. 各種市場インデックスや既存の不確実性指数との相関分析
4. VAR モデルのインパルス応答関数を通じたマクロ経済への影響の検証

3.2 データセット

日本語のニューステキストから不確実性指数の構築を行った。トピックモデルを用いたニュースの分類を行うが、教師ありトピックモデルを用いている。使用するデータセットはニューステキストと教師信号として数値データの 2 種類である。

3.2.1 テキストデータ

使用するテキストデータは日本語のロイターニュースを用いた。ロイターニュースは、イギリスロンドンに本社を置く通信社ロイターが配信している世界の政治、経済、社会についての最新ニュースである。ロイターの日本語ウェブサイトから過去データを取得しているが、マクロ経済動向のカテゴリ下にあるマクロ経済に特化した記事を抽出している (図 33)。

エディション: 日本

REUTERS ロイター

マーケット 外為 株式市場 ニュース 経済・政策 ワールド 企業・産業 オピニオン ライフ 写真 ビデオ

マクロ経済動向

コラム: 「大封鎖」で変わる通貨の勢力図、ドル独り勝ちは続かず=内田稔氏
 年初から新型コロナウイルスの感染拡大が報じられる中でも、欧米市場では株式相場の騰勢が続いた。アジア固有の問題との見方が強かったためだ。
 8:25AM JST

焦点: 米国債17兆ドル市場に構造問題、弱まる大量売りの吸収力
 最近の米国債市場の流動性危機は、17兆ドル規模のこの市場に恐らくすぐには解決できない構造的な問題があることを露呈した。市場では再びボラティリティーが高まり、米政府の国債売却コストが上昇する恐れがある。
 8:25AM JST

焦点: 盛り上がる「韓国買い」、封鎖なしのコロナ封じ込めを評価
 新型コロナウイルスが世界で猛威を振るう中、韓国株式市場が他の主要市場をしのぐ目覚ましい回復をみせている。債券市場にも資金が流入している。こうした「韓国買い」は、同国が政府の対応で新型コロナ危機を他国より早く、力強く切り抜けるという期待が背景にある。
 8:06AM JST

コラム: 欧米の経済活動再開にらみ円安優勢に=亀岡裕次氏
 [東京 22日] - 3月に111円台まで上昇したドル/円<JPY=>が、4月には一転して-

ロイターニュースランキング

- 焦点: 中国でもコロナ「再陽性」増加、SARSにない未知の特性
- 金正恩氏の特別列車か、北朝鮮東部の元山で確認=米分析サイト
- 焦点: 盛り上がる「韓国買い」、封鎖なしのコロナ封じ込めを評価
- 焦点: ミサイル発射映像にマスクなし、北朝鮮が新型コロナ制御暗示
- 焦点: ブーチン氏に試練、コロナが経済直撃 高まる民衆の不満

図 33: ロイターの日本語ウェブサイト (マクロ経済動向のカテゴリー)

マクロ経済動向カテゴリーに含まれる記事は各国の経済イベントや政府の金融政策などについてのロイター記者が書いた記事や業界のエコノミストが書いたコラム記事などが含まれており、記事数は一日平均で10記事ほど更新しており、1記事につき、約1,200単語ほど含まれている。以下に記事の一例を引用する。

[ワシントン 30日 ロイター] - 米商務省が30日発表した7月の個人消費支出(季節調整済み)は前月比0.6%増と、底堅く伸びた。景気後退入りへの懸念を一段と和らげる材料となる可能性はあるが、所得の伸びが緩慢なことから個人消費のペースは保たれないとみられる。市場予想は0.5%増だった。

ここ1年間続いている米中貿易摩擦は金融市場を混乱させている。米国債市場では長短金利が逆転し、景気後退への懸念が浮上。過去最長期間続いている米景気拡大が軌道から外れるとの不安が広がった。ただこのところの貿易や在庫関連の統計に加え、7月の個人消費支出は、米経済が減速する中でも景気が急速に悪化しているわけではないことを示している。

オックスフォード・エコノミクス（ニューヨーク）の米国担当シニアエコノミスト、Lydia Boussoir 氏は「政策の不確実性が増大し、金融市場が不安定化する中でも、大規模な貯蓄が緩衝材となり、米国の消費は勢いを保っている」と述べた。

マクロ経済動向カテゴリには、上記の記事と同様にマクロ経済指数の動向や主要な経済イベントについての記事やコラムが含まれている。

このマクロ経済動向カテゴリの記事を対象にする理由は以下の通りである。先行研究の Baker らは、複数のニュースから事前に定められた「政策」、「経済」、「不確実性」の3つのカテゴリでそれぞれ定義された単語群を用いて、ニュース記事でそれら3つのカテゴリの単語いずれかをすべてを含む記事の数をカウントする手法を用いている。本章においては、その手法になぞらえており、「政策」、「経済」の単語を限定する代わりに、マクロ経済動向カテゴリ下のニュースのみを用いることとしている。本章で使用したテキストデータは、2009年8月から2019年1月までの期間のおける約32,000記事を対象としている。

3.2.2 数値データ

教師ありトピックモデルに用いるシグナルとして、VIX 指数 (図 34) を用いた。VIX 指数とは、米




図 34: VIX 指数の過去推移

国の S&P 500 指数のオプションから計算される指数であり、シカゴ・オプション取引所が公表してい

る。オプションの価格は、投資家が想定する今後の指数の価格変動（ボラティリティ）の大きさによって変化する。逆に、取引されている価格から投資家が想定している今後のボラティリティの値を逆算することができる。そのため、VIX 指数は投資家が想定している今後のボラティリティの期待値であり、そのため、インプライドボラティリティと呼ばれる。VIX 指数の数値が高いほど、市場参加者が相場の先行きに不透明感を持っていると解釈されている。

インプライドボラティリティに対して、過去の価格データから計算される価格変動の標準偏差をヒストリカルボラティリティと呼ばれ、インプライドボラティリティとの相関も高い。インプライドボラティリティは不確実性のプロキシ（代理変数）として、考えられており、そのため、VIX 指数を supervised LDA の教師信号とした。

3.3 提案手法による指数構築

3.3.1 指数構築の全体構成

全体の処理を図 35 に示す。入力データとしては、全セクションで解説したマクロ経済動向を示すロイターニュース記事、および教師信号としての VIX 指数を使用する。入力データそれぞれに対して、前処理を施す。ロイターニュース記事に関しては、まず不確実性を示す記事の抽出を行う。続いて、各記事に対して、形態素解析を行い、トピックモデルへ入力できる BoW 形式にテキストデータを変換する。VIX 指数に関しては、正規化を前処理として施す。そして、前処理を終えた BoW 形式のテキストデータ、および正規化された VIX 指数をトピックモデルのインプットとし、トピックモデルによる記事のトピック分類を行う。最後にトピックモデルで出力された各記事のトピック確率に対して、月次で集計を行い正規化することにより、最終的にトピック別の不確実性を構築する。以下のセクションにおいて、各処理について述べる。




図 35: 処理の全体像

3.3.2 テキストデータに対する前処理

取得したロイター記事に対して、「不確実性」を示す記事のみの抽出を行う。これは Baker らのモデルが定義した不確実性を示す単語と同様に、事前に定義した不確実性を示す単語群を用いて、記事内

にそれらの単語群を含む記事のみを抽出した (表 9)。

表 9: 不確実性に関する単語群

単語群
”不確実”, ”不確定性”
”不透明”, ”不透明感”
”不確定”, ”不明確”, ”不明瞭”

Baker らのモデルでは、事前に定められた「政策」、「経済」、「不確実性」の3つのカテゴリでそれぞれ定義された単語群をすべて含む記事を抽出し、カウントしていたのに対して、提案モデルでは、「不確実性」を示す単語群のみで記事を抽出している。これは、記事を取得する先が既にロイターニュースのうちのマクロ経済動向に限定したカテゴリー下のみであるため、すでに Baker らの「政策」、「経済」の2つカテゴリーから取得するという条件を満たしているからである。

入力データであるマクロ経済動向に限定したカテゴリー下にあるロイターニュース約 32,000 記事に対して、「不確実性」を示す単語のみを抽出した結果、10 分の 1 に当たるは 3,115 記事が対象となった。1 カ月につき約 20~30 記事が分析の対象となる。

その後、MeCab を利用した形態素解析を行い、名詞のみの抽出を行った (図 36)。形態素解析とは、日本語の文章を言葉が意味を持つ最小単位である形態素ごとに分割することである。例えば、「1 年間続いている米中貿易摩擦は金融市場を混乱させている」という文章を形態素解析分析すると「1 / 年間 / 続い / て / いる / 米 / 中 / 貿易摩擦 / は / 金融市場 / を / 混乱 / さ / せ / て / いる」というように文書が分割される。形態素解析をして、最小単位の形態素となったものを、辞書を参照し、形態素の品詞や活用形の種類などを各形態素にラベル付けを行う。これらの形態素のうち名詞のみを抽出する。この時、辞書に別々に登録されていなく複数の連続した名詞として形態素が分解された場合、それらを結合した名詞として扱う。例えば、「日本銀行」を「日本」と「銀行」の二つの連続した名詞として形態素が分解された場合には、「日本銀行」という一つの名詞として結合し、抽出を行った。これにより一般事象には存在しない金融テキスト特有の固有表現を正しく抽出することができる。連続した名詞を結合したのち、文章から分けた全形態素のうち、品詞が名詞のもののみを抽出を行った。なお、MeCab で用いる単語分かち書き辞書は、新語や固有表現に強く、語彙数の多い mecab-ipadic-NEologd を用いた。

形態素分析の結果、全記事から抽出された名詞は、合計 2,945,703 単語、単語種は 1,786 である。

上記の処理により、各記事の文章から名詞のリストを抽出を行ったが、トピックモデルに入力するために単語埋め込み (Word Embedding) を行った。単語埋め込みとは、各記事の文章の名詞のリストを

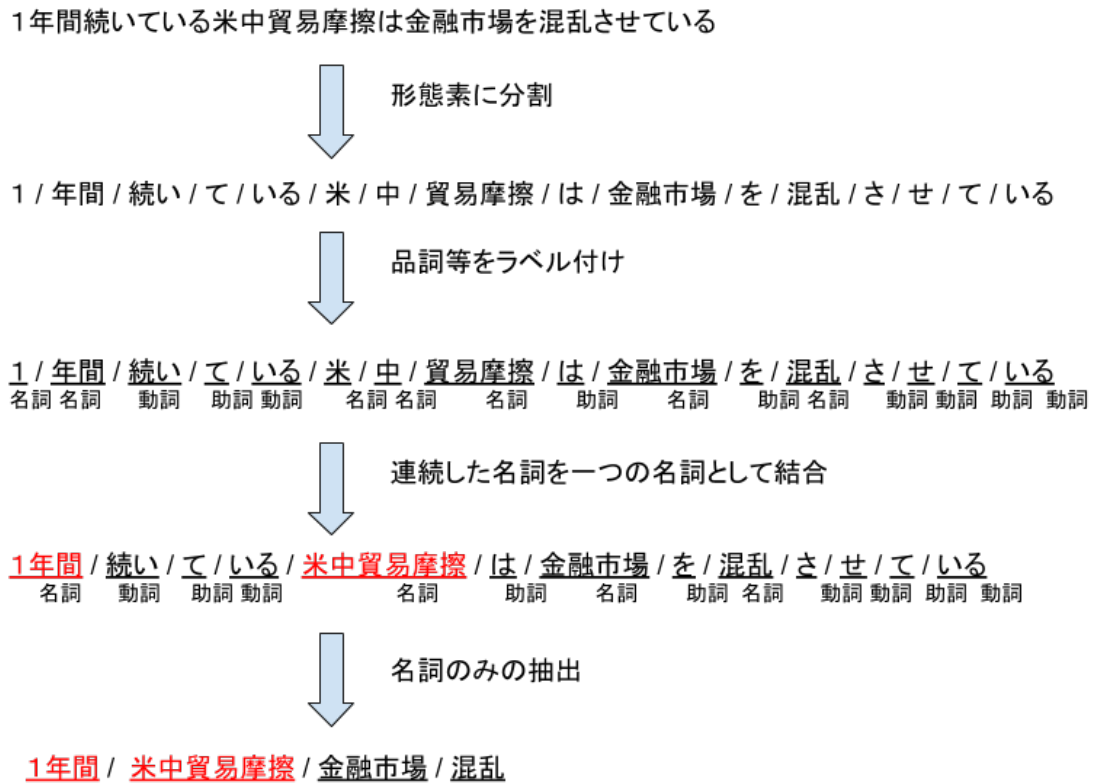


図 36: 形態素解析の流れ

固有のベクトルに変換することである。ここでは、一番シンプルな方法として、Bag-of-words(BoW)表現を用いた。まず、単語種だけ次元を有する one-hot ベクトル (単語に対応する次元の要素を 1 に、それ以外は 0) を作成する。一記事ずつ、文中に含まれる各単語に対して、その単語の one-hot ベクトルを足し合わせて、BoW 表現とする。全記事を BoW 表現に変形した場合、記事数分だけ文章のベクトルを結合したベクトルとなる (図 37)。トピックモデルに代入するテキストデータの埋め込み表現として、全記事を BoW 形式に直したベクトルを用いる。

3.3.3 数値データに対する前処理

sLDA の教師データに用いる数値データとして、VIX 指数を用いているが、以下の式を用いて、平均 0、標準偏差 1 となるよう正規化を施した。各記事に対して、正規化後の VIX 指数を教師信号として supervised LDA のインプットに使用した。

$$\text{NormalizedVIX}_{t=1\dots T} = \frac{\text{VIX}_{t=1\dots T} - \mu}{\sigma} \quad (8)$$

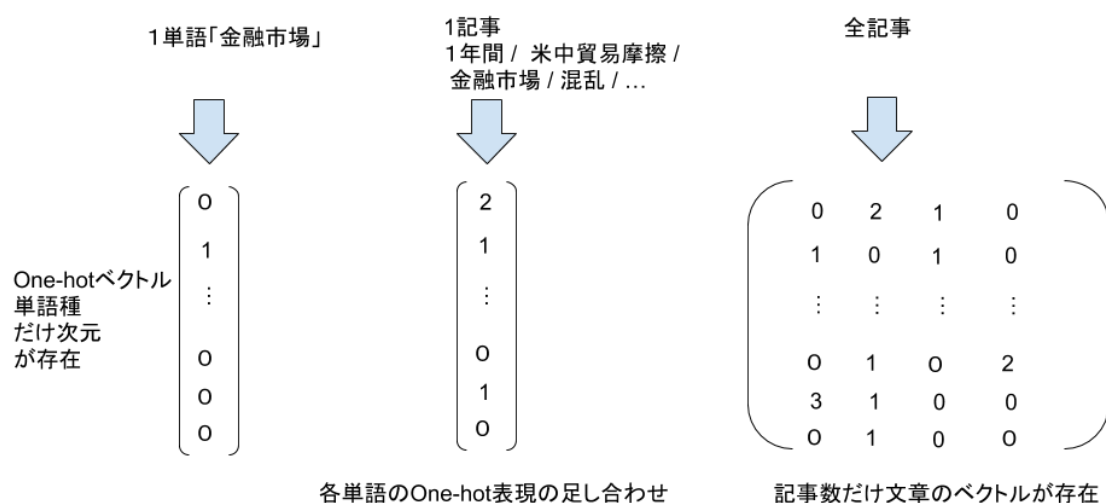


図 37: Bag-of-words 表現による Word Embedding

なお、ここで、 μ 、および σ は元の VIX 指数の時系列データの平均値、および標準偏差である。supervised LDA への入力データとして正規化をする理由については、構築した supervised LDA の教師信号である \mathbf{Y}_d が正規分布を仮定したモデルであり、それに合わせた形である。

正規化する前の VIX 指数の推移 (図 34) と比較して、正規化した VIX 指数の推移 (図 38) は、正と負両方の値をとるものの、推移のピークは一致しており、不確実性指数の教師信号として使用するに十分な情報量を有している。

3.3.4 supervised LDA を用いたトピック分類

トピックモデルとして、supervised LDA を用いている。supervised LDA とは、通常のトピックモデルに対して、教師信号として各ドキュメントに関連する \mathbf{Y}_d が新たな変数として加えたモデルである。この supervised LDA モデルは (Mcauliffe & Blei, 2008) において、通常のトピックモデルを拡張させ開発された。個々のテキストデータに対して、教師信号が付与されたモデルであり、その教師信号の影響を受けながら、トピック分布を推論すると同時に各トピックに対応する教師信号の平均値もパラメータとして推論する。通常の LDA では、教師なしの学習モデルであるのに対し、supervised LDA では、教師ありの学習モデルである。

図 39 に supervised LDA のグラフィカルモデル、表 10 にそのノーターションを示す。




図 38: 正規化した VIX 指数の推移

表 10: sLDA の定義

定義	
α, β	ハイパーパラメーター
φ	各トピックの単語分布
K	トピック数
θ	各ドキュメントのトピック分布
Z	トピックの潜在変数
w	単語
N	単語数
M	ドキュメント数
Y	外部変数
μ, σ	外部変数のハイパーパラメーター

各記事に対して、教師信号として、その記事が公表された日の正規化 VIX 指数の値を教師信号にとる。不確実性指数の proxy(代理変数) としての VIX 指数を教師信号として使用することは、理にか

