

# 深層学習を用いて極性付与されたアナリストレポートと 株式リターンとの関連性

平松賢士<sup>1</sup> 酒井浩之<sup>2</sup> 坂地泰紀<sup>3</sup>

Kenji Hiramatsu<sup>1</sup>, Hiroyuki Sakai<sup>2</sup>, Hiroki Sakaji<sup>3</sup>

<sup>1</sup> 株式会社アイフィスジャパン, 株式会社金融データソリューションズ

<sup>1</sup>IFIS JAPAN LTD., Financial Data Solutions, Inc.

<sup>2</sup> 成蹊大学 理工学部 情報科学科

<sup>2</sup> Department of Computer and Information Science, Faculty of Science and Technology,  
Seikei University

<sup>3</sup> 東京大学

<sup>3</sup> The University of Tokyo

**Abstract:** アナリストレポートは、証券会社のアナリストが企業の経営状態や収益力などを調査してまとめたものである。以前の研究では、学習データを自動生成し、深層学習を用いてアナリストレポートに対して極性を付与する手法を提案した。そこで本研究では、深層学習を用いて極性付与されたアナリストレポートと株式リターンとの関連性について実証分析を行った。その結果、アナリストによる定量情報に対する予想変更が無いレポートについて、市場は当該レポートに付与された極性に沿って短期的に反応することや、レポートにて言及された銘柄は、極性の違いによってその後の長期にわたり株式リターンに違いが表れることが明らかになった。

## 1. はじめに

近年、投資家に対して投資判断の支援を行う技術の必要性が高まり、人工知能分野の手法や技術を金融市場における様々な場面に応用することが期待されている。例えば、決算短信から重要な情報を抽出して投資判断の支援を行うといった研究が行われている[3][4][5][6][7]。

本研究において分析対象となるアナリストレポートは、証券会社のアナリストが企業の経営状態や収益力などを調査してまとめたものである。業績予測や事業の今後の展望などが記載されており、予想を元にレーティングが付与される。高度な専門知識をもつアナリストによるレポートは、投資判断のための重要な情報源のひとつであり、株価の変動要因にもなりうる。多い時には1日に1200本以上ものアナリストレポートが発表されることもあるため、全てのレポートに目を通し、内容を把握することは困難である。人工知能分野やテキストマイニングの手法を用いて投資判断を支援する技術が求められており、様々なアプローチで研究が行われている[1][2]。

以前の研究では、アナリストレポートの重要度を判断し取捨選択するための支援技術として、学習データを自動生成し、深層学習を用いて極性（ポジティブ、ネガティブ）を付与する手法を提案した[1]。そこで本研究では、アナリストレポートに付与された極性と株式リターンとの関連性について実証分析を行う。

極性付与は、アナリストレポートに記載されたレーティングや目標株価、業績予想等の定量情報には寄らず、レポートのテキストデータのみを元に付与されるものである。レポートに付与された極性と株式リターンとの関連性を分析することは、アナリストレポート本文に記載された内容が市場にどのようなインパクトを与えているか理解することや、レポート本文にて記載のされ方が違う銘柄について株式リターンに違いがあるかといった事柄を理解することに繋がる。

アナリストレポート本文に対して実証分析を行った先行研究としては太田[8]があり、人手でヘッドラインを読み、調査する14項目毎に数値化していく方法をとっている。

## 2. アナリストレポートへの極性付与

本研究では、アナリストレポートへの極性付与については酒井らの手法[1]を使用する。以下、酒井らの手法[1]について簡単に述べる。分析対象とするレポートは、2012年から2016年の間で主要証券会社15社から発行された銘柄レポート（個別に銘柄について言及しているレポート）166,223本とする。またアナリストレポートからのテキストデータ抽出においては、アイフィスジャパン独自のクレンジング技術を使用して、本文以外のノイズとなるデータを可能な限り除去している。

### 2.1 学習データの自動生成

酒井らの手法[1]により学習データを生成する。アナリストレポートにはレーティングが付与されており、レーティングが上がっていれば、そのアナリストレポートはポジティブな内容が記述されていることが予想できる。同様にレーティングが下がっていればネガティブな内容と予想できる。そこで、2012年から2013年の間に発行された、レーティングが上がったアナリストレポートを正例、レーティングが下がったアナリストレポートを負例とした学習データを生成する。この時、正例と負例の数を揃えるため、条件に合致するレポートのうち正例1,630本、負例1,630本の計3,260本を使用した。

