

自然言語処理(Natural Language Processing) – パート I: 入門編 決算報告会見に隠された情報の発見

著者:
Frank Zhao
クオンツ・リサーチ
617-530-8107
fzhao@spglobal.com

自然言語処理(Natural Language Processing, NLP)への関心が高まったのは、1950年に Turing が“Computing Machinery and Intelligence”(「計算する機械と知性」)¹という論文を発表してからである。この画期的な発表の中で、Turing は知性の基準を提唱し、コンピューターが人間と対話して、相手が機械であると気づかれなかったら、そのコンピューターは知性を持つと見なせるとした。NLP の開発の中心にはこの考え方があり、NLP の利用者が機械と対話していることをいつい意識せずにデータから有用な情報を入手できることを目標としている。

この入門ガイドでは、投資家の間に NLP への関心が高まっていることを受けて、まだ理解が深まっていない NLP のさまざまな側面について解説している。また、NLP を使用して決算報告会見のセンチメントを定量分析する3つの例と、対応する Python コードも紹介する。最初の例では、セクター・レベルのセンチメントのトレンドを分析し、センチメントの変化や加速についての情報を提供する。残りの2つの例では、i) 銘柄レベルでのセンチメント変化と予測リターンの分析、ii) 決算報告会見の言語的複雑性(第4セクション)の分析を行っている。

S&P 500 決算報告会見のセンチメント分析(セクター別)

GICS Sectors	Calendar Quarters			
	Q3 2016	Q4 2016	Q1 2017	Q2 2017
Industrials	-2.6%	5.9%	15.5%	15.7%
Information Technology	4.1%	0.3%	7.2%	15.2%
Utilities	-4.6%	7.2%	7.0%	14.1%
Financials	-3.4%	3.7%	14.1%	13.0%
Energy	0.1%	13.6%	25.8%	10.3%
Materials	5.7%	-1.8%	12.2%	1.4%
Consumer Discretionary	-9.9%	-2.2%	4.5%	0.1%
Consumer Staples	3.2%	-1.9%	-8.0%	-5.0%
Health Care	-5.7%	-2.9%	-1.3%	-7.0%
Telecommunication Services	9.1%	-13.6%	-36.9%	-29.4%

Sentiment Improved
↑
Sentiment Deteriorated
↓

注: センチメントは、Loughran and McDonald (2011)²に基づく、決算報告会見中のネガティブ単語の比率と定義される。センチメントの変化は、4 四半期前と比較して四半期単位で測定され、わかりやすくするために値に-1 が乗じられている。セクター・レベルの値は、銘柄レベルの値から均等に合算されている。不動産は金融に含まれます。出典: S&P グローバル・マーケット・インテリジェンスのクオンツ・リサーチ、2017年8月8日現在。

このレポートは、次の4つの項目に分かれている。

- **NLP とは何か** – NLP の一般的な用語について解説し(第2セクション)NLP の活用の一般的な手順の概要を示す(第2セクション)。
- **NLP はなぜ重要か** – 2020年までに、インターネット上のデータの総量は40ゼタバイト(10の21乗バイト)に達すると予想されており³、そのうち80%以上が非構造化(Unstructured) データである。このようなデータを処理して理解するには、NLPが必要である(第3セクション)。
- **NLP はどのように役立つか** – NLP を使用して、決算報告会見の議事録データから、業種レベルのセンチメントのトレンドや、決算報告会見の言語的複雑性などのさまざまな情報を抽出する(第4セクション)。
- **どこから始めればよいか** – ユーザーがセンチメント分析を試してみられるように、各使用例のコードを付属している(第6セクション)

¹ Turing, A.M. “Computing Machinery and Intelligence.” Mind 49 (1950), 433-460.

² Loughran, T., AND B. McDonald. “When is a Liability not a Liability? Textual analysis, Dictionaries, and 10-Ks.” Journal of Finance 66 (2011), 35-65.