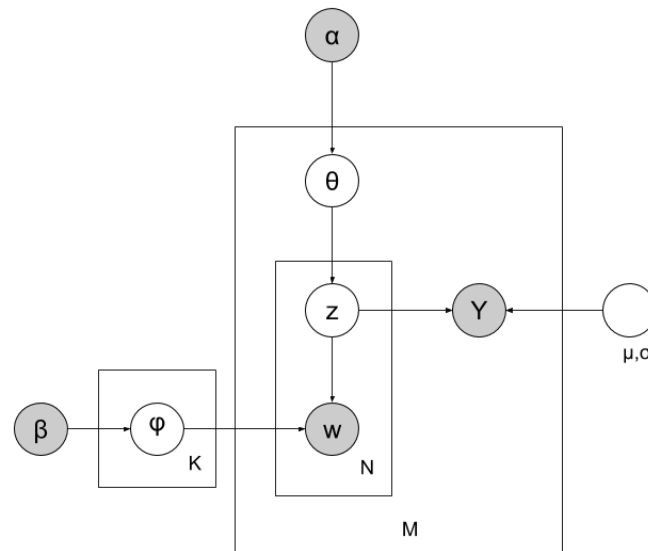


図 39: sLDA モデルのグラフィカルモデル

なっており、各トピックの潜在変数 \mathbf{Z} の分布を推論する際に、テキストデータである記事 \mathbf{w} と外部変数 \mathbf{Y} の両方満足するように進められる。これにより、最終的なアウトプットであるトピック別の不確実性指数が教師信号である VIX 指数の大きさごとに分かれた不確実指数となる。

supervised LDA の生成プロセスについて以下の通り解説する。通常のトピックモデルと比較し、このトピックに影響する外部変数を加えることにより、モデルはドキュメント内の単語の出現、および外部変数の大きさ両方に影響を受けた潜在変数が推論される。（なお、この外部変数は以下の数式 13 により生成される。）

- ドキュメント d の各トピック分布 θ_d が以下の数式 (9) により生成される。なお、ここで α はディリクレ分布のハイパーパラメータである。

$$\theta_d \sim \text{Dirichlet}(\alpha) \quad (9)$$

- 各トピック k に対して、単語分布 φ_k が以下の数式 (10) により生成される。なお、ここで β はディリクレ分布のハイパーパラメータである。

$$\varphi_k \sim \text{Dirichlet}(\beta) \quad (10)$$

- ドキュメント d における、各単語 $w_{i,d}$ に対して

- トピック $z_{d,i}$ が数式 (11) の分布よりからサンプリングされる。

$$z_{d,i} \sim \text{Multinomial}(\theta_d) \quad (11)$$

- 単語 $w_{d,i}$ が数式 (12) の分布よりからサンプリングされる。

$$w_{d,i} \sim \text{Multinomial}(\varphi_{z_{d,i}}) \quad (12)$$

- 各ドキュメント d に対して外部変数 Y_d が数式 (13) の正規分布よりからサンプリングされる。ここで $\bar{z}_d := (\mathbf{1}/N_d) \sum_{n=1}^{N_d} z_n$ を意味する。

$$Y_d \sim N(\eta^T \bar{z}_d, \sigma^2) \quad (13)$$

ディリクレ分布は以下の式 (5) により定式化され、また、 n 回試行における Multinomial 分布は以下の式 (6) により定式化される。

supervised LDA モデルにおけるパラメータチューニングについて述べる。supervised LDA モデルでは以下の通りのパラメーターを用いた。 $\alpha = 0.35, \beta = 0.10, \sigma = 1.0, K = 10$ 。また、教師信号の標準偏差を $\sigma = 1.0$ とした理由としては、既に教師信号には正規化した VIX 指数を使用しているためである。 α, β に関しては、以下の範囲でパラメーターサーチを行った。 $\alpha \in [0.2, 0.25, 0.3, 0.35, 1.0, 3.0, 6.25], \beta \in [0.1, 0.05, 0.01, 0.005]$ 結果として、 $\alpha = 0.35, \beta = 0.10$ を選択したが、これは結果としてのトピック分類の分かれ方が明確か否かにより判断し決定している。

トピック数 (K) ごとのモデルの perplexity を計算した。以下の図 40 にトピック数と perplexity の関係性を示した。




図 40: トピック数と perplexity の関係性

perplexity とは、モデルの負の対数尤度であり、低いほど高い精度予想が可能な良いモデルとみなされる。図 40 の通り、トピック数が多いほど、perplexity が低下し、モデルの精度がよくなっている。

最終的にトピック数を $K = 10$ とした。トピック数を 10 より多くとしたとき、各トピックの解釈が難しくなるためである。また、トピック数を 10 未満の場合は、perplexity が高く、モデルの当てはまりが悪い。

3.3.5 指数構築

supervised LDA モデルにより、トピック分類を行った後、ドキュメント d においてトピック k が出現する確率である $\theta_{d=1..M,k=1..K}$ が推論される。ここで、 M は総ドキュメント数で、 K は総トピック数を表す。次に、以下の式 14 を用いて、月 t におけるトピック k が出現する確率の平均値を求める。

$$S_{t=1..T,k=1..K} = \frac{1}{n_t} \sum_{d_i \in D_t} \theta_{d_i,k=1..K}. \quad (14)$$

ここで、 n_t は月 t に属するドキュメントの数、 D_t は月 t に属するドキュメントを示す。最後に、トピック k に対する不確実指数 $UI_{t,k}$ は $S_{t,k}$ を正規化した値とする。以下の式 15 を用いて、各トピックの平均値が 100 となるように正規化を行った。

$$UI_{t=1..T,k=1..K} = \frac{S_{t=1..T,k=1..K}}{\frac{1}{T} \sum_t S_{t,k=1..K}} \times 100. \quad (15)$$

3.4 不確実性指数を用いた分析

3.4.1 トピック別不確実性指数

前セクションで解説した拡張したトピックモデルによる不確実性指数の構築方法を基に構築された不確実性指数の結果について述べる。まず、トピック分類の結果として、各トピック k の単語分布 φ_k を表 11 に示す。

表 11: 各トピック k の単語分布 φ_k における上位 10 単語

TOPIC 0	TOPIC 1	TOPIC 2	TOPIC 3	TOPIC 4
中銀	EU	行動	政策	リスク
インフレ	離脱	トムソン	トランプ	中国
総裁	英国	私たち	財政	世界経済
予想	欧州連合	規範	政府	指摘
金利	貿易	信頼の原則	政権	欧州
指摘	米国	影響	改革	成長
成長	リスク	回復	議会	新興国
政策	影響	生産	首相	影響
インフレ率	指摘	景気	政治	減速
金融政策	投資	供給	増税	米国
TOPIC 5	TOPIC 6	TOPIC 7	TOPIC 8	TOPIC 9
ギリシャ	日銀	ドル	企業	FRB
欧州	物価	市場	GDP	利上げ
銀行	緩和	ユーロ	エコノミスト	fomc
ユーロ圏	追加	上昇	四半期	議長
市場	委員	下落	投資	縮小
支援	総裁	相場	予想	総裁
ユーロ	影響	米国	輸出	連邦準備理事会
債務	政策	株価	指摘	緩和
金融	金融緩和	ストラテジスト	伸び	政策
指摘	必要	投資家	見方	市場

各トピック k の単語分布 φ_k の上位単語から、次のように各トピックを解釈することができる。トピック 0 については、「中銀」、「インフレ」、「総裁」、「金利」、「政策」などの単語から、欧州連合の金融政策に係る不確実性についてトピックである。トピック 1 については、「英国」、「EU」、「離脱」、「米国」、「貿易」などの単語から、多国間における国際的な経済イベントに係る不確実性についてのトピックである。トピック 2 については、「トムソン」、「行動」、「信頼の原則」などから、ロイター

ニュースに関係するディスクレイマーのトピックと考えられる¹。また、表 11 には示されていないが、トピック 2 の上位単語の 11 位以降については、「日本」、「判断」、「海外」、「国内」、「緩やか」、「動き」、「ニュース」、「解消」、「日本経済」、「復興」と続く。後ほどのトピック別不確実性指数の推移の箇所でも言及するが、これらの単語から、トピック 2 については、2011 年の東日本大震災以降の日本の復興に係る不確実性についても含まれる。トピック 3 については、「トランプ」、「政策」、「財政」、「政府」等の単語から、米国の財政政策に係る不確実性についてのトピックである。トピック 4 については、「中国」、「世界経済」、「新興国」、「リスク」、「減速」等の単語から中国などの新興国をはじめとする世界経済に係る不確実性についてのトピックである。トピック 5 については、「ギリシャ」、「欧州」、「ユーロ圏」、「支援」、「債務」などの単語からユーロ圏における金融危機に係る不確実性についてのトピックである。トピック 6 については、「日銀」、「物価」、「委員」、「政策」、「金融緩和」等の単語から日本の金融政策に係る不確実性のトピックである。トピック 7 については、「ドル」、「ユーロ」、「市場」、「株価」等の単語から金融市場に係る不確実性についてのトピックである。トピック 8 については、「企業」、「GDP」、「輸出」、「四半期」等の単語からの日本経済に係る不確実性についてのトピックである。トピック 9 については、「FRB」、「FOMC」、「連邦準備制度理事会」、「議長」、「利上げ」等の単語から米国における金融政策に係る不確実性についてのトピックである。以上の全トピックのテーマを以下の表 12 にまとめた。

表 12: 全部トピック

TOPIC 0	欧州連合の金融政策に係る不確実性
TOPIC 1	国際的な経済イベントに係る不確実性
TOPIC 2	日本の復興に係る不確実性
TOPIC 3	米国の財政政策に係る不確実性
TOPIC 4	新興国をはじめとする世界経済に係る不確実性
TOPIC 5	ユーロ圏における金融危機に係る不確実性
TOPIC 6	日本の金融政策に係る不確実性
TOPIC 7	金融市場に係る不確実性
TOPIC 8	日本経済に係る不確実性
TOPIC 9	米国における金融政策に係る不確実性

次に、トピック分類の結果として、各ドキュメント d ごとのトピック分布 θ_d について、式 14 により、月次で平均値を求めたものの時系列推移を表 41 に示す。これは、各トピックによる不確実性の全

¹ 私たちの行動規範：トムソン・ロイター「信頼の原則」という免責事項の文言が文中に含まれることが多い。

体の不確実性に対する割合の推移となる。




図 41: 各ドキュメント d ごとのトピック分布の月次平均値の時系列推移

この推移を見ると、国際的な経済イベントに係る不確実性であるトピック 1 の割合は、増加傾向で推移していることがわかる。また、ユーロ圏における金融危機に係る不確実性であるトピック 5 の割合は、減少傾向で推移していることがわかる。その他のトピックの割合については、概ね横這い傾向で推移している。一点、特記すべきこととしては、最も割合が少ないトピックはトピック 2 である。これはトピック 2 にはロイターニュースに関するディスクレイマーのトピックであるため、全体を通して、小さいウェイトで推移している。ただ、2011 年の日本における東日本大震災後にウェイトが増加している。これは、トピック 2 に 2011 年の東日本大震災以降の日本の復興に係る不確実性についても含まれるためである。

3.4.2 マクロ経済不確実性指数の推移

次に、構築した各トピック k に対する不確実性指数 UI_k のうち、実際に起きた経済イベントと比較を行った。

まず、図 42 には、トピック 1 である国際的な経済イベントに係る不確実性指数の時系列推移を示した。




図 42: トピック 1 国際的な経済イベントに係る不確実性指数の時系列推移

この不確定指数の各ピークにおける経済イベントは下記の通りである。

- A: 2014 年 9 月におけるイギリスのスコットランドの離脱を問う住民投票
- B: 2016 年 6 月におけるイギリスの欧州連合（EU）離脱を問う国民投票
- C: 2018 年 3 月における米中貿易戦争

図 43 には、トピック 3 である米国の財政政策に係る不確実性指数の時系列推移を示した。




図 43: トピック 3 米国の財政政策に係る不確実性指数の時系列推移

この不確定指数の各ピークにおける経済イベントは下記の通りである。

- D: 2012 年 11 月においてオバマ氏が大統領に再選
- E: 2016 年 11 月においてトランプ氏が大統領に選出。トランプ政権の不確実性に対する市場の警戒感

が強まった

図 44 には、トピック 4 である新興国をはじめとする世界経済に係る不確実性指数の時系列推移を示した。




図 44: トピック 4 新興国をはじめとする世界経済に係る不確実性指数の時系列推移

この不確定指数の各ピークにおける経済イベントは下記の通りである。

- F: 2011 年 1 月において、新興国・中国をはじめとするインフレによる景気過熱やインフレ懸念
- G: 2012 年 8 月において、中国の鉱工業生産指数の鈍化に伴う景気減速懸念が高まった
- H: 2014 年 3 年において、ウクライナ情勢の緊迫にともない、市場の警戒感が高まった
- I: 2015 年 8 月におけるチャイナショック
- J: 2018 年 3 月における米中貿易戦争

図 45 には、トピック 5 であるユーロ圏における金融危機に係る不確実性指数の時系列推移を示した。




図 45: トピック 5 ユーロ圏における金融危機に係る不確実性指数の時系列推移

この不確定指数の各ピークにおける経済イベントは下記の通りである。

K: 2010 年 4 月におけるギリシャ危機

L: 2010 年 11 月におけるギリシャ国債引き下げ

M: 2011 年 11 月におけるギリシャの欧州連合 (EU) などの支援策受け入れの是非の国民投票

N: 2013 年 3 月におけるキプロス・ショック

O: 2015 年 1 月におけるギリシャの総選挙にて、EU との交渉の先行き不透明感が強まる

P: 2015 年 11 月におけるポルトガルの政治情勢の先行き不透明感の高まり

図 46 には、トピック 6 である日本の金融政策に係る不確実性指数の時系列推移を示した。




図 46: トピック 6 日本の金融政策に係る不確実性

この不確定指数の各ピークにおける経済イベントは下記の通りである。

Q: 2012年4月における日本銀行の資産買入等の基金の10兆円増額

R: 2012年10月における日本銀行の資産買入等の基金の10兆円増額

S: 2013年4月における日本銀行の量的・質的金融緩和の導入

T: 2016年1月における日本銀行のマイナス金利の導入

U: 2016年7月における日本銀行の資産買入等の基金の増額

3.4.3 Bakerらのモデルとの比較

このセクションでは、提案モデルと Baker らのモデルとの比較を行う。(Arbatli, 2017)の研究では、日経新聞、読売新聞、朝日新聞、毎日新聞の日本語のテキストソースをもとに Baker らのモデルを用いて、日本の経済政策不確実性指数を構築を行った。本来なら、同様のテキストデータを用いて、比較を行うべきところ、日本のテキストソースの入手困難さから代替の方法を用いた。テキストデータを本章と同様に日本語のロイターニュースのマクロ経済カテゴリーの記事を用いて、Baker らのモデルで不確実性指数を構築し、提案モデルで構築した日本の不確実性指数の比較を行った。

先行研究を用いて構築した日本の不確実性指数

比較の対象として、Baker らのモデルを用いた日本の経済政策不確実性指数の構築方法を述べる。Baker らは、前述の通り事前に定められた「政策」、「経済」、「不確実性」の3つのカテゴリー(表7)をすべて含む記事をカウントするという手法を用いている。本章では、日本語のロイターニュースのマクロ経済カテゴリーの記事に対して、同様に表7に定義された単語、および「日本」という単語を含む記事を抽出し、その月次の頻度をカウントし、擬似的に日本語のロイターニュースを用いた Baker らの手法による日本の経済政策不確実性指数とした。構築した日本の経済政策不確実性指数の時系列推移は下記、図47の通りとなる。




図 47: ロイターニュースに対する Baker らの手法による日本の経済政策不確実性指数の時系列推移

また、ロイターニュースに対する Baker らの手法による日本の経済政策不確実性指数の時系列推移の各ピーク時点 (A~E) の出現単語の上位は以下の表 13 の通りである。

表 13: Baker らの手法による日本の経済政策不確実性指数の各時点における出現単語上位 10 単語

A	B	C	D	E
先行き	市場	市場	経済	利上げ
円高	日本	欧州	新興国	金融市場
景気	影響	金融	市場	減速
ドル	可能性	先行き	見方	株価
市場	上昇	円高	指摘	市場
経済	日銀	景気	米国	先行き
下値	原油価格	経済	景気	世界経済
企業	FRB	世界経済	動き	中国経済
対策	総裁	財政	緩和	経済
リスク回避	中東	米国	日本経済	新興国

表 13 から Baker らの手法による日本の経済政策不確実性指数では、日本以外の単語 (「米国」、「欧州」、「FRB」、「新興国」、「中国経済」、「中東」) を含む記事も日本の経済政策不確実性指数としてカウントしていることがわかる。また、金融市場関連の単語 (「円高」、「ドル」、「下値」、「市場」、「原油価格」、「上昇」、「株価」) を含む記事も日本の経済政策不確実性指数としてカウントしていることがわかる。

一方で、提案手法で構築した不確実性指数のうち、トピック 6 にあたる日本の金融政策に係る不確実性指数の単語分布 φ_k における上位 10 単語を見ると、すべて日本の金融政策に関する単語が上位を占めており、他国に関する単語は含まれていない（表 11）。

より定量的な比較として、Baker らの手法による日本の経済政策不確実性指数と提案手法で構築したトピック 6 にあたる日本の金融政策に係る不確実性指数のそれぞれのピーク時点の記事に対して、日本関連の単語の割合、海外関連の単語の割合、市場関連の単語の割合を計算した。

表 14: Baker らの手法、提案手法による日本の不確実性指数のピーク時における単語割合

	日本関連の単語の割合	海外関連の単語の割合	市場関連の単語の割合
提案手法	75.56%	12.22%	12.22%
Baker らのモデル	14.22%	40.85%	44.93%

表 14 が示す通り、Baker らのモデルと比較して、提案モデルの方が日本関連の単語の割合が高いことがわかる。Baker らのモデルは、自国の単語の割合よりも他国の単語の割合や市場関連の単語の割合の方がが多い。これは、Baker らのモデルにより構築された不確実性指数は、自国のマクロ経済要因による不確実性よりも、よりグローバルなマクロ経済要因や金融市場要因による不確実性に影響された不確実性指数と言える。一方で、提案モデルによる不確実性指数については、正確にトピックの分類を行っているため、海外の要因や金融市場の要因による不確実性は取り除かれており、自国の要因のみの指数となっている。