### 2.2 素性選択

学習データから入力層の要素となる語（素性）を選択する。自動生成された学習データにおいて、正例に含まれる内容語（名詞、動詞、形容詞）に対して、式1で重みを計算する。

$$W_p(t, S_p) = TF(t, S_p)H(t, S_p) \quad (1)$$

ただし、

$S_p$ : 学習データにおける正例のアナリスト予想根拠文の集合。

$TF(t, S_p)$ : 文集合 $S_p$ において、語 $t$ が出現する頻度。

$H(t, S_p)$ : 文集合 $S_p$ における各文に含まれる語 $t$ の出現確率に基づくエントロピー。

$H(t, S_p)$ が高い語ほど、正例の文集合に均一に分布していることがわかる。 $H(t, S_p)$ は次の式2で求める。

$$H(t, S_p) = -\sum_{s \in S_p} P(t, s) \log_2 P(t, s) \quad (2)$$

$$P(t, s) = \frac{tf(t, s)}{\sum_{s \in S_p} tf(t, s)}$$

ここで、 $P(t, s)$ は文 $s$ における語 $t$ の出現確率を表し、 $tf(t, s)$ は文 $s$ において語 $t$ が出現する頻度を表す。次に、負例の文に含まれる内容語（名詞、動詞、形容詞）に対して、式3で重みを計算する。

$$W_n(t, S_n) = TF(t, S_n)H(t, S_n) \quad (3)$$

ただし、 $S_n$ は学習データにおいて負例に属する文の集合である。

ある語 $t$ の正例における重み $W_p(t, S_p)$ が負例における重み $W_n(t, S_n)$ の2倍より大きければ、その語 $t$ を素性として選択する。もしくは、語 $t$ の負例における重み $W_n(t, S_n)$ が正例における重み $W_p(t, S_p)$ の2倍より大きければ、その語 $t$ を素性として選択する。すなわち、以下の式4の条件のどちらかを満たす語 $t$ を素性として選択する。

$$W_p(t, S_p) > 2W_n(t, S_n) \quad (4-1)$$

$$W_n(t, S_n) > 2W_p(t, S_p) \quad (4-2)$$

上記の条件を課すことで、正例、負例における特徴的な語のみを素性として選択し、正例、負例ともによく出現するような一般的な語を素性から除去する。選択された素性の一部を以下に例示する。

引き上げ、引き下げ、増額、減額、転換、ポジティブ、鈍化、原料、恩恵、苦戦、体質、ポテンシャル、着実、好転、リストラ

### 2.3 モデル

深層学習のモデルについて以下に述べる。入力は学習データから抽出された2,474語を要素、語 $t$ における $W_p(t, S_p)$ 、もしくは、 $W_n(t, S_n)$ の大きいほうを要素値としたベクトルとする。モデルの入力層のノード数を入力ベクトルの次元数と同じとし、隠れ層は、ノード数1,000が3層、ノード数500が3層、ノード数200が3層、ノード数100が3層の計12層とする。出力層は1要素である。また、エポック数は50回、活性化関数として、ReLUを使用した。上記のモデルを図1に示す。

酒井らの手法[1]に記載されている通り、レーティングが変動しなかったアナリストレポートに対して極性を付与した際の精度は75.5%となっている。




図 1: ニューラルネットワークのモデル

### 3. 極性と株式リターン

前述のモデルを使用し、2014 年から 2016 年の間に発行されたレポートに対し極性を付与し、株式リターンとの関連性を分析する。

#### 3.1 イベントスタディ分析

##### 3.1.1 レポート自体の市場へのインパクト

レポート発行前後 1 営業日間の累積超過リターン ( $CAR_{-1,+1}$ ) を算出し、付与された極性の違いによってレポートに対する市場の反応に違いが表れるか検証する。異常リターンの算出には、金融データソリューションズが提供する「日本上場株式 Fama-French 関連データ」から取得した、Fama-French の 3 ファクターモデルを使用した。推定期間は、アナリストレポート発表日の 120 日前から 21 日前までの 100 日間とした。レポートの定量情報の変更があった場合は、変更による市場へのインパクトがノイズとなるため、定量情報の変更が無いレポートに絞り込む。また REIT、外国部上場銘柄に言及したレポートは対象外とした。また IPO 直後の銘柄に言及したレポートなど推定期間中のデータが確保できないものは除外した。最終的に  $CAR_{-1,+1}$  算出対象となったレポート本数は 45,756 本である。レポートに記載されたレーティングと付与された極性毎に  $CAR_{-1,+1}$  のサンプル数、平均値、t 値を表 1 に纏めた。