³ Mearian, L. (2012, Dec. 11). By 2020, there will be 5,200 GB of data for every person on Earth. <http://www.computerworld.com> から取得。

1. はじめに

NLP の歴史は 17 世紀にまで遡る。Gottfried Leibniz や Rene Descartes といった哲学者や博識家たちは、異なる言語の間で単語を関連付けるための理論的提案を行った。1930 年代には、アルメニアのジャーナリストで作家である Grigor Artsrouni が、翻訳機械に関する初めての特許を出願している。1950 年には、「チューリング・テスト」の考案者である Alan Turing が、“Computing Machinery and Intelligence”（「計算する機械と知性」）という画期的論文を発表している。1957 年には、Noam Chomsky の『文法の構造』が、言語学に革命をもたらした。この著作では、統語構造に基づく規則の集合である「普遍文法」が提唱されている。1980 年代を通じて、NLP システムといえは主に手作業で作成された複雑な規則のセットに基づくものであった。1980 年代末になって、統計的アルゴリズムが手作業による規則に代わって普及し始めた。以下では、基本的な NLP の（ほぼ）あらゆる側面に関する解説を試みる。この入門ガイドを読み終えるころには、読者はこの主題に関する基本的な知識を身につけられるだけでなく、付属のコード・スニペットを利用して簡単な NLP を実現できるようになるはずである。

2. NLP とは何か- 定義と手順

このセクションでは、NLP 関連のいくつかの用語について解説し、この後のすべてのセクションで基礎として用いられる単純な定義を紹介する。その後、NLP プロセスの主な手順について説明する。

2.1 定義

NLP に関して語られる際には、ビッグ・データ、オルタナティブ・データ、機械学習、教師あり学習、教師なし学習といった用語が関連して用いられることがある。これらはどういう意味なのか。さらに、NLP 自体の本当の意味は何なのか。

2.1.1 定義: 最重要用語

自然言語処理 (Natural Language Processing, NLP): コンピューターと統計処理を利用して、コーディング以外の人間による介入を伴わずに、言語を系統的かつ意味のある方法で処理して理解すること。

人工知能 (Artificial Intelligence, AI): 知的な(すなわち人間に似た)動作を行えるシステム (データを受け取って、さまざまな学習方法をデータに適用することで情報を生成し、その情報を出力するもの)を構築するプロセス。弊社の見方では、真の AI の実現にはまだ時間がかかりそうであるが、最近では Google AlphaGo⁴ や Facebook⁵ などによる成果も生まれている。ここに示したのは最終的な目標である。

⁴ Mozur, P. (2017, May 25). Google's A.I. Program Rattles Chinese Go Master as It Wins Match. <http://www.nytimes.com> から取得。

⁵ LaFrance A. (2017, June 15). An Artificial Intelligence Developed Its Own Non-Human Language. <https://www.theatlantic.com> から取得。

2.1.2 定義: データの分類

構造化データ:きっちり設計された SQL データベースに格納されている、エラーが除去され、標準フォーマット化されたデータ・セット

非構造化データ/ビッグ・データ/オルタナティブ・データ:これらの用語は、分析やエラー除去、処理などがまだ行われていない(あるいは部分的にしか行われていない)新たなデータを指しており、通常はテキスト・データが主体であるが、音声データや視覚的データを含むこともある。構造化データに分類されないすべてのデータは非構造化データとなる。

2.1.3 定義: 学習方法の分類

機械学習 (Machine Learning, ML):特定のデータ・セットの意味を理解し、そこから有用な情報を引き出したり、あるいは作業を自動化したりするために、統計的手法を用いること。コンピューター科学やデータ科学の分野では「機械学習」という用語が用いられるが、統計学では「応用統計学」、経済学では「計量経済学」という用語が用いられることがある。機械学習のすべてのアルゴリズムは、大きく分けて2つの分類に属している。1つは**教師あり学習**、もう1つは**教師なし学習**である。詳細についてはこの後で説明する。

深層学習 (Deep Learning, DL):機械学習の一分野。一般的には、ニューラル・ネットワーク(神経回路網)によって実現される。これは、人間の脳、すなわちシナプスによって接続されたニューロンのネットワークを模した設計になっている。ニューラル・ネットワークを通じて深層学習を視覚化する1つの方法は、円柱の形をした概念の階層構造によって学習を組織化するものである。この場合、概念は非線形でもかまわない。上の層から下の層に向かって進むほど、概念は複雑さを増す。