この提案モデルと Baker らのモデルの不確実性の要因の違いによる影響については、後述のセクション 3.4.5 において、VAR 分析を行った際にもマクロ経済指標への影響度合いの差として表れている。

3.4.4 他の指標との相関分析

このセクションでは、構築したトピック別の不確実性指数と株式市場、債券市場、為替市場の指数との関連性について分析、および Baker らの構築した各地域の不確実性指数との関連性について分析を述べる。

まず、各市場との関連性について、各トピック別の不確実性指数と各金融市場の指数のボラティリティとの相関係数を計算し、表 15 に記した。株式市場、債券市場、為替市場の代表的な指数として、それぞれ米国 10 年債、S&P500 指数、ドル円の 3 つを用いた。市場のボラティリティは月ごとの日次リターンの標準偏差を用いた。加えて、各トピック別の不確実性指数と月次 VIX 指数との相関（第 6 カラム）、および、モデルで推論された各トピックの正規化 VIX の期待値 η （第 1 カラム）を計算し、表 15 に記した。

表 15: トピック別不確実性指数と各市場指数のボラティリティとの相関係数。なお $\bar{\eta}$ は、モデルで推論された正規化 VIX の期待値

トピック		相関係数			
k	$\bar{\eta}$	米国 10 年債	S&P500	ドル円	VIX 指数
0	0.044	-0.328	-0.118	-0.383	-0.033
1	-0.876	-0.442	-0.133	-0.195	-0.297
2	0.700	0.374	0.197	0.053	0.235
3	-0.354	-0.183	-0.283	0.134	-0.269
4	0.436	0.261	0.253	-0.102	0.183
5	1.286	0.565	0.366	0.177	0.417
6	-0.048	-0.056	0.043	0.065	-0.007
7	0.667	0.346	0.108	0.322	0.213
8	-0.177	-0.216	-0.203	-0.221	-0.110
9	-0.194	-0.277	-0.235	0.046	-0.267

表 15 の結果より、トピック別不確実性指数のうち高い $\bar{\eta}$ の値を持つものについては、各市場指数のボラティリティと正の相関が強いと同時に VIX 指数とも正の相関が強い。反対にトピック別不確実性指数のうち低い $\bar{\eta}$ の値を持つものについては、各市場指数のボラティリティと負の相関が強いと同時に VIX 指数とも負の相関が強い。

例えば、トピック 5 であるユーロ圏における金融危機に係る不確実性指数（表 11, 図 45）やトピック 7 である金融市場に係る不確実性（表 11）は、正規化 VIX の期待値 $\bar{\eta}$ が大きく、市場変動に連動したとトピックとして分類されている。これらのトピックについて、実際に市場指数のボラティリティや VIX 指数との相関は他のトピックより正の相関が強い（表 15）。金融市場に係る不確実性や金融危機に係る不確実性は他のマクロ経済に関する不確実性よりも市場に直結しており市場変動を及ぼす影響度が大きいと言える。

反対にトピック 1 である国際的な経済イベントに係る不確実性指数（表 11, 図 42）やトピック 3 である米国の財政政策に係る不確実指数は、正規化 VIX の期待値 $\bar{\eta}$ が小さい。これらの不確実性が高まった時期において市場変動は弱く、逆に不確実性が低い時期において、市場変動が大きいという市場変動と逆相関のトピックとして分類されている。これらのトピックについて市場指数のボラティリティや VIX 指数との相関は他のトピックより負の相関が強い（表 15）。これらのトピックが逆相関である理由としては、以下のように考察する。トピック 1 である国際的な経済イベントに係る不確実性指

数もトピック 3 である米国の財政政策に係る不確実指数も住民投票や大統領選挙投票に大きく関係している。不確実性が高くなっている時期は投票が行われる月である。他のマクロ経済の不確実性と異なり、選挙での不確実性の高まりと、選挙後に結果が周知されることによる市場変動は落ち着きが月次指数で同じタイミングとなるため、これらの不確実性と市場変動の間に逆相関が生じたのではないかと考えられる。

トピック 0 である欧州連合の金融政策に係る不確実性指数（表 11）やトピック 6 である日本の金融政策に係る不確実性指数（表 11, 図 46）は、0 に近い正規化 VIX の期待値 $\bar{\eta}$ を有しており、これらの不確実性指数が高まった時期には、市場変動が平均値でしかないトピックとして分類されている。これらのトピックについて市場指数のボラティリティや VIX 指数との相関はほぼ無相関である（表 15）。これらのトピックが市場と無相関の理由としては、欧州連合の金融政策も日本の金融政策も緩和政策が続いており、不確実性が高まったタイミングにおいても、市場としては緩和が続くと織り込まれているため、市場変動に結びつかないためだ。

トピック 2 である日本の復興に係る不確実性指数について、他の不確実性指数よりも米国 10 年債と強い正の相関を示している。これは、2011 年の東日本大震災後の復興の不確実性の高まりと欧州債務危機による米国債の低下のタイミングが一致したためである。この 2011 年のピークの一致を除いた場合、両者の相関は 0.37 から 0.14 まで低下し、他の多くのトピックより低いものとなる。

また、トピック 9 である米国における金融政策に係る不確実性指数と S&P500 指数のボラティリティが負の相関をしてしている。こちらについては、S&P500 指数は、米国の株価指数であるが、米国における金融政策よりチャイナショックや欧州債務危機などの他の世界経済要因の影響を受けているためだと考えられる。実際に S&P500 指数は、トピック 4 である新興国をはじめとする世界経済に係る不確実性指数やトピック 5 であるユーロ圏における金融危機に係る不確実性指数と他のトピックより強い正の相関を有している。他の不確実性からの影響が大きいため、相対的に米国における金融政策に係る不確実性からの影響が小さく、そのため負の相関をしてしていると考えられる。

各トピックに対する正規化 VIX の期待値 $\bar{\eta}$ と各市場指数のボラティリティとの相関係数の関係性については、図 48 の散布図がより鮮明に示しており、正規化 VIX の期待値 $\bar{\eta}$ が大きいトピックの不確実性指数ほど、市場のボラティリティと正の相関が強く、逆に正規化 VIX の期待値 $\bar{\eta}$ が小さいトピックの不確実性指数ほど、市場のボラティリティと負の相関が強い。

supervised LDA モデルを用いて構築された各トピック別の不確実性は、それぞれ、市場変動と連動しやすいトピック、市場変動と逆の動きをするトピック、市場変動と連動しないトピックに分けることができる。




図 48: 各トピックの正規化 VIX の期待値 $\bar{\eta}$ および金融市場指数のボラティリティとの相関係数。正規化 VIX の期待値 $\bar{\eta}$ が大きいトピックほど、各市場のボラティリティと正の相関が強い。

次に、Baker らの構築した各国の不確実性指数（世界、中国、英国、米国）との関連性について、これらの不確実性指数と提案モデルで構築したトピック別の不確実性指数の相関係数を計算し、表 16 に記した。相関係数と共にモデルで推論された各トピックの正規化 VIX の期待値 $\bar{\eta}$ を第 1 カラムに記した。

表 16 の結果から、トピック別不確実性指数のうち高い $\bar{\eta}$ の値を持つものについては、Baker らの不確実性指数とは負の相関が強いく、反対にトピック別不確実性指数のうち低い $\bar{\eta}$ の値を持つものについては、Baker らの不確実性指数とは正の相関が強いという結果となった。

表 16: トピック別不確実性指数と Baker らの不確実性指数との相関係数。なお $\bar{\eta}$ は、モデルで推論された正規化 VIX の期待値

トピック		相関係数			
k	$\bar{\eta}$	世界	中国	UK	US
0	0.044	0.251	0.372	0.096	-0.028
1	-0.876	0.687	0.752	0.648	0.260
2	0.700	-0.226	-0.266	-0.312	-0.005
3	-0.354	0.098	0.029	0.325	0.131
4	0.436	-0.117	-0.127	-0.263	0.040
5	1.286	-0.285	-0.381	-0.300	-0.058
6	-0.048	-0.086	-0.078	-0.105	-0.084
7	0.667	-0.481	-0.537	-0.315	-0.182
8	-0.177	0.032	0.120	-0.038	-0.117
9	-0.194	-0.007	0.014	0.038	-0.034

Baker らの不確実性指数との相関分析から次のことが言える。まず、全トピック別の不確実性指数のうち、トピック 1 である国際的な経済イベントに係る不確実性指数が最も Baker らの不確実性指数との相関係数との正の相関が強い。前述の通り、Baker らの不確実性指数については、個別の国の要因以外にも海外要因による不確実性を含まれやすい指数であり、両者に国際的な経済イベントに係る不確実性が含まれているため、相関が強い。

一方で、トピック 9 である米国における金融政策に係る不確実性と Baker らの米国における不確実性指数との相関が弱い。これは、Baker らの米国における不確実性指数のうち、金融政策の割合が全体の 30% 以下であることが起因していると考えられる。

3.4.5 インパルス応答分析

構築した各不確実性指数がマクロ経済指標に対して、どのような影響を与えるか、ベクトル自己回帰 (VAR) モデルのインパルス応答関数による分析を行った。なお、マクロ経済指標として日本の鉱工業生産指数を用いた。VAR モデルは自己回帰モデルを多変量に拡張したもので、変数間の動学的関係の分析に使用できる。 y_1, y_2 の 2 変量 VAR の 1 期モデルは以下の式 16、式 17 で表される

$$y_{1,t} = c_1 + \phi_{11}y_{1,t-1} + \phi_{12}y_{2,t-1} + \epsilon_{1,t} \quad (16)$$

$$y_{2,t} = c_2 + \phi_{21}y_{1,t-1} + \phi_{22}y_{2,t-1} + \epsilon_{2,t} \quad (17)$$

なお、 c は定数、 ϕ は係数、 ϵ は分散共分散行列のベクトルホワイトノイズである。

提案モデルにより構築した各不確実性指数を先行研究のモデルで構築した不確実性指数と比較するため、以下の 3 種類の VAR モデルを構築した。

1. y_1 が VIX 指数、 y_2 が日本の鉱工業生産指数
2. y_1 がセクション 3.4.3 において、Baker らのモデルにより構築した日本の不確実性指数、 y_2 が日本の鉱工業生産指数
3. y_1 が提案モデルにより構築した各不確実性指数、 y_2 が日本の鉱工業生産指数

期間が 2013 年 1 月から 2019 年 11 月のデータセットを用いて、OLS によって各パラメータを推定した。なお、鉱工業生産指数、VIX 指数、Baker らのモデルにより構築した日本の不確実性指数、提案モデルにより構築した各不確実性指数について、単位根検定を行った (表 17)。結果より、鉱工業生産指数のみが単位根過程であり、他の系列については単位根過程ではないことが示された。各 VAR モデルの全変数が単位根仮定の場合に起こりうる見せかけの回帰はなく、VAR モデルの各パラメータの推定が正しく行われる。

推定された VAR モデルのインパルス応答関数による不確実性指数に対する 1 標準偏差分のショックを与えたときの日本の鉱工業生産指数への影響の分析を行った。インパルス応答関数はコレスキー分解により攪乱項である ϵ を互いに無相関な直行化攪乱項に分解し、直行化攪乱項に対して、1 標準偏差分のショックを与えたときの y の時間関数である。

図 49 にインパルス応答による各 VAR モデルの y_1 に 1 標準偏差分のショックを与えたときの日本の鉱工業生産指数への影響の結果を示した。

表 17: 単位根検定。P 値の値が 0.05 より大きい場合、有意水準 5%のもとで単位根過程であるといえる。

系列	P 値	結果
鋳工業生産指数	0.6845	単位根過程である
VIX 指数	0.0008	単位根過程でない
Baker らのモデルにより構築した日本の不確実性指数	0.0000	単位根過程でない
提案モデルにより構築した各不確実性指数 (TOPIC 4)	0.0001	単位根過程でない
提案モデルにより構築した各不確実性指数 (TOPIC 6)	0.0000	単位根過程でない

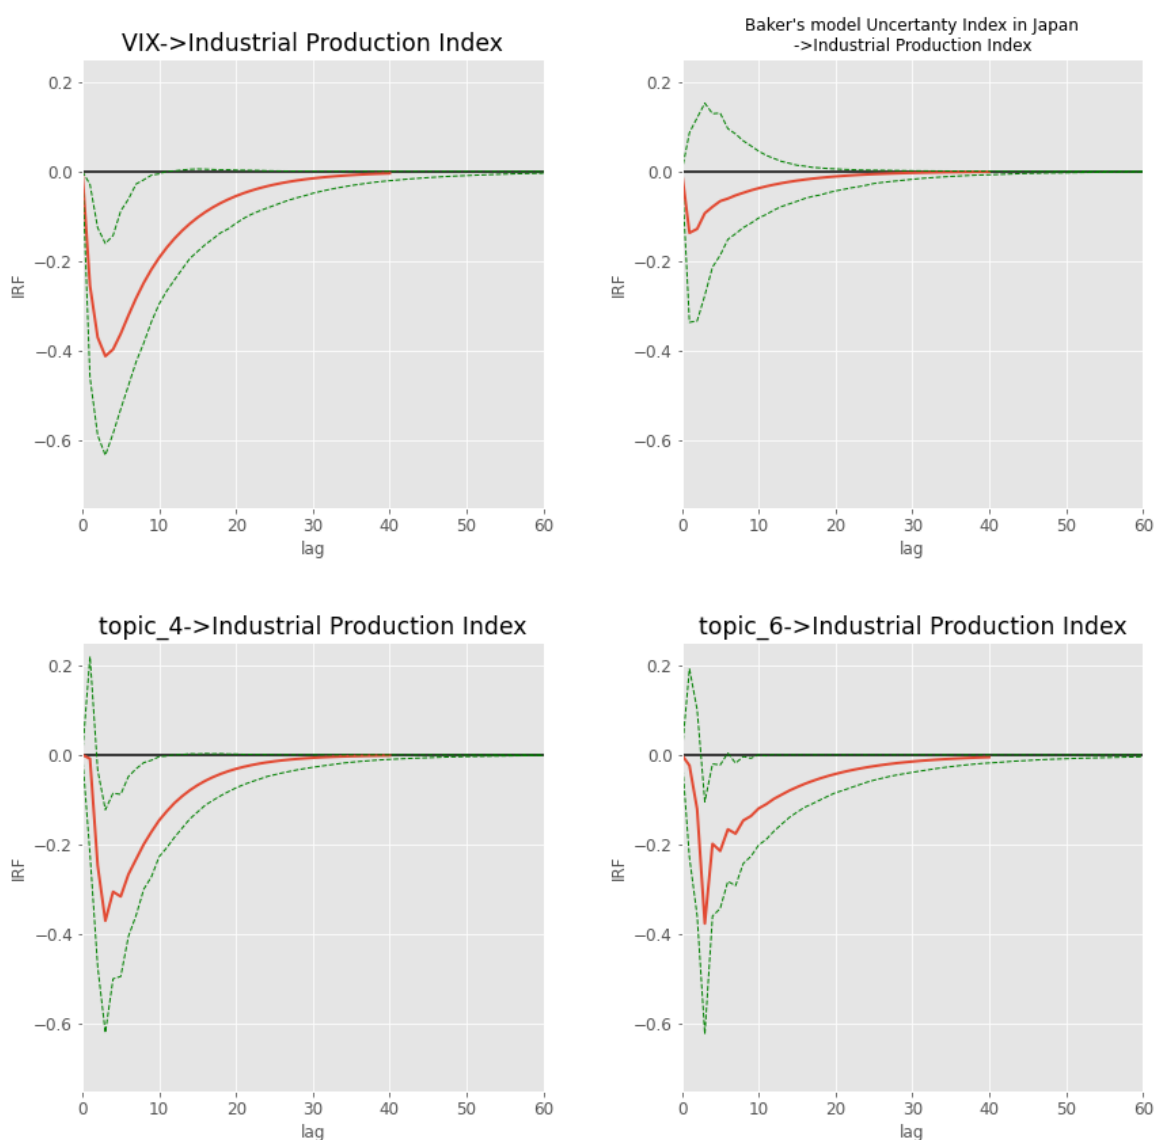


図 49: インパルス応答関数による各変数に対し 1 標準偏差分のショックを与えたときの日本の鋳工業生産指数の変動の時間変化。左上が VIX に対してショックを与えた場合。右上が Baker らのモデルにより構築した日本の不確実性指数に対してショックを与えた場合。左下がトピック 4 である新興国をはじめとする世界経済に係る不確実性指数に対してショックを与えた場合。右下がトピック 6 である日本の金融政策に係る不確実性指数に対してショックを与えた場合。

まず、VIX 指数と日本の鉱工業生産指数の VAR モデルの結果より、VIX 指数に 1 標準偏差分のショックを与えた場合、4 か月後に約 0.4 標準偏差分だけ日本の鉱工業生産指数を押し下げる結果となった。提案モデルのうち、トピック 4 である新興国をはじめとする世界経済に係る不確実性指数とトピック 6 である日本の金融政策に係る不確実性指数に関して、VIX 指数と同様に日本の鉱工業生産指数を 4 か月後に約 0.4 標準偏差分だけ押し下げる結果となった。日本の鉱工業生産指数に対して、世界経済に係る不確実性と日本の金融政策に係る不確実性が負の大きな影響を与えることが言える。

一方で、Baker らのモデルにより構築した日本の不確実性指数と日本の鉱工業生産指数の VAR モデルの結果からは、信頼区間が 0 を割ることがなく、有意に日本の鉱工業生産指数を押し下げる影響を与えているとは言えない。このことは、セクション 3.4.3 で述べた通り、Baker らのモデルにより構築した日本の不確実性指数が様々な国外による要因を含むことに起因し、ノイズの多い指数であるため、日本の鉱工業生産指数に対して有意に影響が認められなかったと考えられる。