全対象レポートをポジティブが付与された群とネガティブが付与された群に分けた場合、平均値  $\overline{CAR}_{-1,+1}$  はそれぞれ、0.3%程度および-0.3%程度と対称の値が得られ、ポジティブな群とネガティブな群の  $\overline{CAR}_{-1,+1}$  の差分は 0.6%程度となった。またレポート内にて言及されているレーティングによって分類した場合も、ポジティブな群とネガティブな群の

$\overline{CAR}_{-1,+1}$  の水準は違えど、その差分は同程度となった。レーティングの取り扱いについては BUY, NEUTRAL, SELL 等の 3 段階評価で付与されることが多いが、一部証券会社では 5 段階評価で付与されている。今回は、5 段階評価で付与されたレポートは、5 段階評価の中間を NEUTRAL とし、それより高い評価のものは BUY、低い評価のものは SELL とし、3 段階評価に置き換えている。またここでは示さないが、レポート発行後 2 営業日以降の異常リターンはほぼ 0%の水準となっており、市場がレポートに対し短期間で反応していることがわかる。これらの結果は、先行研究と整合的な内容である [8] [9]。

表 1: 分類毎の  $CAR_{-1,+1}$  の記述統計量

レーティング	極性	サンプル数	平均値	t値
ALL	ALL	45756	0.176	7.228
	ポジティブ	34899	0.329	12.017
	ネガティブ	10857	-0.313	-5.913
	差分	45756	<b>0.642</b>	<b>10.765</b>
BUY	ALL	21313	0.293	8.521
	ポジティブ	17104	0.393	10.410
	ネガティブ	4209	-0.112	-1.361
	差分	21313	<b>0.505</b>	<b>5.574</b>
NEUTRAL	ALL	21023	0.092	2.542
	ポジティブ	15408	0.281	6.807
	ネガティブ	5615	-0.426	-5.763
	差分	21023	<b>0.707</b>	<b>8.349</b>
SELL	ALL	3420	-0.034	-0.324
	ポジティブ	2387	0.177	1.406
	ネガティブ	1033	-0.521	-2.747
	差分	3420	<b>0.697</b>	<b>3.067</b>

##### 3.1.2 銘柄のパフォーマンス

次に、レポートにて言及された銘柄が、付与された極性の違いによって、レポート発行日以降について株式リターンに違いが表れるか検証する。検証方法は、ファクターによって得られるリターンを正常リターンと定義し、それら以外のリターンを異常リターンと定義して累積超過リターン ( $CAR$ ) を算出する。先ほどの  $CAR_{-1,+1}$  と区別して添え字が無いものがこの定義で算出した累積超過リターンとする。3.1.1 での算出時と同様に、レポートの定量情報の変更があった場合は変更による市場へのインパクトがノイズとなるため、定量情報の変更が無いレポートに絞り込む。また REIT、外国部上場銘柄に言及し

たレポートは対象外とした。最終的に算出対象となったレポート本数は 45,889 本である。

CARの算出には、金融データソリューションズが提供する「日本株式資産運用業務支援サービス(NPMServices)」から取得した、ローゼンバーグ型マルチファクターモデル(リスクファクター12個+業種ファクター33個)を使用した。リスクファクターの内訳は、規模、市場感応度、純資産/株価、利益/株価、財務健全性比率(一般)、財務健全性比率(金融)、米国株感応度、売買回転率、変動性、長期リターン、東証1部外フラグ、新興市場フラグの12個である。この時、異常リターン(AR)は式5で与えられ、累積することでCARが算出される。

$$AR_{i,t} = R_{i,t} - \beta_{i,k,t-1}R_{k,t} \quad (5)$$

ここで、

$AR_{i,t}$ : 銘柄*i*の*t*時点における異常リターン。

$R_{i,t}$ : 銘柄*i*の*t*時点における超過リターン。

$R_{k,t}$ : *t*時点における*k*ファクターリターン。

$\beta_{i,k,t-1}$ : 銘柄*i*の*t-1*時点における*k*ファクターエクスポージャー。時点毎に推定している。

レポート発行日をイベント日*T=0*としその後250営業日までを検証対象期間とした。

対象レポート群のうち、極性がポジティブな群、極性がネガティブな群、それぞれの平均値CARは下記の図2の通りとなった。




図2: 累積超過リターンCARの平均値CAR[%]

