

企業情報センチメントが
株価に及ぼす影響に関する研究

2021年 3月

片山 大輔

企業情報センチメントが
株価に及ぼす影響に関する研究

片山 大輔

システム情報工学研究科
筑波大学

2021年 3月

概要

近年、我が国で資産運用、資産形成がますます重要性を増してきている。その背景として、特に年金の運用についてクローズアップされることが多い。我が国は国民皆年金制度であるものの、少子高齢化に伴う財源不足や、経済成長率の低下により、受給年齢の引き上げや、受給額自体もじわじわと低下してきている。このような環境の中、国民の資産形成の一助となる資産運用業界において、その商品の運用手法の高度化や効率化が重要になっている。近年では情報技術の発展により、資産運用における投資判断に用いられる際の情報量は年々増えてきている。このような大量の情報、すなわちビッグデータへの関心の高まりは、資産運用業界においても例外ではない。資産運用業界におけるビッグデータの最たるものがテキスト情報である。企業の報告書や、ニュースやSNS、アナリストレポートなど多岐にわたる。テキストは理解し投資行動に移すまで時間がかかる。よってこれらを効率的に処理することが求められている。このような背景のもと、本研究では、株価へ影響度が大きいと思われるニュースを、大量であったとしても効率的に扱う手法を検討し、企業毎に関する記事が、企業の株価にどのように影響をあたえるのかを明らかにし、資産運用に活用することを目的に実施したものである。第2章では、自然言語処理技術について、概観したのち、これまでの金融分野におけるテキストマイニングの活用について先行研究を交えて整理する。ニュースからセンチメント情報を抽出する先行研究はいくつかあるものの、市場全体の動きと関連を調査したもの、個別企業であっても特定のイベントを対象としたものが多い。とりわけ我が国における個別企業に関するニュースが個別企業の株価へ与える影響を、長期のデータを利用して検証したものはほとんどないのが現状である。第3章では、ニュースから一般的な極性辞書を用いて、ニュース記事が株価に影響を与えるかどうかを検証した。この章では、つぎの2点を明らかにしている。1点目は、ニュースのセンチメントが株価にどのような影響を与えるのかであり、もう1点は、ニュースのセンチメントを投資戦略に活用できるかである。

1 点目については、3 つの仮説を立て、それぞれ検証を行った。結果、ポジティブ（ネガティブ）なニュースが出たら、その後の当該企業の株価は上昇（下落）するということを明らかにした。加えて 1 面の記事ほど、さらに時価総額が小さい企業ほど、この影響が大きくなることも明らかにしている。これらの結果より、多くの投資家は、ニュースを見てその内容を判断し投資行動を決定しており、さらに 1 面の記事は、2 面以降の記事よりも多くの投資家の目に止まりやすく、一般的に情報が少ないと思われる時価総額の小さい企業ほど、投資家が当該ニュースを投資行動の判断材料とする可能性が他の情報源よりも高いことが要因でとえられる。もう 1 点目については、センチメントスコアの高い銘柄を保有し、低い銘柄を空売りするポートフォリオシミュレーションで高いパフォーマンスを獲得できることを明らかにした。従って、投資家はこの手法を活用することで、効率的に大量のニュースを処理可能となり、さらに超過リターンを獲得できる可能性がある。第 4 章では、個別企業のセンチメント情報をニュースから抽出するにあたって、一般的な極性辞書よりも優れたセンチメント抽出モデルの開発を行った。経済金融分野では専門用語や独特の言い回しが存在し、第 3 章で用いたような一般的な極性辞書では、うまくセンチメントを抽出できない場合もあると考えられる。そこで大量の経済金融分野のテキストとその評価情報からディープラーニングモデルを用いてセンチメントを抽出するモデルを構築した。ニュースから一般的な極性辞書で抽出したセンチメントと、この構築したモデルで抽出したセンチメントを比較したところ、構築したモデルの方がより、センチメントを捉えられていることを明らかにした。具体的には、ポジティブ（ネガティブ）なニュースが出たら、その後の当該企業の株価は上昇するという仮説を立て、株価への影響を調査したところ、係数が統計的にも経済的にも構築したモデルのほうが優れているという結果になった。これは金融や経済に関するニュースには既存の一般的な極性辞書ではとらえられない情報が含まれており、金融経済のデータを利用して構築したモデルのほうがそのような情報をより正確に抽出していると考えられる。第 5 章では、第 4 章で構築した経済金融分野に特化したセンチメント抽出モデルを用いてニュース記事からセンチメントを抽出し、投資戦略を構築し、ポ

ートフォリオシミュレーションで戦略の効果を検証した．具体的には，日次，週次，月次の頻度で個別企業に関するニュースから抽出したセンチメントを個別企業毎に集約し，その大きさを銘柄をバスケットに分けてポートフォリオ構築し投資した場合のパフォーマンスを計算した．結果は，日次頻度での投資戦略のパフォーマンスは高く，週次，月次では全くその効果が得られないことが分かった．これらの結果より，ニュースのセンチメントの株式市場に与える影響は非常に短く，日次以上，週次未満であることを明らかにした．いくつかの先行研究で，日本市場においてセンチメントのマーケット全体へ与える影響は短いことが確認されているが，個別銘柄でも同様の結果となることが明らかにしている．

目次

第 1 章 緒論	1
第 2 章 金融分野における自然言語処理の活用とその課題	4
2.1 はじめに.....	4
2.2 自然言語の情報抽出手法.....	4
2.2.1 言語の解析方法	4
2.2.2 ニューラルネットワークを用いた自然言語処理.....	7
2.3 金融分野における自然言語活用	19
2.3.1 効率的市場仮説と株価予測	19
2.3.2 テキスト情報の株価への影響.....	22
2.4 金融分野における自然言語活用の課題	25
2.5 おわりに	27
第 3 章 極性辞書を用いたセンチメントの抽出および株価への影響	28
3.1 はじめに.....	28
3.2 ニュースと株価の関連性仮説.....	28
3.3 利用するデータ	29
3.3.1 分析ユニバース	29
3.3.2 ニュース情報	31
3.3.3 企業のマーケット情報および財務情報	35
3.3.4 極性辞書	36
3.4 分析条件.....	39
3.4.1 分析対象データ	39
3.4.2 ニュースの極性評価	41
3.5 仮説の検証と結果	44
3.5.1 検証方法	44
3.6 センチメントスコアを活用した投資行動.....	49
3.6.1 ポートフォリオの構築方法	50

3.6.2	パフォーマンス	51
3.7	おわりに	56
第 4 章	金融分野におけるセンチメントモデルの開発	58
4.1	はじめに	58
4.2	センチメントモデルの開発	58
4.2.1	データ	58
4.2.2	モデルの開発	60
4.3	モデルの評価	69
4.3.1	ニュースからのセンチメントの抽出	69
4.3.2	仮説の検証および結果	74
4.4	おわりに	76
第 5 章	ニュースセンチメントの投資戦略への活用	77
5.1	はじめに	77
5.2	金融分野におけるセンチメント測定モデルの構築	77
5.2.1	景気ウォッチャー調査	78
5.2.2	モデル	78
5.3	ニュースのセンチメント	79
5.3.1	分析対象データ	79
5.3.2	ニュースのセンチメント評価	80
5.4	センチメントスコアを活用した投資行動	81
5.4.1	ポートフォリオの構築方法	81
5.4.2	日次投資戦略	82
5.4.3	週次投資戦略	87
5.4.4	月次投資戦略	91
5.5	投資行動のロバストネスチェック	95
5.6	おわりに	102
第 6 章	結論	103
謝辞	107

参考文献	108
関連業績	125

図表目次

図 2-1	ラティス構造の例	6
図 2-2	単純なニューラルネットワーク	9
図 2-3	中間層を含んだニューラルネットワーク	10
図 2-4	word2vec における CBOW と Skip-gram のアーキテクチャ [Mikolov 2013a]より抜粋.....	14
図 2-5	再帰型ニューラルネットワークのイメージ図.....	15
図 2-6	時間方向に展開した再帰型ニューラルネットワークのイメージ図	16
図 2-7	[Kim 2014] における畳み込みニューラルネットワークの概念図	19
図 3-1	トヨタと日本水産のニュース数の月別の推移.....	31
図 3-2	トヨタでの検索例(検索画面).....	33
図 3-3	トヨタでの検索例(見出し)	34
図 3-4	トヨタでの検索例(本文).....	35
図 3-5	月毎のニュースの推移.....	40
図 3-6	センチメントスコアのヒストグラム	43
図 3-7	投資行動の概念図	50
図 3-8	等ウェイトポートフォリオの累積パフォーマンス	54
図 3-9	時価加重ウェイトポートフォリオの累積パフォーマンス	56
図 4-1	モデル開発の概念図	61
図 4-2	サンプル評価の 5 値から 2 値への変換	62
図 4-3	複文から単文へのサンプルの分割	63
図 4-4	深層学習モデルの概要図	65
図 4-5	学習データでのポジティブ予測確率のヒストグラム	67
図 4-6	検証データでのポジティブ予測確率のヒストグラム	67
図 4-7	テストデータでのポジティブ予測確率のヒストグラム	68

図 4-8	モデルから抽出したセンチメントスコアのヒストグラム	72
図 4-9	極性辞書から抽出したセンチメントスコアのヒストグラム	73
図 5-1	日次投資戦略の概念図	83
図 5-2	日次投資戦略 等ウェイトポートフォリオの累積パフォーマンス	86
図 5-3	日次投資戦略 時価加重ウェイトポートフォリオの累積パフォー マンス	87
図 5-4	週次投資戦略の概念図	88
図 5-5	週次投資戦略 等ウェイトポートフォリオの累積パフォーマンス	90
図 5-6	週次投資戦略 時価加重ウェイトポートフォリオの累積パフォー マンス	91
図 5-7	月次投資戦略の概念図	92
図 5-8	月次投資戦略 等ウェイトポートフォリオの累積パフォーマンス	94
図 5-9	月次投資戦略 時価加重ウェイトポートフォリオの累積パフォー マンス	95
表 3-1	トヨタと日本水産のニュース数の比較	30
表 3-2	トヨタと日本水産のニュースの記載場所の比較	30
表 3-3	日本語評価極性辞書（用言編）の分類	36
表 3-4	日本語評価極性辞書（用言編）の例	37
表 3-5	日本語評価極性辞書（名詞編）の例	39
表 3-6	超過リターンと時価総額の要約統計量	41
表 3-7	センチメントスコアの要約統計量	43
表 3-8	仮説（ア）の検証結果	45
表 3-9	仮説（イ）の検証結果	46
表 3-10	仮説（ウ）の検証結果	47
表 3-11	仮説（ウ）のロバストネスチェックの検証結果	49

表 3-12	等ウェイトポートフォリオのパフォーマンス	53
表 3-13	時価加重ウェイトポートフォリオのパフォーマンス	55
表 4-1	景気ウォッチャー調査の例	60
表 4-2	最終的なサンプル数	64
表 4-3	各データセットのサンプル数.....	66
表 4-4	学習データの混同行列	68
表 4-5	検証データの混同行列	69
表 4-6	テストデータの混同行列	69
表 4-7	超過リターンと時価総額の要約統計量	70
表 4-8	センチメントスコアの要約統計量.....	73
表 4-9	センチメントモデルによるセンチメントスコアの検証結果.....	75
表 4-10	極性辞書によるセンチメントスコアの検証結果	75
表 5-1	センチメントスコアの要約統計量.....	81
表 5-2	日次投資戦略 等ウェイトポートフォリオのパフォーマンス ..	85
表 5-3	日次投資戦略 時価加重ウェイトポートフォリオのパフォーマンス	87
表 5-4	週次投資戦略 等ウェイトポートフォリオのパフォーマンス ..	89
表 5-5	週次投資戦略 時価加重ウェイトポートフォリオのパフォーマンス	90
表 5-6	月次投資戦略 等ウェイトポートフォリオのパフォーマンス	93
表 5-7	月次投資戦略 時価加重ウェイトポートフォリオのパフォーマンス	94
表 5-8	日次投資戦略等ウェイトポートフォリオの FF3 ファクター回帰	96
表 5-9	日次投資戦略等ウェイトポートフォリオの FF5 ファクター回帰	97
表 5-10	日次投資戦略時価加重ウェイトポートフォリオの FF3 ファクター回帰.....	99
表 5-11	日次投資戦略時価加重ウェイトポートフォリオの FF5 ファクター回帰.....	100

第1章 緒論

近年、我が国で資産運用、資産形成がますます重要性を増してきている。その背景として、特に年金の運用についてクローズアップされることが多い。我が国は国民皆年金制度であるものの、少子高齢化に伴う財源不足や、経済成長率の低下により、受給年齢の引き上げや、受給額自体もじわじわと低下してきている。2019年に金融庁がまとめた報告書での「人生100年時代では（年金だけでは）老後に資金が2000万円不足する」という言葉は、その金額の大きさと、年金制度を管轄している金融庁が発表したことで、世間を大きく騒がせた[Fsa 2019]。一方で、資産運用の環境事態も厳しいものとなっている。我が国の株式はバブル期に最高値を付けたのち、いまだその高値を越えられないでいる。さらに金利はバブル以降低下の一途をたどり、2016年にはマイナス金利となった。実質金利も足元ではマイナス、預貯金の金利もほとんど0に近い数字である。我が国の個人の金融資産の保有構造は現金預貯金が半分程度を占めており、これは諸外国と比較しても低い。このような年金環境や、金利環境では、この現金および預貯金をリスク性資産に振り向けて、運用を行い、資産を形成していく必要がある。そのため国は、「貯蓄から投資へ」とのスローガンを掲げて、取り組んできた。具体的には、NISAやiDeCoといったスキームを提供してきたものの、その複雑性などから国民へ十分に浸透しているとは言えない。すなわち、国の取り組みはまだ道半ばと言わざるを得ない。

このような環境の中、国民の資産形成の一助となる資産運用業界においても、その商品の運用手法の高度化や効率化が重要になっている。近年の情報技術の発展により、資産運用における投資判断に用いられる際の情報量は年々増えてきている。

2010年代以降ビッグデータといった言葉が注目を浴びているが、その「ビッグデータ」という言葉の定義は様々である。例えば少なくともその特徴には3つのV(Volume, Variety, Velocity)があるとされているが[Laney 2001]、一般的には「既存の技術では管理するのが困難な大量のデータ」と定義されることが多い。インターネットのテキスト情報や、小売りのPOSデータ、携帯電話の位置情報、クレジットカードなどの利用履歴など多様性に富んだ大量のデータが刻一刻と生み出されており、これらはビッグデータの一例といえよう。コンピューター技術の発展によりこのよう

なビッグデータを効率的に活用し、付加価値を創造しようという取り組みが盛んである。日本においても、経済産業省が、「日本再興戦略」改訂 2015 をうけて、IoT・ビッグデータ・人工知能等による産業構造・就業構造の変革に適切に対応すると言及している。具体的なアクションとして、2015 年 8 月 19 日に産業構造審議会に「新産業構造部会」を設置し、ビッグデータの効率的な利用に関して検討が始まった[Meti 2015]。

また、このようなビッグデータへの関心とともに、この扱いにくいデータを分析する手法として機械学習に注目が集まっている。機械学習はアルゴリズムを用いてデータから反復的に「学習」するため、コンピューターが自律的にデータから洞察を行う。ビッグデータはその名の通りそのデータ量から人間の目で全てを観察するのは不可能に近く、機械学習と非常に相性が良いといわれる。機械学習へのニーズの高まりとともに、そのアルゴリズムも進化しており、最近では、ディープラーニングというアルゴリズムで機械が猫を認識できたと話題にもなった。このように、ビッグデータを扱う技術についても近年発展著しく注目を集めている。

ビッグデータへの関心の高まりは、資産運用業界においても例外ではない。市場の高頻度取引データなどに着目して市場予測に役立てようというものや、資産価格に影響を与える経済指標を、様々なリアルタイム性の高い情報をオンラインから収集し、推定しようという Nowcasting を試みる研究や[Galbraith 2013]、決算発表会での企業の担当者の音声を解析し予測に活かそうというものまである[Mayew 2012]。運用商品においてもビッグデータの利用を付加価値としたファンドが近年増えてきている。

資産運用業界におけるビッグデータの最たるものがテキスト情報である。企業の報告書や、ニュースや SNS、アナリストレポートなど多岐にわたる。テキストは理解し投資行動に移すまで時間がかかる。よってこれらを効率的に処理することが求められている。こういったテキスト情報の中でもニュースはその名前の通り、企業や経済に対する新しい情報をもたらすという意味で重要である。確かに企業の有価証券報告書や、アナリストレポートなども重要であるものの、企業の合併や不祥事といった情報は、これらの企業やアナリストが発表する情報よりも早くニュースとして世に出ることが多い。現在の資産運用の根幹をなしているのが、CAPM[Sharpe 1964]に代表される資産価格理論であるが、その基礎となるのは効率的市場仮説である。この効率的市場仮説が成り立つかどうかは議論があるものの、将来の企業の利益に大きな影響を与

えうるニュースが、その企業の株価に対しても影響を与えることが想定される。

このような背景のもと、本論文では、株価へ影響度が大きいと思われるニュースを、大量であったとしても効率的に扱う手法を検討し、企業毎に関する記事が、企業の株価にどのように影響をあたえるのかを明らかにする。たしかに、ニュースは株価へ影響を与えるという点で重要であるが、1つ1つのニュースを人が読み込んで、株価への影響を判断するには、時間がかかりすぎてしまう。さらに読み手によっても、その判断は当然異なってくるであろう。人手による分析手法では限界があると考えられる。そこでテキストマイニング技術を利用して、この問題を解決する。機械的にテキストを扱うことができれば、人手での問題であった時間がかかるといった点や、判断が異なってしまうといった問題が解決される。

このような状況の中、本研究は様々なニュース文書からセンチメントを抽出し、このセンチメントが資産運用に活用することを目的に実施したものである。本研究の構成は以下のとおりである。第2章で金融分野における自然言語処理の流れについて概観し、改めて本研究の目的について述べる。第3章では、まず一般的な極性辞書を用いてニュースからセンチメントを抽出し、個別銘柄の株価への影響を調査する。そもそもニュースから抽出したセンチメントが株価へ影響をあたえるのかどうかを明らかにする予備的な実験に位置づけられる。加えてニュースの特性と企業の特性も踏まえてセンチメントの株価へ影響を明らかにする。さらに、簡単なポートフォリオシミュレーションを行い、資産運用への活用可能性を模索する。第4章では、ニュースから経済金融分野に特化したセンチメントを抽出モデルの開発について述べる。経済金融分野については独特の言い回しなどがあり、一般的な極性辞書では捉えづらい言い回しがあると考えられる。そこで、この章では経済金融分野について記載された大量のテキスト情報とその評価値からディープラーニングを用いてセンチメント抽出モデルを開発する。このモデルを用いることでより精度の高い（経済金融分野における）センチメントをニュースから抽出可能となることを示す。第5章では、第4章で構築したモデルを用いて、改めてニュースからセンチメントを抽出し、ポートフォリオシミュレーションを通じて、資産運用に活用できるかどうかを明らかにする。またニュースのセンチメントの株価への影響期間も明らかにする。第6章は結論であり、本研究を総括する。

第2章 金融分野における自然言語処理の活用とその課題

2.1 はじめに

本章では、最初に自然言語処理によるテキストデータからの情報抽出手法について説明する。その後、金融分野におけるテキストデータの活用の歴史について先行研究を調査する。最後に金融分野においてニュースを活用した先行研究について概観し、その課題と、本研究の目的について述べる。

2.2 自然言語の情報抽出手法

本節では自然言語処理によるテキストデータからの情報の抽出の方法について、特に本論文で用いられる手法を中心にその概要を述べる。まず言語の解析の方法について述べたのち、ニューラルネットワークを用いた情報抽出の手法について述べる。

2.2.1 言語の解析方法

ここでは、自然言語処理を行うときに必要となる形態素解析、構文解析、意味解析の技術について概説する。自然言語処理では、まず語を分類する形態素解析を行って、その後構文解析、意味解析が行われる。これらの解析を行ったのち、情報抽出、情報検索や機械翻訳、要約などを行う。以下それぞれの解析について述べる。

形態素解析

文章は、複数の語の系列として表されており、その構造を解析するためには、文を

語の単位へ分解する必要がある。この最小の単位の語へ分解するための処理が形態素解析処理である。ここで形態素とは意味を持つ最小の言語単位であり、形態素解析とは与えられた文を形態素単位に区切り、各形態素に品詞などの情報を付与する処理である。日本語における形態素解析では、辞書に記載されている見出し語を形態素と見なして文を形態素に分割する。さらに、見出し語にひもづく品詞や標準形などを形態素に付与する処理となる。

英語のように空白文字によって明確に単語が分かち書きされるような言語においては、その単語の品詞の同定が重要な問題となるが、日本語の解析では、形態素の情報を記述した辞書を参照して形態素解析をするのが普通となる。日本語の難しいところは、分かち書きをしない言語であり、かつ一部の品詞が活用を行うため、最小単位の単語を同定しつつ、その品詞の原形を求める処理となり、構文解析や構造解析といったより高度な自然言語処理の基礎となる非常に重要な処理である。

日本語の代表的な形態素解析の手法として 2 つ挙げられる。1 つは規則による形態素解析である。これは事前に用意しておいた規則や辞書と形態素解析をしたい入力文とを照らし合わせ、どの規則や品詞にマッチするのかを延々と試していき分解していくものである。しかしながら、このやり方では、規則や辞書に全通り記載する必要があり、また総当たりとなる可能性もあるため時間がかかる。そこで近年では、確率的言語モデルによる形態素解析が主流となっている。この手法では、単語の表記、品詞、活用などの情報を記述した単語辞書と、どのような単語または、品詞および活用が日本語文中で連続して出現しうるかを記述した接続可能辞書を用いる。

具体的な例として、図 2-1 に「ねたら元気になった」という日本語文の形態素解析の様子を示す。まず、単語辞書を参照して、入力文の各位置からはじまる部分文字列で辞書にマッチするものをすべて取り出し、その各候補に対応するノードを作成する。さらに入力文の各位置において、その位置までの語の候補と、その位置からの語の候補が連携するかどうかを、接続可能辞書を用いて調べる。接続可能であれば、リンクする。このような処理によって、1 文の形態素解析の可能性は図 2-1 に示すようなラティス構造で表現される。




図 2-1 ラティス構造の例

次にこのすべてのパスのうち、どれが尤もらしいのかを統計的に決定するのである。適切なパスの選択方法の 1 つとしてビタビアルゴリズムが用いられる。このアルゴリズムは、語やその接続にコストを与えて、パスのコストの和が最小になるようにパスを選択するというものである。このコストを与える方法として、コーパスに基づいて学習する方法などがある。単純な分であればパスは限られているため、すべて計算すればよいが複雑な文になるとその計算通りは爆発的に増えることになり、総当たりでは解けない。そこで、ビタビアルゴリズムはダイナミックプログラミングの考え方に基づいて効率的に問題を解決している。

その他にも、隠れマルコフモデルや条件付確率場という手法も用いられる。さらに近年ではニューラルネットワークなどの技術が用いられる。

日本語の形態素解析を行うソフトウェアとしては **MeCab** や **JUMAN** といったものがよく利用される。

構文解析

文は 1 次元の語の並びであるが、その中には構文と呼ばれる語の結びつきの構造が存在する。構文解析は、形態素に分けられた単語の系列を用いて、文全体の構造を明らかにするものである。構文は一般的に木構造によって表現することができる。この関係を係り受け構造とよび、係り受け構造を文に自動的に付与することを係り受け解析と呼ぶ。この解析では文脈自由文法が用いられる。文脈自由文法では、句のつながりの規則から係り受け構造を明らかにしようというものである。日本語の係り受け解析のソフトウェアとして **Cabocha** や **KNP** が存在する。

意味解析

文の意味は，文を構成する単位である個々の単語の意味と，それらの単語と他の単語との間にある意味的な関係によって決まる．自然言語処理における意味解析の目的は，このような文の意味を形式的に表現することである．意味解析においては，曖昧さを持たない，解釈や推論の方法を備えている，構文木のような文の形式的な構造から機械的な手順で変換できることが重要となる．前節の構文解析までを完了させることでようやく文章としての意味の解析を行うことができる．

2.2.2 ニューラルネットワークを用いた自然言語処理

近年，様々な分野で機械学習，とりわけニューラルネットワーク，深層学習の利用が注目されている．ニューラルネットワークの利用は自然言語処理においても例外ではなく，その精度の高さから情報抽出のために利用されている．

ニューラルネットワークは生物の神経細胞のふるまいをもとに，モデル化されたアルゴリズムである．1940年代にはじめて提案され，その後も現在に至るまで様々なニューラルネットワークに関するアルゴリズムが提案されてきたものの，これまでその計算量の多さなどからそれほど注目されてこなかった．ところが2000年代に入り，情報技術の発展に伴い，マシンパワーの増大や，ビッグデータと呼ばれる大量データの利用が進み，再び注目されるようになった．特に2010年代に入り，画像認識，音声認識などの様々なタスクで大きな精度向上が見られたところで大きな脚光を浴びることとなった．自然言語処理においてもニューラルネットワークが2010年以降盛んに用いられている．

まず基本的なニューラルネットワークについて述べたのち，自然言語処理で注目されるようになった単語の分散表現についてのべ，自然言語処理においても用いられる再帰型ニューラルネットワークと畳み込みニューラルネットワークについて述べる．