3.5 本章のまとめ

本章では経済の先行きの不確実性をその要因ごとに指数化するモデルを提案した。先行研究である Baker らの手法は特定単語を含む記事数をカウントする手法で不確実性を定量化していたのに対し、提案モデルでは拡張したトピックモデルを用いることで、事前に特定単語を定義することなく、要因ごとの不確実性指数を構築することを可能にした。

さらに本章における提案モデルは、トピックモデルを拡張し、不確実性の代理変数である市場の将来変動を示す VIX 指数を教師信号として、モデル内に組み込んだ。このことにより、推定された各要因ごとの不確実性指数は、市場変動の大きさごとに分かれたものとなり、各要因の不確実性がどの程度市場変動に影響を及ぼすかを同時に推定することができた。

また、先行研究である Baker らの手法による不確実性指数との比較では、国別の不確実性指数を構築する際に既存手法よりも海外要因や市場要因を取り除いた不確実性指数の構築を行うことができた。そのため、マクロ経済指標への影響分析においても、提案モデルによる不確実性指数の方が有意な結果を示すことができた。具体的には、VAR モデルを用いたインパルス応答関数により、日本の鉱工業生産指数に対して、提案手法で構築した日本の不確実性指数に 1 標準偏差分のショックを与えた場合、4 か月後に約 0.4 標準偏差分だけ日本の鉱工業生産指数を押し下げる結果を確認することができた。これは、同じテキストデータに対して、先行研究である Baker らの手法を用いて構築した日本の不確実性指数では有意に示されなかった結果である。

第4章 市場センチメント指数を用いた為替市場 変動の方向性の予想

前章までは、非構造化データである金融テキストから中央銀行の経済や物価に対するセンチメント(第2章)、経済の先行きに対する不確実性(第3章)をトピックモデルを用いて定量化し、マクロ経済への影響について分析を行った。

本章では、金融ニュースのテキストから金融市場における市場参加者の着目する経済トピックとそのセンチメントを拡張したトピックモデルを用いて定量化し、市場変動の予測を行う。市場変動が個々のマクロ経済ファクターの変化だけでなく、加えて心理的な要因の変化から影響を受けるという仮定の下、モデル内にセンチメントの潜在変数を組み込んだトピックモデルを提案する。

市場変動の予測を行うために、テキストからその特徴量を抽出する際、複数のトピックモデルを用いており、トピックモデルの違いにより予測力に違いが生じるかの検証を行った。

4.1 はじめに

4.1.1 為替の決定要因

為替市場の予測に関して、為替の決定要因となる材料は金融政策、財政政策、経済成長、インフレなどのマクロ経済要因から中央銀行による為替介入や政治リスクなど、多岐にわたる(表18)。投資家は、これらの要因について、通貨ごとに点数をつけることで評価し、通貨間の強弱や方向性を予測している(三井住友信託銀行マーケット事業, 2016)。

表 18: 為替の決定要因

要因	影響
金融政策	引き締めが通貨高につながる
財政政策	財政拡張が通貨高につながる
経済成長	高成長が通貨高につながる
インフレ	インフレ率低下が通貨高につながる
金利	金利上昇が通貨高につながる
介入	中央銀行による介入や為替レートの切り下げなどの可能性
政治リスク	地政学リスクが高いと通貨安につながる

ただ、これらの要因に基づく投資方法の課題としては、各要因のウェイト付けがなされていないため、マーケットが重要視している要因が短期間で変動するような場合には、把握が難しいことが挙げられる。近年、ニューステキストからこれらの要因を特定する研究が行われており、一定の成果が挙げられている。(黒坂, 2017) では、日経記事のテキストと為替変動とを比較し、「原油安」、「世界景気の減速懸念」、「米国での早期の追加利上げ観測後退」、「中国による南シナ海地对空ミサイル配備の地政学リスク」、「中国人民銀行による人民元の対米ドル基準値を元安方向設定に基づく中国からの資金流出」などの要因により円ドルレートが変動したと分析している。また、(岩崎他, 2018) では、事前に定義した各要因に関連する重要単語を基に記事をラベル付けし、そのラベルに対して、機械学習を用いて記事を分類している。

本章では、為替概況ニュースのテキストから為替の決定要因となりうる個々のマクロ経済ファクターやそのセンチメントを拡張したトピックモデルを用いて抽出するとともに、抽出した要因を活用し、為替予想の方向性予測を試みる。

4.1.2 金融市場の価格予想に関する先行研究

(Malkiel & Fama, 1970) において、すべての情報が瞬時に価格に反映されるという「効率的市場仮説」が提唱され、市場の価格予想はできないとする学説がある一方で、非常に多くの研究者が価格予想というテーマで研究に取り組んできた。

ヒストリカルな数値データを用いた価格予想

古く経済学分野において、価格予想は価格の時系列データのみを使い、(自己相関モデル) AR モデル、(移動平均モデル) MA モデル、(自己回帰移動平均モデル) ARMA モデル、ARCH モデル(分散自己回帰モデル) 等の時系列分析の手法が用いられてきた。近年では、機械学習や深層学習などの

手法も多く取り入れられている。(Kim, 2003)では、SVMを用いて韓国総合株価指数(KOSPI)の予測を行った。case-based reasoning and neural networksと比べ、SVMはより精度の高い予測精度を示した。また、(Fischer & Krauss, 2018)では深層学習モデルを用いた。彼らは、LSTMネットワークを用いて、米国の代表的な株価指数であるS&P500の予測を行った。ランダムフォレスト、深層ニューラルネットワーク(DNN)、ロジスティック回帰による分類モデルに比べ、LSTMネットワークを用いたものの精度がより高い予測精度を示した。また、(Zuo & Kita, 2012)ではベイジアンネットワークを用いて、日経平均とトヨタ自動車の株価収益率(P/E ratio)の予想を行った。AR、MA、ARMA、ARCH等の伝統的な時系列分析を用いた予測と比べ、ベイジアンネットワークを用いた予測はその他の手法と同等の予測精度を示した。

テキストデータを用いた予測

近年、ビックデータ時代の到来により、金融市場において利用可能なテキストデータも増大しており、多くの研究者はテキストデータを用いた市場の価格予想を行ってきた。多くの場合、テキストデータをBoW形式に変換し、予測モデルの特徴量としている。(Peramunetilleke & Wong, 2002)では、ニュースのヘッドラインを用いて、為替市場の日中足の変動の予測を行った。事前に定めたキーワード群の頻度を各ヘッドラインに対して求め、各キーワード群の占率を予想モデルの特徴量とした。(Antweiler & Frank, 2004)では、Yahoo! Finance、Raging Bull等の株価に関するインターネット掲示板の書き込みを用いて、株価個別銘柄の値動き、出来高、ボラティリティの予測を試みた。彼らのモデルでは、テキストを同様にBoW形式に変換し、特徴量として用いており、株価に関する書き込みはボラティリティの予測に対して有効であることを示した。

BoW形式をはじめとする、単語の出現頻度をもとにしたテキストの表現方法以外に、様々なテキストの表現方法が用いられている。(Ding et al., 2015)では、ニュースのヘッドラインを用いて株価の値動きを予測した。彼らはニューステキストをニューラルテンソルネットワークを用いて、Dense Vectorに変換し、予測モデルに深層畳み込みニューラルネットワークを用いており、入力層にテキストから変換されたdense vectorを代入して予測を行っている。彼らの実験ではベースラインモデルよりニューラルテンソルネットワークを用いた提案モデルの方が6%精度向上した。また、(Peng & Jiang, 2016)は経済ニュースを用いて、株価の値動きの予測を行った。彼らはニューステキストからBoWのテキスト表現以外に、極性スコア、カテゴリータグを特徴量として使用した。深層ニューラルネットワークを用いて、予測を行い、提案した特徴量を用いた結果が他の特徴量を用いた結果よりも高い精度の結果となった。

センチメント分析の株価予想への応用

センチメント分析を価格予想へ応用する研究も盛んに行われている。(Bollen et al., 2011b) では、twitter データを用いて、テキストから6つの感情(落ち着き, 警戒, 確信, 活発, 優しい, 幸福)の指数を抽出し、これらの指数を使い、ダウ工業株30種平均(DJIA)の予測を行った。彼らの指数を用いることにより正答率86.7%の高い予測率を得られたという結果が示されている。(Schumaker et al., 2012)では経済ニュースと共に株価の時系列を用いて、株価のリターンの予測を行った。AZFin Text と呼ばれるシステムを構築し、経済ニュースをセンチメントと名詞句に変換した特徴量を用いて予測しており、結果においては、59.0%の精度を達成した。

トピックモデルの株価予想への応用

トピックモデルを用いた市場予測の研究も多く存在する。(Mahajan et al., 2008)では、経済ニュース記事に対してLDAを適用し、インドの代表的な株価指数であるインド Sensex 指数に関する分析を行った。また、彼らは同時にニュース記事をもとに株価の方向性(上昇、下落)を予測するシステムの開発を行った。一方で、センチメント分析とトピックモデルを同時に考慮した研究もいくつか見受けられる。(Si et al., 2013)では、LDAを拡張した連続的なDirichlet Process Mixture(DPM)モデルを開発した。DPMモデルを用いてツイッターのセンチメントの時系列推移データを抽出し、S&P100の予測を行った。(Jin et al., 2013)では為替通貨ペアの値動きの予測をLDAを用いて、特定されたトピックと単語の出現頻度をベースに手法により抽出したセンチメントをもとに行った。(Nguyen et al., 2015)ではヤフーファイナンスの掲示板のテキストデータを使い、18の個別銘柄の値動きに対する予測を行った。彼らは、テキストからトピックとセンチメントを同時に抽出できるモデルを提案した。SVMを使用し、抽出したセンチメントとトピックの占率を特徴量として、予測を行った。結果、価格のみを特徴量として使用した場合より高い精度を達成した。

4.1.3 先行研究における課題

前述の通り、金融テキストを用いた価格予測、特に株価予想に関する多くの研究は、投資家の楽観的、または悲観的なムードが金融市場の価格に影響を与えるという仮定の下、様々な金融テキストからセンチメントを抽出しており、それを特徴量として、価格予想を行っている(Bollen et al., 2011b; Schumaker et al., 2012)。

しかし、金融テキストに対するセンチメントの抽出は非常に事前の準備が必要なタスクである。多くの研究では、極性辞書を用いたアプローチでセンチメントを計算しているが、その際には金融テキストにあった極性辞書を作成する必要がある。(Nguyen et al., 2015)においては、その課題を解決すべく、株式の個別株の予想において、通常トピックモデルを拡張したjoint sentiment/topic model (JST)モデルを用いて、トピックとセンチメントの双方を同時に推定し、それらの特徴量を用いて、株式の

個別株の予想を行った。外国為替レートの予測においては、(Peramunetilleke & Wong, 2002) のようにニュースのヘッドラインからルールベースのキーワードを定め、そのキーワードの出現頻度を基にした特徴量とする研究は存在するが、トピックモデルを用いて為替レートを価格予測への試みはなされていない。

外国為替レートの予測において、トピックモデルを適応することにより、為替の決定要因となりうる複数のマクロ経済ファクターを自動的に分類し、各記事のトピック分布を特徴量として得ることが可能で、特定キーワードを事前に定義するルールベースのアプローチと比べ、低コストとなる。さらに、(Nguyen et al., 2015) において導入されたセンチメントも同時に推論する拡張を加えたトピックモデルに用いることで、株価予想において有効である投資家のセンチメントを極性辞書を事前に構築せずとも外国為替レートの予測の特徴量に加えることができる。

4.1.4 本章の目的

本章の目的は、トピックモデルを用いて為替の決定要因となるマクロ経済要因やそれに対する投資家のセンチメントを為替関連のニューステキストから抽出し、それらの特徴量として、外国為替レートの予測を行うことである。既存のトピックモデルである、LDA、supervised LDA (sLDA)、JST に加え、supervised joint sentiment/topic model (sJST) を提案した。4つのトピックモデルを用いて、為替関連のニューステキストから特徴量を抽出し、どのトピックモデルで抽出した特徴量の方がより予測力が高いかの比較を行うことで、為替レートの予測力に影響を及ぼす要因について分析を行う。なお、各モデルで考慮している要因は以下の表 19 の通りである。

表 19: 各トピックモデルにおいて考慮されている要因

モデル	考慮されている要因
LDA	マクロ経済ファクター
sLDA	マクロ経済ファクター、市場変動
JST	マクロ経済ファクター、投資家センチメント
sJST	マクロ経済ファクター、投資家センチメント、市場変動

4.2 トピックモデルの拡張

本セクションにおいては、為替市場の方向性予測にセンチメントを特徴量として取り入れるため、通常のトピックモデルを拡張し、トピックを示す潜在変数とセンチメントを示す潜在変数の両方をもつ JST モデルについて解説する。加えて、JST と sLDA 両方の拡張を取り入れた提案モデルである supervised joint sentiment/topic model (sJST) についても解説する。

4.2.1 JST

JSTモデルでは、ドキュメント内の各単語はセンチメント変数 l_d 、およびトピック変数 z_d の両社から影響を受けて生成されるという考えもの構築されているモデルである。図 50 に JST のグラフィカルモデル、表 20 にそのノーテーションを示す。

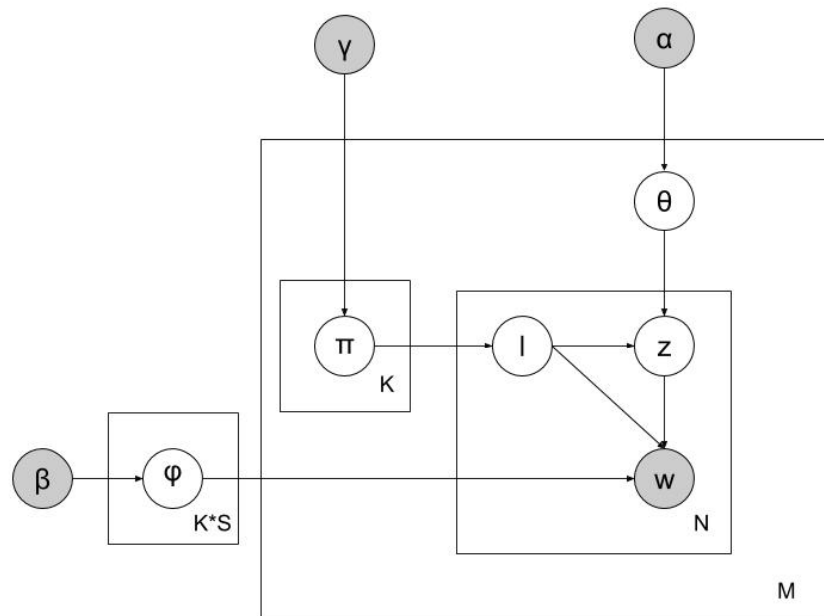


図 50: JST model

表 20: JST の定義

定義	
α, β	ハイパーパラメーター
φ	各トピック・センチメントの単語分布
K	トピック数
θ	各ドキュメントのトピック分布
Z	トピックの潜在変数
l	センチメントの潜在変数
w	単語
N	単語数
M	ドキュメント数
S	センチメント数
π	各ドキュメントにおけるセンチメント分布

通常のとピックモデルである LDA では、ドキュメント d 含まれる i 番目の単語は、数式 (4) の通り、潜在トピック z ごとに決められた単語の生成確率である $\varphi_{z_{d,i}}$ をパラメータに持つ多項分布から生成される。JST においては、以下の数式 (18) トピックの潜在変数 Z に対して、潜在トピック z ごと、かつ潜在センチメント l ごとに決められた単語の生成確率である $\varphi_{z_{d,i}}^{l_{d,i}}$ をパラメータに持つ多項分布から生成される。

$$w_{d,i} \sim \text{Multinomial}(\varphi_{z_{d,i}}^{l_{d,i}}) \quad (18)$$

これにより、今まで単語の共起性からトピックが分類されていたのに対し、JST では、トピックとそのセンチメントの両方が単語の共起性から分類される。

4.2.2 sJST

本章では、新たに supervised Joint Sentiment-Topic (sJST) モデルを提案する。為替レートの予測において、前述の JST を用いてトピックごとセンチメントごと為替の決定要因が抽出できることに対して、supervised LDA の拡張と同じく為替変動を示す教師信号をモデルに加える拡張をすることで、為替変動の大きさに比例したトピックごと、かつセンチメントごと為替の決定要因を抽出できると考えた。sJST モデルは sLDA モデル（外部変数 \mathbf{Y} が潜在変数 \mathbf{Z} に影響を及ぼす）と JST モデル（センチメントとトピックが同時に推論される）を合わせたモデルであり、単語の共起性、および教師信号の

大きさからトピックとセンチメントを両方分類することにより、教師信号である市場変動の大きさごとのトピックとセンチメントを推論することができる。図 51 に sJST のグラフィカルモデル、表 21 にそのノーテーションを示す。