機械学習と深層学習の大きな違いは、深層学習アルゴリズムのパフォーマンスが入力データ量の増加とともに直線的に増加するのに対して、機械学習アルゴリズムのパフォーマンスはある時点で横ばいになることである。

教師あり学習 (Supervised Learning, SL):機械学習または深層学習の1つの分類で、研究者やデータ科学者が何らかのトレーニング・データをアルゴリズムに与えるもの。すなわち、アルゴリズムは事前に決められた「規則」(例:データ・ポイントの間に直線的関係がある、データ・ポイントが正規分布に従う、データ・ポイントが特定の確率で特定の値を取るなど)を参照している。教師あり学習の方法の例としては、線形回帰、ベイズ統計、決定木(decision tree)などがある。

教師なし学習 (Unsupervised Learning, UL):機械学習または深層学習の1つの分類で、アルゴリズム自身が、データ・ポイントをいくつかのグループやカテゴリに分類し、最適な分類方法を見つけることで、「隠された」パターンを自分で発見するもの。オペレーションズ・リサーチについてご存じの方には、これは一種の最適化問題で、アルゴリズムがさまざまなグループ分けを試して、全体的または局所的な「最大値」または「最小値」を見つけようとするものだと言えればわかりやすいかもしれない。教師あり学習との最大の違いは、「規則」やトレーニング・データ・セットが与えられないことである。教師なし学習の方法の例としては、クラスタリングや PCA 期待値最大化法などが挙げられる。

2.1.4 定義:その他

トークン:テキスト内に存在する単語または実体(句読点、数値、URL など)。

トークン化:テキスト(文字列のリスト)をトークンに変換するプロセス。

2.2 NLP の一般的手順

NLP の手順には、一般的に3つの主要な段階がある。最初がテキスト前処理、2番目がテキストからの特徴量の抽出、3番目がテストと改良である。テキスト前処理には、ノイズの除去、語彙の正規化、オブジェクト標準化といった作業がある。テキストからの特徴量の抽出には、構文解析、実体解析、統計的特徴量、単語埋め込みといった作業がある。最後に、テストと改良段階には、コンテンツ・セットからの有用な情報の抽出や自動化された作業の実行に役立つエンジンとなるモデルの設計、調整、改良の作業がある。

2.2.1 テキスト前処理

ノイズの除去とは、目的とする作業に無関係な要素をすべてテキスト・データから取り除く作業である。たとえば、略語、句読点、数値などが除去されることがある。一般的に、URL、ハッシュタグ、略語、ストップワード(theなどの単語)は除去される。実際には、分析に無関係なものはすべてノイズと見なすことができる。弊社が使用した方法の1つは、特定の単語と実体のセットを定義しておいて、それ以外のものをすべてノイズとして除去することである。

語彙の正規化とは、1つの単語が示すさまざまな表現を標準化する方法である(たとえば、単語の屈折形である play、plays、played など)。一般的に用いられる方法としては、STEMMING と LEMMATIZATION の2つがある。どちらの方法も、目標は単語の屈折形や派生形を基本形に還元することである。STEMMING とは、単語のさまざまな屈折形の語尾を切り落とすというおおざっぱな方法である。これに対して LEMMATIZATION は、形態構造に基づいて、単語の屈折語尾を取り除いて基本形に戻す方法である。

オブジェクト標準化とは、省略形や非標準的な綴りを正規の綴りに変換するプロセスである(例:luv を love に変換)。1つの方法としては、包括的な辞書を使用して、綴りの誤りや省略をすべてノイズと見なして除去することが挙げられる。

2.2.2 テキストからの特徴量の抽出

構文解析は、一般的に2種類の分析に分けられる。1つは依存文法、もう1つは品詞タグ付け(Part of Speech, PoS)である。これらは、文の構造をモデル化するために用いられる。依存性は、文法の文脈の中にあり、各文は、3つ組関係(関係、主要部、従属部)に分割される。この3つ組関係は、文法的に言えば、文の主語、動詞、および直接(または間接)目的語と見なすことができる。通常は、木を使用して3つ組を視覚的に表現します。構文解析の主要目的は、テキストを処理する前に文の構造を考慮に入れることである。