ポジティブな群とネガティブな群との間で、レポート発行直後に0.4%程度の差が広がり、その後CARの差は縮まる。60営業日後程度で差が無くなり、その後は差がマイナス方向に広がっていく。

次にレポートに記載されたレーティング情報によって分類した場合も、付与された極性によって結果に差が出るか確認する。下記の図3では、レーティ

ング毎にポジティブな群とネガティブな群のCARの差をプロットした。レーティングは3.1.1での算出時と同様のルールで3段階評価に置き換えている。




図3: レーティング毎のポジティブ群のCARとネガティブ群のCARの差[%]

レーティングがBUYのレポート群において、ポジティブな群とネガティブな群の差は、レポート発行直後に0.2%程度の差が広がり、その後CARの差は10営業日程度で無くなる。その後は差がマイナス方向に広がっていき、ネガティブな群のCARの方が高い値となる。レーティングがNEUTRALのレポート群においては、ポジティブな群とネガティブな群の差は、レポート発行直後に0.45%程度の差が広がり、その後は緩やかに差が縮まっていく。レーティングがSELLのレポート群においては、ポジティブな群とネガティブな群の差は、レポート発行直後に0.4%程度の差が広がり、その後は一旦差が縮まるが130営業日経過後に急速に差が広がっていく。但し、SELLのレポート本数が少ないため統計的に有意な差とは言い切れない。分類毎のCARとt値を表2に纏める。

表2: 分類毎のCARとt値

	CAR (T=60)	CAR (T=120)	CAR (T=180)	CAR (T=240)	
BUY	ポジティブ	0.69 (7.57)	1.09 (8.42)	1.51 (9.48)	1.85 (10.07)
	ネガティブ	0.96 (4.89)	1.70 (6.10)	2.71 (7.97)	3.68 (9.33)
	差分	-0.27 (1.25)	-0.60 (1.97)	-1.20 (3.19)	-1.83 (4.21)
NEUTRAL	ポジティブ	1.07 (11.39)	1.99 (15.07)	3.12 (19.47)	4.06 (22.06)
	ネガティブ	0.65 (4.14)	1.74 (7.68)	2.96 (10.89)	4.09 (13.24)
	差分	0.42 (2.26)	0.25 (0.95)	0.16 (0.50)	-0.04 (0.11)
SELL	ポジティブ	2.26 (7.78)	4.05 (9.44)	6.08 (11.64)	8.32 (13.47)
	ネガティブ	1.93 (4.11)	4.29 (6.37)	5.29 (6.65)	6.98 (7.85)
	差分	0.33 (0.59)	-0.24 (0.30)	0.79 (0.83)	1.34 (1.24)

(図表注) 各T時点におけるCAR [%]を表す。括弧内はt値。

付与された極性によるリターンの違いについてより深く理解するために、レポート発行前後について250営業日前から500営業日後までの長期のCARを算出する。前述の条件で絞り込んだ2014年から2015年までのレポート30,128本を対象とし、レポート発行250営業日前を算出基準日とする。下記の図4は、ポジティブな群とネガティブな群の長期のCARをプロットした。




図4: 長期でのポジティブな群とネガティブな群のCAR [%]

レポート発行前100営業日程度から2群間のCARの差が広がり、レポート発行直後頃に差が最大になる。その後は徐々に差が縮まり、レポート発行後360営業日程度で差が無くなる。その後はポジティブな群のCARとネガティブな群のCARが逆転し、ネガティブな群のCARの方が大きくなる。

同様に、レーティングと極性によって6分類し、長期のCARをプロットした図が下記の図5である。

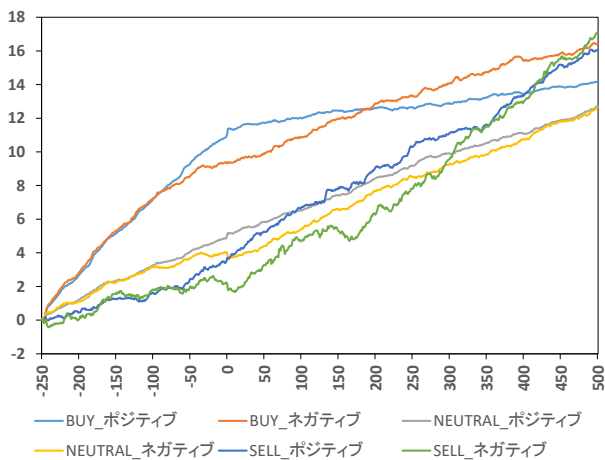


図5: 長期での分類毎のCAR [%]