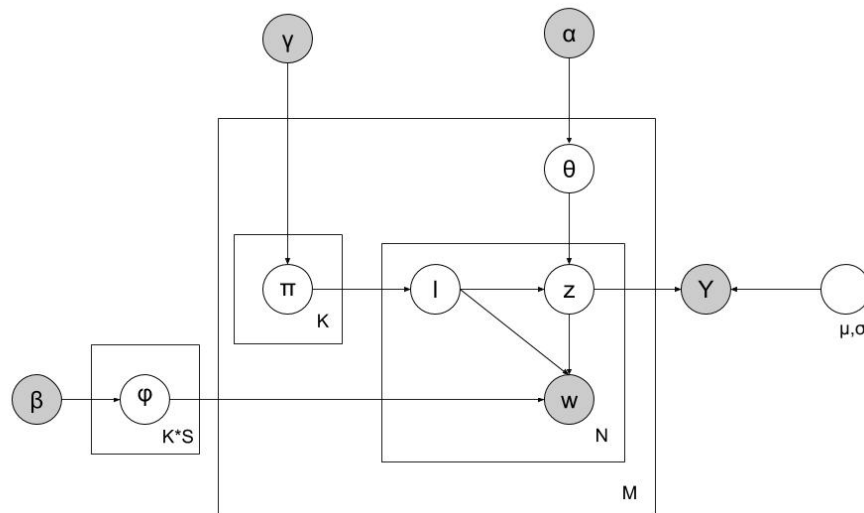


図 51: sJST model

表 21: sJST の定義

定義	
α, β	ハイパーパラメーター
φ	各トピック・センチメントの単語分布
K	トピック数
θ	各ドキュメントのトピック分布
Z	トピックの潜在変数
l	センチメントの潜在変数
w	単語
N	単語数
M	ドキュメント数
S	センチメント数
π	各ドキュメントにおけるセンチメント分布
Y	外部変数
μ, σ	外部変数のハイパーパラメーター

sJST モデルの生成プロセスは以下の通りとなる。

- 各ドキュメント d において、センチメント分布 π_d が以下の数式 19 により生成される。なお、ここで γ はディリクレ分布のハイパーパラメータである

$$\pi_d \sim \text{Dirichlet}(\gamma) \quad (19)$$

- ドキュメント d の各センチメント l に対して、トピック分布 $\theta_{d,l}$ が以下の数式 20 により生成される。なお、ここで α はディリクレ分布のハイパーパラメータである。

$$\theta_{d,l} \sim \text{Dirichlet}(\alpha) \quad (20)$$

- ドキュメント d における、各単語 $w_{i,d}$ に対して

– センチメントラベル $l_{d,i}$ が数式 (21) の分布よりからサンプリングされる

$$l_{d,i} \sim \text{Multinomial}(\pi_d) \quad (21)$$

- トピック $z_{d,i}$ が数式 (3) の分布よりからサンプリングされる
- 単語 $w_{d,i}$ が数式 (18) の分布よりからサンプリングされる
- 各ドキュメント d に対して外部変数 Y_d が数式 (13) の分布よりサンプリングされる

4.2.3 推論法

単語をサンプリングする確率分布は解析的に解くことはできず、ギブスサンプリング近似法を用いて、パラメータを推定し、近似した確率分布を用いてサンプリングされる。

JST において、 i 番目の単語 w_i が他のパラメータが与えられた前提でのトピック z 、およびセンチメント l となる同時確率分布は $P(z_i = z, l_i = l | z_{-i}, l_{-i}, w)$ により表される。ここで、 z_{-i} と l_{-i} はドキュメント d に存在する i 番目を除く単語群のトピックとセンチメントを表すベクトルである。

i 番目の単語 w_i は、以下の近似式 (22) に基づき、サンプリングが行われる。

$$P(z_i = z, l_i = l | z_{-i}, l_{-i}, w) \propto \frac{\{n_m^{(z)}\}_{-i} + \alpha}{\{n_m\}_{-i} + K\alpha} \cdot \frac{\{n_m^{(z,l)}\}_{-i} + \gamma_l}{\{n_m^{(z)}\}_{-i} + \sum_{l=1}^S \gamma_l} \cdot \frac{\{n_{z,l}^{(t)}\}_{-i} + \beta}{\{n_{z,l}\}_{-i} + V\beta} \quad (22)$$

ここで、 $n_m^{(z)}$ はドキュメント m においてトピック z に属する単語数を表す n_m はドキュメント m における全単語数を表す。 $n_m^{(z,l)}$ はドキュメント m においてトピック z 、かつセンチメント l に属する単語数を表す $n_{z,l}^{(i)}$ は単語 i がトピック z かつセンチメント l とアサインされた回数を示す。 $n_{z,l}$ はトピック z 、かつセンチメント l である単語の総数を表す。なお、 $-i$ は i 番目の単語を除いた回数を意味する。

sJST モデルにおいて、 i 番目の単語 w_i の他のパラメータが与えられた前提での同時確率分布は、以下の式で表される。

$$P(w, z, l, y | \alpha, \beta, \gamma, \mu, \sigma) = P(y | z, \mu, \sigma) P(w, z, l | \alpha, \beta, \gamma) \quad (23)$$

ここで、 Y_d は以下の正規分布に従う。

$$P(Y | z, \mu, \sigma) \propto \exp\left(-\frac{(Y_d - \mu^T \bar{z}_d)^2}{2\sigma^2}\right) \quad (24)$$

式 (22)、式 (23)、式 (24) により、sJST モデルにおいて、 i 番目の単語 w_i は、以下の近似式 (25) に基づき、サンプリングが行われる。

$$P(z_i = z, l_i = l | z_{-i}, l_{-i}, w) \propto \frac{\{n_m^{(z)}\}_{-i} + \alpha}{\{n_m\}_{-i} + K\alpha} \cdot \frac{\{n_m^{(z,l)}\}_{-i} + \gamma_l}{\{n_m^{(z)}\}_{-i} + K\gamma_l} \cdot \frac{\{n_{z,l}^{(t)}\}_{-i} + \beta}{\{n_{z,l}\}_{-i} + V\beta} \quad (25)$$

$$\cdot \exp\left(-\frac{(Y_d - \mu^T \bar{z}_d)^2}{2\sigma^2}\right)$$

4.3 データセット

本章のシミュレーションに使用するデータは、予想対象の為替レートの数値データと特徴量抽出を行う為替ニュースのテキストデータとである。

4.3.1 為替レートの数値データ

表 22 に示す 32 通貨ペアの為替 1 分足ヒストリカルデータを為替取引プラットフォームを提供している OANDA¹ の API 取得した。各データセットには 4 本値（始値、終値、高値、安値）が含まれており、データ期間は、ニューステキストのデータ期間に合わせて 2014/1/1～2018/5/31 としている。また、全通貨のうち米ドル/日本円に関しては、教師付きトピックモデルである sLDA と sJST の教師信号として米ドル/日本円の正規化ボラティリティを使用した。

¹<https://www.oanda.jp/>

表 22: 通貨ペア一覧

通貨ペア	シンボル
豪ドル/カナダドル	AUD/CAD
豪ドル/スイスフラン	AUD/CHF
豪ドル/香港ドル	AUD/HKD
豪ドル/日本円	AUD/JPY
豪ドル/ニュージーランドドル	AUD/NZD
豪ドル/シンガポールドル	AUD/SGD
豪ドル/米ドル	AUD/USD
カナダドル/スイスフラン	CAD/CHF
カナダドル/香港ドル	CAD/HKD
カナダドル/日本円	CAD/JPY
カナダドル/シンガポールドル	CAD/SGD
スイスフラン/香港ドル	CHF/HKD
スイスフラン/日本円	CHF/JPY
スイスフラン/南アフリカランド	CHF/ZAR
ユーロ/豪ドル	EUR/AUD
ユーロ/カナダドル	EUR/CAD
ユーロ/スイスフラン	EUR/CHF
ユーロ/チェココルナ	EUR/CZK
ユーロ/デンマーククローネ	EUR/DKK
ユーロ/英国ポンド	EUR/GBP
ユーロ/香港ドル	EUR/HKD
ユーロ/ハンガリーフォリント	EUR/HUF
ユーロ/日本円	EUR/JPY
ユーロ/ノルウェークローネ	EUR/NOK
ユーロ/ニュージーランドドル	EUR/NZD
ユーロ/ポーランドズウォティ	EUR/PLN
ユーロ/スウェーデンクローナ	EUR/SEK
ユーロ/シンガポールドル	EUR/SGD
ユーロ/トルコリラ	EUR/TRY
ユーロ/米ドル	EUR/USD
ユーロ/南アフリカランド	EUR/ZAR
米ドル/日本円	USD/JPY

4.3.2 為替ニューステキスト

為替市場におけるマクロ経済ファクターやセンチメントを抽出する対象として、為替概況ニュースを対象とした。以下に為替概況ニュースの一例を下記に示す。為替概況ニュースとは一日に3本各外国為替市場の取引時間に合わせて、発行されており、東京、ロンドン、ニューヨークの各市場の取引時間(表23)に起きた為替ニュースの概要について記載されている。

早朝に振幅、その後もみ合いから若干ドル買いに=東京為替概況投稿:2019/10/07 15:11
週明けの東京市場、ドル円は早朝に振幅を見せた後、もみ合いに転じた。週明けはいったん上昇して始まった。先週末の米雇用統計後のドル買いを受けて、米指標の弱さを懸念したドル売り基調が一服したとの思惑などが、ドル円を支え、オセアニア市場朝に107円台を回復する場面が見られた。しかし中国当局関係者筋情報として、10日の米中通商協議で中国側としては知的財産権などを含んだ幅広い合意に消極的と報じられ、一転してドル売り円買いに。ドル円は106円57銭まで値を落とす格好となった。

東京勢が本格参加してくるといったんは買い戻しで106円80銭台まで。その後106円60銭台にと、早朝のレンジの中でもみ合う動きに。リスク警戒感から米株先物時間外取引の売りや、米長期債利回りの低下(債券価格の上昇)などが目立つ場面があり、ドルの重石となった。

もっとも午後に入って米債利回りが持ち直すと、ドル売りも一服。106円90銭近辺までと、早朝の振幅後の高値を付ける動きに。豪ドルが対ドルで0.6750割れとなるなど、ドルは全般にしっかりとっている。ユーロドルは狭いレンジでの問引きに。ドル売りの流れで1.0990を付けたものの、先週末から1.10が重くなっていることもあり、そこからの買いは続かず、1.0970台へ

MINKABU PRESS 山岡和雅

上記のように、主要通貨の変動とマクロ経済指標や米中通商協議のようなマクロ経済イベントについて述べられている。為替概況ニュースは、Klug FXのウェブサイトより取得した。Klug FXは個人投資家向けの為替ニュースのプロバイダーであり、一日に約200記事ほど為替に関するニュース、レポート、コラムを掲載している。加えて、主要通貨ペアの値動きについても述べられている²。Klug FXの為替概況ニュースは1記事約500文字程度の要約であり、KlugFXに在籍している編集委員によって執筆されている。取得できたKlug FXの為替概況ニュースは2014/1/1 2018/5/31における4,384本であり、テキストデータセットとして用いた。

²2019/10時点ではKlug FXはみんかぶFXに統合されている。<https://fx.minkabu.jp/>

表 23: 各外国為替市場の取引時間 (グリニッジ標準時)

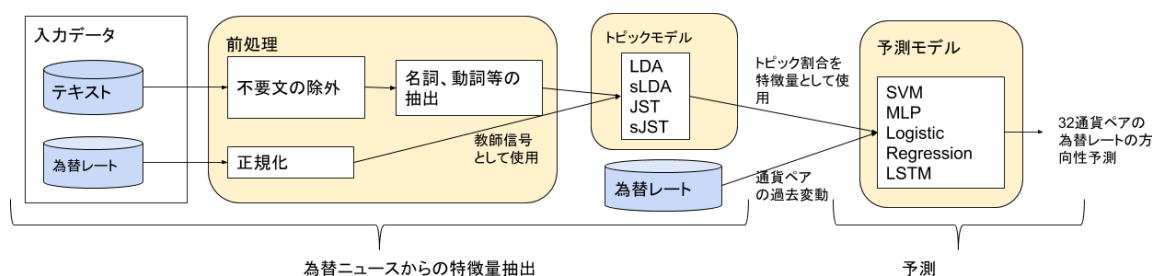
市場	取引時間
東京	11:00 PM ~ 07:00 AM
ロンドン	08:00 AM ~ 04:00 PM
ニューヨーク	01:00 PM ~ 09:00 PM

4.4 モデル

4.4.1 モデルの全体像

モデルの全体像を図 52 に示す。大きく分けるとテキストに対する前処理、トピックモデルによる特微量抽出、そして価格変動の予想の 3 つの部分から構成されている。

図 52: モデルの全体像



前処理の部分では、入力テキストデータである為替概況ニュースに対して、マクロ経済ファクターに関係のない為替マーケットの値動きに関する文章を除外し、形態素解析を行い、トピックモデルへ入力できる BoW 形式にテキストデータを変換した。また、教師付きトピックモデルの入力データとして、米ドル/日本円の為替レートに関しては、そのボラティリティに対して正規化を施す。前処理を終えた BoW 形式のテキストデータ、および米ドル/日本円の為替レートの正規化したボラティリティをインプットデータに、LDA、sLDA、JST、sJST の 4 種類のトピックモデルを用いて、トピック分類を行う。最後にトピックモデルで出力された各記事のトピック確率を記事の特徴量として、為替レートの過去データを加え、SVM、MLP、LR、LSTM の 4 つも予測モデルを用いて、32 通貨ペアの 6 時間後の為替レートの方向性の予測を行った。予測で用いるテキストの特徴量、予測モデル、予測対象

について、表 24 にまとめた。

表 24: 特徴量、予測モデル、予測対象のまとめ

テキストの特徴量	予測モデル	予測対象
LDA のトピック確率	SVM	32 通貨ペア
sLDA のトピック確率	MLP	
JST のトピック・センチメント確率	Logistic Regression	
sJST のトピック・センチメント確率	LSTM	
予測対象の通貨ペアの価格データ		

4.4.2 テキストデータに対する前処理

為替概況ニュースのテキストデータに対し、為替の値動きの記述（「ドル円は107円後半で小動き」）を示すテキストの除去を行った。これは、為替概況ニュースからマクロ経済要因に対して、トピック分類を行いたい、値動きの記述がある場合に値動きに係るトピックが大半を占めてしまい、正しくマクロ経済要因の抽出を行うことができないからである。値動きに関する単語をストップワードとして予め定義し、それらのストップワードを含まない文節のみを対象とした。これにより、通貨ペアに関する値動きを示す文章が除かれ、分析対象として為替市場に関わる経済イベントや要人の発言の文のみをトピックモデルのインプットの対象とすることができる。

次に MeCab を用いて形態素解析を行い、名詞、動詞、形容詞、形容動詞、副詞の取得を行った。その結果、4,284 文に対し、79,511 単語を抽出し取得した。単語種数は 2,125 単語である。

最後にトピックモデルに入力するために単語埋め込み (Word Embedding) を行った。トピックモデルに代入するテキストデータの埋め込み表現として、全記事を BoW 形式に直したベクトルを用いた。

4.4.3 数値データに対する前処理

教師付きトピックモデルである sLDA と sJST において、米ドル/日本円のボラティリティを正規化した値を各為替概要ニュースの教師信号として、インプットに用いる。米ドル/日本円というメジャー通貨間の為替レートボラティリティを為替市場全体における市場変動の大きさを示すと仮定している。教師付きトピックモデルに入れること理由は、第 2 章の supervised LDA を不確実性指数の構築に応用する際に述べた通り、為替の決定要因となる各マクロ経済ファクターが市場変動の大きさに応じて、分類されるためである。

まず、各為替概要ニュースに対応する東京、ロンドン、ニューヨークいずれかの市場の取引時間 (表 23) における米ドル/日本円の 1 分足の過去値を OANDA API を通じて取得し。その期間におけるヒストリカルボラティリティ $volatility_t$ を価格の標準偏差として求める。

例えば、為替概要ニュースが2018年10月1日の東京市場について述べられている場合、2018年10月1日23時(GMT)から2018年10月2日7時(GMT)までの米ドル/日本円の1分足のボラティリティを計算し使用する。各概況ニュースに対するボラティリティを計算したのち、各概況ニュースに対応するボラティリティの全データが平均0標準偏差1となるように正規化を行った。

$$\text{Normalized volatility}_{t=1\dots T} = \frac{\text{volatility}_{t=1\dots T} - \mu}{\sigma} \quad (26)$$

なお、ここで、 μ 、および σ は volatility_t の時系列の平均値、および標準偏差である。supervised LDAへの入力データとして正規化をする理由は、構築したsupervised LDAの教師信号である \mathbf{Y}_d が正規分布を仮定したモデルであり、それに合わせた形である。正規化したボラティリティをsLDA、sJSTモデルにおける各テキストデータに対応する教師信号としてトピックモデルのインプットに用いる。

4.4.4 LDAモデルによる特徴量抽出

前節までに述べた各トピックモデルであるLDA、sLDA、JST、sJSTを用いて、為替概況ニュースから特徴量の抽出を行った。各LDAモデルへのインプットは前項で述べたBoW形式の為替概況ニュースである。加えて、sLDA、およびsJSTモデルに関しては、個々の為替概況ニュースに対応した正規化した米ドル/日本円のボラティリティを教師信号として使用する。各トピックモデルのパラメータについては、ハイパーパラメータを $\alpha, \beta, \gamma = 0.01$ とした。これは結果としてのトピック分類の分け方が明確か否かにより判断し決定している。また、センチメント数 $S = 2$ とした。これは、JSTの先行研究である(Nguyen et al., 2015)を習い、センチメント数はポジネガの2値としているためである。なお、トピック数については、 $K = 2 \sim 20$ でトピックモデル、予測モデルごとにパラメータサーチを行い、バリデーション期間におけるAccuracyの精度がもっとも数をそれぞれ選択している。

4.4.5 機械学習による予測変動

東京、ニューヨーク、ロンドンの各市場の為替概況ニュースの特徴量を基に、その市場が閉じてから6時間後の表22に定めた32通貨ペアの変動(上昇、下降)を予測する。各トピックモデルから推論された為替概況ニュース d のトピック割合(θ_d)、またはセンチメント/トピック割合($\pi \times \theta_d$)と予測対象である為替価格自身の過去推移(過去6時間前、12時間前、18時間前³)を特徴量として用いる(表25)。