構文を理解するためのもう1つの一般的なツールとして、PoSがある。たとえば、英語の単語の多くは、文脈に応じて異なる品詞を取ることができる。例として、bookという単語は、「book a flight」（航空便を予約する）のように動詞として使うことも、「reading a book」（本を読む）のように名詞として使うこともできる。PoS タグ付けを使用することで、NLPで処理できる情報が増え、品詞という次元から単語を理解することが可能となる。

統計的特徴量は、テキストを定量化可能な特性に変換した数値結果である。一般的な例としては、テキストの単語、文、または音セクションの数量が挙げられる。これにより、たとえば、テキスト内のネガティブな単語の比率を求めることでテキストのセンチメント(トーン)を推定したり、1文あたりの単語数とテキスト内の多音セクション語の比率を計算することでテキストの読みやすさ(例: ガニング・フォッグ・インデックス)を判定したりすることができる。

単語埋め込み

さらに高度な統計的特徴量として、**単語埋め込み**がある。これは、数値のベクトルを使用して、単語のさまざまな次元を把握する方法である。直観的に言えば、各次元(数値)はその単語の使用状況を示すと考えられる。ただし、実際の使用においては、次元は解明されてない。

資料1に、単語埋め込みの簡単な例を示している。左端の列は、理解しようとしている単語のさまざまな次元を表す。数値は、各次元の数値表現であり、トレーニング・データ・セットから生成された値である。この例では、各セルの値は0以上1以下の範囲に制限されている。値の大きさは、単語と次元の間の関係の強さを表す。たとえば、Queen(女王)とRoyalty(王族)に対応する値は0.990と、きわめて近い関係を示すのに対して、King(王)とFemininity(女性性)に対応する値は0.050で、あまり関係がないことを示す。想像できるように、各単語について何百もの次元を作成すれば、ベクトル内の各数値はその単語の文脈的使用を効果的に表現できるはずだ。

資料1: 単語埋め込みの単純な例

次元	単語			
	King	Queen	Woman	Princess
Royalty	0.990	0.990	0.020	0.980
Masculinity	0.990	0.050	0.010	0.020
Femininity	0.050	0.930	0.999	0.960
Age	0.700	0.600	0.500	0.100

注: 値は説明用の架空のものであり、次元は実際にはわかっていない。出典: S&P グローバル・マーケット・インテリジェンスのクオンツ・リサーチ。Drozd et al., (2016)⁶。

次元の数が増えるにつれて、単語埋め込みは、単語が使用される可能性があるさまざまな文脈を効果的に網羅でき、数値によってその関連付けの強さを表現できると考えられる。

⁶ Drozd, A., Gladkova, A., Matsuoka, S. "Word Embeddings, Analogies, and Machine Learning: Beyond King – Man + Woman = Queen". Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers, pages 3519–3530

たとえば、ここに示した例にベクトル演算を適用することで、単語埋め込みは、人間が明示的に教えなくても、「ジェンダー」という概念を学習した(たとえば、King(王) - Masculinity(男性性) + Femininity(女性性) = Queen(女王)という演算が実行できる)。単語埋め込みは、現在最も急速に進歩している最先端の技術であり、NLP の分野のいくつかの重要なブレイクスルーにおいて、主要なツールとしての役割を果たしている。⁷

2.2.3 テスト、改良、有効性評価

テストと改良は、プロセスの最後の段階である。テストとは、NLP が課題を達成できたかどうかを、ユーザーが事前に定義した“しきい値”(たとえば、受信した実際の迷惑メールの 60%が迷惑メールに分類される)を使用して判定することである。改良とは、有効性しきい値が満たされるまで、NLP アルゴリズムの調整を繰り返すことである。データ・マイニングのリスクを軽減するため、入力データ・セット全体を 3 つ以上の部分に分割するのが普通である。たとえば、データの(ランダムに選択した)50%をトレーニング・セットとして使用し、残りの 50%を評価セット用に残しておく。トレーニング・セットをさらに 2 等分し、その一方(データ全体の 25%)を開発セット、もう一方(残りの 25%)を開発テスト・セットに指定する。

$$\begin{aligned} \text{データ・セット全体(100\%)} &= \text{開発セット(50\%)} + \text{評価セット(50\%)} \\ \text{開発セット(50\%)} &= \text{トレーニング・セット(25\%)} + \text{開発テスト・セット(25\%)} \end{aligned}$$