ニューラルネットワーク

ニューラルネットワークにおける基本的な仕組みを図 2-2 に示す。単層のニューラルネットワークは入力を受け付ける N 個の入力ノード（ニューロンとも呼ぶ）とそれを集約して出力する 1 つの出力ノードからなり，入力ノードの 1 つ 1 つが，それぞれ出力ノードと重み w_i ($i=1\dots N$) のエッジでつながっている。入力ノードはそれぞれ入力値 x_i が与えられる。出力ノードではまず入力と重みで線形和として集約し，さらにバイアス項を足し合わせる。これを

$$u = \sum_i w_i x_i + b \quad (2-1)$$

として定義する。ここで， b はバイアスである。この値 u があるしきい値を超えた場合にのみ出力を行う。この関数を活性化関数と呼ぶ。出力ノードでの出力値 out はこの活性化関数を f として下記であらわされる。

$$out = f(u) \quad (2-2)$$

活性化関数には様々な種類があるが，のちに説明する誤差逆伝播法を用いる場合には微分可能であることが求められ，シグモイド関数などがよく利用される。

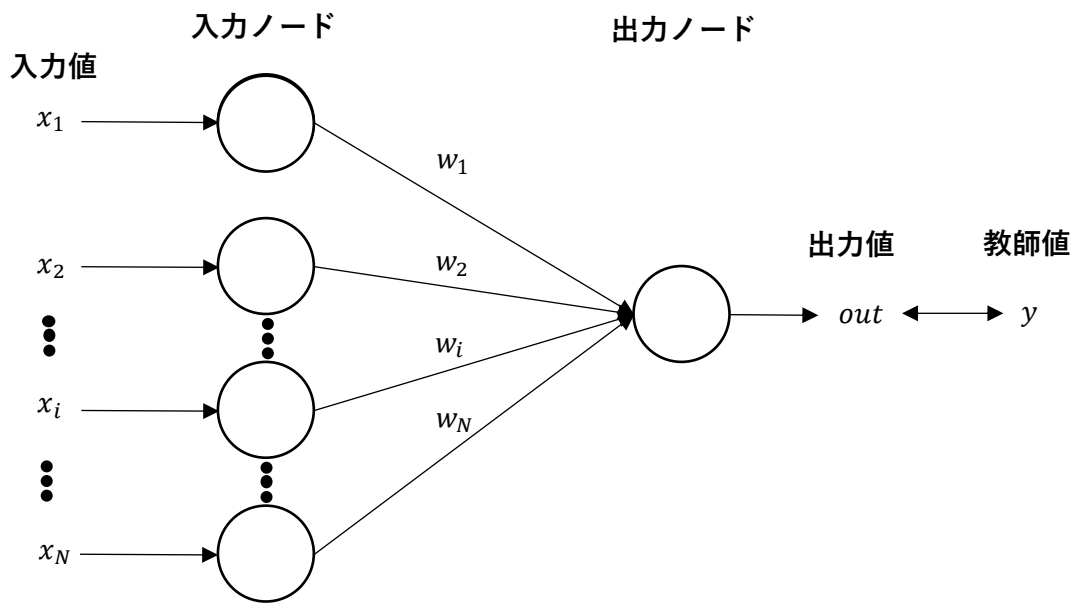


図 2-2 単純なニューラルネットワーク

今日用いられるニューラルネットワークは図 2-2 のように単層ではなく，入力層と出力層の間に複数の中間層（隠れ層ともよばれる）を含めることが多い．中間層を増やすほどニューラルネットワークの表現力がまし，複雑な処理を行うことが可能となる一方で，その計算量が増大してしまう点には注意が必要である．中間層を含んだニューラルネットワークを図 2-3 に示す．これを順伝播型ニューラルネットワークとも呼ぶ．この場合，層の数は M であり，出力値の数は O となる．各層のノード数は任意であり，かつ各層のノードはその次の層のノードとすべてエッジでつながっているとする．

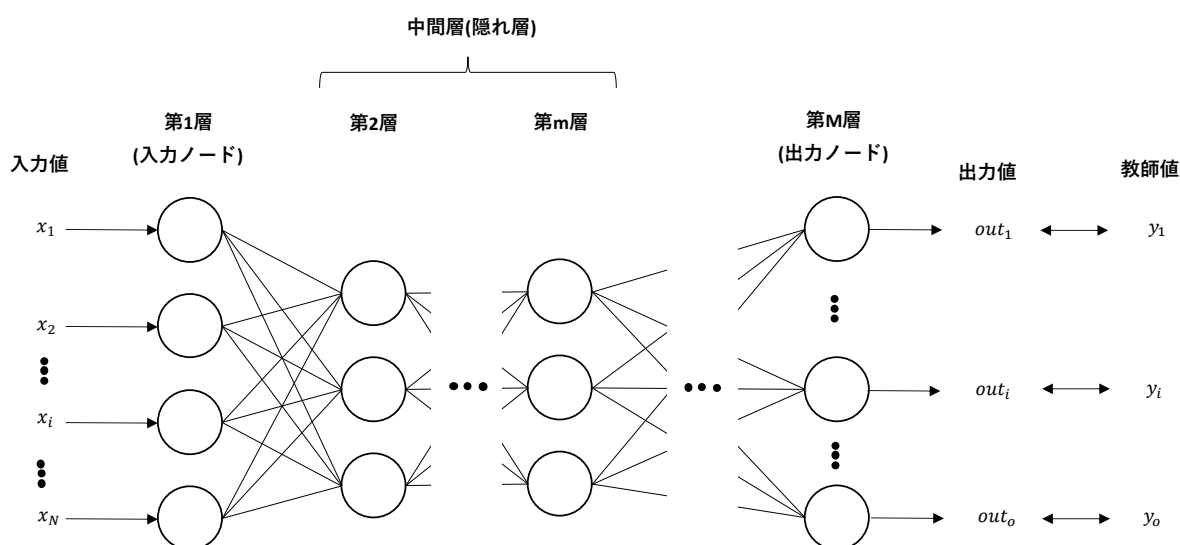


図 2-3 中間層を含んだニューラルネットワーク

ニューラルネットワークの学習において解くべき問題は，入力値 x に対応する教師信号 y が与えられた際に出力 out が y に近づくように誤差を最小化する最適化問題となる．具体的には，この誤差を最小化するように重み w とバイアス b を求めることになる．簡単のためにバイアスを今後は考慮しない（もしくは常に 1 を出力するノードを各層に加えてバイアスを重みの中に加えてもよい）．

この最適化の解法には誤差逆伝播法（バックプロパゲーション）が用いられることが多い．具体的に図 2-3 での誤差逆伝播法について述べる．誤差を二乗誤差で定義する場合，出力値と教師値の誤差 E は下記で表される．

$$E = \frac{1}{2} \sum_{i=1}^o (y_i - out_i)^2 \quad (2-3)$$

勾配降下法を用いて，この E が減少するように各ノード間の重みを更新する．第 $m-1$ 層のノード数が L_{m-1} であり，第 m 層のノード数が L_m であるとする．第 $m-1$ 層の i 番目のノードから第 m 層の j 番目のノードをつなぐエッジの重みを $w_{j,i}^{m,m-1}$ のように表記すると，この重みは以下のように更新される．

$$w_{j,i}^{m,m-1(new)} = w_{j,i}^{m,m-1(old)} - \eta \frac{\partial E}{\partial w_{j,i}^{m,m-1(old)}} \quad (2-4)$$

ここで、第二項の偏微分は合成微分によって、 m 層の j 番目のノードでの線形和 u_j^m と活性化関数による出力 out_j^m を用いて、以下のようになる。

$$\frac{\partial E}{\partial w_{j,i}^{m,m-1}} = \frac{\partial E}{\partial out_j^m} \frac{\partial out_j^m}{\partial u_j^m} \frac{\partial u_j^m}{\partial w_{j,i}^{m,m-1}} \quad (2-5)$$

活性化関数は微分可能であるので、第二項の偏微分は入力値が決まれば値が求まる。

ここで、

$$u_j^m = \sum_{i=1}^{L_{m-1}} w_{j,i}^{m,m-1} out_i^{m-1} \quad (2-6)$$

$$out_j^m = f(u_j^m) \quad (2-7)$$

である。よって第三項は、 out_j^{m-1} に等しい。第一項の偏微分は、第 m 層のノード j の出力が第 $m+1$ 層のすべてのノードとエッジでつながっていることを思い出すと、偏微分の連鎖率より、さらに、

$$\begin{aligned} \frac{\partial E}{\partial out_j^m} &= \sum_{k=1}^{L_{m+1}} \frac{\partial E}{\partial u_k^{m+1}} \frac{\partial u_k^{m+1}}{\partial out_j^m} \\ &= \sum_{k=1}^{L_{m+1}} \frac{\partial E}{\partial out_k^{m+1}} \frac{\partial out_k^{m+1}}{\partial u_k^{m+1}} \frac{\partial u_k^{m+1}}{\partial out_j^m} \\ &= \sum_{k=1}^{L_{m+1}} \frac{\partial E}{\partial out_k^{m+1}} \frac{\partial out_k^{m+1}}{\partial u_k^{m+1}} w_{k,j}^{m+1,m} \end{aligned} \quad (2-8)$$

と書くことが可能である．先ほどと同じくこの第二項は入力値が求まれば求まる．第三項は重みそのものである．第一項は再び第 $m+1$ 層と第 $m+2$ 層がつながっているため，同じように書き下すことができる．これは漸化式であるとみなせば，最後の出力層で，誤差を計算すれば，出力層から入力層に向かって誤差が伝播していき勾配を求めることが可能となる．この出力層から入力層への伝播が誤差逆伝播法と呼ばれる所以である．

次に，実際のニューラルネットワークの学習方法について述べる．最終的なモデルを構築するために使用されるデータは，通常，複数のデータセットに分割されうるが，特に 3 つのデータセットへの分割が一般的に用いられる．訓練データセット，検証データセット，テストデータセットである．訓練データセットは，実際の重み更新のための計算に求められる．この訓練データセットを数十から数百のサンプル数からなるミニバッチに分割をし，それぞれのミニバッチでの平均的な誤差を計算し，重みを更新する．これをミニバッチ学習と呼ぶ．ニューラルネットワークの学習ではミニバッチ学習が用いられることが多い．訓練データセットすべてのサンプルを操作することをエポックと呼ぶ．1 エポックにおける全訓練データでの誤差の総和がさがっていることを確認することで，学習が進んでいるかどうかを確認することができる．2 つ目のデータセットである検証データセットは，モデルのハイパーパラメータ（ニューラルネットワークの中間層の数や各層のノードの数など）を調整しながら，訓練データセットで構築したモデルに対して，偏りのない評価を提供することができる．検証データセットを訓練データセットで構築したモデルに入力し誤差を計測する．この誤差が増加する場合，訓練データセットへの過学習の兆候であると考えられるため，検証データセットは学習の停止判定に利用することができる．最後に，テストデータセットは，訓練データセット上で構築された最終的なモデルに対して，偏りのない評価を提供するために使用されるデータセットである．

ニューラルネットワークは表現力が高いため，過学習が問題となる．すなわち，訓練データセットに対して適応しすぎるにより，訓練データセットに対しては高い精度となるが，他のデータに対しては精度が大きく下がってしまうことがありうる．過学習を抑えるために，検証データセットでの評価を行うのであるが，その外にも過学習を抑える手法にドロップアウトがある．ドロップアウトでは訓練データセットご

とにランダムにノードを選び、それらが無いものとして学習を行う．これは多数の異なるニューラルネットワークの結果を平均していることがあり，過学習を抑えることができる．

Word Embedding

ニューラルネットワークが自然言語処理に活用された成功例として，word embedding がある．Word embedding とは，ニューラルネットワークを用いて，大規模なコーパスから語の意味のベクトル表現（分散表現）を学習したものである．

Mikolov らによって 2013 年に発表された Word2Vec は，最も有名な word embedding のアルゴリズムである [Mikolov 2013a], [Mikolov 2013b]．ここでは本論文でも用いる word2vec のアルゴリズムについて説明する．

word2vec が行うことを簡潔に述べると大量のコーパス（wikipedia などがよく用いられる）を用いて，似ている文脈に出てくる単語が同士の距離を近づけ，同じ文脈に出てこない単語同士の距離が遠ざけるように，コーパス内の単語を超空間に配置するということである．このとき超空間上の各単語の座標を取り出したものが分散表現ベクトルとなる．このような表現を得るために，2 つの手法が提案されている．

Continues Bag of Words (CBOW) モデルと skip-gram モデルである．CBOW モデルは，注目する単語を中心に与えられたウィンドウサイズ内の周囲の単語を用いて現在の単語を予測するモデルである．一方，skip-gram モデルは，CBOW とは逆にある単語を用いて周囲の単語を予測するモデルである．図 2-4 に，CBOW と Skip-gram モデルのアーキテクチャを示す．モデル自体は，階層的ソフトマックス法またはネガティブサンプリング法で学習される．

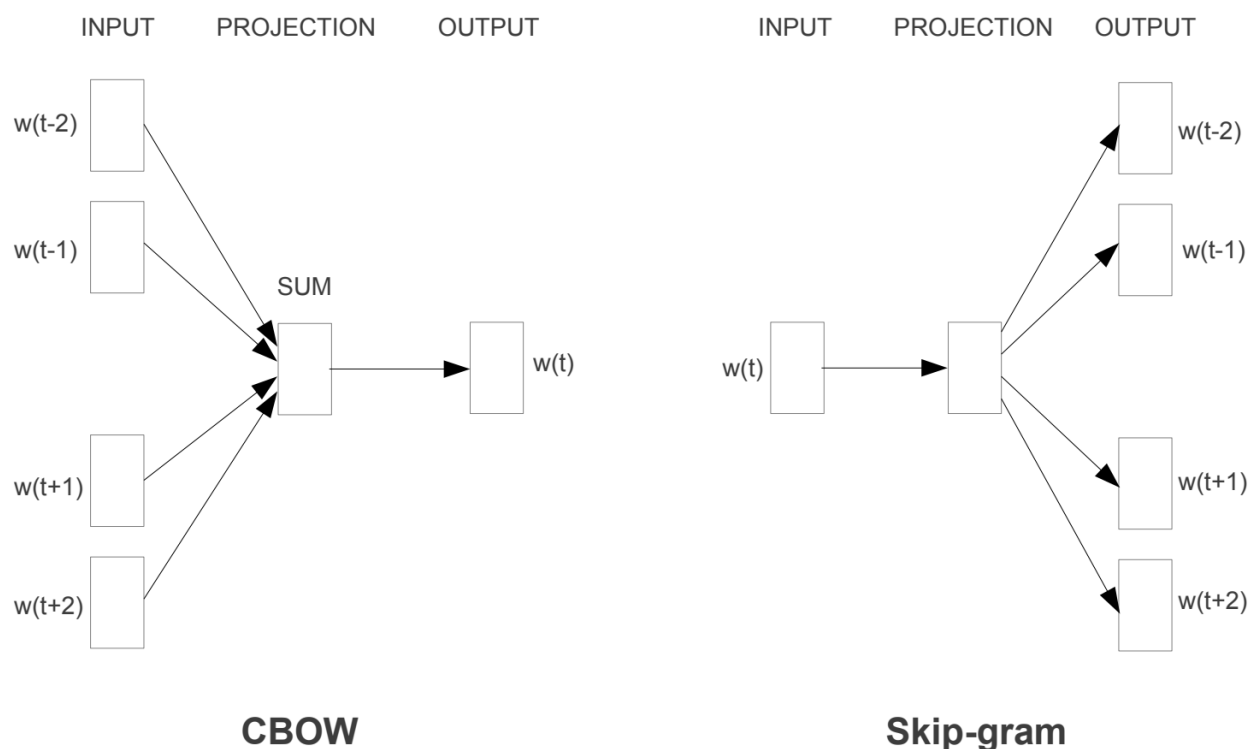


図 2-4 word2vec における CBOW と Skip-gram のアーキテクチャ [Mikolov 2013a]より抜粋

密なベクトル表現は，データセット内の単語の同時出現率に基づいて意味関係を抽出する．与えられた 2 つの単語の表現の精度は，モデルがコーパス全体で同じ文脈の中でこれらの単語を何回見たかに依存する．学習中に単語と文脈の共起回数が増えると，隠れた表現が変化し，モデルは将来の予測をより成功させることができ，ベクトル空間における単語と文脈のより良い表現が可能になる．実際に単語がベクトルで表現されることとなるが，異なる単語の類似性などが得られる．よくモデルが学習されていれば

$$v_{king} - v_{man} + v_{woman} \cong v_{queen} \quad (2-9)$$

という関係が成り立つ．ここで v_{king} は「king」という単語の， v_{man} は「man」という単語の， v_{woman} は「woman」という単語， v_{queen} は「queen」という単語のベクトル表現である．そのほかにも，似たような意味をもつ単語の分散表現のコサイン距

離が近くなるというような関係も成り立つ．このような特徴から，単語のベクトル表現は，自然言語処理分野の様々なタスクで利用されており．word2vec 以外にも，Glove や fast text といったアルゴリズムが提案されている．

再帰型ニューラルネットワーク

順伝播型ニューラルネットワークでは入力と教師信号のペアは他のペアと独立で，ペア事に中間層の状態をリセットしていた．これに対して，中間層の状態をリセットせずに，次の入力の時に中間層の状態を引き継ぐニューラルネットワークを再帰型ニューラルネットワーク（Recurrent Neural Network: RNN）と呼ぶ．このように前の情報を次の情報へとつなげていくために，時系列情報や連続した情報の解釈に利用される．再帰型ニューラルネットワークのイメージ図を図 2-5 に示す．




図 2-5 再帰型ニューラルネットワークのイメージ図

RNN 層の出力が再び RNN 層の入力になっておりループ構造になっている．このループを時間方向に展開すると，図 2-6 のように右方向に延びるニューラルネットワークとなる．




図 2-6 時間方向に展開した再帰型ニューラルネットワークのイメージ図

再帰型ニューラルネットワークの伝播は次のように与えられる。

$$h_t = f(W_x x_t + W_h h_{t-1} + b) \quad (2-10)$$

ここで、 h_t は再帰型ニューラルネットワーク層からの出力、 W_x は入力値 x に対する重み、 W_h は 1 つ前の再帰型ニューラルネットワークからの出力に対する重みであり、 b はバイアスとなる。重みは行列、それ以外はベクトルである。さらに f は活性化関数となる。ループを展開した後のネットワークについても、順伝播型ニューラルネットワークと同じような誤差逆伝播法を適用できる。この方法は通時的誤差逆伝播法 (back propagation through time, BPTT) と呼ばれる。このような再帰型ニューラルネットワークは、いくつか問題がある。再帰型ニューラルネットワークは一見、浅いニューラルネットワークに見えるものの、実際には、時間方向に展開するため深いネットワークである。したがって、同じ重みに何度も影響されるため、信号や、勾配が消失もしくは爆発してしまためである。この問題を解決するアルゴリズムの 1 つとして、長・短期記憶 (Long-Short Term Memory: LSTM) ニューラルネットワークが提案された。LSTM はゲート付き再帰型ニューラルネットワークとも呼ばれ、一般的な LSTM ユニットは、メモリーセル、入力ゲート、出力ゲート、忘却ゲートからなる。それぞれのゲートは、「入力からメモリーセルへどれくらい情報を通すか」、「メモリーセルからどれくらい出力するか」、「メモリーセルにある情報をどれくらい忘却するか」を制御する。これらのゲートによってメモリーセルの情報を制御し、時系列データの前後関係の重要な情報を長期的に記憶することができる構造となっている。そのほか、同様にゲート付きの再帰型ユニットを用いた GRU (gated recurrent unit) も

存在する。GRUはLSTMでゲートを1つ減らした構造となっており、LSTMよりも表現力が低下するものの、計算時間が少ないという特徴がある。

再帰型ニューラルネットワークは時系列情報を扱うのに適しているニューラルネットワークであるが、自然言語も系列であることから、自然言語処理においても、よく利用されるアルゴリズムである。言語モデル学習や、系列ラベリングなど、系列を扱う場合に用いられることが多いが、機械翻訳や文書分類にも利用される。

畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (Convolutional Neural Networks: CNN) とは、全結合していない順伝播型ニューラルネットワークの一種である。動物の視覚野の細胞の反応をベースにした、ニューラルネットワークである。実際にも、動物の視野細胞のニューロンの結合と似たネットワークとなっている。このため、動物の認知と似た性質をもっており、特に画像認識によく利用されるネットワークアルゴリズムである。2012年のコンピューターによる物体認識の精度を競う国際コンテスト ILSVRC で、畳み込みニューラルネットワークをベースとした AlexNet モデルが優勝し、しかもこれまでの、精度を大幅に更新したことから、ニューラルネットワークを世に広く知らしめることとなった。

畳み込みニューラルネットワークは、主に、大きくわけて3つの層からなる。畳み込み層と、プーリング層と、全結合層である。畳み込み層とは、視覚野のなかでの単純型細胞と呼ばれる細胞を模した役割を果たす。単純型細胞は、ある特定の形状に反応する細胞であり、その種類によって、さまざまな形状に反応する。この単純型細胞が連携して活動することで複雑な形状の物体を認識することができるのである。具体的に畳み込み層は、元の入力に対して、フィルタを作用させ、畳み込み演算を行う。次のプーリング層は、視覚野のなかでの複雑型細胞と呼ばれる細胞を模した役割を果たす。複雑型細胞は視野に入ったものの形状のずれを吸収する作用がある。単純型細胞だけだとある形状が空間的な位置がずれてしまうと、もとの形状と同じであると認識することができないが、複雑型細胞があるため、空間的な形状のずれがあっても同一と、認識できるのである。具体的にプーリング層は、畳み込み層の出力をダウンサンプリングする。最大プーリングと呼ばれる手法では、畳み込み層の複数の出力のう

ちの最大のもののみを選択する．最後の全結合層では，通常の順伝播型ニューラルネットワークと同じく，プーリング層からのすべての出力と，全結合層のノードをつなぐ．これまで 3 次元であったデータを 1 次元に変換する役割を持っている．

畳み込みニューラルネットワークの特徴として，順伝播型ニューラルネットワークと比較して，前の層のノードと次の層のノードが，完全結合しているわけではないため過剰適合となりにくいという利点がある．さらに，再帰型ニューラルネットワークと比較して，並列処理が可能になり，計算効率が高いという点があげられる．

自然言語処理においても，畳み込みニューラルネットワークは利用されている．

[Kim 2014]では，畳み込みニューラルネットワークを用いて，文書の分類タスクを行っている．この論文では文書を画像のように扱っている．例えば，ある文が 9 単語から成り立っており，各単語が **word embedding** により 6 次元のベクトルで表現されているとすると，9 行 6 列の行列として表記可能となる．これを画像と見立てて畳み込みニューラルネットワークで扱う．画像の場合は畳み込みのフィルタは，水平方向と垂直方向に動作させるが，この文書の行列の場合，行方向が単語の分散表現となるため，列方向，つまり垂直方向下にのみ移動させて，畳み込み計算を行っている．このように処理を行うことで，文脈をとらえることができると考えられる．彼らのモデルの概念図を図 2-7 に示す．




図 2-7 [Kim 2014] における畳み込みニューラルネットワークの概念図

彼らは、いくつかのタスクで再帰型ニューラルネットワークを含むいくつかの機械学習アルゴリズムの結果を上回る結果となったと報告している。その他、[Zhang 2015]では、単語ではなく、文字の分散表現を入力値として用いた畳み込みニューラルネットワークのモデルで、いくつかの文書分類の精度が上がると述べている。[Wang 2016]では、短いテキストに対するセンチメント分析での畳み込みニューラルネットワークと再帰型ニューラルネットワークの合成モデルを提案している。

2.3 金融分野における自然言語活用

2.3.1 効率的市場仮説と株価予測

株式などの金融資産の資産価格がどのように決定するのかというのには様々な議論があるものの、[Sharpe 1964] で提案された CAPM (Capital Asset Pricing Model) が最も有名なモデルである。CAPM は下記の式で表される。

$$E[R_i] - r_f = \beta_i(E[R_m] - r_f)$$

ここで、 $E[R_i]$ は資産 i の期待収益率、 r_f は安全資産の利子率、 $E[R_m]$ は、市場ポートフォリオと呼ばれるすべての金融資産の時価加重平均ポートフォリオの期待収益率、 β_i は、 $E[R_m] - r_f$ で表されるマーケットリスクプレミアムに対する資産 i の感応度である。即ち株式の場合には個別銘柄のリターンは、市場リターンとマーケットリスクプレミアムに対する感応度から決定するというモデルである。この CAPM は効率的市場仮説と呼ばれるモデルに依拠している。

効率的市場仮説は Fama によって、体系づけられた[Fama 1970]。効率的な金融市場であれば、株式取引は常に公正な価格で取引されており、追加的なリスクをとることなしに市場リターン以上のリターンを得ることは難しいというものである。効率的市場仮説には一般的にウィーク型効率性、セミストロング型効率性、ストロング型効率性が存在する。それぞれのパターンを下記に示す。

- ウィーク型効率性

ウィーク型効率性が成り立つ市場においては、現在の株式の価格は過去の株価の動きがすべて織り込まれた価格であると仮定している。つまり、過去の株式価格情報に基づいて、将来の価格の予想はできないような市場である。ウィーク型の効率性のもとでは、過去の価格の動きを利用するチャート分析や、テクニカル分析では追加的なリスクなしに市場リターンを上回るリターン、すなわち、超過リターンを獲得することは不可能となる。

- セミストロング型効率性

セミストロング型効率性が成り立つ市場においては、現在の株式の価格には、過去の株価の動きだけではなく、すべての公開情報が即座にそして完全に価格に織り込まれることを仮定している。公開情報とは、企業の発表する決算に関する情報や、合併等や M&A に関するニュースといったものである。これらを利用して価格も予測できないということである。よって、セミストロング型の効率性のもとでは、ウィーク型効率性市場では成立しないテクニカル分析だけでなく、企業の財務情報などを用いたファンダメンタル分析でも、追加的なリスクなしに超過リターンを獲得することができない。

- ストロング型効率性

ストロング型効率性が成り立つ市場においては、現在の株式の価格には、過去の株価の動きおよび公開情報だけではなく、未公開である企業内部情報も含めたすべての情報が織り込まれていると仮定している。このような市場においてはインサイダー情報をもってしても、追加的なリスクなしに超過リターンを獲得することができない。

現実の金融市場が効率的であるかどうかについては長らく議論が続けられてきた。効率的かどうかについては、リスク以上リターンを獲得できるかについて検証されなければならない。この際に Sharpe によって提案された CAPM によって実際に市場が効率的かどうか検証されてきたものの、CAPM の問題点についての批判もある。例えば、[Ross 1976]では、CAPM が成立するための前提条件が非常に厳しすぎて現実には即していないとしている。[Roll 1977]でも、どのような批判がなされている。さらに CAPM では説明できないアノマリーの存在も様々な研究で指摘されている。例えば、代表的なアノマリーとして、時価総額の小さい企業の方が、リターンが高いという小型株効果や、PBR(時価簿価比率)の低い割安な企業のリターンの方が割高なものより高いというバリュー効果、過去の株価が高い企業のリターンが高いというモメンタム効果などである。このような CAPM では説明できないアノマリーの出現を受けて、[Fama 1993]では、CAPM の市場ベータに加えて、簿価時価比率と時価総額（企業規模）という2つの変数からバリューファクターとサイズファクターを説明変数に組み込んだモデルを提案している。このモデルは Fama-French3 ファクターモデルと呼ばれ、非常にスタンダードなモデルとなっている。その後も、[Carhart 1997]による Fama-French3 ファクターモデルにモメンタムファクターを追加した4ファクターモデルの提案や、[Fama 2015]による Fama-French3 ファクターモデルに企業の収益性に関するファクターと、企業の投資に関するファクターを加えた Fama-French5 ファクターモデルの提案など、現在でもあらたな資産価格モデルの提案が続いている。資産価格を決定するためのモデルについての議論はいまだに絶えないのである。