³価格の特徴量に関しては、6時間前~42時間前までの各期間の組み合わせで最適化を行った結果、過去6時間前、12時間前、18時間前とした。

表 25: 予測モデルで用いた特徴量

トピックモデル	特徴量
LDA	$\theta_d, price_{t-1}, price_{t-2}, price_{t-3}$
sLDA	$\theta_d, , price_{t-1}, price_{t-2}, price_{t-3}$
sJST	$\pi_d \times \theta_d, price_{t-1}, price_{t-2}, price_{t-3}$
JST	$\pi_d \times \theta_d, price_{t-1}, price_{t-2}, price_{t-3}$

価格変動の予測モデルとして、サポートベクターマシン (SVM)、ロジスティクス回帰 (LR)、多層パーセプトロン (MLP)、LSTM の 4 つのモデルを用いた。

予測モデルのデータ期間、および評価方法

訓練期間、バリデーション期間、テスト期間は、それぞれ、6 対 2 対 2 の割合で分割しており、以下の表 26 の通りである。

表 26: データ期間

	期間
訓練期間	2014/1/1 ~ 2016/11/1
バリデーション期間	2016/11/1 ~ 2017/8/15
テスト期間	2017/8/15 ~ 2018/5/31

モデルの評価は、Accuracy と F 値を用いて評価した。Accuracy は、予測の精度を示す指標であり、テストデータに対して、モデルの予測した値と実際の値の組み合わせによって表 27 のように分類したとき、

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (27)$$

と求められる。

表 27: モデルの予測した値と実際の値の組み合わせ表

		実際の価格変動		
		上昇	下降	横這い
予想した価格変動	上昇	TP	FP	FP
	下降	FN	TN	TN

また、適合率である Precision と再現率である Recall を

$$Precision = \frac{TP}{TP + FP} \quad (28)$$

$$Recall = \frac{TP}{TP + FN} \quad (29)$$

とした場合、F 値は Precision と Recall の調和平均値である。

$$F \text{ 値} = \frac{2Recall \cdot Precision}{Recall + Precision} \quad (30)$$

4.5 結果

4.5.1 各トピックモデルによるトピック分類の結果

為替概況ニュースに対して、各トピックモデルにより、抽出されたトピックの結果を以下に示す。各トピックモデルの違いにより、抽出されるトピックがどのように異なるかについて、解説する。

LDA

LDAにより、為替概況ニュースを分類した結果を全トピックのうち8つを選び、表28に示す。各トピックの単語分布の上位単語から、中央銀行の政策に関するトピック (TOPIC0, TOPIC3, TOPIC5)、政府の財政政策に関するトピック (TOPIC1)、物価 (TOPIC4) や雇用 (TOPIC6) に関するマクロ経済のトピック、地政学リスク (TOPIC7) に関するトピックなど複数の為替の決定要因に分類されていることがわかる。

表 28: LDA による各トピック k の単語分布 φ_k における上位単語

TOPIC0	TOPIC1	TOPIC2	TOPIC3
日銀	トランプ氏	英国	ecb
追加緩和	経済政策	e u 離脱	欧州中央銀行
黒田日銀総裁	期待	離脱	qe
金融政策	1 2月	e u	ドラギ ecb 総裁
反応	トランプ政権	eu	量的緩和
物価	ロシア	国民投票	ドラギ総裁
発言	大統領	欧州連合	発言
総裁	否決	議会	現行
目立つ	クリントン氏	表明	定例理事会
マイナス金利	インフレ期待	メイ首相	実施
TOPIC4	TOPIC5	TOPIC6	TOPIC7
生産者物価指数	市場	米国	北朝鮮
中国	e c	経済指標	イタリア
消費者物価指数	利上げ	下落	報道
小売売上高	理事会	予想	休場
生産者物価コア指数	f r b	万件	スペイン
米国	期待	万戸	実施
下落	予想	失業保険申請件数	合意
消費者物価コア指数	強まる	強まる	大統領
経済指標	強い	後退	米国
自動車	弱い	予想外	連立政権

sLDA

sLDAにより、為替概況ニュースを分類した結果を全トピックのうち8つを選び、表29に示す。中央銀行の政策に関するトピック (TOPIC3)、政府の財政に関するトピック (TOPIC1、TOPIC7)、雇用に関するマクロ経済のトピック (TOPIC2)、地政学リスクに関するトピック (TOPIC0, TOPIC5) など、LDAモデルと同様に複数の為替の決定要因に分類されている。

表 29: sLDA による各トピック k の単語分布 φ_k における上位単語

TOPIC0 ($\bar{\eta}=-0.898$)	TOPIC1 ($\bar{\eta}=-0.784$)	TOPIC2 ($\bar{\eta}=-0.675$)	TOPIC3 ($\bar{\eta}=-0.266$)
ロシア	安倍首相	中国	日銀
合意	首相	影響	増額
ウクライナ情勢	解散	輸出	急伸
米国	増税	世界経済	指値オペ
ウクライナ	可能	介入	動く
減産	延期	混乱	観測
欧米	黒田日銀総裁	懸念	通知
シリア	与党	輸出額	国債
緊迫化	国民	再燃	10年以下
姿勢	当初	注視	台頭
TOPIC4 ($\bar{\eta}=-0.182$)	TOPIC5 ($\bar{\eta}=0.075$)	TOPIC6 ($\bar{\eta}=0.116$)	TOPIC7 ($\bar{\eta}=29.311$)
ギリシャ	北朝鮮	米国	急落
合意	報道	経済指標	割れ
協議	ミサイル発射	下落	トランプ氏優勢
ユーロ圏財務相会合	過半数	予想	報道
ギリシャ問題	報じる	万件	決定
ギリシャ政府	確保	万戸	一気に
報道	発射	失業保険申請件数	トランプ氏
債権団	解任	強まる	入れる
ドイツ	否定	後退	メンバー
提出	市場全体	下回る	政策金利

一方で、sLDA では教師信号を用いており、各トピックに対し正規化米ドル/日本円のボラティリティの期待値が η として推定される。これにより、どのトピックが市場変動とより強く結びついているかがわかる。表 29 に関して、米国に関するトピックや地政学リスクに関するトピックの η が大きく、米ドル/日本円のボラティリティに大きく影響しているトピックとして抽出されている。

JST

JST により、為替概況ニュースを分類した結果を全トピックのうち 4 つを選び、表 30 に示す。トピックごとにセンチメントが二つに分かれており、上位単語が異なる。トピックごとに見ると、中央銀行の政策に関するトピック (TOPIC2)、米国経済に関するトピック (TOPIC0)、財政問題に関するトピック (TOPIC1)、欧州の株式市場に関するトピック (TOPIC3) に関するトピックに分類されていることがわかる。またセンチメントごとでは、「下落」、「下回る」、「後退」、「安値」、「低下」等を含むネガティブセンチメント (SENTIMENT0) と「強まる」、「上回る」、「高まる」、「期待感」、「高値」等を含むポジティブセンチメント (SENTIMENT1) ごとに抽出されている。

表 30: JST による各トピック k 、センチメント l の単語分布 $\varphi_{k,l}$ における上位単語

TOPIC0		TOPIC1	
SENTIMENT0	SENTIMENT1	SENTIMENT0	SENTIMENT1
下落	経済指標	ギリシャ	ギリシャ
米国	米国	合意	高まる
経済指標	万戸	協議	優勢
予想	強まる	ユーロ圏財務相会合	期待
下回る	予想	可決	発言
英国	万件	提出	期待感
後退	上回る	ギリシャ問題	合意
万件	優勢	向ける	大きい
予想外	失業保険申請件数	ギリシャ政府	協議
生産者物価指数	好感	承認	債権団
TOPIC2		TOPIC3	
SENTIMENT0	SENTIMENT1	SENTIMENT0	SENTIMENT1
追加緩和	日銀	欧州株	欧州株
市場	市場	控える	高値
反応	追加緩和	広げる	上回る
日銀	今晚	安値	予想
総裁	金融政策	割れ	事前予想
下落	反応	下回る	伸ばす
ecb	発言	低下	反応
利上げ	姿勢	下落	伸び
政府	黒田日銀総裁	市場	市場
目立つ	マイナス金利	予想	速報値

sJST

sJST により、為替概況ニュースを分類した結果を全トピックのうち4つを選び、表 31 に示す。JST モデルと同様にトピックごとにセンチメントが二つに分かれており、上位単語が異なる。トピックごとに見ると、中央銀行の政策に関するトピック (TOPIC1,3)、米国経済に関するトピック (TOPIC0)、

欧州の Brexit に関するトピック (TOPIC2)、欧州の株式市場に関するトピック (TOPIC0) に関するトピックに分類されていることがわかる。またセンチメントごとでは、「控える」、「下落」、「下回る」等を含むネガティブセンチメント (SENTIMENT0) と「伸び」、「上回る」、「回復」、「拡大」、「高値」等を含むポジティブセンチメント (SENTIMENT1) ごとに抽出されている。加えて、sLDA と同様に sJST では教師信号を用いており、各トピックに対し正規化米ドル/日本円のボラティリティの期待値が η として推定される。米国の金融政策に関するトピックや欧州の Brexit に関するトピックの η が大きく、米ドル/日本円のボラティリティに大きく影響しているトピックとして抽出されている。

表 31: sJST による各トピック k 、センチメント l の単語分布 $\varphi_{k,l}$ における上位単語

TOPIC0 ($\bar{\eta}=-0.291$)		TOPIC1 ($\bar{\eta}=-0.092$)	
SENTIMENT0	SENTIMENT1	SENTIMENT0	SENTIMENT1
欧州株	欧州株	市場	黒田日銀総裁
反応	高値	下落	追加緩和
市場	控える	政策金利	市場
控える	市場	語る	物価
下落	伸び	下回る	マイナス金利
広げる	上回る	日銀	日銀
目立つ	方向性	原油価格	据え置く
割れ	欠ける	日経平均株価	指摘
振れる	流れ	反応	必要性
発言	休場	理事会	原油安
TOPIC2 ($\bar{\eta}=0.339$)		TOPIC3 ($\bar{\eta}=0.685$)	
SENTIMENT0	SENTIMENT1	SENTIMENT0	SENTIMENT1
英国	英国	利上げ	拡大
メイ英首相	国民投票	市場	市場
イタリア	合意	下落	f o m c
メイ首相	報道	トランプ氏	利上げ
e u	離脱	出口戦略	e c b
世論調査	世論調査	来年	回復
総選挙	e u	f o m c	3回
e u 離脱	e u 離脱	全体的	雰囲気
保守党	問う	経済政策	言及
米国	実施	通過	原油安

4.5.2 為替予想の結果

本実験では、表 24 で示したようにトピックモデルの違いによる特徴量の違い、予測モデルの違い、予測対象の通貨ペアの違い、というように複数の組み合わせにより予測精度の結果が異なってくる。予測モデルの違い、特徴量による違い、通貨ペアによる違いという順番で結果を分析していく。

予測モデルの違い

表 32 に、予測モデルごとの予測精度を示す。なお、32 通貨ペア (表 22) および予測に使用する特徴量 (表 25) についてすべての組み合わせの予測精度を求め、その平均値、および標準偏差を求めている。なおベースラインとして、ランダムに予測を行った場合の予測精度を併記している。

表 32: 予測モデルごとの平均予測精度

	学習期間				テスト期間			
	Accuracy (%)		F 値		Accuracy (%)		F 値	
予測モデル	mean	std	mean	std	mean	std	mean	std
ランダム	50.3	1.0	0.510	0.015	50.2	1.3	0.510	0.017
LR	56.3	1.1	0.587	0.052	56.0	2.8	0.590	0.072
LSTM	52.3	1.1	0.543	0.155	50.6	2.4	0.478	0.234
MLP	55.3	2.9	0.580	0.104	51.5	1.9	0.554	0.108
SVM	55.9	1.0	0.587	0.081	55.0	2.6	0.584	0.107

表 32 の結果より、テスト期間における Accuracy は、LR モデルが最も高く、続いて SVM モデル、MLP モデル、LSTM モデルの順となった。LSTM モデルについては、Accuracy は、ランダムに予測したもののと同程度であった。また、F 値についても、LR モデルが最も高く、続いて SVM モデル、MLP モデル、LSTM モデルの順となった。ニューラルネットワーク型のモデルよりも機械学習型のモデルの方が予測精度がよいと言える。これは、ニューラルネットワーク型のモデルである MLP モデルと LSTM モデルが学習期間に過学習をしてしまったと考えられる。

テキストの特徴量による違い

続いて、トピックモデルごとに抽出したテキストの特徴量による違いについて、表 32 にテキストの特徴量ごとの予測精度を示す。なお、予測モデルについては、予測精度の高い LR モデルと SVM モデルに限定し、32 通貨ペア (表 22) の平均値、標準偏差を求めた。なお、特徴量のベンチマークとして、

- 数値データのみを特徴量とした場合

- 数値データに加え、BoW形式の為替概況ニュースに対して、主成分分析 (PCA) を行い、各主成分を weight を特徴量とした場合

の2つの特徴量での予測結果も併記している。

表 33: 特徴量、モデルごとの予測精度

予測モデル	特徴量	学習期間				テスト期間			
		Accuracy(%)		F 値		Accuracy(%)		F 値	
		mean	std	mean	std	mean	std	mean	std
LR	数値データのみ	53.1	1.3	0.592	0.108	51.2	2.4	0.586	0.115
	PCA	55.5	1.4	0.580	0.063	53.1	2.7	0.570	0.073
	LDA	56.4	1.2	0.587	0.051	55.5	2.7	0.583	0.077
	sLDA	56.3	1.1	0.587	0.051	55.7	2.8	0.588	0.079
	JST	56.3	1.1	0.586	0.052	56.0	2.8	0.593	0.066
	sJST	56.1	1.2	0.586	0.055	56.7	2.9	0.598	0.070
	SVM	数値データのみ	52.5	1.1	0.568	0.214	51.1	2.3	0.554
PCA		54.9	1.4	0.580	0.111	52.7	2.5	0.568	0.120
LDA		56.0	1.0	0.589	0.078	54.4	2.5	0.575	0.110
sLDA		55.9	1.1	0.589	0.079	54.8	2.7	0.582	0.112
JST		55.9	1.0	0.586	0.082	55.2	2.6	0.587	0.098
sJST		55.6	1.1	0.586	0.090	55.4	2.7	0.591	0.111
平均		数値データのみ	52.8	1.2	0.580	0.161	51.2	2.4	0.570
	PCA	55.2	1.4	0.580	0.087	52.9	2.6	0.569	0.096
	LDA	56.2	1.1	0.588	0.065	55.0	2.6	0.579	0.094
	sLDA	56.1	1.1	0.588	0.065	55.2	2.7	0.585	0.095
	JST	56.1	1.1	0.586	0.067	55.6	2.7	0.590	0.082
	sJST	55.8	1.1	0.586	0.073	56.0	2.8	0.595	0.090

表 32 の結果より、LR、SVM の両方のモデルのテスト期間における Accuracy の平均値は、各トピックモデルを特徴量とした場合の方が、ベースラインである数値のみである場合と PCA の場合に比べて高いことがわかる。また、トピックモデル間では、提案モデルである sJST が最も高く、続いて、JST、sLDA、LDA の順番で高かった。一方、F 値については、同様にベースラインである数値のみである

場合と PCA の場合に比べて、各トピックモデルを特徴量とした場合の方が高く、トピックモデル間では、提案モデルである sJST が最も高く、続いて、JST、sLDA、LDA の順番で高かった。

なお、ベースライン間の数値のみの場合と数値データに PCA を加えた場合とで比較した場合には、F 値についてはほぼ同程度に対して、Accuracy については、数値データに PCA を加えた場合の方が高い。PCA による特徴量がある程度予測力を向上させるが、各トピックモデルの方がより高い予測力を持つ特徴量を抽出することが出来ていると言える。

各トピックモデル間において、予測精度の差が有意か否かを分析するため、Accuracy、F 値に対して、各トピックモデルの違いによる精度の違いに対する t 検定を実施した。表 34 に t 検定の結果を記す。

表 34: トピックモデルの違いによる精度の違いに対する t 検定

評価指標	特徴量	mean	std	平均値の差	t 値	p 値
Accuracy (%)	LDA	55.0	2.6	0.3	-1.50	0.143
	sLDA	55.2	2.7			
	LDA	55.0	2.6	0.7	-3.84	0.001
	JST	55.6	2.7			
	sLDA	55.2	2.7	0.8	-3.65	0.017
	sJST	56.0	2.8			
	JST	55.6	2.7	0.4	-0.91	0.369
	sJST	56.0	2.8			
	LDA	55.0	2.6	1.1	-4.76	0.00004
	sJST	56.0	2.8			
F 値	LDA	0.579	0.094	0.006	-1.15	0.259
	sLDA	0.585	0.095			
	LDA	0.579	0.094	0.011	-2.85	0.008
	JST	0.590	0.082			
	sLDA	0.585	0.095	0.010	-2.14	0.041
	sJST	0.595	0.090			
	JST	0.590	0.082	0.004	-1.20	0.238
	sJST	0.595	0.090			
	LDA	0.579	0.094	0.016	-4.50	0.00009
	sJST	0.595	0.090			

p 値が 0.05 未満で差が有意と認められたものは、Accuracy、F 値の両者ともに、LDA と JST における差、sLDA と sJST における差、LDA と sJST における差である。一方で、LDA と sLDA における差、および JST と sJST における差は有意であるとは言えない。トピックのみの潜在変数を持つ LDA から拡張について、センチメントを新たな潜在変数として加える拡張の場合には、為替の方向性予測に有意な影響を与える。一方で、教師信号を加える拡張については、為替の方向性予測に有意な影響を与えるとは言えない。センチメントを加えることにより、為替の方向性予測精度が向上することは、これまでの先行研究においてセンチメントを特徴量とした金融市場予測の精度が高いことから整合