この方法では、開発トレーニング・セットを使用してモデルを調整し、そのモデルの有効性を開発テスト・セットでテストする。改良が十分であると判断されたら、モデル(少なくとも現時点ではこれ以上変更を加えない)を評価セットに適用することで、最終的な有効性テストを行う。実証研究についてご存じの方なら、データ・セットをサンプル内とサンプル外に分けるのと同じ考え方だと気づかれるかもしれない。先ほどの迷惑メールの例なら、迷惑メール・フォルダーに分類されたメールを調べて、アルゴリズムを検証。評価セット内での成功率が、事前に決めた成功しきい値、すなわち 60%以上であれば、アルゴリズムは成功と見なされる。

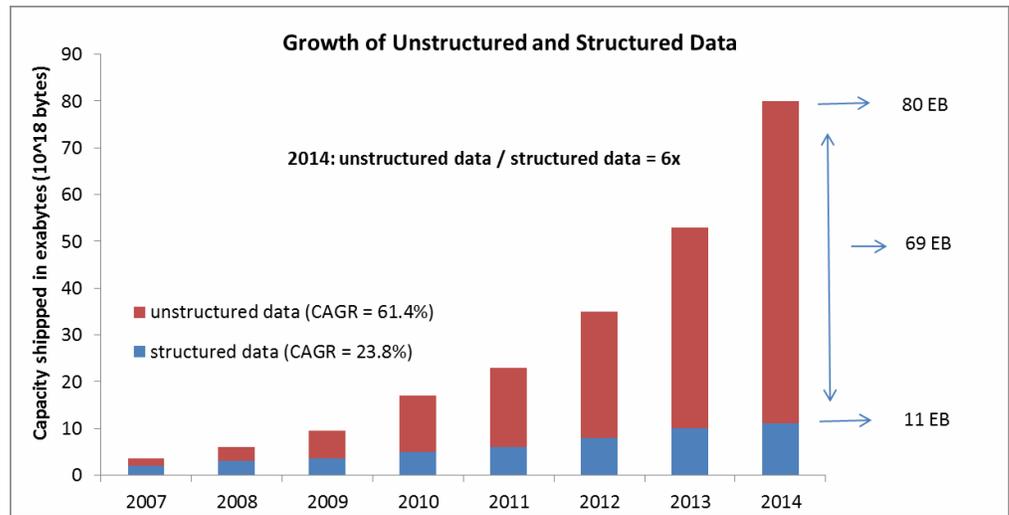
3. NLP はなぜ重要か

現在、インターネット上では、毎日 2.5 エクサバイト(10 の 18 乗)の非構造化データが作成されている。⁸それがどれだけの量かという、この入門ガイドを読んでいる 2 日間の間に作成されたデータは、人類の歴史が始まってから 2003 年末までの間に作成されたすべてのデータと同程度の量になる。⁹International Data Corporation (IDC)によれば、インターネット上で利用可能なデータ全体の 80%が非構造化データであり、非構造化データと構造化データの間の増加率の差はますます広がりがつある(資料 2)。この膨大であり利用されていないコンテンツの集合が持っている情報を、人間が処理し、理解し、利用するためには、2 つの方法がある。1 つは手作業による処理であるが、これは現実的ではない。もう 1 つは自動処理で、そのために NLP が必要になる。

⁷ Mikolov T., Yih W., Zweig G. “Linguistic Regularities in Continuous Space Word Representations.” Proceedings of NAACL-HLT (2013), 746–751.

⁸ Khoso, M. (2016, May 13). How Much Data is Produced Every Day? <http://www.northeastern.edu> から取得。

資料 2: 非構造化データと構造化データの増加の歴史



出典: S&P グローバル・マーケット・インテリジェンスのクオンツ・リサーチ。IDC。2015年。

4. NLP はどのように役立つか- 決算報告会見から得られる情報

このセクションでは、S&P グローバル・マーケット・インテリジェンスの決算報告会見の議事録データ (earnings call transcripts)を題材として、NLP による情報抽出の例をいくつか紹介する。