このように資産価格モデルもいくつか提案されている背景として先ほども述べたようなアノマリーの発見がある。これらのアノマリーは多くが企業の財務情報や過去の

株価情報がベースとなったファクターであり、テキストを利用したアノマリーの提案はほとんどない。[Harvey 2016]は、トップジャーナルに掲載された会計情報などを利用した米国株式市場におけるアノマリーは 316 個あるとしている。テキストを用いたアノマリーファクターが少ない背景として、このようなアノマリーの提案には比較的長期のデータが必要となるが、テキストの長期データがあまり存在しないことや、テキスト自体の取り扱いが難しいことなどがあげられる。

2.3.2 テキスト情報の株価への影響

前述の通り、テキストのデータを利用した株価への影響を調査した先行研究は、財務情報や株価情報を利用したものと比較すると非常に少ない。そのような中でも海外におけるテキストマイニング分析については比較的、例が多い。例えば [Tetlock 2007] では、Wall street Journal column から、記事中に含まれている単語を用いて記事の悲観度を抽出し、その増減が将来の株価の予測可能性を持つと指摘している。具体的には、既存の（属性のふられている）辞書を用いて、記事の幾つかの感情を抽出している。その感情の中から悲観度を表す指標のみを説明変数として、被説明変数に将来のダウ工業平均株価リターンを用いて回帰を行ったところ、有意に負の係数を得ている。続く [Tetlock 2008] においては、個別企業に着目し、ニュース記事の情報が将来の企業の利益およびリターンを予測できるのかを検証している。結果、ニュースにネガティブな単語が多いほど、将来の当該企業の利益およびリターンが低くなるとしている。この結果ニュースは定量化の難しいファンダメンタ情報を保有していると結論付けている。Tetlock のこれらの分析はニュースが本源的な価値を保有している可能性を示唆するものである。しかしながら既存の辞書を用いており、定性性が排除されておらず、テキストから情報を完全に抽出できていない可能性がある。

Tetlock の分析に限らず、海外の分析事例では、辞書を用いたものがほとんどである。[Kearney 2014] では、過去のテキストマイニング分析のサーベイを行っている。これによると海外における先行研究の 90%以上が辞書を用いたベースのものであり、何かしらの定性判断で作成された辞書から情報を抽出しており、完全に情報を抽出でき可能性がある。一方、情報ソースに目を向けると企業が発表している情報もしくはニュース、SNS、アナリストレポートといった情報を用いて分析を行っている。これ

らの情報ソースの例としては、[Jegadeesh 2013]では、日本の有価証券報告書に相当する米国の 10k レポートに着目し、10k から抽出したセンチメントとレポート発表数日後の株価と関連があるとしている。また、[Chen 2014]では、SNS の情報から個別銘柄のテキストマイニングでセンチメント情報を抽出し、将来の株価リターンだけにとどまらず、財務情報とも関連があるとしている。アナリストレポートを扱った例としては、[Allen 2014]があげられる。[Allen 2014]では、米国株式を対象にアナリストレポートからナイーブベイズモデルを用いてセンチメントを抽出し、テキストのセンチメントがレポートの発表後の株価リターンと関係していると結論付けている。こういった情報に本源的な価値が含まれている可能性が高いと考えられる結果であろう。

特にニュース情報から個別銘柄のセンチメントを抽出して、株価予測や投資戦略の分析を行っている研究もいくつかある。例えば、[Sinha 2016]では、トムソンロイターが提供しているニュースセンチメント情報を利用して、米国市場において、週次のセンチメントがその後の 4 半期リターンを予測するとしている。[Steven 2017]も同様に、トムソンロイターのセンチメント情報を利用して、これらの結果は個別銘柄の予測が可能であるとしている。ニュースセンチメントが将来予測に役立つことを示唆するものではある。近年データプロバイダがセンチメント情報を提供することも増えており、トムソンロイター以外にも RevenPack 社などが同様の情報を提供しているが、有償であることに加えて再現性の観点からも課題である。

日本においてもテキストマイニングの手法を用いた分析は少なからず存在する。[Suwabe 2015] では、セルサイドアナリストが作成するアナリストレポートを情報源とし、テキストマイニング分析を行っている。彼はセルサイドアナリストのレーティングが変わらない場合で合っても、アナリスト自身の見通しの微小な変化がテキストに現れ、マイニングによって、その微小な変化を捉えることで超過リターンを得られるのではないかと仮説を立てている。具体的には、レポートから単語を抜き出し、独自作成した辞書と機械学習の手法を用いて、レポートからアナリストの見通しの変化を抽出する。結果、抽出された変化がポジティブな銘柄群のリターンが、ネガティブな銘柄群と比較してレポート発行後、長期にわたって高いリターンが得られたと報告している。この結果から、アナリストレポートは個別銘柄に対して本源的な価値を保有していると考えられる。但し、辞書を利用していることから辞書の選定の定性性から、テキスト情報からすべての情報を抽出できていない可能性もあると考えられる。

[Takahashi 2003]も同様に、アナリストレポートを対象として分析を行っている。

[Takahashi 2003]では、アナリストレポートのテキストと発表後の株価リターンとから学習モデルを構築し、株価予測のモデルを提案している。特にニュースを対象にセンチメント抽出をしたものとして[Okada 2011], [Okimoto 2014], [Katakura 2015], などがある。[Okada 2011] では、ブルームバーグニュースを用いて市場全体がポジティブかネガティブかを表すニュース指標を構築し、市場との関係を分析している。具体的には、個別企業毎に、毎日その企業に関連するニュースを収集し、独自辞書を用いてニュースがポジティブかネガティブかを表す指標を作成する。次に企業の指標をすべて集めて市場全体のニュース指標を構築する。この指標と市場のリターンやボラティリティ、出来高との関係を調査したところ、ニュース指標がネガティブ方向に悪化した場合には、将来の負のリターンと関係が強いが、その逆の現象は見られないと結論付けている。この分析からニュース情報が本源的な価値を保有している可能性が示唆される。[Okimoto 2014]では[Tetlock 2007] を参考に、QUICK 端末で配信される日経ニュースを定量化したニュース指標を用いて、株式市場の予測可能性について検証している。具体的には、配信されるニュースを金融工学研究所が定義したタグ情報(辞書)から、ポジティブネガティブを判断する。ある日すべてのニュースについて判断を集約し、最終的なその日のニュース指標を作成する。ニュース指標が大きいほど市場全体がポジティブであることを示す。分析の結果、彼らはニュース指標が翌日の株式リターンおよび出来高に対して有意に正の影響を持つことを確認した。加えて、ニュース指標は翌営業日以降の株価に対して有意に負の影響は持たないことも確認している。[Tetlock 2007] では翌営業日以降の株価に対して有意に負の影響を与えていたことからニュース指標は本源的な情報を持たず市場センチメントを表すと結論付けていたが、彼らは分析結果からニュース指標は本源的価値を保有している可能性があると結論付けている。この結果から、ニュースが、市場全体だけではなく、個別銘柄に対しても、単にセンチメントではなく本源的情報を持ちうると示唆される。しかしながら、ニュース情報を金融工学研究所が開発したアルゴリズムで定量化しており、どのような処理が公開されていないという問題がある。[Katakura 2015]では、CBOWを用いて既存辞書の改良を試みている。具体的にはトムソンロイターのニュースをCBOWで定量化を行い、既存辞書と似ている単語を新たに辞書にて加えて新辞書を作成している。この辞書を用いてマーケットとの関係を調査したところ、

Negative スコアはマーケットファクターと，Positive スコアは企業規模ファクターと同時点で強い関係性を有していることを確認している．本分析では CBOW を用いて辞書では捉えられていない情報を取り出そうと試みているものの，既存辞書に存在する単語と近い単語を抽出し，辞書を改良しようというものであり，結果的には，定性判断でもって作成された辞書に依存した分析である．このように日本においてもニュースからテキストマイニングでセンチメントを抽出している例はあるものの，市場との関連を調査したものが多く，個別銘柄ベースで検証した研究はまだ少ないのが現状である．

2.4 金融分野における自然言語活用の課題

金融分野特に，資産運用業界では投資行動を行うにあたってファンドマネジャーは多くの情報を元にその行動を判断する．一般的な企業の財務情報などであれば，処理や理解もしやすいが，ニュースやアナリストレポートといったテキスト情報は，1つ1つ読んで理解し，判断するまで時間を要する．科学技術の発展によりファンドマネジャーにもとに届くテキスト情報は年々増加しており，これらを効率的に扱うことが求められる．

前節で概観した通り，金融分野において自然言語処理を活用した研究はいくつか存在するものの，長らく用いられてきた企業の財務情報といったような数値情報と比較するとまだまだ少ない．そのような研究の中でも，ニュースを利用した分析は比較的多く存在するものの，短期的な市場全体への影響を調査したものが多い．しかしながら，資産運用においては，市場全体の動きの予測も重要であるものの，基本的にはポートフォリオを構築する，個別銘柄毎の予測が最も重要である．特にベンチマークポートフォリオ以上のリターンを獲得しようとするアクティブ運用では，その重要性が増してくる．アクティブ運用の基本法則として[Grinold 1989]と，その後[Grinold 1989]を拡張した[Clarke 2002]による定式化が有名である．下記に[Clarke 2002]の基本法則を述べる．

$$IR \sim IC \times TC \times \sqrt{BR} \quad (2-12)$$

ここで、*IR*は、インフォメーションレシオと呼び、ポートフォリオのベンチマークに対する超過リターンをポートフォリオの超過リスクで割ったものであり、高い方がよい。*IC*は、情報係数(Information Coefficient)と呼ばれ、ファンドマネジャーの運用のスキルであり、具体的には個別銘柄のリターンの予測値と事後的な個別銘柄のリターンとの相関で決まる。*TC*は伝達係数(Transfer Coefficient)と呼ばれ、リターンの予測値と、ポートフォリオの対ベンチマークのアクティブウェイトとの相関であり、情報をどの程度ポートフォリオに反映させられるかを表している。*BR*はプレスと呼ばれ、アクティブ運用における独立な予測の決定回数となる。この基本法則によれば、インフォメーションレシオを高めるためには、*IC*、*TC*、*BR*のいずれかを高める必要がある。*IC*はマネジャーのスキルであり、それほど大きく変わるものではない。同様に*TC*も、運用の制約などから大きく上昇させることは難しい。一方で、*BR*は年あたりの予測の回数であり、したがって、例えば月に一度、市場の上げ下げのみを予測するよりも、月に一度、多くの個別銘柄の予測をする方が予測の回数が増加する。よって、個別銘柄を対象にした予測が重要となる。

しかしながら、前述したとおり、そのような個別銘柄を対象にした研究は、特に日本の株式市場を対象としたものは稀であるのが現状である。そこで本研究では、日本の株式市場を対象として、ニュースからセンチメントを抽出し、株価にどのように影響を与えるかを明らかにする。そのため、3つの研究目的を設定した。1つ目は、先行研究でもある通り、一般的な極性辞書を用いてニュースから個別企業に対するセンチメントを抽出し、個別銘柄の株価にセンチメントが影響を与えるかどうかを長期のデータを利用して確認する。2つ目は、より精度の高いセンチメント抽出のモデルを構築である。金融経済分野では、専門用語などもあり一般的な極性辞書でそのすべてをとらえることができない。また辞書ベースでは文脈全体をとらえるのには適していない。そこで金融経済のテキストとニューラルネットワークを用いて、より精度の高いセンチメント抽出モデルの利用の提案を行う。3つ目は、提案したセンチメント抽出モデルでニュースから個別企業に対するセンチメントを抽出し、ポートフォリオシミュレーションを行い、センチメントがどの程度先の株価まで影響するのかを明らかにする。

2.5 おわりに

本章では、まず自然言語処理によるテキストデータからの情報抽出の手法についての説明を行った。次に、金融分野における自然言語処理の活用の先行研究について概説した。その後、金融分野における自然言語処理の課題と本研究の焦点について明らかにした。自然言語処理による情報抽出については、まず基本的な言語の解析方法についての概観を行い、その後、本研究で用いるニューラルネットワークを用いた自然言語処理について、いくつかのアルゴリズムをもとに、その自然言語処理での活用方法について説明した。先行研究の概説では、テキストを活用した株価予測についてサーベイを行った。財務情報を活用した研究と比較して、テキストを活用した研究はまだまだ数が少ない。そのような中でもニュースの株価への影響を調査したものはいくつかあった。しかしながら、米国の株式市場を対象としたものが多く、また個別銘柄を対象にした分析よりも市場全体の動きとの関係を研究したものが多く、日本の株式市場の個別銘柄を対象としたものはまだまだ数が少なく、分析の期間も数年程度と短い。資産運用においては個別銘柄の予測が非常に重要となってくる。したがって、本研究では、日本の株式市場の個別銘柄を対象として、ニュースから効率的にセンチメントを抽出することを提案し、投資戦略に活用できるかどうかを明らかにする。

第3章 極性辞書を用いたセンチメントの抽出 および株価への影響

3.1 はじめに

本章では、日本の上場企業に関するニュースが株式市場にどのように影響を与えるのかを検証する。本章におけるニュースとは、日本経済新聞朝刊に掲載されたニュースの事を指す。大量のニュース情報に対して極性辞書を用いてセンチメント測定し、以下の2点の評価を行う。1点目は、ニュースのセンチメントが株価にどのような影響を与えるのかを評価する。もう1点は、ニュースのセンチメントを投資戦略に活用できるかを評価する。

3.2 ニュースと株価の関連性仮説

ここでは、個別銘柄において、当該銘柄のニュースが株価に与える影響を調査するため、以下に示す3つの仮説を構築し、検証する。

仮説(ア) ポジティブ（ネガティブ）なニュースが出たら、その後の当該企業の株価は上昇（下落）する。

前川ら(9)では多くの投資家は、ニュースを見てその内容を判断し、投資行動を決定すると述べられている。従って、ある企業にとってポジティブなニュースが出れば投資家はその企業の株を買うという投資行動をおこし、結果として株価があがると考えられる。

仮説(イ) 仮説(ア)の影響は1面の記事のほうがその影響が大きくなる。

本研究におけるニュースとは新聞朝刊の記事である。1面の記事は構造的に最も人の目にとまることが多くなる。例えば[Barber 2008]では、個人投資家は注目度が高い銘柄を買う傾向にあると結論付けている。従って投資家は注目度が高い1面の情報をより投資行動に反映させると考えられる。

仮説 (ウ) 仮説 (ア)は時価総額が小さい企業ほどその影響が大きくなる。

一般的に時価総額の大きな企業は時価総額の小さな企業と比較して、多くの投資家やアナリストが注目している。よってニュース以外の手段でその内容が事前に投資家に伝わる可能性がある。従って、そのような手段が限られる時価総額の小さな企業のニュースは大きい企業と比較して影響度合いが大きくなると考えられる。

3.3 利用するデータ

3.3.1 分析ユニバース

本研究では個別銘柄を対象とするため、分析のユニバースを選定する必要がある。本来であれば日本市場に各時点で上場している全銘柄を対象としたいが、以下の2つの問題により、2017年1月末時点のTOPIX500の構成銘柄をユニバースとした。1つ目の問題点は、時価総額の小さい銘柄はニュースがほとんど出ないということである。日本において大型銘柄のユニバースとして利用されることの多いTOPIX500の構成銘柄であったとしても、時価総額の最も小さな企業のニュースの数は月に数回である。参考として2017年1月末のTOPIX500の構成銘柄の中で時価総額の大きいトヨタと、小さい日本水産のニュースの数を表3-1に示す。両社の記事の総数のうちトヨタの占める割合は95%となっており、日本水産のニュースはかなり少ない。さらに、図3-1に示す月別の比較をみても明らかである。表3-2には、さらにニュースの記載の場所についても両社の比較を行っており、1面にトヨタの記事が載るのはトヨタのニュースのうち10%程度であるのに対して、日本水産は1%にも満たない。これらよ

り TOPIX500 であっても，下の方の時価総額の銘柄はニュース記事が，時価総額が大きい銘柄と比較して非常に少ないことがわかる．

表 3-1 トヨタと日本水産のニュース数の比較

ニュースの数の比較			
ソース	トヨタ	日本水産	合計
朝刊	19346	823	20169
朝刊第2部	129	1	130
朝刊第3部	6	0	6
朝刊第4部	4	0	4
合計	19485	824	20309

表 3-2 トヨタと日本水産のニュースの記載場所の比較

ニュースの記載場所		
記載場所	トヨタ	日本水産
一面	2051	6
一面以外	17435	818
一面の割合	11.76%	0.73%




図 3-1 トヨタと日本水産のニュース数の月別の推移

3.3.2 ニュース情報

本研究では、ニュース情報として日本経済新聞（以下、日経新聞もしくは日経）の朝刊情報を活用する。日経新聞は日本の5つの全国紙のうちの1つであり、日本最大の経済紙である。朝刊の販売部数は2017年10月のデータで約260万部となっている。

日経新聞の特徴はその名の通り、経済紙であるため、株価欄を始めとして、経済や産業関係記事が多いことでよく知られる。また、日本経済新聞社が算出する日本市場の株価指数（日経平均株価）、「NIKKEI 225」の算出なども行っている。

こういったことから多くの市場参加者は日本経済新聞を読んで投資行動の参考にしていると考えられ、今回のニュース情報の対象として日本経済新聞を選択した。

ニュース情報の収集

日経新聞の朝刊情報は日経テレコンから抽出する。日経テレコンは日本経済新聞社が過去 30 年分以上の新聞・雑誌記事を中心に、国内外の企業データベース、人物プロフィールなど、幅広いビジネス情報を収録しているデータベースである。今回対象とする日経新聞朝刊の情報は、全文記事の取得が 1981 年 10 月から可能である。

日経テレコンでは記事 1 つ 1 つに証券コードをメタ情報として保有しているため、証券コードを検索条件とするとその銘柄に関連した記事を取得することができる。本研究では、この証券コードで検索した場合に結果として現れた記事を当該銘柄の関連記事として扱う。参考に検索の画面のイメージを図 3-2、図 3-3、図 3-4 に示す。このようにして分析対象銘柄に関連する記事を収集した。

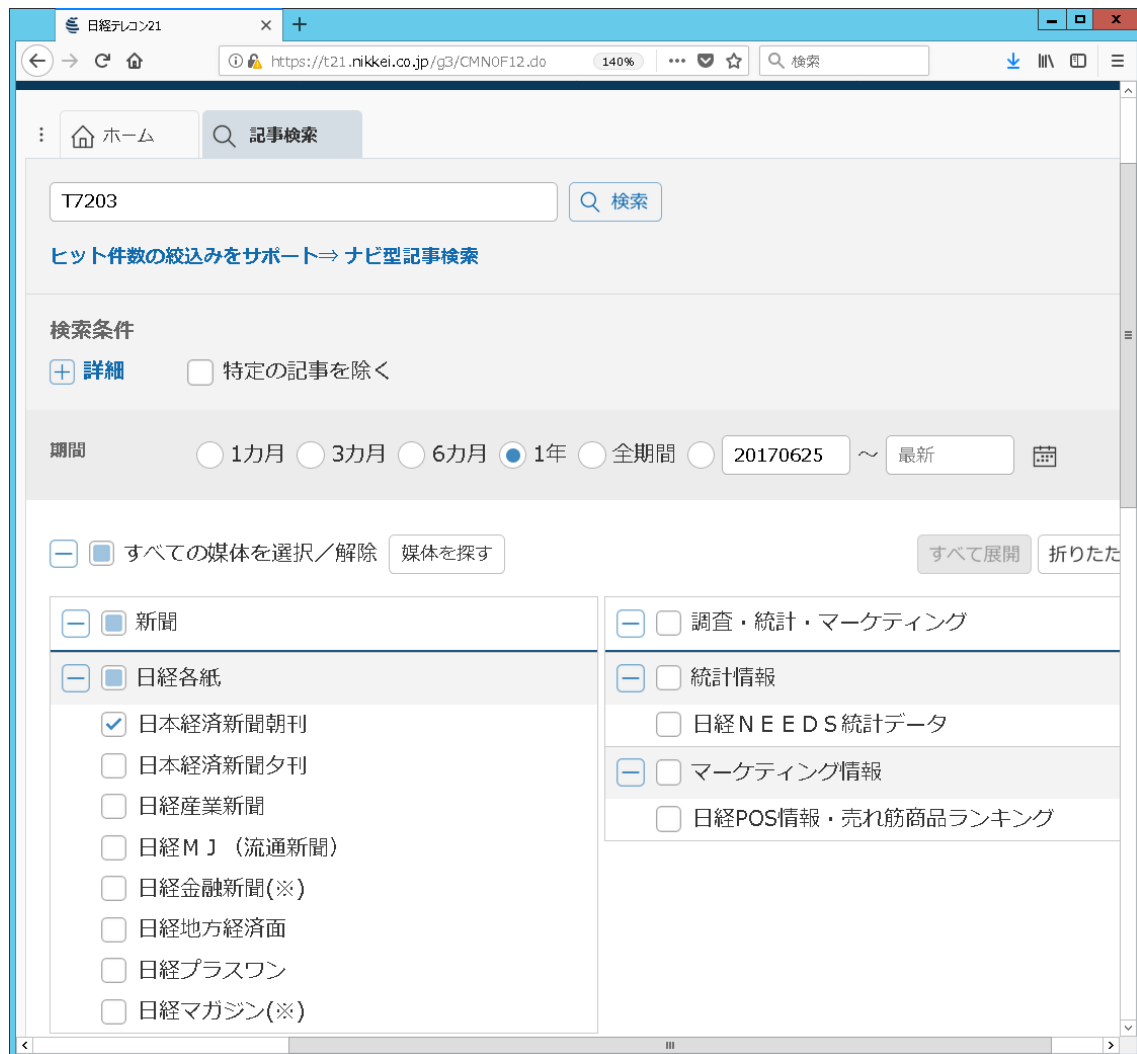


図 3-2 トヨタでの検索例(検索画面)



図 3-3 トヨタでの検索例(見出し)

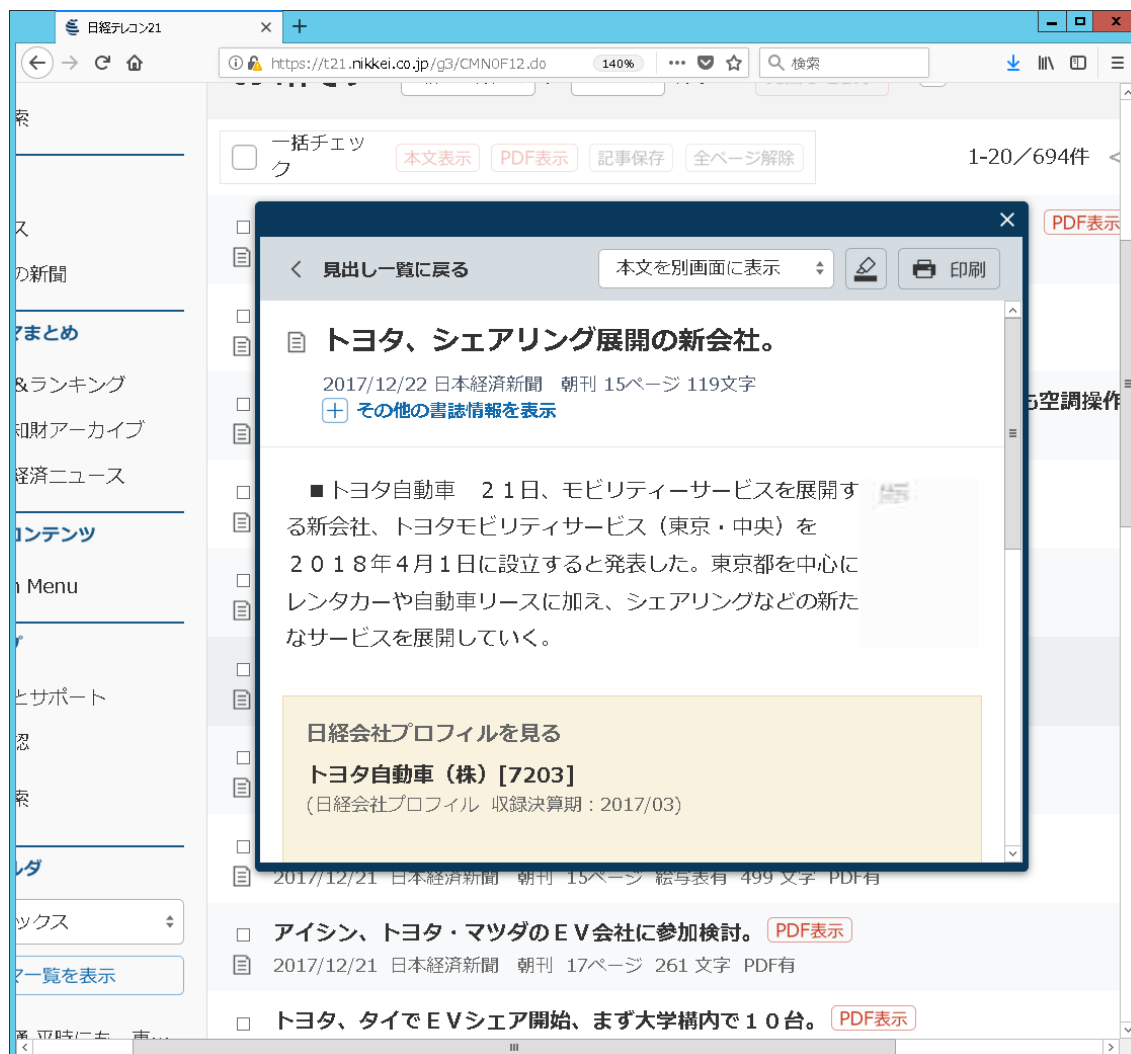


図 3-4 トヨタでの検索例(本文)