的であると言える (Bollen et al., 2011b; Schumaker et al., 2012)。教師信号として、市場変動の大きさを加えることで、市場変動ごとのより精緻なトピック分類が行われ、トピック分類の精度が上がり、それが将来の方向性予測にもプラスの影響を与えることを期待していたが、為替の方向性予測の精度向上に有意ではないという結果となった。このことの原因として、以下が考えられる。教師信号として、市場変動の大きさであるボラティリティを加えているため、絶対値としての情報しかなく、方向性の予測には影響はしない。また、過去の3期間の価格データをすでに特徴量として、加えているため、市場変動の大きさであるボラティリティと情報が類似しているため、方向性の予測には影響はないと考えられる。

通貨ペアごとの違い

予測対象である通貨ペアの種類により、予測精度の違いにどのような差が生じるかについて、分析を行った。

これまでの分析結果から為替概況ニュースからトピックモデルにより抽出した特徴量を加えた場合、数値データのみを特徴量とした場合より予測精度が向上することがわかった。どの通貨がより、精度向上したかを検証するために、各通貨ペアの取引量を国際決済銀行 (BIS) が公表しているデータより取得し、数値データのみを特徴量とした場合からの Accuracy からの精度向上値と比較を行った。なお、取得できた取引量のデータ制限から、通貨ペアは予測対象の32通貨ペアのうち15通貨ペアを対象とする。また、Accuracy からの精度向上値は LDA、sLDA、JST、sJST の精度の平均値から価格データのみを特徴量とした場合の精度の差を取っている。以下の図 53 を結果を示す。




図 53: 各通貨ペアの取引量とトピックモデルによる特徴量に起因する Accuracy の精度向上

図 53 の結果から、通貨ペアの取引量に比例して、トピックモデルで抽出したテキストの特徴量を加えたことによる予測精度の向上幅が大きいことがわかる。ユーロ/米ドル、豪ドル/米ドル、米ドル/日本円、ユーロ/英国ポンド、ユーロ/日本円等の取引量の多いメジャー通貨ペアに対して、大きく精度向上し、ユーロ/ハンガリーフォリント、ユーロ/ノルウェークローネ、ユーロ/ポーランドズウォティ等の取引量の少ないマイナー通貨を含む通貨ペアに対しては、精度向上が少ない。このことは、為替概況ニュースがメジャー通貨間の為替の決定要因に関するマクロ経済の記述が多く、マイナー通貨に相当する国におけるマクロ経済の記述が少ないからであると考えられる。

4.6 本章のまとめ

本章では、拡張したトピックモデルを用いてニューステキストから抽出した特徴量と数値データを組み合わせて、複数の予測モデルを用いて為替市場における価格変動の方向性予測を行った。テキストとしては、東京、ロンドン、ニューヨークの各為替市場の主要ニュースをまとめた為替概況ニュースを使用した。トピックモデルとして、既存モデルである LDA、sLDA、JST に加え、新たに sJST を提案した。sJST は、既存の sLDA と JST を組み合わせたモデルであり、教師信号の変数を持つ sLDA

の特徴と、潜在変数としてトピックとセンチメントの両方の変数を持つ JST モデルの特徴の両方が加味されたモデルである。テキストから拡張したトピックモデルを用いて為替の決定要因となるマクロ経済ファクターやそれに対するポジネガを示すセンチメントを抽出し、特徴量とし、32 通貨ペアの価格変動の方向性予測を行った結果、提案モデルである sJST が最も精度が高いという結果となった。各トピックモデルにより抽出したテキストの特徴量の差に起因する予測精度の違いについて t 検定を行った結果、センチメントを潜在変数と加えるトピックモデル拡張は、予測精度の向上に寄与することが有意に認められたが、価格変動を教師信号として加えるトピックモデル拡張は、予測精度の向上に寄与することは有意に認められなかった。また、通貨ペア単位での予測精度の違いから、トピックモデルによるテキストの特徴量を加えることにより、取引量の少ない通貨ペアより取引量の多いメジャー通貨の方が、より多く予測精度が向上した。

第5章 結論

本論文では、金融分野において、「非構造化データ」である金融テキストを使用し、今まで投資家が定性的にしか扱えなかった日本銀行の経済や物価に対する個別のセンチメント(第2章)、マクロ経済の先行きに対する不確かさ(第3章)をトピックモデルを用いて定量的に計測し、それを指数として構築した。加えて、金融テキストデータの資産運用への活用として、金融テキストから為替の決定要因となるマクロ経済要因、およびそれに対する投資家のセンチメントを抽出し、為替市場における短期間の価格変動の方向性予想を行った(第3章)。

本論文の学術的な貢献は、投資家にとって今まで定量的な活用が難しかった「非構造化データ」である金融テキストを、必要な情報量を落とすことなく解釈しやすいトピックごとの構造化データへ変換し、指数として定量化する手法を提案し、その指数を用いて、マクロ経済の分析や資産運用への応用を行ったことにある。また、各章それぞれにおいて、使用する金融テキストの特性や分析の目的に合わせて、使用するトピックモデルを拡張し、既存の手法に対してその有意性について示している。多くの金融テキストが未だに活用されていない中、本論文で示した拡張したトピックモデルを適応し、投資家にとって新たな経済分析や資産運用手法の開発に繋げることが可能である。各章の具体的な成果は以下ようになる。

第2章：中央銀行の経済や物価に対する個別のセンチメントの可視化

日本銀行のマクロ経済見通しを各マクロ経済要素ごとに定量的に把握するため、日本銀行の金融経済月報に対して、深層学習モデルを用いたセンチメントの付与とトピックモデルによるトピック分類を組み合わせたモデルにより、「個人消費」、「企業収益」、「資金供給」、「物価」等の12個の各マクロ経済の要因ごとの日本銀行のセンチメント指数を構築した。

構築した各マクロ経済の要因ごとのセンチメント指数の時系列推移と日本銀行の金融政策との比較から、各トピックのセンチメントの変化と金融政策への影響について論じた。また、多くのマクロ経済指標と各センチメント指数との間に正の相関がある中、日銀の物価に対するセンチメントは、金融政策の特性上、マクロ経済指標とは連動しないことが確認した。

第3章：拡張したトピックモデルによる不確実性指数の構築

マクロ経済の先行きの不確実性をその要因ごとに定量的に把握するため、不確実性の代理変数である市場の将来変動を示す VIX 指数を教師信号としてモデル内に組み込んだトピックモデルを提案し、要因ごとの不確実性指数を構築した。拡張したトピックモデルを用いたことで各要因の不確実性がどの程度市場変動に影響を及ぼすかを同時に推定することができ、教師信号の推定値の大きさに比例して、実際の各市場指数の変動との相関が大きいことを確認した。また、先行研究の手法との比較を通じて、提案モデルの方が、より不確実性の要因を特定したノイズが少ない指数を構築することができると示した。マクロ経済指標への影響分析において、日本の金融政策に起因する不確実性指数の変動は、日本の鉱工業生産指数を押し下げることを確認した。

第4章：市場センチメント指数を用いた為替市場変動の方向性の予想

為替のニューステキストから拡張したトピックモデルを用いて為替の決定要因となるマクロ経済ファクターやそれに対するポジネガを示すセンチメントを抽出し、それを特徴量として数値データを合わせて、為替市場における価格変動の方向性予測を行った。潜在変数としてトピックとセンチメントの両方の変数を持ち、加えて、教師信号の変数を持つ sJST モデルを提案し、32 通貨ペアの価格変動の方向性予測を行った結果、最も精度が高いという結果となった。モデルの差に起因する分析を行い、センチメントを潜在変数と加えるトピックモデル拡張のみ、予測精度の向上に寄与することが有意に認められた。使用するテキストの内容の特性から、通貨ペア間では、取引量の少ない通貨ペアより取引量の多いメジャー通貨の方が、より多く予測精度が向上した。

以上のように、金融政策、マクロ経済、金融市場など複数の領域において、拡張したトピックモデルを活用した金融テキストの指数化を通じて、定量的に把握できなかったマクロ経済要因をより細かい粒度で資産運用への応用することができると言える。また、金融テキストが数値データと関係性のある場合、金融テキストに投資家センチメントが含まれている場合などにおいて、トピックモデルを拡張することで、指数の精緻化や予測精度の向上等のメリットを示すことができた。

本研究で構築した指数は、金融分野の様々な分野で利用することができる。例えば、経済アナリストが、中央銀行の経済や物価に対する個別のセンチメント指数を用いて経済レポートを執筆することや、ファンドマネージャーが、要因ごとの不確実性指数を用いて、ポートフォリオのヘッジ戦略を構築したりすることなどが挙げられる。また、本論文で論じてきた指数化の手法は、汎用性が高く、中央銀行に関するセンチメント指数や不確実性指数以外にも、多くの金融テキストから指数を構築することに用いることができる手法である。例えば、決算短信や個々の企業に関するニュースなどの公開

されたテキスト情報に対して、企業の決算数値や株価などを教師信号とし、本論文で論じてきた指数化の手法を適用することで、業績や株価変動に連動した個別企業に関するトピック別のセンチメント指数を構築することができる。定量化した指数を利用して、個別株のアナリストが決算予想に活用することやファンドマネージャーが銘柄選択を行う際に利用することができる。また、今まで活用されることが少ない金融機関の社内テキストにも本手法を用いることができる。例えば、金融機関が貸付融資する際の対象企業について記述したテキストとその信用ランクに対して、本論文で論じてきた指数化の手法を適用することが考えられる。これまで定性的な判断にしか用いられなかった融資先企業のテキスト情報から定量的な特徴量を抽出し、それをを用いた新たな信用評価モデルを構築するも考えられる。個別株のアナリストが決算短信などの膨大な企業に関する公開テキスト情報に、本論文で論じてきた指数化の手法を適用し抽出した特徴量を用いて、業績予想に活用することも可能だ。

今後、金融テキストはさらに増大し、機械学習、深層学習などを資産運用の分野へ活用の流れが加速していく中において、テキストデータの活用の可能性はさらに増すだろう。膨大かつ非構造化データである金融テキストデータを効率よく、かつ人間の解釈可能な形に定量化、指数化することは、資産運用モデルの構築時においても、パフォーマンスの評価時においても非常に重要になっている。本研究では、金融政策、マクロ経済、金融市場など複数の領域において、トピックモデルによる金融テキストの指数化がマクロ経済分析や資産運用モデル構築へ有用であることを示した。

付録 A 不確実性指数の可視化ツール

本セクションでは、これまで解説してきた第3章における不確実性指数について、投資家が利用できるようにシステム実装を行ったので、それについて解説する。具体的には、ロイターニュースを基にした国別の不確実性指数のウェブアプリケーションを構築した。ウェブアプリケーションの構成、画面の解説、およびユースケースの順番で解説を行う。

A.1 全体構成図

以下に全体のシステム構成図を示す。Docker を使い、分析、データベース、WEB アプリの3つの機能をそれぞれ別のコンテナ上で稼働する形となっている。

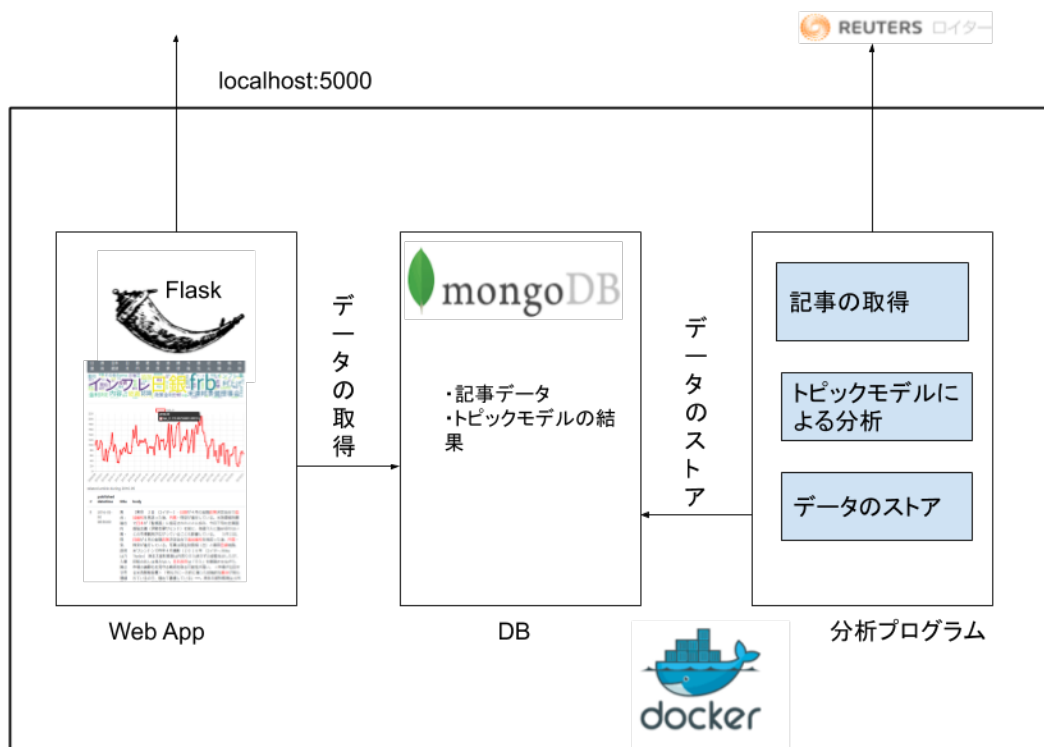


図 54: システム構成図

A.1.1 分析

分析を行うコンテナ内では3つの役割を担っている。

- 記事データの取得: 定期的にロイターの日本語ページの経済カテゴリー下にある記事を取得する。
- トピックモデルの実施: 新たに取得した記事と過去の記事を合わせた全記事データに対して、トピックモデルを適応し、不確実性指数の構築を行う。
- データベースへのデータ格納 (記事データ、およびトピックモデルの実行結果)

A.1.2 データベース

データベースはドキュメント指向データベースである MongoDB を用いており、記事内容、およびトピックモデルで算出した各ドキュメントのトピックウェイト、および各トピックの単語ウェイトを保持している。

A.1.3 WEB アプリ

Python 用の軽量フレームワークである Flask を用いて、Web アプリを構築しており、ユーザーのインプットに従って、各トピックの単語ウェイト、およびそのトピックの時系列推移を示すことができる。加えて、日付をしてすることで、その日付の対象トピックの記事を表示することが可能である。

A.2 フロント画面

フロントの画面は以下の5つのコンポーネントからなる。


- 【ユーザー入力】トピックの選択
- 【ユーザー入力】日付の指定
- 【システム出力】トピックの関連単語
- 【システム出力】トピックの時系列推移
- 【システム出力】記事の描写

TOPIC:

DATE:

Submit

TOPIC 0



related article during 2010-09

#	published datetime	title	body
1	2010-09-01	市場は民	9月1日、民主党代表選で菅首相（右）と小沢前幹事長（左）の一騎打ちが確定したが、市場関係者が現時点でシナリオを描く

図 55: フロント画面

A.2.1 トピックの選択

画面に表示される対象のトピック（不確実性指数のカテゴリー）の選択できる。日本、米国、中国、欧州のいずれかの不確実性指数を選択することが可能である。



TOPIC:

0 ①トピックの選択 ▼

DATE:

2010-09 ▼

Submit

図 56: トピックの選択

A.2.2 トピックの関連単語

選択されたトピック（不確実性指数）と関連する単語を上位 15 をリストとして表示するとともに、Word Cloud としてもその下に配置している。関連度大きさは潜在トピック z における各単語の出現確率をもとに決められており、その大きさによって Word Cloud のフォントの大きさが変わる。大きい単語ほど関連度が大きいことを示す。

TOPIC 0

トピックの関連単語の出力




図 57: トピックの関連単語の出力

A.2.3 トピックの時系列推移

選択されたトピック（不確実性指数）の時系列推移の表示を表示している。横軸が日付で、縦軸が不確実性の強さを示している。不確実性の強さは、前章で示した通り時系列の平均が 100 となるように正規化されている。

TOPIC 0




図 58: トピックの時系列推移の出力

A.2.4 日付の指定

不確実性の強さの描写に加えて、該当する不確実性がどの記事をもとに生成されたものなのか、を知るため記事の表示させる機能も実装している。月次の日付を選択することができる。

TOPIC:

0

DATE:

2010-09 日付の選択

Submit





図 59: 日付の選択

A.2.5 記事の描写

選択されたトピック、および選択された日付をもとに月次の記事を表示させることができる。なお、記事は各トピックの出現確率の内、選択したトピックが最も大きい記事のみを表示させている。赤くハイライトされた文字はそのトピックに関連する単語であることを示す。




related article during 2016-05

#	published datetime	title	body	記事の描写
1	2016-05-02 08:56:00	焦点：進む高・株安、政府は介入意を識させ市場鎮	〔東京 2日 ロイター〕 - 日銀が4月の金融政策決定会合で追加緩和を見送った後、円高・株安が進行している。米為替報告書で日本が「監視国」に指定されたことに加え、今月下旬の主要国首脳会議（伊勢志摩サミット）を前に、為替介入に踏み切れないとの市場観測が広がっていることも影響している。5月2日、日銀が4月の金融政策決定会合で追加緩和を見送った後、円高・株安が進行している。写真は麻生財務相（左）と黒田日銀総裁、米ワシントンで昨年4月撮影（2016年 ロイター/Mike Theiler）麻生太郎財務相は円売り介入辞さずの姿勢を示したが、反転の兆しは見えない。日本政府は「介入」を意識させながら、市場の鎮静化を見守る戦術を取る可能性が高い。〈市場が注目する米為替報告書〉「明らかに一方的に偏った投機的な動きが見られているので、極めて憂慮している」――。麻生太郎財務相は4月	