3 分類したどのレーティングの場合でも、レポート

発行前にポジティブな群とネガティブな群のCARの差が広がり、レポート発行後は、徐々に差が縮まっている。またレポート発行前は、BUYのレポート群のCARが先行して大きな値をとるが、レポート発行後は他のレーティング群のCARの増加の方が大きくなっている。

### 3.2 レポート発行後のレーティング変更率

アナリストレポートの極性によって、その後アナリストがレーティングを変更する確率に差が生じるか確認した。表3は、各分類において発行されたレポート数とその後1年1カ月後までに発行されたレポートにおいて、レーティング変更等のアクションの有無を示している。対象としたレポートは3.1.2と同様の条件を元に抽出した45,889本で、複数回変更があった際には、最初の変更内容を採用している。

表3: 分類毎レポート数とその後の変更状況

ポジティブ	カバー廃止	下方修正	変化無し	上方修正	総計
SELL	40 (1.7%)		1389 (58.2%)	959 (40.2%)	2388
NEUTRAL	303 (2.0%)	1038 (6.7%)	11093 (71.8%)	3009 (19.5%)	15443
BUY	264 (1.5%)	4496 (26.2%)	12418 (72.3%)		17178
総計	607 (1.7%)	5534 (15.8%)	24900 (71.1%)	3968 (11.3%)	35009

ネガティブ	カバー廃止	下方修正	変化無し	上方修正	総計
SELL	24 (2.3%)		615 (59.5%)	394 (38.1%)	1033
NEUTRAL	135 (2.4%)	475 (8.4%)	4014 (71.3%)	1004 (17.8%)	5628
BUY	64 (1.5%)	1171 (27.8%)	2984 (70.7%)		4219
総計	223 (2.0%)	1646 (15.1%)	7613 (70.0%)	1398 (12.8%)	10880

(図表注) レポート本数を表す。括弧内は分類内の比率 [%]

若干の差ではあるが、極性がポジティブなレポートはレーティングが上方修正およびカバー継続されやすく、極性がネガティブなレポートはレーティングが下方修正およびカバー廃止されやすい傾向がみとれる。

### 3.3 極性を元にしたポートフォリオ分析

前節までの分析は、全て個々のレポートについて分析を行った。ここでは、個々のレポートに付与された極性を元に、ある基準日時点において銘柄をポジティブ、ネガティブに分類し、分類された銘柄群による等金額ポートフォリオを作成して、その後のパフォーマンスを測定する。分類方法は下記の通り。

1. 銘柄毎に基準日の前営業日から3ヶ月前までのレポートを収集する。この時、同一証券会社から複数のレポートが発行されていた場合は、最新のレポートのみを対象とする。
2. レーティング変更による市場に対するインパクトを排除するため、レーティングが変更されたレポートを含む銘柄は排除する。
3. 極性がポジティブなレポート本数と極性がネガティブなレポート本数を集計し、ポジティブなレポート本数がネガティブなレポート本数より2本以上多いものをポジティブ銘柄、ネガティブなレポート本数がポジティブなレポート本数より2本以上多いものをネガティブ銘柄とする。

2014年6月末を基準に各銘柄群の等金額ポートフォリオを作成し、その後は半年毎に銘柄を分類し直し、各ポートフォリオのリバランスを実施する。2014年6月末から2017年6月末までの各ポートフォリオのパフォーマンスと同期間のTOPIXのパフォーマンスを図6で示す。2014年6月末時点をも100とした。




図6: ポートフォリオ毎のパフォーマンス

期間中のTOPIXのリターンは35%であったが、ポジティブ銘柄群のポートフォリオは52%、ネガティブ銘柄群のポートフォリオは72%となった。このときポジティブ銘柄群のポートフォリオの平均銘柄数は250銘柄程度で、ネガティブ銘柄群のポートフォリオの平均銘柄数は23銘柄程度であった。

## 4. 考察

前章までの結果から、アナリストレポートに付与された極性の違いによって、言及された銘柄はその後の長期にわたり株式リターンの振る舞い方に違いが出ることを示された。図4および図5にて示した