- 使用例 1: 個別銘柄のセンチメント変化と将来リターンの関係を分析
- 使用例 2: 産業グループ別センチメントのトレンド・ヒートマップ
- 使用例 3: 2017 年第 2 四半期に、決算報告会見の言語的複雑性とセルサイド・アナリストの選別率の間に関連性が見られた。これは、経営者が悪材料の影響を和らげようとしたためである。
- 使用例 4: 2017 年第 2 四半期にセルサイド・アナリストの選別率が高かった企業は、2.14%アンダーパフォームした。これは NLP の使用例ではないが、決算報告会見の議事録データの発言者をタイプ別に判別することの効果を示している。

⁹ DeAngelis, S. F. (2014, Feb.). The Growing Importance of Natural Language Processing [ブログ投稿]。2017年8月8日に<http://www.wired.com>から取得。

4.1 Loughran and McDonald(2011) 金融辞書の詳細

使用例 1 と 2 では、センチメントの変化を特定銘柄レベルと産業グループ・レベルで測定している。では、センチメントはどのように定義されるのか。センチメントを定義するにはさまざまな方法があるが、ここでは、単語の袋 (bag-of-words) 法を使用し、センチメント単語のリストを Loughran and McDonald(2011) 金融辞書から取得している。この辞書は、**アクセスしやすさ、包括性、金融に特化した内容、時事用語への非依存性**、そしておそらく最も重要な理由として、**あいまいさのない単一の含意を持つ単語**といった理由により、NLP 用の金融辞書の業界標準となっている。この点について、以下に詳しく説明する。

- **アクセスしやすさ** – 単語リストはオンラインで無償で公開されているため、容易にアクセスできる。
- **包括性** – この辞書は包括的なので、経営者がシステムを出し抜く(すなわち、経験的に将来の株式の低パフォーマンスにつながるということがわかっているいくつかの単語を避ける)ことが困難である。これは、この辞書が考えられるすべての英語の単語から出発し、単語のすべての屈折形を考慮することで、マスター単語リストに合計 80,000 語以上の相異なる単語を収録しているからである。
- **金融に特化した内容** – マスター単語リストを出発点として、1994 年から 2008 年までの 10-K 報告書を基に絞り込むことで、センチメント単語リストを作成している。
- **単語の永続性** – マスター単語リストとセンチメント単語リストは、考えられる最も包括的な英語の単語のリストを基にしていることと、さらに重要なこととして、マスター単語リストが「iPhone」といった時事用語に依存していないことから、すぐに古くなることはないと考えられる。
- **あいまいさのない単一の含意を持つ単語** – センチメント単語リストが、あいまいさのない単一の含意を持つ単語から構成されるように、マスター単語リストの単語のうち、10-K 報告書に最も頻繁に現れる単語が調査の対象とされている。それらの単語が 1 つ 1 つ調べられ、ビジネスの文脈での意味が評価されている。このような処理により、リストに残った単語は、意味にあいまいさがなく、単一の含意を持つようになっている。

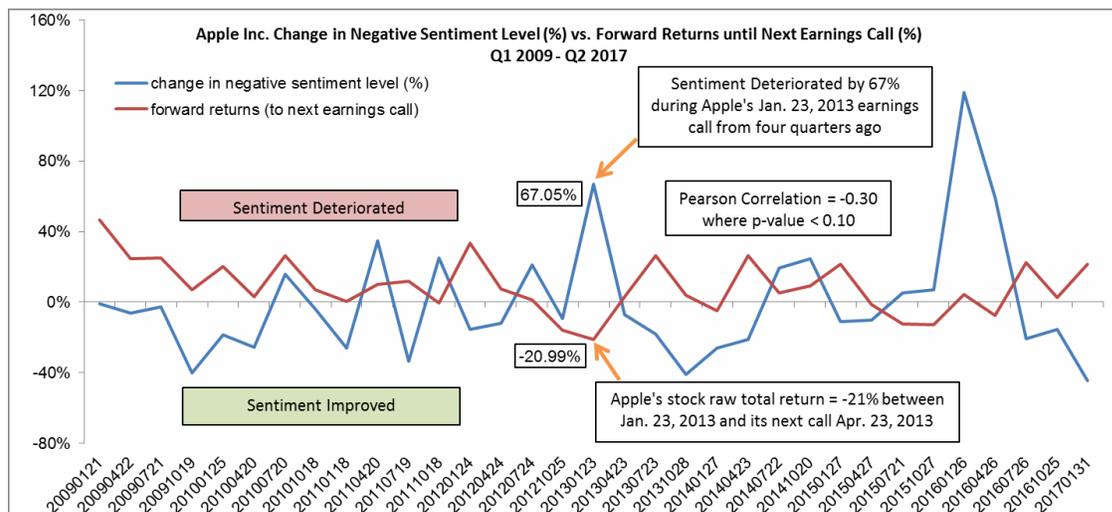
ここで紹介する使用例において重要な単語リストは、マスター単語リスト、ポジティブ・センチメント単語リスト、ネガティブ・センチメント単語リストの 3 つである。それぞれの語数は、80,000 語強、350 語強、2300 語強となっている。ポジティブ単語の例としては、able(できる)、abundance(豊富)、acclaimed(歓迎される)、accomplish(達成)などがある。ネガティブ単語の例としては、abandon(断念)、abdicate(辞任)、aberrant(異常)、abetting(教唆)などがある。