図 60: 記事の描写

A.3 ユースケース

当アプリケーションのユースケースを示す。まず、トピックとして日本の不確実性指数を選択し、Submit ボタンを押す。日本の不確実性指数に関連するキーワードとしては、「日銀」、「物価」、「政府」、「日本経済」などの日本を言及する単語がトピックの関連単語として表示される。次に日本の不確実性指数の推移を見ると、2016年05月のピークがあることがわかる。その詳細としてどのような事象の不確実性が高まっていたのかを知りたい場合、その日付の記事の内容を表示させると原因を知ることができる。2016年05月を選択し、再度 Submit ボタンを押すと、2016年05月に日本の不確実性について言及した記事が下段に表示される。記事を参考にすると、2016年05月の不確実性の高まりは日本銀行が追加緩和策を見送ったことにより、市場参加者が今後の金融政策に対する不確実性を懸念したため不確実性が高まったことがわかる。



related article during 2016-05

#	published datetime	title	body
1	2016-05-02 08:56:00	焦点：進む円高・株安、政府は介入意識させ市場鎮静化	<p>[東京 2日 ロイター] - 日銀が4月の金融政策決定会合で追加緩和を見送った後、円高・株安が進行している。米為替報告書で日本が「監視国」に指定されたことに加え、今月下旬の主要国首脳会議（伊勢志摩サミット）を前に、為替介入に踏み切れないとの市場観測が広がっていることも影響している。</p> <p>5月2日、日銀が4月の金融政策決定会合で追加緩和を見送った後、円高・株安、株安が進行している。写真は麻生財務相（左）と黒田日銀総裁、米ワシントンで昨年4月撮影（2016年 ロイター/Mike Theiler）麻生太郎財務相は円売り介入辞さずの姿勢を示したが、反転の兆しは見えない。日本政府は「介入」を意識させながら、市場の鎮静化を見守る戦術を取る可能性が高い。〈市場が注目する米為替報告書〉「明らかに一方的に偏った投機的な動きが見られているので、極めて憂慮している」――。麻生太郎財務相は4月</p>

図 61: 使用例

文献

- Arbatli, E. C. (2017). Policy uncertainty in Japan. Tech. rep. 17, International Monetary Fund.
- Azqueta-Gavaldón, A. (2017a). Developing news-based Economic Policy Uncertainty index with unsupervised machine learning. *Economics Letters*, **158**, 47–50.
- Azqueta-Gavaldon, A. (2017b). Financial investment and economic policy uncertainty in the UK. *ACM International Conference Proceeding Series*.
- Bloom, N. (2014). Fluctuations in uncertainty. *Journal of Economic Perspectives*, **28** (2), 153–176.
- Hamid, A. (2015). Forecasting volatility with empirical similarity and Google Trends. *Journal of economic behavior & organization*, **117**, 62–81.
- Hüning, H. (2017). Asset market response to monetary policy news from SNB press releases. *The North American Journal of Economics and Finance*, **40**, 160–177.
- Kim, K.-j. (2003). Financial time series forecasting using support vector machines. *Neurocomputing*, **55** (1-2), 307–319.
- Knight, F. H. (1921). Risk, uncertainty and profit.. Tech. rep..
- Rauh, C. (2019). Measuring Uncertainty at the Regional Level Using Newspaper Text..
- Tetlock, P. C. (2007). Giving content to investor sentiment: The role of media in the stock market. *The Journal of finance*, **62** (3), 1139–1168.
- 白井さゆり (2014). 「日本銀行の金融緩和とコミュニケーション政策コロンビア大学における講演の邦訳」 ..
- チェソンウク (2017). 「TRMI データを使ったレジームの分類」 ..
- 黒坂佳央 (2017). 「2016 年における円ドルレートの変動原因について一日経記事アプローチ」 ..

- 黒木祥弘 (2001). 「論説」 1990 年代における日本の金融政策: 金利先物市場の情報を用いた実証分析」. 『大阪府立大学経済研究』, **47** (1), 1–38.
- 三井住友信託銀行マーケット事業 (2016). 『投資家のための金融マーケット予測ハンドブック』. NHK 出版.
- Antweiler, W., Frank, M. Z. (2004). American Finance Association Is All That Talk Just Noise ? The Information Content of Internet Stock Message Boards Published by : Wiley for the American Finance Association Stable URL : <http://www.jstor.org/stable/3694736> Your use of the JSTOR archive in. *The Journal of Finance*, **59** (3), 1259–1294.
- Bachmann, R., Elstner, S., Sims, E. R. (2013). Uncertainty and economic activity. *American economic journal*, **5** (2), 217–249.
- Baker, S. R., Bloom, N., Davis, S. J. (2016). Measuring economic policy uncertainty..
- Baker, S. R., Bloom, N., Davis, S. J., Kost, K. J. (2019). Policy news and stock market volatility. Tech. rep., National Bureau of Economic Research.
- Berger, H., Ehrmann, M., Fratzscher, M. (2011). Monetary policy in the media. *Journal of Money, Credit and Banking*, **43** (4), 689–709.
- Blei, D. M., Ng, A. Y., Jordan, M. I. (2003). Latent Dirichlet allocation. *Journal of Machine Learning Research*, **3** (4-5), 993–1022.
- Blinder, A. S., Ehrmann, M., Fratzscher, M., De Haan, J., Jansen, D.-J. (2008). Central bank communication and monetary policy: A survey of theory and evidence. *Journal of Economic Literature*, **46** (4), 910–45.
- Bollen, J., Mao, H., Zeng, X. (2011a). Twitter mood predicts the stock market. *Journal of computational science*, **2** (1), 1–8.
- Bollen, J., Mao, H., Zeng, X. (2011b). Twitter mood predicts the stock market. *Journal of Computational Science*, **2** (1), 1–8.
- Brogaard, J., Detzel, A. (2015). The asset-pricing implications of government economic policy uncertainty. *Management Science*, **61** (1), 3–18.

- Campbell, J. R., Evans, C. L., Fisher, J. D., Justiniano, A., Calomiris, C. W., Woodford, M. (2012). Macroeconomic effects of federal reserve forward guidance [with comments and discussion]. *Brookings Papers on Economic Activity*, 1–80.
- Castelnuovo, E., Tran, T. D. (2017a). Google it up! a google trends-based uncertainty index for the united states and australia. *Economics Letters*, **161**, 149–153.
- Chuliá, H., Guillén, M., Uribe, J. M. (2017b). Measuring uncertainty in the stock market. *International Review of Economics & Finance*, **48**, 18–33.
- Cieslak, A., Vissing-Jorgensen, A. (2020). The economics of the Fed put. Tech. rep., National Bureau of Economic Research.
- Ding, X., Zhang, Y., Liu, T., Duan, J. (2015). Deep Learning for Event-driven Stock Prediction. In *Proceedings of the 24th International Conference on Artificial Intelligence, IJCAI'15*, pp. 2327–2333. AAAI Press.
- Ehrmann, M., Talmi, J. (2019). Starting from a blank page? Semantic similarity in central bank communication and market volatility. *Journal of Monetary Economics*.
- Fernández-Villaverde, J., Guerrón-Quintana, P., Kuester, K., Rubio-Ramírez, J. (2015). Fiscal volatility shocks and economic activity. *American Economic Review*, **105** (11), 3352–3384.
- Fischer, T., Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, **270** (2), 654–669.
- Galardo, M., Guerrieri, C. (2017). The Effects of Central Bank's Verbal Guidance: Evidence from the ECB. *Bank of Italy Temi di Discussione (Working Paper) No*, **1129**.
- Gertler, P., Horvath, R. (2018). Central bank communication and financial markets: New high-frequency evidence. *Journal of Financial Stability*, **36**, 336–345.
- Graves, A., Mohamed, A.-r., Hinton, G. (2013). Speech recognition with deep recurrent neural networks. In *Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on*, pp. 6645–6649. IEEE.
- Gulen, H., Ion, M. (2016a). Policy uncertainty and corporate investment. *Review of Financial Studies*, **29** (3), 523–564.

- Hansen, S., McMahon, M. (2016b). Shocking language: Understanding the macroeconomic effects of central bank communication. *Journal of International Economics*, **99**, S114–S133.
- Heston, S. L., Sinha, N. R. (2013). News versus Sentiment: Comparing Textual Processing Approaches for Predicting Stock Returns. *SSRN Electronic Journal*.
- Hirano, M., Sakaji, H., Kimura, S., Izumi, K., Matsushima, H., Nagao, S., Kato, A. (2019). Related Stocks Selection with Data Collaboration Using Text Mining. *Information*, **10** (3), 102.
- Hochreiter, S., Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, **9** (8), 1735–1780.
- Hubert, P., Fabien, L. (2017). Central bank sentiment and policy expectations..
- Husted, L., Rogers, J., Sun, B. (2019a). Monetary policy uncertainty. *Journal of Monetary Economics*.
- Izumi, K., Sakaji, H. (2019b). Economic Causal-Chain Search using Text Mining Technology. In *Proceedings of the First Workshop on Financial Technology and Natural Language Processing*, pp. 61–65.
- Jegadeesh, N., Wu, D. A. (2017). Deciphering FedSpeak: The information content of FOMC meetings. *Available at SSRN 2939937*.
- Jin, F., Self, N., Saraf, P., Butler, P., Wang, W., Ramakrishnan, N. (2013). Forex-foreteller: Currency trend modeling using news articles. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Part F1288*, 1470–1473.
- Jin, X., Chen, Z., Yang, X. (2019a). Economic policy uncertainty and stock price crash risk. *Accounting and Finance*, **58** (5), 1291–1318.
- Kawamura, K., Kobashi, Y., Shizume, M., Ueda, K. (2019b). 「Strategic central bank communication: Discourse analysis of the Bank of Japan ’ s Monthly Report」 . *Journal of Economic Dynamics and Control*, **100**, 230–250.
- Lin, C., He, Y. (2009). Joint sentiment/topic model for sentiment analysis. *International Conference on Information and Knowledge Management, Proceedings*, 375–384.

- Mahajan, A., Dey, L., Haque, S. M. (2008). Mining financial news for major events and their impacts on the market. *Proceedings - 2008 IEEE/WIC/ACM International Conference on Web Intelligence, WI 2008*, **1**, 423–426.
- Malkiel, B. G., Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, **25** (2), 383–417.
- Manela, A., Moreira, A. (2017). News implied volatility and disaster concerns. *Journal of Financial Economics*, **123** (1), 137–162.
- Mcauliffe, J. D., Blei, D. M. (2008). Supervised topic models. In *Advances in neural information processing systems*, pp. 121–128.
- Murakami, S., Watanabe, A., Miyazawa, A., Goshima, K., Yanase, T., Takamura, H., Miyao, Y. (2017). Learning to Generate Market Comments from Stock Prices. In *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pp. 1374–1384 Vancouver, Canada. Association for Computational Linguistics.
- Nguyen, T. H., Shirai, K., Velcin, J. (2015). Sentiment analysis on social media for stock movement prediction. *Expert Systems with Applications*, **42** (24), 9603–9611.
- Pástor, c., Veronesi, P. (2013). Political uncertainty and risk premia. *Journal of Financial Economics*, **110** (3), 520–545.
- Peng, Y., Jiang, H. (2016). Leverage Financial News to Predict Stock Price Movements Using Word Embeddings and Deep Neural Networks.. pp. 374–379.
- Peramunetilleke, D., Wong, R. (2002). Currency exchange rate forecasting from news headlines. *Australian Computer Science Communications*, **24** (2), 131–139.
- Picault, M., Renault, T. (2017). Words are not all created equal: A new measure of ECB communication. *Journal of International Money and Finance*, **79**, 136–156.
- Saltzman, B., Yung, J. (2018). A machine learning approach to identifying different types of uncertainty. *Economics Letters*, **171**, 58–62.
- Schmeling, M., Wagner, C. (2019). Does central bank tone move asset prices?. *Available at SSRN 2629978*.

- Schumaker, R. P., Zhang, Y., Huang, C. N., Chen, H. (2012). Evaluating sentiment in financial news articles. *Decision Support Systems*, **53** (3), 458–464.
- Si, J., Mukherjee, A., Liu, B., Li, Q., Li, H., Deng, X. (2013). Exploiting topic based twitter sentiment for stock prediction. *ACL 2013 - 51st Annual Meeting of the Association for Computational Linguistics, Proceedings of the Conference*, **2**, 24–29.
- Tobback, E., Naudts, H., Daelemans, W., de Fortuny, E. J., Martens, D. (2018). Belgian economic policy uncertainty index: Improvement through text mining. *International Journal of Forecasting*, **34** (2), 355–365.
- Zuo, Y., Kita, E. (2012). Stock price forecast using Bayesian network. *Expert Systems with Applications*, **39** (8), 6729–6737.
- 翁邦雄, 白塚重典 (2003). 「コミットメントが期待形成に与える効果: 時間軸効果の実証的検討」. 『金融研究』, **22** (4), 255–292.
- 和泉潔, 後藤卓, 松井藤五郎 (2010). 「テキスト情報による金融市場変動の要因分析」. 『人工知能学会論文誌』, **25** (3), 383–387.
- 近藤浩史, 與五澤守, 成瀬道紀, 森正和 (2019). 「金融機関のテキストデータを活用した景気センチメントの計測」. 『人工知能学会全国大会論文集』, **JSAI2019**, 1P2J1302–1P2J1302.
- 酒井浩之, 西沢裕子, 松並祥吾, 坂地泰紀 (2015). 「企業の決算短信 PDF からの業績要因の抽出」. 『人工知能学会論文誌』, **30** (1), 172–182.
- 岡田克彦, 羽室行信 (2011). 「相場の感情とその変動–自然言語処理で測定するマーケットセンチメントとボラティリティ(特集 ボラティリティと証券投資)」. 『証券アナリストジャーナル』, **49** (8), 37–48.
- 風戸正行, 黒崎哲夫, 五島圭一 (2019). 「日本銀行による景気判断のトーン分析」. 『金融研究所ディスカッション・ペーパー』, **No.2019-J-16**.
- 水門善之, 勇大地 (2017). 「人工知能を用いた日銀総裁会見動画の分析と金融政策決定に対する示唆」. 『行動経済学』, **10**, S5–S8.
- 磯沼大, 藤野暢, 浮田純平, 村上遥, 浅谷公威, 森純一郎, 坂田一郎, 他 (2016). 「業績変動を考慮した決算短信からの重要文抽出」. 『研究報告自然言語処理 (NL)』, **2016** (6), 1–6.

- 青嶋智久, 中川慧 (2019). 「日本語 BERT モデルを用いた経済テキストデータのセンチメント分析」. 『人工知能学会全国大会論文集』, **JSAI2019**, 4Rin127–4Rin127.
- 中島上智, 服部正純 (2010). 「新日銀法 10 年間における情報発信の影響に関する一考察」. 『金融研究』, **29** (2), 1–26.
- 岩崎有基, 松下光範, 他 (2018). 「予想材料に基づく為替の動向情報分析を目的としたニュース記事分類手法」. *SIG-AM*, **20** (01), 1–8.
- 山本裕樹, 松尾豊 (2016). 「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』, **2016**, 3L3OS16a2–3L3OS16a2.
- 参木裕之, 北野道春, 渡部裕晃 (2018). 「Self-Attentive-LSTM への順序ロジットモデル適用」. 『人工知能学会全国大会論文集』, **JSAI2018**, 1P103–1P103.
- 関雄太, 佐藤広大 (2017). 「人工知能とビッグデータの金融業への活用」. 『野村資本市場研究所』.

謝辞

本研究は東京大学大学院工学系研究科システム創成学専攻における博士論文研究として行ったものです。論文作成にあたりましては、先生方をはじめ様々な方のご協力を賜りました。

指導教員の和泉潔教授には、博士時代の4年間に加え、修士時代にも金融テキストマイニングの共同研究をご一緒させていただく機会があり、実に6年近くご指導を賜りました。当時、SIG-FINの学会で和泉先生の研究発表を拝見し、それに感銘を受けたことがきっかけでした。その後テキストマイニングについて右も左もわからない私の共同研究の申し出にご快諾いただき、今まで長くにわたりご指導いただいたことに本当に感謝しております。日頃の研究室ゼミや、個別に研究の方向性について相談させていただく中で、意義があると思った研究テーマをやり抜く姿勢や、意味のある研究とは何かといった研究の基礎となる考え方を先生に指導していただけました。坂地泰紀特任講師には、ジャーナルの投稿にあたり、多くのアドバイスを頂きました。粘り強く自身の研究の意義を他者にわかりやすく伝えるためにはどのように執筆すればいいのか、多くのアドバイスを頂き、加えて論文の添削など多大なご協力を賜り大変感謝しております。

松島裕康特任助教には、初めての海外の学会であるイタリアの学会で面倒を見ていただき、大変お世話になりました。加えて、研究室ゼミでも多くの有意義なアドバイスを頂き、大変感謝しております。島田尚准教授には研究室ゼミにおきまして、私の発表に対して、的確なご指摘を頂き、まことに感謝申し上げます。

青山先生、陳先生、村上先生、藤井先生には論文の審査にあたり大変お世話になりました。研究の背景や分析方法の部分に関して数多くご指摘をいただいたことで、論文の内容をさらに深めることが出来ました。大変ご多忙にもかかわらず論文の副査を担当していただき、有難うございます。特に陳先生には、修士課程に在籍していた頃にもご指導をいただき、本当に感謝しております。

研究室で同じく社会人をやりながら研究を行っている水門さんには、日頃からエコノミストの見地から研究について議論したり、仕事や家庭との両立について相談したりと、非常に心の支えとなりました。感謝申し上げます。

研究室の皆様にも、研究室ゼミや普段の研究室で研究の話をしたり、他愛のない日常の話をしたりと有意義にかつ楽しく過ごさせてもらいました。大変お世話になりました。特に山本さんには、事務書類をはじめ、研究生活全般でサポートしていただき大変感謝しております。

そして最後に、博士時代の私を支えてくれた家族に最大の感謝の意を表し、本論文の謝辞といたします。