3.3.3 企業のマーケット情報および財務情報

企業のマーケット情報および財務情報に関しては、SPEEDA から取得した。SPEEDA は、BtoB 向けのオンラインサービスで、世界中の企業の情報を取得可能である。日本の上場企業の情報としては、会社概要 財務諸表（B/S, P/L, C/F）詳細財務（原価明細、借入明細など） マルチプル 市場データ（株価など） 開示資料 IR データ ニュース / 人事情報が取得可能である。株価情報については、1983 年の 1 月から日次で取得可能となっている。財務データについては同様の期間で取得可能である。

本研究では株価の日次情報を利用するため、分析期間は、株価情報に合わせて 1983 年 1 月から 2016 年 12 月末までとする。

3.3.4 極性辞書

本節では、本研究で用いる極性辞書について概観する。極性辞書とは、単語毎に極性（センチメント）が付与されており、文全体のセンチメントを計測するのに利用する。極性辞書は様々な種類が存在し、金融に特化したものも存在する。しかしながら日本語辞書で金融に特化したものは存在しない。したがって本研究では一般的な単語の極性辞書を利用することとした。具体的には、東北大学が提供している日本語評価極性辞書（用言編）と、日本語評価極性辞書（名詞編）を利用した。

日本語評価極性辞書（用言編）に関しては、用言を中心に収集した評価表現約 5 千件のリスト（小林らの評価値表現辞書）を一部改編し、人手で評価極性情報を付与したデータである。評価極性タグは次の 4 分類となっている(表 3-3)。

表 3-3 日本語評価極性辞書(用言編)の分類

	ポジティブ	ネガティブ
客観的	ポジ(経験)	ネガ(経験)
主観的	ポジ(評価)	ネガ(評価)

また、具体的な辞書の中身は表 3-4 のようになっている。

表 3-4 日本語評価極性辞書(用言編)の例

種類	番号	内容
ネガ（経験）	1	あがく
	2	あきらめる
	3	あきる
	4	あきれる
	5	あせる
ネガ（評価）	1	あいた口がふさがらない
	2	あきれるてものが言えない
	3	あくが強い
	4	あくどい
	5	あざとい
ポジ（経験）	1	あこがれる
	2	あじわう
	3	かなう
	4	こだわりがある
	5	したう
ポジ（評価）	1	あう
	2	あか抜ける
	3	あでやかだ
	4	あでやかです
	5	あわせやすい

本研究では、客観的、主観的の区別は利用せずポジティブ、ネガティブの分類のみ

を利用した。また，日本語評価極性辞書（用言編）ver.1.0（2008 年 12 月版） / Japanese Sentiment Dictionary (Volume of Verbs and Adjectives) ver. 1.0 を利用した。

日本語評価極性辞書（名詞編）は，評価極性を持つ（複合）名詞，約 8 千 5 百表現に対して評価極性情報を付与した，人手によるチェック済みのデータとなっている。名詞の評価極性は概ね以下の基準に従っている[Higashiyama 2008]。

- ～である・になる(評価・感情)主観：「○○が～である・～になる」ことは，○○を P/N と評価しているか？
- ～である・になる(状態)客観：「～(という状態)になる」ことは良いことか悪いことか？
- ～い(評価・感情)主観：「～い」は良いか悪いか？
- ～する(感情)主観：「～する」は良い感情か，悪い感情か？
- ～する(出来事)：「～する」ことは嬉しいことか嫌なことか？
- ～する(行為)：「～する」と，その人は賞賛されるか非難されるか？「～される」と嬉しいか嫌か？
- ～がある・高まる(存在・性質)：「～がある・増える・高まる」と良いか悪いか？
- ～に行く(場所)：「～にいる・行く」は嬉しいことか嫌なことか？

名詞編の辞書の中身は表 3-5 のようになっている。

表 3-5 日本語評価極性辞書(名詞編)の例

極性	名詞	係受け例
ポジティブ	あこがれ	～がある・高まる (存在・性質)
	あざやか	～である・になる (状態) 客観
	あたたかさ	～がある・高まる (存在・性質)
	あっぱれ	～である・になる (評価・感情) 主観
	あでやか	～である・になる (状態) 客観
ネガティブ	あいまい	～である・になる (評価・感情) 主観
	あからさま	～である・になる (評価・感情) 主観
	あきらめ	～がある・高まる (存在・性質)
	あせも	～である・になる (状態) 客観
	あだ	～である・になる (評価・感情) 主観

これらの 2 つの辞書を利用して、本研究ではニュースの極性を評価する。

3.4 分析条件

3.4.1 分析対象データ

分析対象データは、2017 年 1 月末時点の TOPIX500 の構成銘柄とする。

TOPIX500 とは日本の代表的な株式指数である TOPIX の構成銘柄のうち時価総額上位 500 銘柄のみで構築される株式指数である。この指数を選択した理由として、時価総額が小さい企業は、ニュースがそもそも存在しない可能性があるためである。加えて、時価総額の小さな企業は大きな企業と比較して売買の流動性が低いことが多く、実務上売買ができないなどの問題が生じるためである。TOPIX500 の構成銘柄であれば、このような問題は解消される。しかしながら、2017 年 1 月末時点で TOPIX500

の中で相対的に時価総額が小さいマルハニチロの 2016 年のニュースの数は 24 であり、相対的に大きいトヨタの同期間のニュースの数は 641 と、TOPIX500 の構成銘柄であっても相対的に時価総額の小さい銘柄のニュースの数は非常に少ないことがわかる。

分析期間は 1983 年 1 月初めから 2016 年 12 月末までとする。ニュース情報は、日本経済新聞朝刊の記事情報を日経テレコンから取得し利用する。各記事には、メタ情報としてどの企業に関するニュースかという情報が付与されている。これを用いて、ニュースと企業とのマッチングを行う。同一の記事に対して複数の企業がメタ情報として含まれることもあるが、この場合にはそれぞれの企業に関する記事として扱う。また、何面の記事であるかというメタ情報も含まれており、これにより 1 面の記事かどうかの判定を行う。月毎のニュース数の推移を図 3-5 に示す。当初はニュースの数は毎月 1000 件未満であったが、2000 年前後で 2000 件を超えてピークを迎え、足元では 1500 件前後で推移している。




図 3-5 月毎のニュースの推移

個別企業に関する株価，時価総額およびマーケットデータは，SPEEDA から取得する．個別銘柄のリターンは株価情報を用いて計算を行う．リターンを計算するにあたって，配当はデータが取得できなかったため加味されていない．個別銘柄のリターンと TOPIX のリターンから超過リターンを算出する．全 367,248 サンプルの超過リターンおよび時価総額の要約統計量を表 3-6 に示す．

記事の極性を評価するための極性辞書は，東北大学で公開されている日本語評価極性辞書の用言編[Kobayashi 2005]，名詞編[Higashiyama 2008]を利用する．

表 3-6 超過リターンと時価総額の要約統計量

	超過リターン	時価総額
平均	0.001	1.48e+12
標準偏差	0.023	2.46e+12
最小値	-0.628	2.81e+09
25%	-0.010	2.98e+11
中央値	0.000	7.19e+11
75%	0.011	1.64e+12
最大値	0.484	4.33e+13

3.4.2 ニュースの極性評価

ニュースの極性は，先述の極性辞書を用いて評価する．用言編，名詞編ともに，ポジティブもしくはネガティブの極性が付与されている単語のみを抽出し利用する．ポジティブと評価される単語は約 4,000 単語，ネガティブと評価される単語は約 6,000 単語である．

次に企業毎にその日に発表された記事全てをマージし，1つのテキストとする．このテキストに対して形態素解析エンジン MeCab (<http://taku910.github.io/mecab/>) を用いて形態素解析を行う．形態素解析を行う際に用いた辞書は標準の IPA 辞書に加え

て、日本語評価極性辞書の名詞編の単語を追加している。形態素解析結果において活用語となる形態素は、全て基本形に変換し、極性辞書の単語と照合する。ある企業 i の時点 t のニュースの極性を、センチメントスコア $x_{i,t}$ とする。センチメントスコア $x_{i,t}$ は、式 (3-1) で算出する。 $w_{p,i,t}$ はポジティブな単語の出現回数、 $w_{n,i,t}$ はネガティブな単語の出現回数、 $w_{a,i,t}$ は全単語数(形態素の総数)である。

$$x_{i,t} = \frac{(+1) \times w_{p,i,t} + (-1) \times w_{n,i,t}}{w_{a,i,t}} \quad (3-1)$$

例えば、「トヨタの決算は良かった。」という文があったとすると、「トヨタ / の / 決算 / は / 良い / た / 。」と形態素に分解し、基本形とする。この中で極性辞書ではポジティブな単語は「良い」の 1 個、ネガティブな単語は 0 個、全形態素の数は 7 であることから、センチメントスコアは $(1 + 0) / 7 \cong 0.143$ となる。同じポジティブ若しくはネガティブな単語が複数文章に含まれているとすると重複してカウントされる。

全ニュースのセンチメントスコアの分布を図 3-6 に、要約統計量を表 3-7 に示す。センチメントスコアは正規分布に近いことがわかる。センチメントスコアが 0 のデータが多いのは極性辞書の単語が含まれないニュースが多く存在することを示している。ニュースの中には社債の発行金額のみが記載されている記事も存在しており、このような記事には極性を振ることができない。要約統計量より、センチメントスコアは平均的には正であることがわかる。この主たる要因として、新聞記事自体が広告等の関係からポジティブな記事が多くなるというバイアスや、対象が 2017 年 1 月末時点の TOPIX500 の構成銘柄であるというサバイバーシップバイアスが影響している。




図 3-6 センチメントスコアのヒストグラム

表 3-7 センチメントスコアの要約統計量

	全サンプル	0を除いたサンプル
総数	367248	348659
平均	0.025	0.026
標準偏差	0.027	0.027
最小値	-0.200	-0.200
25%	0.009	0.012
中央値	0.025	0.026
75%	0.040	0.041
最大値	0.292	0.292

3.5 仮説の検証と結果

3.5.1 検証方法

仮説の検証については、対象となる全期間と全銘柄のパネルデータを用いて回帰分析で行う。被説明変数を個別企業の対マーケット超過リターンとする。ここでマーケットリターンは、SPPEDA から取得する TOPIX の(プライス)リターンである。超過リターンを計算するにあたってはマーケットベータの調整は行わない。リターンは、朝刊の日付の前営業日の終値から、朝刊の日付の終値までの価格変化率として計測される。説明変数は各時点の個別企業のセンチメントスコアである。また仮説毎に必要な変数を適宜説明変数として加える。

仮説（ア）の検証

仮説（ア）を式の回帰分析で検証する。

$$r_{i,t} = \beta_0 + \beta_1 x_{i,t} + \varepsilon \quad (3-2)$$

ここで、 i は個別企業を、 t は時点を表す。 r は超過リターン、 x はセンチメントスコアである。仮説より、 β_1 の符号は正であることが期待される。

この回帰分析の結果を 表 3-8 に示す。

結果より、センチメントスコアの係数 β_1 は正である。さらに係数が 0 と有意に異なるかどうかを判定する p 値も 0.1%水準であり、統計的に有意である。よって、仮説の通り、企業に関するニュースがポジティブ（ネガティブ）な場合は記事発表後の株価リターンに正（負）の影響を与えることがわかる。次に、その影響の大きさについて検討する。センチメントスコアの係数は 0.026 であり、センチメントスコアの標準偏差は 0.027 である。このことから、センチメントスコアが 1 標準偏差大きくなると、超過リターンには 7.0bp の影響を与えることがわかる。

表 3-8 仮説（ア）の検証結果

説明変数	係数	t 値
切片 β_0	0.000	1.96*
センチメントスコア β_1	0.026	17.87**
自由度修正済み決定係数	0.001	
データ数	367248	

*means p-value < 0.05, ** means p-value < 0.01, *** means p-value < 0.001

仮説（イ）の検証

仮説（イ）を式の回帰分析で検証する．

$$r_{i,t} = \gamma_0 + \gamma_1 x_{i,t} + \gamma_2 D_{i,t} + \gamma_3 D_{i,t} x_{i,t} + \varepsilon \quad (3-3)$$

ここで、仮説(ア)と同じく、 r は超過リターン、 x はセンチメントスコアである．仮説(イ)では1面の影響を調査したいため、新たに D というダミー変数を導入している．このダミー変数はセンチメントスコアを計算する際のニュース記事の中に1面の記事が含まれていれば1となる．今回のサンプルでは、1面記事を含んだ記事から測定されたセンチメントスコアは26,743件存在する．仮説により、センチメントスコアのみ係数 γ_1 と、センチメントスコアとダミー変数との交差項の係数 γ_3 が、ともに正であることが期待される．

この回帰分析の結果を表 3-9 に示す．

結果より、センチメントスコアの係数 γ_1 および γ_3 は正である．係数が0と有意に異なるかどうかを判定する p 値もそれぞれ0.1%水準で、ともに統計的に有意である．即ち、仮説の通り、企業に関するニュースがポジティブ(ネガティブ)な場合は記事発表後の株価リターンに正(負)の影響を与え、さらに、その影響は1面の記事が含まれているほど大きくなることがわかる．次に、1面の記事の影響の大きさについて

検討する．1面ダミーの係数 γ_3 は，センチメントスコアの係数 γ_1 の 1.32 倍と非常に大きい．従って，1面の記事があるとその影響は1面にない場合と比較して，トータルではセンチメントスコアの係数の影響とダミー係数の影響の和で 2.32 (=1+1.32) 倍となる．先ほどと同様の計算でセンチメントスコアが 1 標準偏差大きくなり，さらに1面の記事である場合の超過リターンには 15.6 bp の影響を与える．

表 3-9 仮説 (イ) の検証結果

説明変数	係数	t 値
切片 γ_0	0.000	2.02*
センチメントスコア γ_1	0.025	16.55**
1面ダミー γ_2	-0.001	-1.91
1面ダミー×センチメントスコア γ_3	0.033	4.54**
自由度修正済み決定係数	0.001	
データ数	367248	

*means p-value < 0.05, ** means p-value < 0.01, *** means p-value < 0.001

仮説 (ウ) の検証

仮説 (ウ) を式の回帰分析で検証する．

$$r_{i,t} = \delta_0 + \delta_1 x_{i,t} + \delta_2 m_{i,t} + \delta_3 m_{i,t} x_{i,t} + \varepsilon \quad (3-4)$$

ここで，仮説(ア)と同じく， r は超過リターン， x はセンチメントスコアである．仮説(ウ)では時価総額の影響を調査するため，対数時価総額 m を導入している．ここで対数時価総額とは時価総額の自然対数をとったものである．仮説により，センチメントスコアのみ係数 δ_1 は正になることが期待される．一方，センチメントスコアと時価総額との交差項の係数 δ_3 は，時価総額が小さいほど影響が大きくなることが期待されることから，負になることが期待される．

この回帰分析の結果を 表 3-10 に示す．

結果より，センチメントスコアの係数は δ_1 は正で， δ_3 は負であり，係数が 0 と有意に異なるかどうかを判定する p 値もそれぞれ 0.1%水準で，統計的に有意である．このことから，仮説の通り企業に関するニュースがポジティブ(ネガティブ)な場合は記事発表後の株価リターンに正(負)の影響を与えることが，時価総額の大小でその影響が変わってくることがわかる．その影響の大きさについて検討する．今銘柄が 2 銘柄存在し，センチメントスコアは同じで対数時価総額がサンプルの 1 標準偏差異なる場合に，超過リターンは，日率で 1.2%変わってくる(時価総額が小さい銘柄でより影響が大きくなる)．これは非常に大きく経済的にも意味があるものである．

表 3-10 仮説 (ウ) の検証結果

説明変数	係数	t 値
切片 δ_0	-0.002	-1.51
センチメントスコア δ_1	0.343	10.46***
対数時価総額 δ_2	0.000	-1.65
対数時価総額×センチメントスコア δ_3	-0.012	-9.68***
自由度修正済み決定係数	0.001	
データ数	367248	

*means p-value < 0.05, ** means p-value < 0.01, *** means p-value < 0.001

仮説 (ウ) のロバストネスチェック

仮説 (ウ) の検証で時価総額の大小がセンチメントの効果の影響を変えることが明らかとなっている．ここでさらに，ロバストネスチェックとして，時価総額の小さい企業がその影響を変えるのか，時価総額の大きい企業がその影響を変えるのかをより明確に調査する．ここでは時価総額の大きい企業の定義を各時点上場している銘柄の時価総額を用いてその大きさが上位 20%であるものと定義する．逆に時価総額が小さい企業を時価総額の大きさが下位 20%であるものと定義する．時価総額の大小の影響

を別々に確認するために、以下の式を用いて、検証を行う。

$$r_{it} = \varphi_0 + \varphi_1 x_{it} + \varphi_2 S_{it} + \varphi_3 S_{it} x_{it} + \varphi_4 L_{it} + \varphi_5 L_{it} x_{it} + \varepsilon \quad (3-5)$$

ここで、 r は超過リターン、 x はセンチメントスコアである。 S および L はダミー変数であり、それぞれ先ほど定義した時価総額の小さい企業もしくは大きい企業に該当する場合に 1 となる。仮説により、センチメントスコアのみ係数 φ_1 およびセンチメントスコアと時価総額の小さい企業を示すダミー変数との交差項の係数 φ_3 は正になることが期待される。一方時価総額の大きい企業を示すダミー変数との交差項の係数 φ_5 の正負はどうか不明である。

この回帰分析の結果を 表 3-11 に示す。

結果より、センチメントスコアの係数は φ_1 は正で、係数が 0 と有意に異なるかどうかを示す p 値は 0.1%水準で統計的に有意となり、期待通りである。一方、時価総額が小さい企業でセンチメントスコアの影響度が強まるかどうかを確認する係数 φ_3 に着目すると、こちらも符号は正で統計的に有意である。つまり時価総額が小さい企業はセンチメントスコアの影響度を強めることがわかる。一方、時価総額が大きい企業のセンチメントスコアの影響度がどうかを確認する係数 φ_5 に着目すると、こちらの符号は負で統計的に有意である。したがって、時価総額が小さい企業はセンチメントスコアの影響を強めるだけではなく、時価総額の大きい企業はセンチメントスコアの影響を弱めることがわかる。時価総額の小さな企業はアナリストカバレッジや機関投資家の保有比率が低く情報量が少ないため、ニュースに大きく反応する。一方で、時価総額の大きな企業は、アナリストカバレッジや機関投資家の保有比率が高く、ニュース以外での情報量が大きいため、ニュースの内容自体がすでに株価に織り込まれている可能性があり、ニュースの影響が低下すると考えられる。

表 3-11 仮説 (ウ) のロバストネスチェックの検証結果

説明変数	係数	t 値
切片 φ_0	0.000	1.14
センチメントスコア φ_1	0.032	15.68***
小型ダミー φ_2	-.000	1.31
小型ダミー×センチメントスコア φ_3	0.018	3.48***
大型ダミー φ_4	0.001	1.09
大型ダミー×センチメントスコア φ_5	-0.020	-6.35***
自由度修正済み決定係数	0.001	
データ数	367248	

*means p-value < 0.05, ** means p-value < 0.01, *** means p-value < 0.001

3.6 センチメントスコアを活用した投資行動

本節では、実際にセンチメントスコアを投資戦略に活用できるかどうかを検証する。前節では、朝刊のニュースが当日のリターンにどのように影響を与えるかということ明らかにした。しかしながら、このリターンは実際の投資では獲得不可能なものである。先行研究では、ニュースのセンチメントがマーケット全体の動きを予測することを明らかにしている。これが個別の銘柄であっても同様に予測可能であるかは非常に興味深い。もしそうであれば投資戦略として活用することができる。そこで本節では、より現実に近い形で、ニュース発表当日の株式市場が開始する前場から翌日の前場までで獲得できるリターンを用いて検証する。ニュースは朝刊で発表されるものを利用しているため、前場の開始時刻の 9:00 と比較して十分に早く、実際に投資可能な想定であると考えられる。具体的には、センチメントスコアの大きさを基準に銘柄を分け、ポートフォリオを構築し銘柄を保有した場合のパフォーマンスを検証する。

3.6.1 ポートフォリオの構築方法

センチメントスコアを用いて、ポートフォリオをどのように構築するかについて説明する．先述の通り、毎朝発刊される朝刊に記載のニュースから抽出される各企業のセンチメントスコアを利用して、株式の取引が始まる午前 9 時から翌営業日の午前九時までセンチメントスコアの大きさに分割したポートフォリオでの投資を行う．この投資の概念図を図 3-7 に示す．

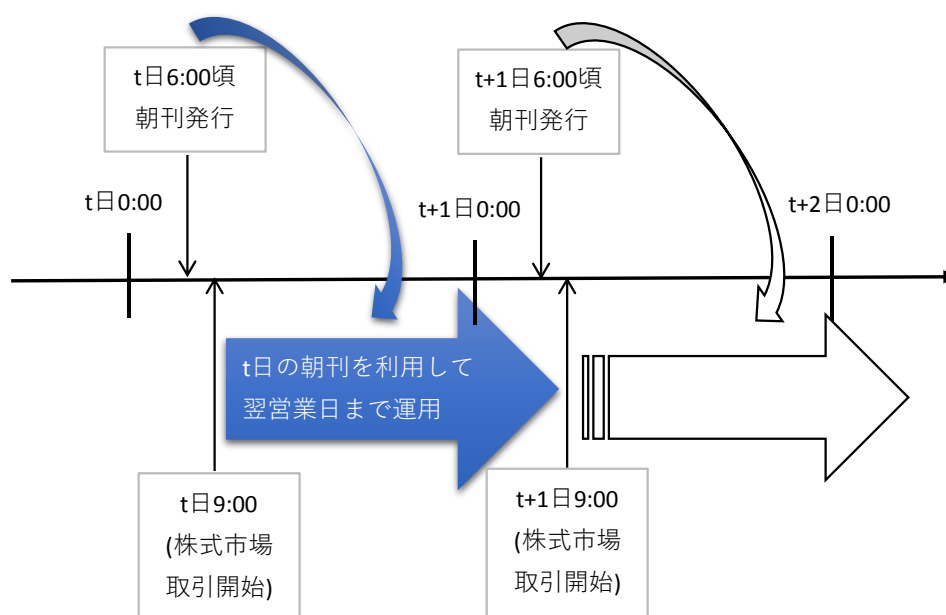


図 3-7 投資行動の概念図

具体的にはセンチメントスコアの存在する銘柄を、そのスコアの大きさに 3 つの銘柄群を作成する．例えばある日のニュースセンチメントが 300 銘柄分存在するとすれば、スコアの大きい順に 100 銘柄ずつ 3 つの銘柄群を作成する．この概念図を図 3-7 に示す．その後、各銘柄群でポートフォリオを構築する．ポートフォリオのウェイト

は、等ウェイトと時価加重ウェイトで計算する。等ウェイトポートフォリオとは、銘柄をそれぞれ同じウェイトで保有するポートフォリオのことであり、時価加重ウェイトポートフォリオとは、銘柄をその時価総額に比して保有するポートフォリオのことである。ウェイトの計算方法は式(6)、式(7)に示す通りである。

$$w_{eq,i,T} = \frac{1}{n} \quad (3-6)$$

$$w_{cap,i,T} = \frac{NAV_{i,T}}{\sum_{i=1}^n NAV_{i,T}} \quad (3-7)$$

ここで n は銘柄総数、 i は銘柄、 T は時点(日)を表す。 $w_{eq,i,T}$ は、等ウェイトポートフォリオでのウェイト、 $w_{cap,i,T}$ は時価加重ウェイトポートフォリオでのウェイトである。 $NAV_{i,T}$ は、時点 T の前場開始時点、銘柄 i の時価総額である。この時価総額は浮動株を調整していない。

分析ユニバースは、前節と同じく 2017 年 1 月末時点の TOPIX500 の構成銘柄で、分析期間は 1983 年 1 月末から 2016 年 12 月末までである。

最低 10 銘柄が各ポートフォリオに含まれるようにする。この条件を満たすようなニュースが少ない日についてはポートフォリオを構築しない。各ポートフォリオをニュース発表当日の前場で投資し、これを翌日の前場まで 1 日間バイアンドホールドした場合のパフォーマンスを検証する。センチメントの大きさによる投資行動が有効かどうかの比較のためにベンチマークとして全銘柄で計算したポートフォリオのパフォーマンスを利用する。このベンチマークはセンチメント情報を利用していないため良い比較対象であると考えられる。各ポートフォリオでの平均的な銘柄数は、センチメントが最も高いポートフォリオで 16 銘柄、次に高いポートフォリオで 16 銘柄、最も低いポートフォリオで 17 銘柄であった。

3.6.2 パフォーマンス

2 つのウェイトで構築したポートフォリオを実際に運用した結果を考察する。

等ウェイトポートフォリオ

等ウェイトポートフォリオの結果を 表 3-12 に示す。表 3-12 では 5 つのポートフォリオ（列方向）に対して 7 項目（行方向）を示す。1 列目の全銘柄はその名の通り全銘柄を組み入れたポートフォリオを表し、スコアで分けたポートフォリオに対するベンチマークとなる。2 列目から 4 列目までの Q1 から Q3 は、それぞれ、前項で述べたスコアの大きさで分類されたポートフォリオを表す。Q1 はスコアが高い銘柄で、Q3 はスコアが低い銘柄群でそれぞれ構成されたポートフォリオである。最後の列の Q1-Q3 は Q1 のポートフォリオを買うと同時に Q3 のポートフォリオを売るというポートフォリオを表す（ロングショートポートフォリオと呼ばれる）。7 項目については、リターンはポートフォリオの日次のリターンを年率化したものを表す。リスクは、ポートフォリオの日次のリターンの標準偏差を年率化したものを表す。リターン/リスクは、リターンをリスクで割ったものである。一般的にリスクあたりのリターンが高い方が良いとされる。 α は各ポートフォリオのベンチマークに対する日次の超過リターンを年率化したものである。T.E. はトラッキングエラーであり、日次の α の標準偏差を年率化したものである。IR はインフォメーションレシオであり、 α を T.E. で割ったもので、こちらも一般的に高い方が良いとされる。p 値は α が統計的に有意に 0 と異なるかどうかの t 検定の結果である。 α 以降の 4 つの項目については対ベンチマークに対する値であり、ベンチマークとなる全銘柄ポートフォリオの値は N.A. となる。