4.2 個別銘柄レベルにおけるセンチメントのトレンド

最初の使用例では、Apple Inc.の決算報告会見からのセンチメント・レベルの変化と、次の決算報告までの将来リターンとの歴史的関係を調べる(資料 3)。センチメントの変化は、4 四半期前と比べた四半期単位の変化と定義される(季節性を考慮するため)。Apple の決算報告会見のセンチメントは、決算議事録データ内のネガティブ単語の比率と定義される。ここで、ネガティブ単語リストとマス

この使用例ではセンチメントをネガティブ単語で測定しているため、正の変化はセンチメントの悪化、負の変化は改善を意味する。Apple の次の決算報告までの将来リターンは、センチメントの変化と将来リターンが資料内で縦方向に揃うように、1 四半期分前にずらされている。1 つの有益な観察結果として、2009 年第 1 四半期以降のピアソン相関は約-0.30 になっている。これは、歴史的に Apple の将来リターンがセンチメントの悪化に伴って減少していることを示す。

資料 3: 特定銘柄レベル - センチメントの変化と将来リターンの関係



注: センチメントは、Loughran and McDonald(2011)に基づく、決算報告会見中のネガティブ単語の比率と定義される。センチメントの変化は、4 四半期前と比較して四半期単位で測定される。出典: S&P グローバル・マーケット・インテリジェンスのクオンツ・リサーチ。2017 年 8 月 8 日現在のデータ。

4.3 産業グループ・レベルの使用例: センチメント変化のトレンド

2 番目の使用例では、S&P 500 GICS 産業グループに関するセンチメントのトレンドを表すヒートマップを作成する。資料 4 に、2016 年第 3 四半期から 2017 年第 2 四半期までの、24 の GICS 産業グループに関する暦四半期ごとのセンチメントの変化を示す。産業グループは、2017 年第 2 四半期からのセンチメントの変化の降順に並んでいる。先ほどの Apple の例と同様に、センチメントの値はすべて、4 四半期前と比較した四半期単位の変化である。各産業グループのセンチメントは、各銘柄レベルのセンチメント(当該企業の決算報告会見内のネガティブ単語の比率から測定)を均等ウェイトに基づいて集計した値である。直観的にわかりやすくするため、値には-1 が乗じられている。すなわち、緑の値はその産業グループに関するセンチメントの改善、赤の値は悪化を示し、色合いはセンチメント変化の大きさを表す。

これにより、産業グループのセンチメントのトレンドを容易に観察して、転換点や加速の徴候をつかむことができる。たとえば、2016 年第 4 暦四半期から 2017 年第 1 暦四半期までの間に、銀行に関するセンチメントは大幅に改善している。投資家はこのことを、上向きの転換点として認識し、その情報を投資に関する意思決定プロセスの参考として利用することができる。

資料 4: S&P 500 のセンチメント変化のトレンド (産業グループ別)