が、レポート発行前までは、ポジティブを付与された銘柄のパフォーマンスが良く、レポート発行後は、ネガティブを付与された銘柄のパフォーマンスが良くなる。これは、定性情報についてアノマリーが存在するかもしれないことを示していると考えられる。

また得られた極性情報を活用したポートフォリオを構築することで、TOPIXをアウトパフォーム出来る可能性が示唆された。ネガティブ銘柄群のポートフォリオのパフォーマンスが優れているのは、先ほど言及した定性情報についてのアノマリーが存在するならば、その寄与によると考えられる。

但し今回の分析は、2014年から2016年までのレポートとその後の株式リターンを用いたものであり、分析対象とした期間に依存している可能性は否定できない。他の期間を対象に比較検証する必要がある。本文中では示さなかったが、今回分析対象とした期間を複数区切り、期間の違いで結果に差が生じるか確認したところ、統計的に有意な差は生じなかった。少なくとも今回分析対象とした期間中は、極性の違いによって株式リターンに差異が表れるという特徴は安定していると言えるだろう。また3.1.2では累積超過リターンによる結果を示したが、対TOPIX超過リターンの平均値やFama-Frenchの3ファクターモデルによる回帰分析等で検証しても同様の特徴が表れた。

## 5. まとめ

本研究では、アナリストレポートに付与した極性によって株式リターンに差が生じるか検証してきた。極性は、アナリストレポート内で記載されているレーティングや目標株価、業績予想などの定量情報にはよらず、本文のテキストデータのみによって算出されるもので、そのレポートの本文表現がポジティブなのかネガティブなのか分類しているとみなせる。極性と株式リターンの関連性は、アナリストレポート本文に記載された定性情報がどのように市場に影響を与えているか、また定性情報自体に付加価値があるか理解することに繋がる。従来困難であった定性情報の計量化が、近年の自然言語処理技術や機械学習技術の発展により、大量のアナリストレポートに対しても簡便に計量化が出来るようになったことは大変興味深いことだろう。今回はポジティブ、ネガティブの2極性に分類したが、他の方法による計量化を実施することで、アナリストレポート本文が市場に与えている影響や、アナリストレポートの定性情報の持つ付加価値について、また別の特徴を捉えることも可能となるだろう。今後の研究課題としていきたい。

## 参考文献

- [1] 小林和正, 酒井浩之, 坂地泰紀, 平松賢士, “アナリストレポートからのアナリスト予想根拠情報の抽出と極性付与”, 第 19 回金融情報学研究会, pp.68-73, 2017.
- [2] 工藤秀明, 永島淳, 宮崎義弘 “自然言語処理技術を用いたアナリストレポートの実証分析—センチメントの変化と株式市場反応について—” 証券アナリストジャーナル vol.55, no.9, pp.66-77, 2017.
- [3] 酒井浩之, 西沢裕子, 松並祥吾, 坂地泰紀, “企業の決算短信 PDF からの業績要因の抽出”, 人工知能学会論文誌, vol.30, no.1, pp.172-182, 2015.
- [4] 坂地泰紀, 酒井浩之, 増山繁, “決算短信 PDF からの原因・結果表現の抽出”, 電子情報通信学会論文誌 D, vol.J98-D, no.5, pp.811-822, 2015.
- [5] 北森詩織, 酒井浩之, 坂地泰紀, “決算短信 PDF からの業績予測文の抽出”, 電子情報通信学会論文誌 D, vol.J100-D, no.2, pp.150-161, 2017.
- [6] 酒井浩之, 松下和暉, “決算短信からの業績要因文の抽出”, 第 11 回テキストアナリティクス・シンポジウム, pp.87-91, 2017.
- [7] 室野莉沙, 酒井浩之, 坂地泰紀, ベネット ジェイソン, “決算短信から抽出した原因・結果表現の意外性の判定”, 第 11 回テキストアナリティクス・シンポジウム, pp.93-98, 2017.
- [8] 太田浩司 “アナリストレポートの実証分析 —目標株価とレポート内容の分析を中心に—” 証券アナリストジャーナル vol.47, no.11, pp.48-62, 2009.
- [9] 近藤江美, 太田浩司 “アナリストによる株式推奨と利益予想の情報内容” 証券アナリストジャーナル vol.47, no.11, pp.110-122, 2009.