表 3-12 に示す結果からわかるように、等ウェイトポートフォリオでは、センチメントスコアが高い銘柄のパフォーマンスは、低い銘柄と比較して高い。さらに全銘柄の平均値と比較しても高いパフォーマンスとなっている。最も高い分位の Q1 の全銘柄平均に対する IR は 0.32 となっている。 α は年率 2.4% と経済的にも有意なものの、p 値は 8.7% と統計的に有意とは言えない。一方、センチメントスコアの最も低い分位の全銘柄平均に対する α は年率 -2.8% で IR は -0.37 である。こちらも α は経済的には大きい、統計的に有意とは言えない。スコアの大きい銘柄群を買い、小さい銘柄群を売る戦略(Q1-Q3)では、年率 5% とより大きな α を獲得できる。IR も 0.39 となる。この α は経済的にも統計的にも有意である。これらの結果より、センチメントスコアによる等ウェイトポートフォリオ投資戦略が有効であることがわかる。

1983 年を 1 としたときの等ウェイトポートフォリオの超過リターンの累積の推移を図 3-8 に示す。図 3-8 より 1983 年から投資した場合のパフォーマンスは Q1 が最も高いことがわかる。特に IT バブルのころに、ベンチマークに対して大きく超過リターンを挙げている。その後リーマンショックで大きく価値を棄損し、足元ではほぼ横ばいの傾向にある。

表 3-12 等ウェイトポートフォリオのパフォーマンス

	全銘柄	Q1(高)	Q2	Q3(低)	Q1-Q3
リターン	9.7%	12.1%	9.9%	6.9%	--
リスク	22.8%	23.8%	24.2%	24.1%	--
リターン/リスク	0.42	0.51	0.41	0.29	--
α	--	2.4%	0.2%	-2.8%	5.2%
T.E.	--	7.5%	7.6%	7.6%	13.3%
IR	--	0.32	0.03	-0.37	0.39
p 値	--	8.7%	86.3%	5.3%	3.8%

(注)全て年率化済




図 3-8 等ウェイトポートフォリオの累積パフォーマンス

時価加重ウェイトポートフォリオ

時価加重ウェイトポートフォリオの表 3-13 に、パフォーマンスの推移を図 3-9 に示す。

結果からわかるように、センチメントスコアが高い銘柄群(Q1)のパフォーマンスは、センチメントスコアが低い銘柄群(Q2)と比較して高い。しかしながら全銘柄で構築したベンチマークと比較するとそのリターンはほとんど同程度という結果になっている。またセンチメントが低い銘柄で構築された Q3 ポートフォリオもベンチマークよりわずかに悪いという結果である。Q1 から Q3 のすべてのポートフォリオの α は統計的にも経済的にも有意とは言えない結果である。超過リターンの推移のグラフを見ると等ウェイトポートフォリオの場合とは異なり、スコアの中位の銘柄群(Q2)のパフォーマンスが Q1 とほとんど同程度であり、各ポートフォリオ間での線形関係が見られない。

時価加重ウェイトポートフォリオが等ウェイトポートフォリオと比較してあまりパフォーマンスが優れない要因として、2 つ考えられる。1 つ目は、前節でも検証を行

ったが、時価総額の大きな企業のニュースはマーケット参加者の注目度も高く加えて新聞以外の情報元によって、株価に情報が織り込まれるスピードが速いことが考えられる（時価加重ウェイトポートフォリオは等ウェイトポートフォリオと比較して時価総額の大きな企業の影響が大きくなる）。2つ目は時価総額加重でポートフォリオを構築しているため、場合によっては1つの時価総額の大きい企業でそのポートフォリオのパフォーマンスが決まってしまうことがあるためである。実際、多数の時価総額が小さい銘柄群と1つの大きな銘柄群でポートフォリオが構築され1銘柄のウェイトが50%を超えることもある。平均的にセンチメントの効果を獲得できる等ウェイトポートフォリオと比較して、ポートフォリオ内の1つの巨大銘柄の影響がこの違いを生み出した可能性がある。

パフォーマンスの推移を見ると、どちらのポートフォリオも2000年ごろまでは有効に機能しているように見える。それ以降はその有効性は低下している。この原因として、今回は朝刊のニュースを利用しているが、インターネットの発達により投資家はすぐにニュースを受け取り投資行動に移すようになったため、株価への情報の折込みスピードが速くなったのではないかと考えられる。

表 3-13 時価加重ウェイトポートフォリオのパフォーマンス

	全銘柄	Q1(高)	Q2	Q3(低)	Q1-Q5
リターン	4.6%	4.6%	4.8%	4.1%	--
リスク	24.7%	26.4%	26.5%	25.6%	--
リターン/リスク	0.19	0.18	0.18	0.16	--
α	--	0.0%	0.2%	-0.6%	0.6%
T.E.	--	9.8%	9.2%	10.7%	17.0%
IR	--	0.00	0.02	-0.05	0.03
p 値	--	99.5%	91.5%	77.7%	86.2%

(注)全て年率化済




図 3-9 時価加重ウェイトポートフォリオの累積パフォーマンス

3.7 おわりに

本章では、極性辞書を用いて測定したニュースのセンチメントが、株式市場に影響を与えることを確認した。具体的には、次の2点を明らかにしている。1点目は、ニュースのセンチメントが株価にどのような影響を与えるのかであり、もう1点は、ニュースのセンチメントを投資戦略に活用できるかである。

1点目については、3つの仮説を立て、それぞれ検証を行った。仮説(ア)は、ポジティブ(ネガティブ)なニュースが出たら、その後の当該企業の株価は上昇(下落)するというもので、回帰分析の結果は、仮説を採択した。多くの投資家は、ニュースを見てその内容を判断し投資行動を決定していると考えられる。仮説(イ)は、1面の記事ほど

仮説（ア）の影響が大きくなるというものである。同じく回帰分析の結果により、この仮説が正しいことを確認された。やはり 1 面の記事は、2 面以降の記事よりも多くの投資家の目に止まりやすく、投資家が投資行動の判断材料とする可能性が他の面よりも高いことが要因であろう。仮説（ウ）は時価総額が小さい企業ほど仮説（ア）の影響が大きくなるというものである。こちらの仮説についても結果は仮説を採択された。さらにはロバストネスチェックの結果により、時価総額が小さい企業ほど仮説（ア）の影響が大きくなるだけでなく、時価総額が大きい企業ほど仮説（ア）の影響が小さくなることも明らかにした。時価総額の大きな企業は、時価総額が小さい企業と比較して、多くのアナリストや機関投資家の保有比率が大きいため、ニュースにでるような記事はすでに株価に織り込まれている可能性があるためであると考えられる。

もう 1 点目については、センチメントスコアの高い銘柄を保有し、低い銘柄を空売りする投資戦略で高いパフォーマンスを獲得できることを明らかにした。したがって、投資家はこの戦略を活用することで超過リターンを獲得できる可能性がある。

第4章 金融分野におけるセンチメントモデルの開発

4.1 はじめに

前章では、極性辞書を用いてニュース記事からセンチメントの抽出を行った。しかしながら、一般の極性辞書を用いており、金融特有の言葉をうまく評価できない。さらに極性辞書では、単語毎に極性がついており、単語の組み合わせである文全体の評価に適さない場合が多い。このような問題を解決するため金融分野へ特化したセンチメント抽出モデルを構築したい。

本章では、金融・経済に関するレポート情報から深層学習を用いた極性判定モデルの開発を行い、一般的な極性辞書との比較を交えて日本の上場企業に関するニュースが株式市場にどのように影響を与えるのか検証する。

4.2 センチメントモデルの開発

日本語の金融経済テキストを用いて極性モデルの開発を行う。具体的には[Yamamoto 2016]を参考に景気ウォッチャー調査と深層学習を利用したモデルの開発を行う。景気ウォッチャー調査は景気や金融経済に関する調査であり、このデータを用いて極性モデルを開発することで一般的な極性辞書ではとらえることのできなかった、金融や経済などの専門的な単語がとらえられると考えられる。

4.2.1 データ

景気ウォッチャー調査とは内閣府が地域の景気に関連の深い動きを観察できる立場にある人々の協力を得て、地域ごとの景気動向を的確かつ迅速に把握し、景気動向判

断の基礎資料とすることを目的とし、毎月公表しているレポートである。対象地域は日本全国の12の地域であり、調査項目は「景気の現状に対する判断（方向性）」とその理由と説明、また「景気の先行きに対する判断（方向性）」とその理由と説明である。これらのデータをもとに内閣府が景気の動向を示す指数を算出している。実際には指数値だけでなく上記の調査項目の結果も公開されている。具体的な調査項目の例を表4-1に示す。これは2019年1月の北海道地区の景気ウォッチャー調査の「景気の現状に対する判断（方向性）」から判断の異なる5つのデータサンプルを選択したものである。

景気の判断は表4-1の1列目に示されている通り5段階で評価される。そしてその評価の具体的な説明が5列目に文章で表示されている。この5段階の評価情報(1列目)とそれを説明したテキスト(5列目)を用いてモデルを開発する。例に示したのは「景気の現状に対する判断（方向性）」であるが「景気の先行きに対する判断（方向性）」の場合にも同様に景気の先行きに対しての5段階の評価とその説明のテキストが存在する。

モデルの構築には2000年1月から2018年11月までの景気ウォッチャー調査のデータを用いた。「現状」と「先行き」の両方のデータを利用した。評価情報とテキストが正しく取得できたデータサンプル数23万4626件をモデル開発に利用する。

表 4-1 景気ウォッチャー調査の例

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
◎	一般小売店 [土産]（経営者）	来客数の動き	・ 1 月前半は穏やかな天候だったが、後半は天候の悪い日が多く、交通機関も大幅に乱れることが多かった。ただ、1 月の売上そのものは決して悪くなかった。
○	一般小売店 [酒]（経営者）	販売量の動き	・ 例年 1 月は年末商戦の反動もあり、売上が芳しくないが、今年は堅調に推移している。新規の取引先が大分増えてきていることも寄与している。
□	商店街（代表者）	お客様の様子	・ 年明けということもあり、客の動きとしてはまずまず落ち着いている。
▲	商店街（代表者）	来客数の動き	・ 初売りは前年とほぼ変わりなく推移したが、月全体をみると、大雪などの天候不順の影響で客足が大きく減少した。
×	タクシー運転手	販売量の動き	・ 売上の減少が続いている。短期的な諸要因を考慮しても景気減速との判断は否めない。

4.2.2 モデルの開発

景気ウォッチャー調査のレーティングとそのレーティングを説明したテキスト情報を用いて深層学習を利用しモデルを構築する。[Sosa 2017]では twitter のセンチメントの測定について、いくつかのモデルで検証し、LSTM と CNN が良いと結論付けて

いる．本研究もこれを参考に深層学習のモデルは LSTM と CNN を用いた．モデル開発の概念図を図 4-1 に示す．具体的には評価情報をポジティブとネガティブ 2 値に分類し，テキスト情報を分散表現して，深層学習を利用した分類問題としてモデルを構築する．

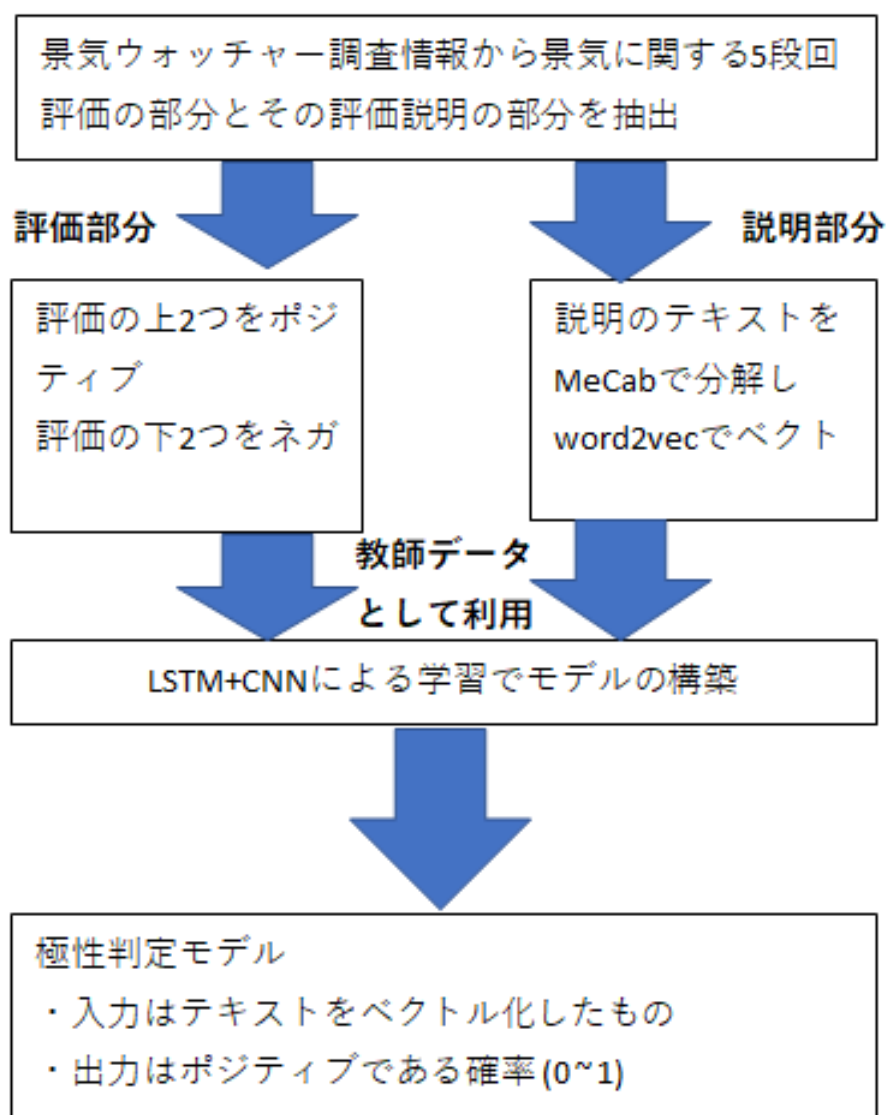


図 4-1 モデル開発の概念図

5 値問題から 2 値問題への変換

まず、景気ウォッチャー調査の評価を 5 段階からポジティブかネガティブかの 2 値に変換する。この処理を行う理由として、5 値問題だとサンプル量が少なくなってしまうことや、出力の解釈が難しなることが上げられる。本研究では問題を簡単にするため、2 値の問題に評価を変換し、モデルを構築する。具体的には 5 段階のうち良い上の 2 つの評価(サンプルの◎と○)をポジティブとし、悪い下 2 つの評価(サンプルの▲と×)をネガティブとする。5 段階のうちの真ん中の評価のものは除外した。図 4-2 にこの処理の概念図を示す。全サンプル 23 万 4626 件のうち、◎は 4216 件、○は 5 万 106 件、□は 11 万 2475 件、▲は 5 万 884 件、×は 1 万 6945 件である。これを上記の手順に従ってポジティブとネガティブのみにすると、ポジティブとなるサンプルは 5 万 4322 件、ネガティブとなるサンプルは 6 万 7829 件となり、総サンプルは 12 万 2151 件となる。

評価(5値)	サンプル数		評価(2値)	サンプル数
◎	8,897	}	ポジティブ	109,496
○	100,599			
□	223,059		--	--
▲	112,947	}	ネガティブ	151,943
×	38,996			
合計	484,498		合計	261,439

図 4-2 サンプル評価の 5 値から 2 値への変換

複文から単文への変換

次にテキストの処理を行う。評価の説明のテキストは単文であったり複文であったりする。そこで、複文であった場合には単文に分割し、分割後のそれぞれの単文には

元の複文の評価を与えるという処理を行う。例えば表 4-1 の景気ウォッチャー調査の例の◎のサンプルの場合、前述の 2 価変換の処理からポジティブに割り当てられるが、その評価の説明のテキストは複文で、「1 月前半は穏やかな天候だったが、後半は天候の悪い日が多く、交通機関も大幅に乱れることが多かった。ただ、1 月の売り上げそのものは決して悪くなかった。」である。これは 2 文からなる複文であり、「1 月前半は穏やかな天候だったが、後半は天候の悪い日が多く、交通機関も大幅に乱れることが多かった。」と「ただ、1 月の売り上げそのものは決して悪くなかった。」という 2 つの単文に分割する。そしてそれぞれのテキストについてポジティブの評価を付与する。この処理の概要図を図 4-3 に示す。

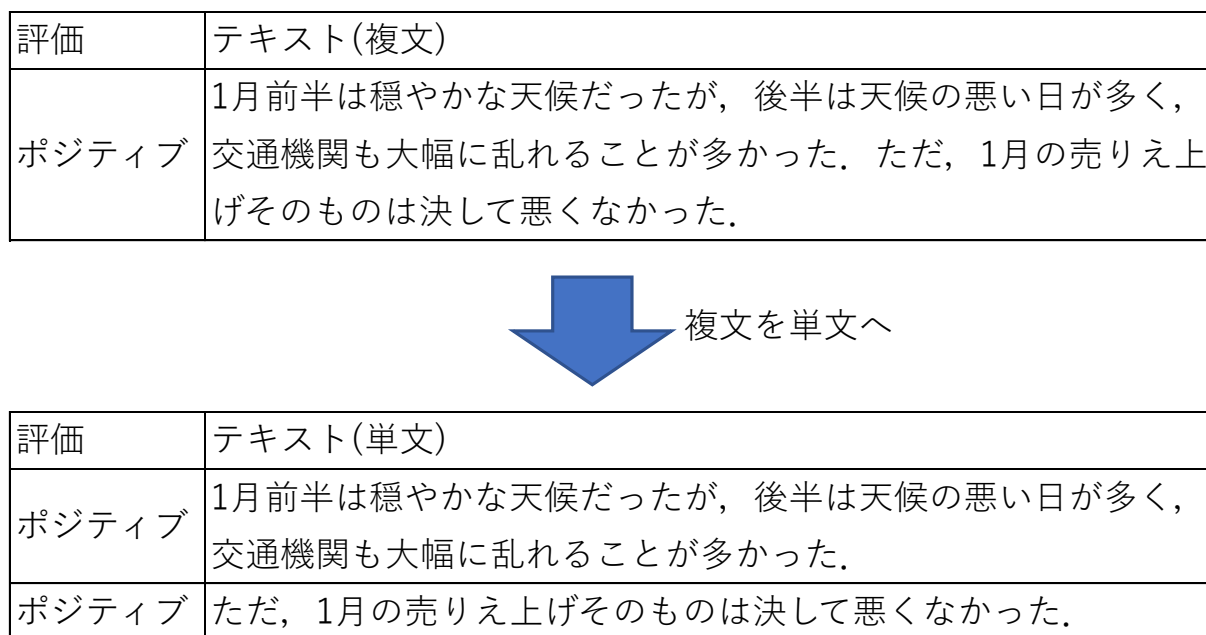


図 4-3 複文から単文へのサンプルの分割

これらの処理を行い、最終的に 40 万 1808 件のデータを得た。うちポジティブとなるサンプルが 23 万 1728 件、ネガティブとなるサンプルが 17 万 80 件でとなる。ややポジティブのサンプル数が多い。最終的なサンプル数を表 4-2 に示す。

表 4-2 最終的なサンプル数

評価	サンプル数
ポジティブ	231,728
ネガティブ	170,080
合計	401,808

テキストのベクトル化

さらにテキストの分散表現を得るための処理を行う．具体的には MeCab でテキストを分割し基本形の単語を得る．次に word2vec によって単語をベクトル化する．word2vec モデルは東北大学で公開されている「日本語 Wikipedia エンティティベクトル」(http://www.cl.ecei.tohoku.ac.jp/~m-suzuki/jawiki_vector/) を利用する．このモデルでは 120 万語を 300 次元のベクトルで分散表現できる．これによりテキストにおける各単語のベクトル情報が得られる．

深層学習モデルによるモデルの構築

最後にポジティブかネガティブの 2 値の情報とそれを説明するテキストのベクトル情報を利用して、深層学習のリカレントニューラルネットワークの 1 種である LSTM モデルと Convolution モデルを利用して(2 値)分類問題としてモデルを構築する．具体的には Bi-Directional LSTM(ユニット数 128), 1 次元 Convolution(ユニット数 64, 32), 全結合層(ユニット数 16)のネットワークを構築した．各層にドロップアウト(ドロップアウト率 0.5)を加えて活性化関数には ReLU を採用している．モデルの概要図を図 4-4 に示す．

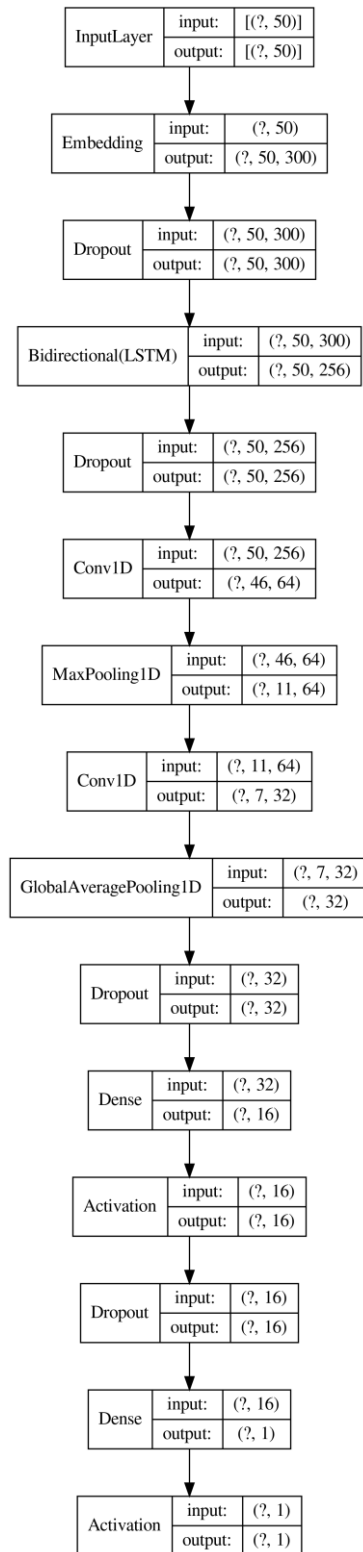


図 4-4 深層学習モデルの概要図

このモデルを学習するため、データセットを学習用、検証用、テスト用に分割す

る．それぞれのサンプルの数は検証用とテスト用はそれぞれポジティブデータが 5000，ネガティブデータが 5000 になるように分割し，学習用には残り全てのサンプルを利用する．各データセットのサンプル数を表 4-3 に示す．

表 4-3 各データセットのサンプル数

評価	学習	検証	テスト	合計
ポジティブ	221,728	5000	5000	231,728
ネガティブ	160,080	5000	5000	170,080
合計	381,808	10,000	10,000	401,808

このような条件で学習を行ったところ，最終的にテスト用のデータで[Yamamoto 2016]と同程度の Accuracy 93%という高い値を得ることができた．開発したモデルは，景気ウォッチャー調査のテキストに対してよい精度でポジティブかネガティブかを判定できる．開発したモデルの各データセットでの予測確率のヒストグラムを図 4-5，図 4-6，図 4-7 に示す．どのデータセットでも 0 近辺と 1 近辺での出力が多くなっている．さらに各データセットでの混同行列をそれぞれ，表 4-4，表 4-5，表 4-6 に示す．




図 4-5 学習データでのポジティブ予測確率のヒストグラム




図 4-6 検証データでのポジティブ予測確率のヒストグラム




図 4-7 テストデータでのポジティブ予測確率のヒストグラム

表 4-4 学習データの混同行列

		予測	
		ポジティブ	ネガティブ
実績	ポジティブ	214609	13840
	ネガティブ	7119	146240

表 4-5 検証データの混同行列

		予測	
		ポジティブ	ネガティブ
実績	ポジティブ	4622	378
	ネガティブ	336	4664

表 4-6 テストデータの混同行列

		予測	
		ポジティブ	ネガティブ
実績	ポジティブ	4633	367
	ネガティブ	337	4663

4.3 モデルの評価

本節ではニュース記事からセンチメントを抽出するのに前章で用いた一般的な極性辞書よりも，構築したモデルの方が優れているかどうかを検証する．具体的には前章の仮説（ア）を，景気ウォッチャー調査を用いて開発したセンチメントモデルで抽出したニュースのセンチメントと，前章で用いた一般的な極性辞書を用いて抽出したセンチメントでそれぞれ検証する．検証を行う仮説は下記のとおりである．

- ポジティブ（ネガティブ）なニュースが出たら，その後の当該企業の株価は上昇（下落）する．

4.3.1 ニュースからのセンチメントの抽出

分析データ

分析対象は、2017 年 1 月末時点の TOPIX500 の構成銘柄とする。理由としては、時価総額が小さい企業は、ニュースがそもそも存在しない可能性があることに加えて、実際の投資において流動性の問題などが生じるためである。TOPIX500 の構成銘柄であれば、このような問題はおおむね解消される。

分析期間は 1983 年 1 月頭から 2016 年 12 月末までとする。ニュース情報は、日経新聞朝刊の記事情報を日経テレコンから取得し利用した。各記事には、メタ情報としてどの企業に関するニュースかという情報が付与されている。これを用いて、ニュースと企業とのマッチングを行う。同一の記事に対して複数の企業がメタ情報として含まれることもあるが、この場合にはそれぞれの企業に関する記事として扱った。株価および時価総額といった個別企業に関するデータおよびマーケットデータについては SPEEDA から取得した。個別銘柄のリターンは株価情報を用いて計算を行った。リターンを計算するにあたって、配当はデータが取得できなかったため加味されていない。個別銘柄のリターンと TOPIX のリターンから超過リターンを算出する。超過リターンおよび時価総額の要約統計量を表 4-7 に示す。

表 4-7 超過リターンと時価総額の要約統計量

	超過リターン	時価総額(円)
平均	0.001	1.48e+12
標準偏差	0.023	2.46e+12
最小値	-0.628	2.81e+09
25%	-0.010	2.98e+11
中央値	0.000	7.19e+11
75%	0.011	1.64e+12
最大値	0.484	4.33e+13

新たに開発した極性判定モデルと比較を行うために一般的な極性辞書を用いる。東

北大学で公開されている日本語評価極性辞書の用言編 [Kobayashi 2005], 名詞編 [Higashiyama 2008] を利用した.

センチメントの抽出

ニュースの極性評価は, 開発した極性判定モデルと先述の極性辞書を用いる. まず極性判定モデルでのニュース極性評価について述べる. 極性判定モデルではモデル構築時のテキスト処理と同様にニュースを MeCab で分かち書きし, 基本形に変換したのちに word2vec で分散表現を得る. 次に得られた分散表現を深層学習のモデルの入力値として, 出力値としてテキストがポジティブである確率(0~1)のスコアを得る. これを極性判定モデルで得られたスコアとする.

次に極性辞書を用いた評価について述べる. 極性辞書は用言編, 名詞編ともに, ポジティブもしくはネガティブの極性が付与されている単語のみを抽出し利用した. ポジティブと評価される単語は約 4000 単語, ネガティブと評価される単語は約 6000 単語となった.

次に企業毎にその日に発表された記事を全て合算し, 1つのテキストとする. このテキストに対して MeCab を用いて形態素解析を行った. 形態素を全て基本形に変換し, 極性辞書の単語の存在を確認する. ある企業 i の時点 t のニュースの極性 (以下センチメントスコアと呼ぶ) は, ポジティブな単語の出現回数を $w_{p,i,t}$ とし, ネガティブな単語の出現回数を $w_{n,i,t}$, 全単語数(形態素の総数)を $w_{a,i,t}$ として, センチメントスコア $x_{i,t}$ を次式で定義する.

$$x_{i,t} = \frac{(+1) \times w_{p,i,t} + (-1) \times w_{n,i,t}}{w_{a,i,t}} \quad (4-1)$$

今回の分析ではニュース内に極性辞書に含まれる単語が存在しないサンプルは除外した.

全ニュースの極性判定モデルによるセンチメントスコアの分布を図 4-8 に, 極性辞書によるセンチメントスコアを図 4-9 に示す. また要約統計量を表 4-8 に示す.




図 4-8 モデルから抽出したセンチメントスコアのヒストグラム




図 4-9 極性辞書から抽出したセンチメントスコアのヒストグラム

表 4-8 センチメントスコアの要約統計量

	モデル	極性辞書
総数	367215	367215
平均	0.566	0.025
標準偏差	0.180	0.027
最小値	0.000	-0.200
25%	0.451	0.009
中央値	0.579	0.025
75%	0.691	0.040
最大値	1.000	0.292

両センチメントスコアとも形状は釣鐘型に近い分布をしている。さらに両センチメントスコアともにやや中央値よりも平均値が大きく、極性判定モデルでは平均値が 0.566 と、0.5 より大きく、極性辞書によるセンチメントスコアは平均値が 0.025 と、

0 よりも大きいことから、どちらのモデルでもニュースは全体的にポジティブな記事が多いことがわかる。この要因として、新聞記事自体が広告等の関係からポジティブな記事が多くなるというバイアスや、対象が 2017 年 1 月末時点の TOPIX500 の構成銘柄であるというサバイバーシップバイアスが影響している可能性がある。さらに細かく分布をみると、極性判定モデルによるセンチメントスコアは分布の裾である 0 もしくは 1 に非常に近いサンプルが存在するのに対して極性辞書によるセンチメントスコアでは分布の裾のデータ数はそれほど多くない。極性判定モデルでは一部のニュースに対しては極端な評価を下してしまう可能性があることがわかる。逆に極性辞書によるセンチメントモデルの分布では 0 に近い部分のデータ数が多くなっている。これは極性辞書の単語が含まれないニュースが多く存在することを示している。ニュースの中には社債の発行金額のみが記載されている記事も存在しており、こういった記事には極性を振ることができない。一方極性判定モデルでは単語が存在しないという確率は非常に小さくなるため、0 のサンプルが多くなるということはない。このような点も極性判定モデルの利点と考えられる。

4.3.2 仮説の検証および結果

仮説を以下の回帰分析で 2 つのセンチメントスコアで検証した。

$$r_{i,t} = \beta_0 + \beta_1 x_{i,t} + \varepsilon \quad (4-2)$$

ここで、 i は個別企業を、 t は時点を表す。 r は超過リターン、 x はセンチメントスコアである。仮説より、 β_1 の符号は正であることが期待される。さらにセンチメントモデルでの係数の方が大きくなることが期待される。

結果をそれぞれ表 4-9 と表 4-10 に示す。

表 4-9 センチメントモデルによるセンチメントスコアの検証結果

説明変数	係数	t 値
切片 β_0	-0.004	-27.24***
センチメントスコア β_1	0.007	34.67***
自由度修正済み決定係数	0.003	
データ数	367215	

*means p-value < 0.05, ** means p-value < 0.01, *** means p-value < 0.001

表 4-10 極性辞書によるセンチメントスコアの検証結果

説明変数	係数	t 値
切片 β_0	0.000	1.95
センチメントスコア β_1	0.026	17.87***
自由度修正済み決定係数	0.001	
データ数	367215	

*means p-value < 0.05, ** means p-value < 0.01, *** means p-value < 0.001

結果より，両モデルのセンチメントスコアの係数 β_1 は正であり，係数が 0 と有意に異なるかどうかの p 値も 0.1%水準で統計的に有意である．仮説の通り，企業に関するニュースがポジティブ(ネガティブ)な場合は記事発表後の株価リターンにプラス(マイナス)の影響を与えることがわかる．その影響の大きさについて検討する．極性判定モデルによるセンチメントスコアの係数は 0.007，一方極性辞書によるセンチメント

スコアの係数は 0.026 である．極性辞書によるセンチメントスコアの係数の方が，一見大きいですが，それぞれのスコアの分布が異なることに注意する必要があります．実際に両スコアが 1 標準偏差動いたと仮定すると，極性判定モデルによるセンチメントスコアの場合 $0.007 \times 0.180 = 12.6\text{bp}$ ，極性辞書によるセンチメントスコアの場合には $0.026 \times 0.027 = 7.02\text{bp}$ となる．従って極性判定モデルによるセンチメントスコアの影響が大きいことがわかる．また t 値を比較しても極性判定モデルの方が大きいことから極性判定モデルによるセンチメントスコアの方が統計的にも経済的にも極性辞書によるセンチメントスコアよりも優れていることがわかる．これはつまり極性判定モデルが極性辞書よりもニュースの株価に対するセンチメントをよりの確にとらえられていると考えられる．

4.4 おわりに

本実験では，景気ウォッチャー調査のデータを用いて金融や経済により特化したセンチメント抽出モデルの開発を行った．学習したモデルの正答率は 93%と高いものであった．このモデルを利用して一般的な極性辞書を用いた場合の比較を行った．具体的には，ポジティブ（ネガティブ）なニュースが出たら，その後の当該企業の株価は上昇するという仮説を立て，各々のセンチメントスコアの係数およびその有意性の比較を行った．結果は，両センチメントスコアで仮説通りとなったが，構築したモデルでのセンチメントスコアの方が極性辞書を用いたセンチメントスコアよりも統計的および経済的に有意であるという結果になった．これは金融や経済に関するニュースには既存の一般的な極性辞書ではとらえられない情報が含まれており，金融経済のデータを利用して構築した極性判定モデルではそのような情報をより正確に抽出していると考えられる．

第5章 ニュースセンチメントの投資戦略への活用

5.1 はじめに

本実験では、第4章で構築した金融分野のためのセンチメント抽出モデルを利用し、ニュースから抽出された個別銘柄に対するセンチメントを投資戦略に活用できるかどうかの検証を行う。第3章および第4章では、 t 日の朝に配布される新聞記事が $t-1$ 日に終値から、 t 日の終値までの株価と関係があることを明らかにした。しかしながら、この関係は必ずしも実際に投資して獲得できるものではない。よってこの章では、実際に投資戦略に活用できるかどうかを t 日の終値から、1日(日次)、1週間(週次)、1か月(月次)間で、それぞれ投資を行い、リターンを獲得できるかどうかを検証する。すなわち、効率的にテキストから情報(センチメント)を抽出し、投資行動に活用できるかどうかを明らかにするという本研究の目的の、投資行動に活用できるかどうかの部分明らかにする。

5.2 金融分野におけるセンチメント測定モデルの構築

この節では、金融分野におけるセンチメントモデルの構築方法について、簡単に述べる。具体的には第4章で構築したセンチメントモデルを構築する。景気ウォッチャー調査のテキスト情報を利用してモデルを構築し、ニュースの文章に対してセンチメント評価を行う。景気ウォッチャー調査は景気や金融経済に関する調査であり、このデータを用いてモデルを開発することで一般的な極性辞書ではとらえることのできなかった、金融や経済などの専門的な単語や言い回しをとらえたセンチメント評価が可能になると考えられる。

5.2.1 景気ウォッチャー調査

景気ウォッチャー調査とは内閣府が地域の景気に関連の深い動きを観察できる立場にある人々の協力を得て、地域ごとの景気動向を的確かつ迅速に把握し、景気動向判断の基礎資料とすることを目的とし、毎月公表しているレポートである。調査項目は「景気の現状に対する判断」とその判断の材料および詳細な説明からなる。「景気の先行きに対する判断」についても同様に調査されている。具体的な調査項目の例を Table 1.に示す。これは 2019 年 1 月の北海道地区の景気ウォッチャー調査の「景気の現状に対する判断」から判断の異なる 5 つのデータサンプルを選択したものである。

景気の判断は例の 1 列目に示されている通り 5 段階で評価される。そしてその評価の具体的な説明が 5 列目に文章で表示されている。この 5 段階の評価情報(1 列目)とそれを説明したテキスト(5 列目)を用いてモデルを開発する。

モデルの構築には 2000 年 1 月から 2018 年 11 月までの景気ウォッチャー調査のデータを用いた。「現状」と「先行き」の両方のデータを利用した。評価情報とテキストが正しく取得できたデータサンプル数 23 万 4626 件をモデル開発に利用する。

5.2.2 モデル

景気ウォッチャー調査の評価情報とその評価を説明したテキスト情報を用いて深層学習を利用しモデルを構築する。具体的には評価情報をポジティブとネガティブ 2 値に分類し、テキストを分散表現に変換して、深層学習を利用した分類問題としてモデルを構築する。

まず、景気ウォッチャー調査の評価を 5 段階からポジティブかネガティブかの 2 値に変換する。具体的には 5 段階のうち良い上の 2 つの評価(サンプルの◎と○)をポジティブとし、悪い下 2 つの評価(サンプルの▲と×)をネガティブとする。5 段階のうちの真ん中の評価のものは除外する。

次にテキストの処理を行う。評価の説明のテキストは単文であったり複文であったりする。そこで、複文であった場合には単文に分割し、分割後のそれぞれの単文には元の複文の評価を与えるという処理を行う。これらの処理を行い、最終的に 26 万 1439 件のデータを得た。うちポジティブとなるサンプルが 10 万 9496 件、ネガティ

ブとなるサンプルが 15 万 1943 件となる。

さらにテキストの分散表現を得るための処理を行う。具体的には日本語の形態素解析エンジンである MeCab(<https://taku910.github.io/mecab/>)でテキストを分割し基本形の単語を得る。次に word2vec によって単語をベクトル化する。word2vec モデルは東北大学で公開されている「日本語 Wikipedia エンティティベクトル」(http://www.cl.ecei.tohoku.ac.jp/~m-suzuki/jawiki_vector/) を利用する。このモデルでは 120 万語を 300 次元のベクトルで分散表現できる。これによりテキストにおける各単語のベクトル情報が得られる。

最後にポジティブかネガティブの 2 値の情報とそれを説明するテキストのベクトル情報を利用して、深層学習のリカレントニューラルネットワークの 1 種である LSTM モデルと Convolution モデルを利用して(2 値)分類問題としてモデルを構築する。具体的には Bi-Directional LSTM(ユニット数 128), 1 次元 Convolution(ユニット数 64, 32), 全結合層(ユニット数 16)のネットワークを構築した。各層にドロップアウト(ドロップアウト率 0.5)を加えて活性化関数には ReLU を採用している。データセットを学習用, 検証用, テスト用に分割する。それぞれのサンプルの数は検証用とテスト用はそれぞれポジティブデータが 5000, ネガティブデータが 5000 になるように分割し, 学習用には残り全てのサンプルを利用する。このような条件で学習を行ったところ, 最終的にテスト用のデータで Accuracy 93%という高い値を得ることができた。以降の分析ではこのセンチメント測定モデルを用いてニュースのセンチメントを測定し, 投資戦略へ活用できるかを検証する。

5.3 ニュースのセンチメント

5.3.1 分析対象データ

分析対象データは, 2017 年 1 月末時点の TOPIX500 の構成銘柄とする。TOPIX500 とは日本の代表的な株式指数である TOPIX の構成銘柄のうち時価総額上位 500 銘柄のみで構築される株式指数である。この指数を選択した理由として, 時価総額が小さい企業は, ニュースがそもそも存在しない可能性があるためである。加え

て、時価総額の小さな企業は大きな企業と比較して売買の流動性が低いことが多く、実務上売買ができないなどの問題が生じるためである。TOPIX500の構成銘柄であれば、このような問題は解消される。

分析期間は1983年1月初めから2016年12月末までとする。ニュース情報は、日経新聞朝刊の記事情報を日経テレコンから取得し利用する。各記事には、メタ情報としてどの企業に関するニュースかという情報が付与されている。これを用いて、ニュースと企業とのマッチングを行う。同一の記事に対して複数の企業がメタ情報として含まれることもあるが、この場合にはそれぞれの企業に関する記事として扱う。

個別企業に関する株価、時価総額およびマーケットデータは、SPEEDAから取得する。個別銘柄のリターンは株価情報を用いて計算を行う。リターンを計算するにあたって、配当はデータが取得できなかったため加味されていない。

5.3.2 ニュースのセンチメント評価

センチメント測定モデルでのニュースセンチメント評価について述べる。モデル構築時のテキスト処理と同様にニュースをMeCabで分かち書きし、基本形に変換したのちにword2vecで分散表現を得る。次に得られた分散表現を深層学習のモデルの入力値として、出力値としてテキストがポジティブである確率(0~1)のスコアを得る。これをセンチメントスコアとする。

全ニュースのセンチメント測定モデルによるセンチメントスコアの要約統計量を表5-1に示す。統計量は、平均値が0.566と、中央値0.5より大きい。したがって、ニュースは全体的にポジティブな記事が多いことがわかる。この要因として、新聞記事自体が広告等の関係からポジティブな記事が多くなるというバイアスや、対象が2017年1月末時点のTOPIX500の構成銘柄であるというサバイバーシップバイアスが影響している可能性がある。

表 5-1 センチメントスコアの要約統計量

	センチメントスコア
総数	367215
平均	0.566
標準偏差	0.180
最小値	0.000
25%	0.451
中央値	0.579
75%	0.691
最大値	1.000

5.4 センチメントスコアを活用した投資行動

本節では、実際にセンチメントスコアを投資戦略に活用できるかどうかを検証する。先行研究では、日本においてはニュースのセンチメントが短期的にマーケット全体の動きを予測することを明らかにしている。これが個別の銘柄であっても同様に予測可能であるかは非常に興味深い。もしそうであれば投資戦略として活用することができる。さらに先行研究では日本においては短期的な予測能力のみを確認していたが、本研究では、週次や月次の頻度で予測できるかを確認する。具体的には、センチメントスコアの大きさを基準に銘柄を分け、ポートフォリオを構築し銘柄を保有した場合のパフォーマンスを検証する。

5.4.1 ポートフォリオの構築方法

センチメントスコアを用いて、ポートフォリオをどのように構築するかについて説明する。まず、日次、週次、月次でセンチメントスコアを個別銘柄毎に集約する。そのスコアの大きさに2つの銘柄群を作成する。例えば、ある時点でのニュースセンチ

メントが 200 銘柄分存在する場合，スコアの大きい順に 100 銘柄ずつ 2 つの銘柄群を作成する．その後，各銘柄群でポートフォリオを構築する．ポートフォリオのウェイトは，等ウェイトと時価加重ウェイトで計算する．等ウェイトポートフォリオとは，銘柄をそれぞれ同じウェイトで保有するポートフォリオのことであり，時価加重ウェイトポートフォリオとは，銘柄をその時価総額に比して保有するポートフォリオのことである．ウェイトの計算方法を下記に示す．

$$w_{eq,i,T} = \frac{1}{n} \quad (5-1)$$

$$w_{cap,i,T} = \frac{NAV_{i,T}}{\sum_{i=1}^n NAV_{i,T}} \quad (5-2)$$

ここで n は銘柄総数， i は銘柄， T は時点(日)を表す． $w_{eq,i,T}$ は，等ウェイトポートフォリオでのウェイト， $w_{cap,i,T}$ は時価加重ウェイトポートフォリオでのウェイトである． $NAV_{i,T}$ は，時点 T ，銘柄 i の時価総額である．この時価総額は浮動株比率を調整していない．

最低 10 銘柄が各ポートフォリオに含まれるようにする．この条件を満たすようなニュースが少ない日についてはポートフォリオを構築しない．各ポートフォリオを基準日時点の引け価格で投資し，これを各投資頻度の期間でバイアンドホールドした場合のパフォーマンスを検証する．センチメントの大きさによる投資行動が有効かどうかの比較のためにベンチマークとして全銘柄で計算したポートフォリオのパフォーマンスを利用する．このベンチマークはセンチメント情報を利用していないため良い比較対象であると考えられる．

5.4.2 日次投資戦略

日次投資戦略では，前営業日の翌日の朝のニュースから当日の朝のニュースまでを利用して，各センチメントを個別銘柄ごとに平均し，各銘柄のセンチメントとする．そのセンチメントの相対的な大きさを銘柄群を分けてポートフォリオを構築する．そ

して、各ポートフォリオを、その日の引けから翌営業日の引けまで投資する。例えば、前営業日の翌日が当日の場合には、当日の朝のニュースのみを利用する。一方、前営業日が金曜日の場合には(近年日本では通常月曜日から金曜日に取引が行われる)、月曜日が平日の場合であると、土曜日、日曜日そして月曜日のニュースを用いる。日次の投資戦略の概念図を図 5-1 に示す。この図で t は営業日を表す。

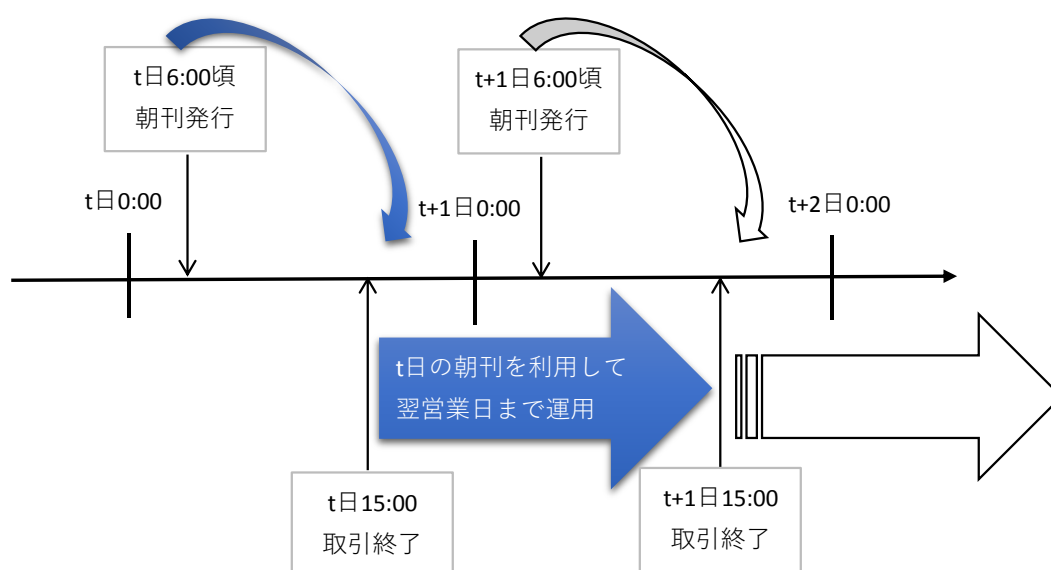


図 5-1 日次投資戦略の概念図

等ウェイトポートフォリオと時価加重ウェイトポートフォリオの統計値をそれぞれ表 5-2 および 表 5-3 に示す。これらの表では等ウェイトと時価加重ウェイトのそれぞれについて、2つのポートフォリオ（列方向）に対して9つの統計値（行方向）を示す。2種類のウェイトの各ポートフォリオの1列目の **Q1(positive)**は前項で述べたスコアの相対的に大きい銘柄群で構築したポートフォリオを示し、2列目の **Q2(negative)**は小さい銘柄群を表す。3列目の **ALL**はその名の通り全銘柄を組み入れたポートフォリオを表し、スコアで分けたポートフォリオに対するベンチマークとなる。4列目の **Q1-Q2**は **Q1(positive)**をロングし、**Q2(negative)**をショートするロング

ショートポートフォリオを示している。9つの統計値については、1行目のリターンはポートフォリオの日次のリターンの平均値を年率化したものを表す。2行目のリスクは、ポートフォリオの日次のリターンの標準偏差を年率化したものを表す。3行目のリターン/リスクは、リターンをリスクで割ったものである。一般的にリスクあたりのリターンが高い方が良いとされる。4行目のアルファは各ポートフォリオのベンチマーク(ALLに相当)に対する日次の超過リターンの平均値を年率化したものである。5行目のT.E.はトラッキングエラーであり、日次のアルファの標準偏差を年率化したものである。6行目のIRはインフォメーションレシオであり、 α をT.E.で割ったもので、こちらも一般的に高い方が良いとされる。7行目のp-valueはアルファが統計的に有意に0と異なるかどうかのt検定のp値である。また8行目のTur1noverはポートフォリオの平均的な回転率である。この回転率が高いと銘柄の売買が増えて、取引コストがかかってしまう。最後のnamesはポートフォリオの平均的な構成銘柄数である。

表 5-2 に示す通り、等ウェイトポートフォリオでは、センチメントスコアが高い銘柄のパフォーマンスは、低い銘柄と比較して高い。さらに全銘柄の平均値と比較しても高いパフォーマンスとなっている。相対的にセンチメントが高いQ1(positive)のベンチマーク ALL に対する IR は 0.89 となっている。一方、センチメントスコアの低いQ(negative)の全銘柄平均に対する α は年率 -4.8% で IR は -0.89 である。また p-value は 0%であることにより、両ポートフォリオともに統計的に有意なアルファである。さらにロングショートポートフォリオである Q1-Q2 についても統計的かつ経済的に有意なアルファを獲得できる。これらの結果より、日次でのセンチメントスコアによる等ウェイトポートフォリオ投資戦略は有効である。しかしながら、ポートフォリオ回転率は非常に高い。これはニュースのある銘柄が限られてしまうのが原因であるのと、ニュースセンチメントは日々大きく変化することを示している。このような高い回転率では、獲得したアルファが棄損してしまう可能性が高く、取引の方法などは検討する必要があると考えられる。

表 5-2 日次投資戦略 等ウェイトポートフォリオのパフォーマンス

	Q1(positive)	Q2(negative)	ALL	Q1-Q2
Return	13.8%	4.0%	8.8%	--
Risk	21.1%	21.4%	20.5%	--
Return/Risk	0.66	0.19	0.43	--
Alpha	5.0%	-4.8%	--	9.8%
T.E.	5.7%	5.3%	--	11.0%
IR	0.89	-0.89	--	0.89
p-value	0.00%	0.00%	--	0.00%
Turnover	21667%	20968%	18170%	--
Names	23	24	46	--

1983 年を 1 としたときの等ウェイトポートフォリオの超過リターンの累積の推移を図 5-2 に示す。2000 年ごろまでは相対的にセンチメントスコアの良い銘柄群 Q1(positive)のリターンは高い。一方 2000 年以降は、リターンはプラスであるもののリターンの大きさは低下している。これは、インターネット環境の発達や、テキストマイニングの発達とともに、ニュースがより速報性を増し、それを扱うスピードも向上したためニュースセンチメントのマーケットへの折り込みがより早くなったと考えられる。一方で、Q2(negative)の方はそのような効果が見られない。これについては、悪い銘柄を空売りするのには制約があるためであることが要因であると考えられる。




図 5-2 日次投資戦略 等ウェイトポートフォリオの累積パフォーマンス

次に時価加重ウェイトポートフォリオの結果を確認する．統計値は表 5-3 に，ベンチマークに対する超過リターンのパフォーマンスの推移を図 5-3 に示す．時価加重ウェイトにおいても，相対的にセンチメントスコアが高い Q1(positive)のパフォーマンスは，相対的に低い Q2(negative)と比較して高い．しかしながら等ウェイトポートフォリオと比較すると，その大きさは低下する．

時価加重ウェイトポートフォリオが等ウェイトポートフォリオと比較してあまりパフォーマンスが優れない要因として，時価総額の大きな企業のニュースはマーケット参加者の注目度も高く加えて新聞以外の情報元によって，株価に情報が織り込まれるスピードが速いことが考えられる（時価加重ウェイトポートフォリオは等ウェイトポートフォリオと比較して時価総額の大きな企業の影響が大きくなる）．

パフォーマンスの推移を見ると，こちらのポートフォリオも 2000 年ごろまでは特に有効に機能している．この要因は等ウェイトポートフォリオと同じであると考えられる．

表 5-3 日次投資戦略 時価加重ウェイトポートフォリオのパフォーマンス

	Q1(positive)	Q2(negative)	ALL	Q1-Q2
Return	7.8%	2.9%	5.4%	--
Risk	23.2%	23.1%	22.2%	--
Return/Risk	0.34	0.12	0.24	--
Alpha	2.4%	-2.5%	--	5.0%
T.E.	7.5%	7.4%	--	14.4%
IR	0.32	-0.34	--	0.89
p-value	5.86%	4.55%	--	4.43%
Turnover	19743%	19198%	13812%	--
Names	23	24	46	--




図 5-3 日次投資戦略 時価加重ウェイトポートフォリオの累積パフォーマンス

5.4.3 週次投資戦略

週次投資戦略では、前週の最終営業日(近年では金曜日、過去は土曜日)の翌日の朝のニュースから当該週の最終営業日の朝のニュースまでの各センチメントを個別銘柄ごとに平均し、各銘柄のセンチメントとする。そして、そのセンチメントの相対的な大きさに銘柄群を分けてポートフォリオを構築し、最終営業日の引けで投資し、翌週の最終営業日の引けまで投資する。これを毎週繰り返していく。この投資戦略の概念図を図 5-4 に示す。

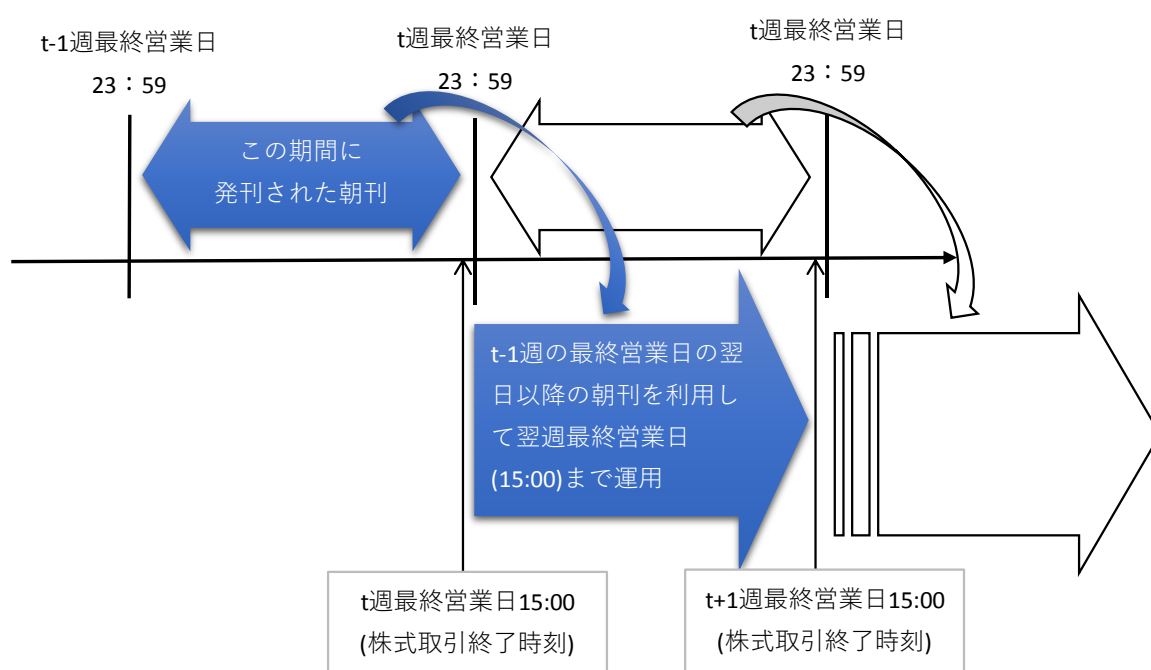


図 5-4 週次投資戦略の概念図

等ウェイトポートフォリオおよび時価加重ウェイトポートフォリオの結果の統計値を表 5-4 および表 5-5 に示す。また、1983 年を 1 としたときの等ウェイトポートフォリオの超過リターンの累積の推移を図 5-5 に、時価加重ウェイトポートフォリオの超過リターンの累積の推移を図 5-6 に示す。

表 5-4 および表 5-5 の結果から、日次投資戦略とは異なり、等ウェイト、時価加重ウェイト問わず、どちらも相対的にセンチメントが高いポートフォリオと低いポー

トフォリオのアルファは小さく統計的にも有意ではない。相対的にセンチメントの高い Q1(positive)のアルファがプラス，想定的にセンチメントの低い Q2(negative)のアルファがマイナスになることが期待されるが，等ウェイトベースでは，むしろ逆の結果となっている。時価加重ウェイトポートフォリオではわずかに相対的にセンチメントが高い Q1(positive)のアルファはプラスで，低い Q2(negative)のアルファはマイナスであるがその大きさは日次戦略と比較しても小さい。超過リターンの累積の推移をみるとより明らかであるが，センチメントが良い銘柄と悪い銘柄の差はほとんどない。したがって，週次のセンチメントを利用して週次で投資する戦略は有効でない。[Sinha 2016]によれば米国では週次のセンチメントを利用すると，最大 13 週間(1 四半期)まで予測可能であるという結果であったが，日本は異なる結果となった。この点は非常に興味深い。

表 5-4 週次投資戦略 等ウェイトポートフォリオのパフォーマンス

	Q1(positive)	Q2(negative)	ALL	Q1-Q2
Return	8.8%	9.7%	9.2%	--
Risk	19.1%	19.3%	19.0%	--
Return/Risk	0.46	0.50	0.49	--
Alpha	-0.4%	0.4%	--	-0.8%
T.E.	3.2%	3.1%	--	6.3%
IR	-0.13	0.14	--	-0.13
p-value	45.84%	42.47%	--	44.14%
Turnover	3784%	3589%	2504%	--
Names	68	70	138	--

表 5-5 週次投資戦略 時価加重ウェイトポートフォリオのパフォーマンス

	Q1(positive)	Q2(negative)	ALL	Q1-Q2
Return	5.5%	4.9%	5.4%	--
Risk	20.7%	20.2%	20.0%	--
Return/Risk	0.26	0.24	0.27	--
Alpha	0.1%	-0.5%	--	0.6%
T.E.	4.7%	5.4%	--	9.8%
IR	0.02	-0.09	--	0.06
p-value	90.64%	61.48%	--	74.07%
Turnover	3239%	3040%	1367%	--
Names	68	70	138	--




図 5-5 週次投資戦略 等ウェイトポートフォリオの累積パフォーマンス




図 5-6 週次投資戦略 時価加重ウェイトポートフォリオの累積パフォーマンス

5.4.4 月次投資戦略

月次投資戦略では，週次と同様に，前月の最終営業日の翌日の朝のニュースから当該月の最終営業日の朝のニュースを利用して，各センチメントを個別銘柄ごとに平均し，各銘柄のセンチメントとする．そして，そのセンチメントの相対的な大きさに銘柄を分けてポートフォリオを構築し，その最終営業日の引けで投資し，翌月の最終営業日の引けまで投資する．これを毎月繰り返していく．この投資戦略の概念図を図 5-7 に示す．

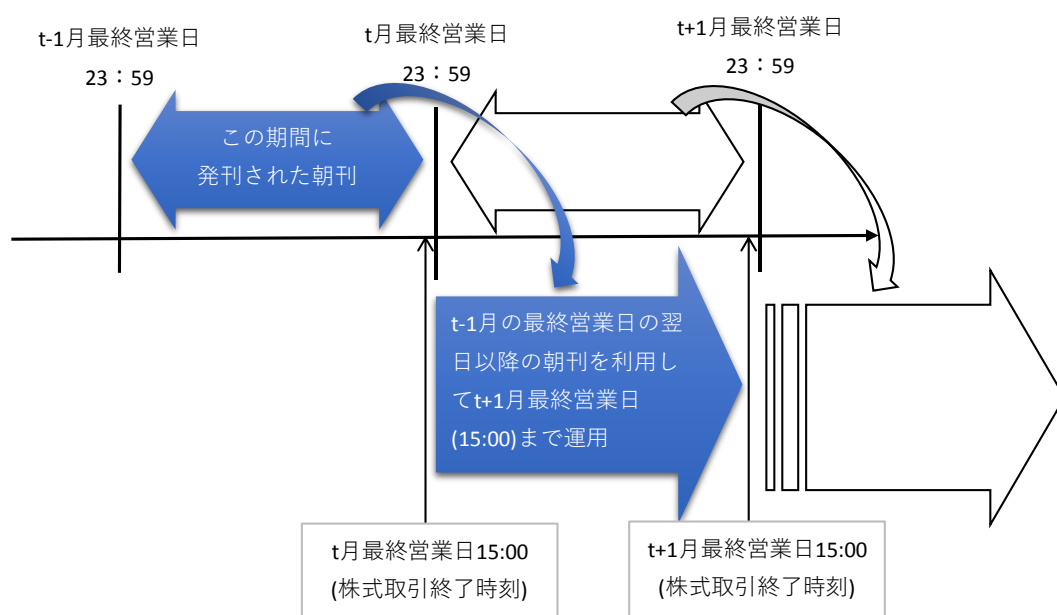


図 5-7 月次投資戦略の概念図

等ウェイトポートフォリオおよび時価加重ウェイトポートフォリオの統計値を

表 5-6 および

表 5-7 に示す。また、1983 年を 1 としたときの等ウェイトポートフォリオの超過リターンの累積の推移を図 5-8 に時価加重ウェイトポートフォリオの超過リターンの累積の推移を図 5-9 に示す。

表に示すとおり、週次投資戦略の結果と非常に似ている。つまり等ウェイト、時価加重ウェイト問わず、ポートフォリオのアルファは小さく、また統計的にも有意ではない。週次投資戦略とは異なり、等ウェイト、時価加重ウェイト両方とも相対的にセンチメントが高い Q1(positive)のアルファは平均的にプラスであり、センチメントが低い Q2(negative)のアルファはマイナスであるが、その大きさは日次戦略と比較しても小さい。累積リターンの推移をみるとより明らかであるが、その差は 2000 年前後

で出ているのみである。したがって、月次のセンチメントを利用して月次で投資する戦略は有効でない。

表 5-6 月次投資戦略 等ウェイトポートフォリオのパフォーマンス

	Q1(positive)	Q2(negative)	ALL	Q1-Q2
Return	10.0%	8.9%	9.4%	--
Risk	18.9%	19.4%	19.0%	--
Return/Risk	0.53	0.46	0.50	--
Alpha	0.6%	-0.6%	--	1.2%
T.E.	2.7%	2.6%	--	5.3%
IR	0.23	-0.21	--	0.22
p-value	18.85%	21.91%	--	20.31%
Turnover	687%	658%	299%	--
Names	136	137	273	--

表 5-7 月次投資戦略 時価加重ウェイトポートフォリオのパフォーマンス

	Q1(positive)	Q2(negative)	ALL	Q1-Q2
Return	6.5%	5.1%	5.7%	--
Risk	19.7%	19.1%	19.0%	--
Return/Risk	0.33	0.27	0.30	--
Alpha	0.8%	-0.6%	--	1.4%
T.E.	4.0%	5.1%	--	8.9%
IR	0.20	-0.11	--	0.15
p-value	24.74%	52.37%	--	37.43%
Turnover	586%	546%	118%	--
Names	136	137	273	--




図 5-8 月次投資戦略 等ウェイトポートフォリオの累積パフォーマンス




図 5-9 月次投資戦略 時価加重ウェイトポートフォリオの累積パフォーマンス

5.5 投資行動のロバストネスチェック

前節では、日次投資戦略で構築したポートフォリオのパフォーマンスは等ウェイトポートフォリオおよび時価加重ウェイトポートフォリオともに有効であった。本節ではリスクを調整した場合でもこのパフォーマンスが有意かどうかを検証する。

具体的には Fama-French のファクターリターンで先ほどの日次投資戦略のポートフォリオのリターンを調整した場合に有意にアルファが残るかどうかを検証する。データは Kenneth French のサイトから取得した。本データの期間は 1990 年 7 月からとなっているため、前節で計測した期間よりも短いことに注意する。また、マーケットリターンおよびリスクフリーレートについてはドルベースであるため、円ベースに修正する。具体的には、マーケットリターンをセンチメント計算対象銘柄で構築したポートフォリオに、リスクフリーレートを国債の 1 年物の利回りを用いた。今回の分析対象は 2017 年 1 月末の TOPIX500 の構成銘柄であるため、通常の TOPIX などの市場を代表する指数のリターンを利用すると、サバイバーシップバイアスの存在が懸念され、この影響でアルファが有意に観測される可能性があるからである。また、

等ウェイトポートフォリオおよび時価加重ウェイトポートフォリオの両方で検証を行うが、等ウェイト効果を除外するために、等ウェイトポートフォリオの場合には等ウェイトで計算したマーケットリターンを用いた。

まず、日次戦略の等ウェイトポートフォリオの場合の結果を表 5-8 および表 5-9 に示す。

表 5-8 日次投資戦略等ウェイトポートフォリオの FF3 ファクター回帰

	Q1(positive)	Q2(negative)	Q1-Q2
α	3.6%	-6.7%	10.3%
p 値	0.0108	0.000	0.0000
Mkt-Rf	0.9661	1.0052	-0.0391
p 値	0.0000	0.000	0.0000
SMB	-0.2197	-0.1756	-0.0441
p 値	0.0000	0.000	0.0005
HML	-0.1318	-0.0334	-0.0984
p 値	0.0000	0.0023	0.000
Adj. R ²	0.894	0.891	0.009
データ数	6516	6516	6516

α は切片項で年率化済

表 5-9 日次投資戦略等ウェイトポートフォリオの FF5 ファクター回帰

	Q1(positive)	Q2(negative)	Q1-Q2
α	3.4%	-6.7%	10.0%
p 値	0.0177	0.0000	0.0000
Mkt-Rf	0.9744	1.0049	-0.0305
p 値	0.0000	0.0000	0.0000
SMB	-0.2212	-0.1778	-0.0433
p 値	0.0000	0.0000	0.0007
HML	-0.0580	-0.0006	-0.0574
p 値	0.0000	0.9618	0.0008
RMW	0.0826	0.0044	0.0782
p 値	0.0000	0.7888	0.0007
CMA	-0.0389	-0.0145	-0.0244
p 値	0.0116	0.3668	0.2777
Adj. R ²	0.895	0.891	0.012
データ数	6516	6516	6516

α は切片項で年率化済

センチメントスコアの高い分位の Q1 の α は FF3 ファクターで年率 3.6%, FF5 ファクターで 3.4%と正で、統計的にも経済的にも有意である。一方で、センチメントスコアの低い Q2 の α も FF3 ファクターで年率-6.7%, FF5 ファクターで-6.7%と負で、統計的にも経済的にも有意である。一般的なリスクファクターを調整しても、センチメントスコアの高いポートフォリオの α はプラスで、センチメントスコアの低い α はマイナスであることがわかる。ロングショート戦略のパフォーマンスに着目すると、こちらでも FF3 ファクターで年率 10.3%, FF5 ファクターで年率 10.0%を獲得できるが、経済的には非常に大きく、統計的にも有意となっている。

次にエクスポージャーに着目する。マーケットベータについては、センチメントスコアが高いポートフォリオ Q1 はややベータが 1 より低く、センチメントスコアが低い

ポートフォリオ **Q2** のベータはほとんど 1 である。一方、サイズファクター(**SMB**)については、**FF3** ファクター、**FF5** ファクターによらず、**Q1**、**Q2** ともに負のエクスポージャーである。これは大型のバイアスがあることを意味するが、背景としては対象銘柄が 2017 年 1 月末の時価総額が相対的に大きい **TOPIX500** の構成銘柄にしていることが考えられる。バリューファクター(**HML**)に着目すると、**FF3** ファクター、**FF5** ファクターによらず、**Q1** はわずかに負のエクスポージャーとなっており、**Q2** については、ほとんどエクスポージャーは 0 である。つまり **Q1** ポートフォリオは、ややグロースの傾向にある。これは、前節の累積パフォーマンスにおいて、IT バブル崩壊で大きくリターンを棄損していることと整合的である。**FF5** ファクターモデルで計測される 2 つのファクターに着目すると、センチメントスコアが高いポートフォリオは営業利益率(**RMW**)がやや高い。また、両ポートフォリオとも、投資(**CMA**)がややアグレッシブであるということがわかる。ロングショートポートフォリオについては、**HML** と **RMW** に対して、それぞれ負および、正のエクスポージャーを持っている。エクスポージャーに関しては、いずれのポートフォリオもマーケットベータとサイズファクター以外には、大きなエクスポージャーをとっているポートフォリオはない。サイズファクターが大型による原因は先ほどの対象銘柄によるものであると考えられる。したがって、センチメントスコアで構築されるポートフォリオは、これらの結果からほとんど一般的なファクターに対してエクスポージャーを持たないことがわかる。

次に、日次戦略の時価加重ウェイトポートフォリオの場合の結果をおよびに示す。

表 5-10 日次投資戦略時価加重ウェイトポートフォリオの FF3 ファクター回帰

	Q1(positive)	Q2(negative)	Q1-Q2
α	1.5%	-2.6%	4.1%
p 値	0.3823	0.1554	0.1380
Mkt-Rf	0.9939	1.0111	-0.0172
p 値	0.0000	0.0000	0.0834
SMB	-0.1422	-0.0954	-0.0468
p 値	0.0000	0.0000	0.0125
HML	-0.0942	0.0164	-0.1106
p 値	0.0000	0.2334	0.0000
Adj. R ²	0.865	0.855	0.004
データ数	6516	6516	6516

α は切片項で年率化済

表 5-11 日次投資戦略時価加重ウェイトポートフォリオの FF5 ファクター回帰

	Q1(positive)	Q2(negative)	Q1-Q2
α	1.1%	-2.6%	3.7%
p 値	0.5118	0.1519	0.1772
Mkt-Rf	1.0013	1.0091	-0.0078
p 値	0.0000	0.0000	0.4437
SMB	-0.1397	-0.0944	-0.0453
p 値	0.0000	0.0000	0.0157
HML	0.0084	0.0642	-0.0558
p 値	0.5638	0.0000	0.0161
RMW	0.1087	-0.0116	0.1204
p 値	0.0000	0.5547	0.0001
CMA	-0.1224	-0.1043	-0.0181
p 値	0.0000	0.0000	0.5484
Adj. R ²	0.868	0.856	0.007
データ数	6516	6516	6516

α は切片項で年率化済

等ウェイトポートフォリオと同じくセンチメントスコアの高い分位の Q1 の α は FF3 ファクターで年率 1.5%，FF5 ファクターで 1.1%と正で，経済的に優位であるが，統計的には有意ではない．一方で，センチメントスコアの低い Q2 の α は FF3 ファクターで年率-2.6%，FF5 ファクターで-2.6%と負で，こちらも経済的に有意であるが，統計的には有意ではない．ロングショート戦略のパフォーマンスに着目すると，こちらも FF3 ファクターで年率 4.1%，FF5 ファクターで年率 3.7%を獲得できるが，経済的には大きいものの統計的には有意ではない．前節と異なり，このような結果となった背景として，パフォーマンスの計測の期間が異なることが考えられる．この期間の時価加重ウェイトでの日次戦略のパフォーマンスは，全銘柄のポートフォリオ QALL に対するセンチメントスコアの高い Q1 の超過リターンは年率 1.6%，センチメ

ントスコアの低い **Q2** の超過リターンは年率-1.9%である。この結果は期待通りであるものの、この超過リターンが有意にゼロと異なるかどうかの(両側)検定の p 値はそれぞれ、24%、18%と統計的に有意ではない。また、**Q1-Q2** のリターンは、年率 3.6%で経済的に大きいものの、同様の検定による p 値は、19.3%とこちらも統計的に有意ではないという結果であった。このように **Fama-French** 回帰を行う期間では、時価加重ウェイトポートフォリオの超過リターンのパフォーマンスは経済的には大きいものの、統計的には有意ではないのである。しかしながら、**FF** ファクター回帰による α の統計的に優位とは言えないものの、時価加重ウェイトポートフォリオにおいてもセンチメントスコアが高い分位はリスクを調整しても正の α である。一方、低い分位は負の α を生み出していることがわかる。

次にエクスポージャーに着目する。マーケットベータについては、**Q1** のほうが、**Q2** と比較してわずかに低ベータとなっているものの、ほとんどベータは 1 に近い。サイズファクターは、等ウェイトポートフォリオと同じく、どちらのポートフォリオも大型の傾向がある。この背景は等ウェイトポートフォリオも同じく、対象銘柄が大型に寄っているからであると考えられる。バリュウファクターは、等ウェイトポートフォリオとは異なり、**FF3** ファクターでは、**Q1** はグロース傾向、**Q2** はわずかにバリュウ傾向がある。一方、**FF5** ファクターでは、どちらもややバリュウ傾向にある。**FF5** ファクターモデルで計測される 2 つのファクターでは、等ウェイトポートフォリオと同じくセンチメントスコアが高いポートフォリオでは営業利益率(**RMW**)が高く、投資(**CMA**)がアグレッシブであるということがわかる。ロングショートポートフォリオをみると、ほとんどのリスクファクターに対するエクスポージャーはとっておらず、**RMW** にのみプラスのエクスポージャーをもっている。マーケットベータとサイズファクターを除けば、等ウェイトポートフォリオと同じくどのポートフォリオもリスクファクターに大きくエクスポージャーを持つものではない。

前節と異なり、計測期間が変わってしまったため、時価加重ウェイトポートフォリオについては統計的な有意であるとは言えないものの、どちらのウェイトのポートフォリオもセンチメントスコアの低いポートフォリオ **Q2** は負の α が確認された。また、その大きさも大きいものである。特に等ウェイトポートフォリオに関しては統計的にも有意であった。よって、センチメントスコアから獲得できる超過リターンは特定のリスクファクターで説

明できるものではないと考えられる．

5.6 おわりに

本実験では，深層学習を用いたセンチメント測定機で計測したニュースのセンチメントを投資戦略に活用できるかどうかを調査した．具体的には，日次，週次，月次の頻度でセンチメントスコアを集約し，その大きさを投資した場合のパフォーマンスを計算した．結果は，日次頻度での投資戦略のパフォーマンスは高く，週次，月次では全くその効果が得られないことが分かった．これらの結果より，ニュースのセンチメントの株式市場に与える影響は非常に短く，日次以上，週次未満であることを明らかにした．

いくつかの先行研究で，日本市場においてセンチメントのマーケット全体へ与える影響は短いことが確認されているが，個別銘柄でも同様の結果となることが明らかとなった．つまりニュースはマーケット全体，個別銘柄どちらにもすぐに織り込まれるのである．

本実験によって，ニュース記事から抽出したセンチメントは投資行動に活用できるということを示した．

第6章 結論

本論文は、株価への大きな影響を与えると思われるニュースから、その量が多くとも、効率的にセンチメントを抽出する手法を確立し、さらに、そのセンチメントが株価に影響を与えるか、つまり、資産運用に活用できるかどうかの分析を行ったものである。

近年、我が国の資産形成の重要性が高まってくる中、資産運用の高度化および効率化も重要となってきた。情報技術の発展により、ビッグデータという言葉がトレンドとなるように、実際に投資判断を行うのに用いられる情報はどんどん増えてきており、とても人間が処理できる量ではなくなってきた。そのような中でもテキストデータは、数値情報とは異なり、人間が読んで理解するのにとりわけ時間がかかる。さらに、場合によってはそのテキストの解釈が人によって異なったりもする。従って資産運用の高度化および効率化では、このニュースを適切に処理し、株価への影響を検証することは重要である。企業が発表する財務諸表に代表されるような数値データと株価との研究はこれまで数多くなされておき、今日の資産価格理論の礎となる効率的市場仮説では説明できないようなあのマリーについても数多く報告されている。一方で、テキスト情報の中でもニュースはその名前の通り、企業や経済に対する新しい情報をもたらすという意味で重要であり、企業の合併や不祥事といった情報は、株価に影響を与えてきた例は数多くみられる。しかしながら、ニュースと株価の関係に関する分析は、まだ緒に就いたばかりである。

そのような中、本論文では、テキストマイニングを用いて、ニュースソースとして新聞の朝刊を利用し、ニュースから効率的にセンチメントを抽出する手法を提案し、さらに株価への影響を明らかにした。ニュースからセンチメント情報を抽出する先行研究はいくつかあるものの、市場全体の動きと関連を調査したもの、個別企業であっても特定のイベントを対象としたものが多い。とりわけ我が国における個別企業に関するニュースが個別企業の株価へ与える影響を、長期のデータを利用して検証したのはほとんどなく、その点は本論文の重要な成果である。さらに、センチメントの抽出においても一般的な極性辞書を利用するのではなく、大量の経済金融分野のテキストを利用して、その精度の高さから近年注目されているディープラーニングに手法を

利用してセンチメント抽出モデルを開発した点も貢献といえる。

第3章では、ニュースから一般的な極性辞書を用いて、ニュース記事が株価に影響を与えるかどうかを検証した。この2点を明らかにしている。1点目は、ニュースのセンチメントが株価にどのような影響を与えるのかであり、もう1点は、ニュースのセンチメントを投資戦略に活用できるかである。1点目については、3つの仮説を立て、それぞれ検証を行った。結果、ポジティブ（ネガティブ）なニュースが出たら、その後の当該企業の株価は上昇（下落）するということを明らかにした。加えて1面の記事ほど、さらに時価総額が小さい企業ほど、この影響が大きくなることも明らかにしている。これらの結果より、多くの投資家は、ニュースを見てその内容を判断し投資行動を決定しており、さらに1面の記事は、2面以降の記事よりも多くの投資家の目に止まりやすく、一般的に情報が少ないと思われる時価総額の小さい企業ほど、投資家が当該ニュースを投資行動の判断材料とする可能性が他の情報源よりも高いことが要因でと考えられる。もう1点目については、センチメントスコアの高い銘柄を保有し、低い銘柄を空売りするポートフォリオシミュレーションで高いパフォーマンスを獲得できることを明らかにした。従って、投資家はこの手法を活用することで、効率的に大量のニュースを処理可能となり、さらに超過リターンを獲得できる可能性がある。

第4章では、一般的な極性辞書よりも優れたセンチメント抽出モデルの開発を行った。経済金融分野では専門用語や独特の言い回しが存在し、第3章で用いたような一般的な極性辞書では、うまくセンチメントを抽出できない場合もあると考えられる。そこで大量の経済金融分野のテキストとその評価情報からディープラーニングモデルを用いてセンチメントを抽出するモデルを構築した。ニュースから一般的な極性辞書で抽出したセンチメントと、この構築したモデルで抽出したセンチメントを比較したところ、構築したモデルの方がより、センチメントを捉えられていることを明らかにした。具体的には、ポジティブ（ネガティブ）なニュースが出たら、その後の当該企業の株価は上昇するという仮説を立て、株価への影響を調査したところ、係数が統計的にも経済的にも構築したモデルのほうの方が優れているという結果になった。これは金融や経済に関するニュースには既存の一般的な極性辞書ではとらえられない情報が含まれており、金融経済のデータを利用して構築したモデルのほうがそのような情報をより正確に抽出していると考えられる。

第5章では、第4章で構築した経済金融分野に特化したセンチメント抽出モデルを用いてニュース記事からセンチメントを抽出し、投資戦略を構築し、ポートフォリオシミュレーションで戦略の効果を検証した。具体的には、日次、週次、月次の頻度で個別企業に関するニュースから抽出したセンチメントを個別企業毎に集約し、その大きさを銘柄をバスケットに分けてポートフォリオ構築し投資した場合のパフォーマンスを計算した。結果は、日次頻度での投資戦略のパフォーマンスは高く、週次、月次では全くその効果が得られないことが分かった。これらの結果より、ニュースのセンチメントの株式市場に与える影響は非常に短く、日次以上、週次未満であることを明らかにした。いくつかの先行研究で、日本市場においてセンチメントのマーケット全体へ与える影響は短いことが確認されているが、個別銘柄でも同様の結果となることが明らかにしている。

今後の取組としては、センチメント抽出モデルのさらなる改良が考えられる。本論文で構築したモデルは、一般的な極性辞書よりも精度が高くなるものの、同じテキストであればどの企業についても同一のセンチメントを抽出する。しかしながら、例えば「円安」という単語は、輸入が主体となる企業と、輸出が主体となる企業で、本来であれば将来的な利益への影響は異なるはずである。複数の企業に関係する1つのニュースであったとしても、1つ1つの企業への影響度は違うはずであり、究極的には企業毎にセンチメント抽出モデルがあるのが望ましい。また、今回はニュースのみを対象としているが、その範囲をさらに広げるのも興味深いであろう。企業の発行する有価証券報告書や、アナリストレポートはもちろんのこと、近年盛んとなってきているSNSも対象となろう。実際、SNSでの大統領発言が株価に影響を与えている。

また、実務へのさらなる応用の検討も重要な課題である。第5章にセンチメントを利用したポートフォリオシミュレーションを実施しているが、売買回転率が非常に高く、運用金額が大きくなってくるとコストが大きくなってしまい、バックテスト上で獲得できたリターンはコストを考慮するとマイナスになってしまう可能性が高い。回転率が高まる原因として、個別企業のセンチメント自体の変化というよりも、そもそも個別企業のニュースの頻度自体が少ないという点にある。本論文ではニュースソースとして(1つの)新聞の朝刊を採用している。新聞の朝刊はその紙面が限られているため、記者が社会的に影響度の高いと考える記事が優先的に載せられる可能性があり必ずしもすべての記事が載るわけではない。例えば対象とする新聞を拡大や、金融ベン

ダーが専用端末提供するニュースなどに対象範囲を広げることで解決できるであろう。また、さらに大型にユニバースを絞るというような手立ても考えられる。加えて本論文ではセンチメントの影響は日次以上週次未満であるとしているが、実際何日程度まで有効なのかを明らかにすることで、さらにリバランス頻度を下げることができるだろう。一方でより頻度の短い分析も考えられる。近年では高頻度で取引を行う投資家も増えてきており、彼らは1日で非常に多くの売買を行うことで、収益を得ることを目的としている。個別銘柄のティックデータを活用して、朝刊ではないリアルタイムで配信されるニュースがどのように影響を与えるのか詳細な分析が求められる。

謝辞

本論文は著者が、筑波大学大学院システム情報工学研究科リスク工学専攻に在籍中の研究成果をまとめたものである。

研究を進めるにあたり、同専攻教授 津田和彦先生には研究方法、進め方など全ての段階において多大なるご指導を賜り、さらに学内だけではなく研究会の紹介など学外からのアドバイスを頂ける機会も用意くださいました。心より深謝申し上げます。

また、津田研究室のゼミ生、先輩各位には、ゼミの時間で様々なアドバイスやご指摘をいただきました。皆様からの助言があり本研究をスムーズに進めることができました。誠にありがとうございました。

最後に様々な専門分野で活躍する同期生、仕事と研究の両立に理解を示してくれた方々に心より感謝申し上げます。

参考文献

[Allen 2014]

Allen H. Huang, Amy Y. Zang and Rong Zheng (2014). "Evidence on the Information Content of Text in Analyst Reports," *The Accounting Review* (2014) 89 (6): 2151–2180.

[Allen 2019]

David E. Allen, Michael McAleer & Abhay K. Singh (2019). "Daily market news sentiment and stock prices," *Applied Economics* 51 (30): 3212-3235.

[Antweiler 2004]

Antweiler, W., and M. Z. Frank (2004). "Is All That Talk Just Noise? The Information Content of Internet Stock Message Boards," *Journal of Finance* 59.

[Azuma 2014]

Takahiro Azuma, Katsuhiko Okada, Yukinobu Hamuro (2014). "Is No News Good News?: The Streaming News Effect on Investor Behavior Surrounding Analyst Stock Revision Announcement," *International Review of Finance, International Review of Finance Ltd.*, vol. 14(1), pages 29-51.

[Barber 1993]

Barber, Brad M., and Douglas Loeffler (1993). "The "Dartboard" Column: Second-Hand Information and Price Pressure." *The Journal of Financial and Quantitative Analysis* 28, no. 2 (1993): 273-84.

[Barber 2008]

Barber, Brad and Odean, Terrance (2008). "All That Glitters: The Effect of

Attention and News on the Buying Behavior of Individual and Institutional Investors,” *Review of Financial Studies*, 21, issue 2, p. 785-818.

[Beschwitz 2013]

von Beschwitz, B., D.B. Keim, and M. Massa (2013). “Media-Driven High Frequency Trading: Evidence from News Analytics.” Working paper (October).

[Bhattacharya 2009]

Bhattacharya, Utpal, Neal Galpin, Rina Ray, and Xiaoyun Yu (2009). "The Role of the Media in the Internet IPO Bubble," *The Journal of Financial and Quantitative Analysis* 44, no. 3 (2009): 657-82.

[Bollen 2011]

Bollen, J., H. Mao and X. Zeng (2011). “Twitter mood predicts the stock market,” *Journal of Computational Science* 2 (2011).

[Boudoukh 2013]

Boudoukh, J., R. Feldman, S. Kogan, and M. Richardson (2013). “Which News Moves Stock Prices? A Textual Analysis,” NBER Working Paper 18725 (January).

[Butler 2013]

Butler, D.. (2013). “When Google Got Flu Wrong.” *Nature*, vol. 494, no. 7436 (14 February): 155–156.

[Bushee 2010]

Bushee, B.J., Core, J.E., Guay, W. and Hamm, S.J. (2010). “The Role of the Business Press as an Information Intermediary,” *Journal of Accounting Research*, 48: 1-19.

[Campbell 1992]

Campbell, J.Y., and L. Hentschel (1992). "No News Is Good News: An Asymmetric Model of Changing Volatility in Stock Returns," *Journal of Financial Economics*, vol. 31, no. 3 (June): 281–318.

[Carhart 1997]

Carhart, Mark M. (1997). "On persistence in mutual fund performance," *The Journal of Finance* 52 (1): 57-82.

[Carretta 2011]

Carretta, A., V. Farina, E. A. Graziano, and M. Reale (2011). "Does investor attention influence stock market activity? The case of spin-off deals." SSRN: <http://ssrn.com/abstract=1930861>.

[Chahine 2015]

Chahine, Salim., Mansi, Sattar. and Mazboudi, Mohamad (2015). "Media news and earnings management prior to equity offerings," *Journal of Corporate Finance*, Elsevier, vol. 35(C), pages 177-195.

[Chan 2003]

Wesley S. Chan (2003). "Stock price reaction to news and no-news: drift and reversal after headlines," *Journal of Financial Economics*, Volume 70, Issue 2, 2003, Pages 223-260.

[Chen 2014]

Chen, H., P. De, J. Hu, and B.-H. Hwang (2014). "Wisdom of Crowds: The Value of Stock Opinions Transmitted through Social Media," *Review of Financial Studies*, vol. 27, no. 5 (May): 1367–1403.

[Clarke 2002]

Clarke, Roger, Harindra de Silva, and Steven Thorley (2002). "Portfolio

Constraints and the Fundamental Law of Active Management,” *Financial Analysts Journal*, vol. 58, no. 5 (September/October):48–66.

[Da 2011]

Da, Z., Engelberg, J. and Gao, P. (2011). “In Search of Attention,” *The Journal of Finance*, 66: 1461-1499.

[Da 2014]

Zhi Da, Umit G. Gurun and Mitch Warachka (2014). “Frog in the Pan: Continuous Information and Momentum,” *The Review of Financial Studies*, Volume 27, Issue 7, July 2014, Pages 2171–2218.

[Dang 2015]

Tung Lam Dang, Fariborz Moshirian and Bohui Zhang (2015). “Commonality in news around the world,” *Journal of Financial Economics*, Volume 116, Issue 1, 2015, Pages 82-110.

[Das 2007]

Das, S.R., and M.Y. Chen (2007). “Yahoo! for Amazon: Sentiment Extraction from Small Talk on the Web.” *Management Science*, vol. 53, no. 9 (September): 1375–1388.

[Dougal 2012]

Dougal, C., J. Engelberg, D. Garcia, and C. A. Parsons (2012). "Journalists and The Stock Market, " *Review of Financial Studies* 25.

[Drake 2014]

Michael S. Drake, Nicholas M. Guest, and Brady J. Twedt (2014). “The Media and Mispricing: The Role of the Business Press in the Pricing of Accounting Information,” *The Accounting Review*: September 2014, Vol. 89, No. 5, pp. 1673-

1701.

[Dzielinski 2013]

Dzielinski, M., and H. Hasseltoft (2013). "Aggregate News Tone, Stock Returns, and Volatility," Working paper (June).

[Engelberg 2008]

Engelberg, J. (2008). "Costly information processing: evidence from information announcements." AFA 2009 San Francisco Meetings Paper.

[Engelberg 2012]

Engelberg, J., A. V. Reed, and M. C. Ringgenber (2012). "How are shorts informed?: Short sellers, news, and information processing," *Journal of Financial Economics*. Volume 105, Issue 2, August 2012, Pages 260-278.

[Fama 1970]

Fama, Eugene (1970). "Efficient Capital Markets: A Review of Theory and Empirical Work," *Journal of Finance* 25 (2): 383–417.

[Fama 1993]

Fama, Eugene F. and French, Kenneth R. (1993). "Common risk factors in the returns on stocks and bonds," *Journal of Financial Economics* 33.

[Fama 2008]

Fama, Eugene F., and Kenneth R. French (2008). "Dissecting anomalies," *Journal of Finance* 63 (2008).

[Fama 2015]

Fama, Eugene F. and French, Kenneth R (2015). "A five-factor asset pricing model," *Journal of Financial Economics* 116 (2015).

[Fang 2009]

Fang, L. and Peress, J. (2009). "Media Coverage and the Cross - section of Stock Returns," The Journal of Finance, 64: 2023-2052.

[Ferguson 2012]

Ferguson, N. J., J. Guo, H. Y. T. Lam, and D. Philip (2012). "Media Content and Stock Returns: The Predictive Power of Press," Multinational Finance Journal, Vol. 19, No. 1, p. 1-31.

[Fsa 2019]

金融庁 (2019). "「高齢社会における資産形成・管理」," 金融審議会 市場ワーキング・グループ報告書, https://www.fsa.go.jp/singi/singi_kinyu/tosin/20190603/01.pdf.

[Galbraith 2013]

Galbraith, John W. and Tkacz, Greg (2013). "Nowcasting GDP: Electronic Payments, Data Vintages and the Timing of Data Releases," CIRANO - Scientific Publications 2013s-25 (2013).

[Galbraith 2018]

Galbraith, John W. and Tkacz, Greg (2018). "Nowcasting with payments system data," International Journal of Forecasting 34 (2): 366-376.

[Garcia 2013]

Garcia, D. (2013). "Sentiment during Recessions," The Journal of Finance, 68: 1267-1300.

[Goshima 2016a]

五島圭一, 高橋大志 (2016). "ニュースを用いた CSR 活動が株価に与える影響の分析," ジャフイー・ジャーナル, 8-35 頁.

[Goshima 2016b]

五島圭一, 高橋大志 (2016). “ニュースと株価に関する実証分析 - ディープラーニングによるニュース記事の評判分析,” 証券アナリストジャーナル第 54 巻第 3 号.

[Griffin 2011]

Griffin, J.M., N.H. Hirschey, and P. J. Kelly (2011). “How Important is the Financial Media in Global Markets?,” Review of Financial Studies 24.

[Grinold 1989]

Grinold, Richard C. (1989). “The Fundamental Law of Active Management,” The Journal of Portfolio Management, vol. 15, no. 3 (Spring): 30–38.

[Hagenau 2013]

Hagenau, M., M. Hauser, M. Liebmann, and D. Neumann (2013). “Reading All the News at the Same Time: Predicting Mid-Term Stock Price Developments Based on News Momentum,” In Proceedings of the Forty-Sixth Annual Hawaii International Conference on System Sciences.

[Harvey 2016]

Campbell Harvey, Yan Liu and Heqing Zhu (2016). “and the Cross-Section of Expected Returns,” Review of Financial Studies, volume 29, issue 1, p. 5 – 68.

[Healy 2011]

Healy, A., and A.W. Lo (2011). “Managing Real-Time Risks and Returns: The Thomson Reuters NewsScope Event Indices,” In The Handbook of News Analytics in Finance.

[Hendershott 2015]

Hendershott, T., D. Livdan, and N. Schürhoff (2015). “Are Institutions Informed

about News?,” *Journal of Financial Economics*, vol. 117, no. 2 (August): 249–287.

[Higashiyama 2008]

東山昌彦, 乾健太郎, 松本裕治 (2008). “述語の選択選好性に着目した名詞評価極性の獲得,” 言語処理学会第 14 回年次大会論文集.

[Hillert 2014]

Alexander Hillert, Heiko Jacobs and Sebastian Müller (2014). “Media Makes Momentum,” *The Review of Financial Studies*, Volume 27, Issue 12, December 2014, Pages 3467–3501.

[Hong 2000]

Hong, H., T. Lim, and J. Stein (2000). “Bad News Travels Slowly: Size, Analyst Coverage, and the Profitability of Momentum Strategies,” *Journal of Finance*, vol. 55, no. 1 (February): 265–295.

[Huberman 2001]

Huberman, G. and Regev, T. (2001). “Contagious Speculation and a Cure for Cancer: A Nonevent that Made Stock Prices Soar,” *The Journal of Finance*, 56: 387–396.

[Jegadeesh 1993]

Jegadeesh, N., and S. Titman (1993). “Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency,” *Journal of Finance*, vol. 48, no. 1 (March): 65–91.

[Jegadeesh 2013]

Jegadeesh, N., and D. Wu. (2013). “Word Power: A New Approach for Content Analysis,” *Journal of Financial Economics*, vol. 110, no. 3 (December): 712–729.

[Johtaki 2009]

上瀧弘晃, 高橋悟, 高橋大志 (2009). “クレジット市場におけるヘッドラインニュースの効果,” 日本ファイナンス学会第 17 回大会予稿集

[Kearney 2014]

Kearney, Colmand. and Liu, Sha (2014). “Textual Sentiment in Finance: A Survey of Methods and Models,” International Review of Financial Analysis 33.

[Katayama 2018]

Daisuke Katayama and Kazuhiko Tsuda (2018). “A Method of Measurement of The Impact of Japanese News on Stock Market.” 22nd International Conference on Knowledge-Based and Intelligent Information & Engineering Systems KES2018.

[Katayama 2019]

Daisuke Katayama, Yasunobu Kino and Kazuhiko Tsuda (2019). “A Method of Sentiment Polarity Identification in Financial News using Deep Learning,” 23rd International Conference on Knowledge-Based and Intelligent Information & Engineering Systems KES2019.

[Katayama 2020a]

Daisuke Katayama and Kazuhiko Tsuda (2020) “A Method of Using News Sentiment for Stock Investment Strategy.” 24th International Conference on Knowledge-Based and Intelligent Information & Engineering Systems KES2020.

[Katayama 2020b]

片山大輔, 津田和彦 (2020). “センチメントスコアを用いたニュースの株価への影響と投資戦略の活用法,” 電気学会論文誌 C (電子・情報・システム部門誌), 140(2), pp.249-256.

[Katakura 2015]

片倉賢治, 高橋大志 (2015). “金融市場ニュースの分散表現学習による辞書作成と金融市場分析,” The 29th Annual Conference of the Japanese Society for Artificial Intelligence.

[Khandani 2010]

Khandani, A.E., A.J. Kim, and A.W. Lo (2010). “Consumer Credit-Risk Models via Machine-Learning Algorithms,” *Journal of Banking & Finance*, vol. 34, no. 11 (November): 2767–2787.

[Kim 2014]

Yoon Kim (2014). “Convolutional neural networks for sentence classification,” arXiv preprint arXiv:1408.5882.

[Klibanoff 1998]

Klibanoff, P., Lamont, O. and Wizman, T.A. (1998). “Investor Reaction to Salient News in Closed - End Country Funds,” *The Journal of Finance*, 53: 673-699.

[Kobayashi 2005]

小林のぞみ, 乾健太郎, 松本裕治, 立石健二, 福島俊一 (2005). “意見抽出のための評価表現の収集,” *自然言語処理*, Vol.12, No.3.

[Kurohashi 2016]

黒橋貞夫, 柴田知秀 (2016). ”自然言語処理概論,” サイエンス社.

[Kothari 2009]

Kothari, S.P., Shu, S. and Wysocki, P.D. (2009). “Do Managers Withhold Bad News?,” *Journal of Accounting Research*, 47: 241-276.

[Komachi 2016]

小町守 (2016). ”自然言語処理の基本と技術,” 翔泳社.

[Laney 2001]

Laney, D. (2001) "3D data management: Controlling data volume, velocity and variety," META Group Research Note. 6 (70).

[Leinweber 2011]

Leinweber, D., and J. Sisk (2011). "Event-Driven Trading and the 'New News'," *Journal of Portfolio Management*, vol. 38, no. 1 (Fall): 110–124.

[Lerman 2010]

Lerman, A., and J. Livnat (2010). "The New Form 8-K Disclosures," *Review of Accounting Studies*, vol. 15, no. 4 (December): 752–778.

[Liang 1999]

Liang, Bing (1999). "Price Pressure: Evidence from the "Dartboard" Column," *The Journal of Business* 72, no. 1 (1999): 119-34.

[Liu 2013]

Liu, B. and J. J. McConnell (2013). "The role of the media in corporate governance: Do the media influence managers' capital allocation decisions?," *Journal of Financial Economics* Volume 110, Issue 1, October 2013, Pages 1-17.

[Loughran 2011a]

Loughran, T. and B. McDonald (2011). "When Is a Liability Not a Liability? Textual Analysis, Dictionaries, and 10-Ks," *Journal of Finance* 66 (2011).

[Loughran 2011b]

Loughran, T. and B. McDonald (2011). "Barron's red flags: Do they actually work?," *Journal of Behavioral Finance*, 12(2), 90-97.

[Maekawa 2013]

前川浩基, 中原孝信, 岡田克彦 (2013). “大規模ニュース記事からの極性付き評価表現の抽出と株価収益率の予測,” オペレーションズ・リサーチ第 58 巻第 5 号.

[Mayew 2012]

Mayew, W. and M. Venkatachalam (2012). “The power of voice: Managerial affective states and future firm performance,” *Journal of Finance* 67(1), 1–43 (2012).

[Maruyama 2008]

丸山健, 梅原英一, 諏訪博彦, 太田敏澄 (2008). “インターネット株式掲示板の投稿内容と株式市場の関係,” 証券アナリストジャーナル第 46 巻第 11 号.

[Meti 2015]

経済産業省 (2015). “「新産業構造部会」の設置について,” 第 1 回 産業構造審議会新産業構造部会,
https://www.meti.go.jp/shingikai/sankoshin/shinsangyo_kozo/pdf/001_02_00.pdf.

[Mikolov 2013a]

Mikolov (2013). “Efficient estimation of word representations in vector space,” arXiv

[Mikolov 2013b]

Mikolov (2013). “Distributed representations of words and phrases and their compositionality,” In *Advances in Neural Information Processing Systems*.

[Nishio 2014]

西尾泰和 (2014). “word2vec による自然言語処理,” オライリージャパン.

[Novy-Marx 2013]

Novy-Marx, Robert (2013). “The other side of value: The gross profitability premium,” *Journal of Financial Economics*, vol.108.

[Okada 2011]

岡田克之, 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ー,” *証券アナリストジャーナル* 第 49 巻第 8 号.

[Okatani 2015]

岡谷貴之 (2015). "深層学習 (機械学習プロフェッショナルシリーズ)," 講談社.

[Okimoto 2014]

沖本竜義, 平澤英司 (2014). “ニュース指標による株式市場の予測可能性,” *証券アナリストジャーナル* 第 52 巻第 4 号.

[Okumura 2010]

奥村学 (2010). “自然言語処理の基礎,” コロナ社.

[Pound 1990]

Pound, J., and R. Zeckhauser (1990). “Clearly Heard on the Street: The Effect of Takeover Rumors on Stock Prices,” *Journal of Business*, vol. 63, no. 3 (July): 291–308.

[Riordan 2013]

Riordan, R., A. Storkenmaier, M. Wagener, and S.S. Zhang (2013). “Public Information Arrival: Price Discovery and Liquidity in Electronic Limit Order Markets,” *Journal of Banking & Finance*, vol. 37, no. 4 (April): 1148–1159.

[Roll 1977]

Roll, Richard (1977). “A critique of the asset pricing theory's tests Part I: On past and potential testability of the theory,” *Journal of Financial Economics* 4 (2): 129–

176.

[Ross 1976]

Ross, Stephen A (1976). "The arbitrage theory of capital asset pricing," *Journal of Economic Theory* 13 (3): 341-360.

[Sharpe 1964]

Sharpe, William F. (1964). "Capital asset prices: A theory of market equilibrium under conditions of risk," *The Journal of Finance* 19 (3): 425-442.

[Sicherman 2015]

Nachum Sicherman, George Loewenstein, Duane J. Seppi and Stephen P. Utkus (2015). "Financial Attention," *The Review of Financial Studies*, Volume 29, Issue 4, April 2016, Pages 863–897.

[Simon 2015]

Simon, D., and R. Heimer (2015). "Facebook Finance: How Social Interaction Propagates Active Investing," *Federal Reserve Bank of Cleveland Working Paper* 15-22 (October).

[Sinha 2016]

Sinha, N.R. (2016). "Underreaction to News in the US Stock Market," *Quarterly Journal of Finance* Vol. 6, No. 2 (June).

[Sosa 2017]

Sosa, P. M. (2017). "Twitter sentiment analysis using com-bined lstm-cnn models." https://www.academia.edu/download/55829451/sosa_sentiment_analysis.pdf.

[Steven 2017]

Steven L. Heston and Nitish Ranjan Sinha (2017). "News vs. Sentiment: Predicting

Stock Returns from News Stories,” *Financial Analysts Journal* 73 (3): 67-83.

[Steven 2010]

Steven Bird 他 (2010). ”入門自然言語処理,” オライリージャパン.

[Suimon 2017]

水門善之, 勇大地, (2017). “日銀総裁会見の表情解析に基づく感情値の計測と金融政策変更との関係,” 人工知能学金融情報学研究会(SIG-FIN) 第 19 回研究会.

[Suwabe 2015]

訪部貴嗣 (2015). “データ革命と株式運用,” 証券アナリストジャーナル第 53 巻第 4 号.

[Takahashi 2003]

高橋悟, 津田和彦 (2003). “アナリストレポートからの資産運用知識の学習システム,” FIT2003.

[Taki 2017]

瀧雅人 (2017). "機械学習スタートアップシリーズ これならわかる深層学習入門 (KS 情報科学専門書)," 講談社.

[Tetlock 2007]

Tetlock, Paul C. (2007). “Giving content to investor sentiment: The role of media in the stock market,” *Journal of Finance*, 62.

[Tetlock 2008]

Tetlock, Paul C., Mayta L. Saar-Tsechansky and Sofus Macskassy (2008). “More than words: Quantifying language to measure firms’ fundamentals,” *Journal of Finance*, 63.

[Tetlock 2010]

Tetlock, Paul C. (2010). "Does Public Financial News Resolve Asymmetric Information?," *The Review of Financial Studies* 23, no. 9 (2010): 3520-557.

[Tsuboi 2017]

坪井祐太, 海野裕也, 鈴木潤 (2017). "深層学習による自然言語処理 (機械学習プロフェッショナルシリーズ)," 講談社.

[Uhl 2015]

Uhl, M.W., M. Pedersen, and O. Malitius (2015). "What's in the News? Using News Sentiment Momentum for Tactical Asset Allocation," *Journal of Portfolio Management*, vol. 41, no. 2 (Winter): 100–112.

[Vega 2006]

Clara Vega (2006). "Stock price reaction to public and private information," *Journal of Financial Economics*, Volume 82, Issue 1, 2006, Pages 103-133.

[Wang 2016]

Xingyou Wang, Weijie Jiang, and Zhiyong Luo (2016). "Combination of convolutional and recurrent neural network for sentiment analysis of short texts," In *Proceedings of COLING 2016*. pages 2428–2437.

[Yamamoto 2016]

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," 2016 年度人工知能学会全国大会.

[Yuan 2015]

Yu Yuan (2015). "Market-wide attention, trading, and stock returns," *Journal of Financial Economics*, Volume 116, Issue 3, 2015, Pages 548-564.

[Zhan 2015]

Xiang Zhang, Junbo Zhao, and Yann LeCun (2015). “Character-level convolutional networks for text classification,” arXiv preprint arXiv:1509.01626

関連業績

第 3 章

片山大輔, 津田和彦 (2020), “センチメントスコアを用いたニュースの株価への影響と投資戦略の活用法,” 電気学会論文誌 C (電子・情報・システム部門誌), 140(2), pp.249-256.

Daisuke Katayama and Kazuhiko Tsuda(2018), "A Method of Measurement of The Impact of Japanese News on Stock Market," Knowledge-Based and Intelligent Information & Engineering Systems: Proceedings of the 22nd International Conference (KES-2018).

第 4 章

Daisuke Katayama, Yasunobu Kino and Kazuhiko Tsuda (2019), "A Method of Sentiment Polarity Identification in Financial News using Deep Learning," Knowledge-Based and Intelligent Information & Engineering Systems: Proceedings of the 23rd International Conference (KES-2019).

第 5 章

Daisuke Katayama and Kazuhiko Tsuda(2020), "A Method of Using News Sentiment for Stock Investment Strategy," Knowledge-Based and Intelligent Information & Engineering Systems: Proceedings of the 24th International Conference (KES-2020).