GICS Industry Groups	Calendar Quarters			
	Q3 2016	Q4 2016	Q1 2017	Q2 2017
Consumer Services	-4.1%	-4.0%	16.9%	20.1%
Software & Services	-0.2%	4.1%	-3.9%	19.2%
Transportation	-3.6%	-2.8%	14.6%	19.1%
Diversified Financials	5.4%	13.8%	16.5%	18.0%
Technology Hardware & Equipment	4.8%	7.1%	18.1%	17.5%
Banks	-3.7%	-0.4%	18.1%	16.8%
Capital Goods	-4.9%	9.1%	16.9%	15.5%
Commercial & Professional Services	7.6%	-4.4%	-6.2%	14.6%
Utilities	-4.6%	7.2%	7.0%	14.1%
Insurance	0.0%	14.4%	10.2%	11.9%
Energy	0.1%	13.6%	25.8%	10.3%
Real Estate	-11.5%	-2.4%	0.5%	5.5%
Media	-11.6%	-12.6%	5.0%	4.2%
Materials	5.7%	-1.8%	12.2%	1.4%
Semiconductors & Semiconductor Equipment	6.3%	-3.7%	14.5%	0.5%
Retailing	-18.4%	-0.3%	2.4%	-1.6%
Consumer Durables & Apparel	10.7%	0.2%	-4.7%	-2.6%
Pharmaceuticals, Biotechnology & Life Sciences	-5.7%	-3.6%	-1.3%	-2.9%
Household & Personal Products	-3.3%	-2.9%	-7.8%	-3.9%
Food & Staples Retailing	17.7%	-0.8%	-16.5%	-4.0%
Food, Beverage & Tobacco	2.2%	0.4%	-3.6%	-5.0%
Health Care Equipment & Services	-8.2%	-2.7%	-1.0%	-7.5%
Autos & Components	-14.6%	-4.3%	34.2%	-8.5%
Telecommunication Services	9.1%	-13.6%	-36.9%	-29.4%

Sentiment Improved



Sentiment Deteriorated



注: センチメントは、Loughran and McDonald(2011)に基づく、決算報告会見中のネガティブ単語の比率と定義される。センチメントの変化は、4 四半期前と比較して四半期単位で測定され、わかりやすくするために値に-1 が乗じられている。産業グループ・レベルの値は、個別銘柄レベルの値から均等ウェイトに基づいて集計されている。出典: S&P グローバル・マーケット・インテリジェンスのクオンツ・リサーチ。2017 年 8 月 8 日現在のデータ。

4.4 決算報告会見の言語的複雑性とセルサイド・アナリストの選別率の間に関連性はあるか

3 番目の使用例は、S&P グローバル・マーケット・インテリジェンスの決算報告会見の議事録データの発言者タイプ毎の識別機能を利用して、特にセルサイドのアナリストに焦点を当てて分析している。この例では、なんらかの悪材料があるときに、経営者がそのインパクトを和らげようとしているかどうかを調べる。調査の対象として、2 つの切り口を選んでみる。決算報告会見の言語的複雑性と、決算会見中に質問を許可されたセルサイド・アナリストの選別率である。

4.4.1 ガニング・フォッグ・インデックスの定義と弊社の仮説

決算報告会見の言語的複雑性は、(ガニングの)フォッグ・インデックスによって測定されている(資料 5 の Y 軸を参照)。これは、分析対象のテキスト、すなわちこの例では決算報告会見の議事録に用いられている用語を理解するために必要な正規教育の年数を表す(たとえば、値が 16 なら大学卒業生に相当)。フォッグ・インデックスには 2 つの入力がある。1 つは 1 文の平均単語数、もう 1 つは多音セクション語(3 音セクション以上)の比率である。テキスト内の 1 文の単語数が多く、多音セクション語の比率が高いほど、フォッグ・インデックスは大きくなる。

経営者が悪材料を分かりづらくしようとしているかどうかを評価するのに、なぜフォグ・インデックスが役立つのか。第1に、収益の未達などの悪材料がある場合、経営者は開示義務や受託者義務に従ってそれを開示しなければならない。悪材料が株価に与える影響を軽減するために、経営者は長々と込み入った説明を行う可能性がある。これに対して、好材料がある四半期には、セルサイド・アナリストに対する回答はもっと簡単で直接的なものになるはずである。第2に、決算報告会見の時間は過去の平均で約1時間なので、経営者は質疑応答の残り時間をできるだけ少なくするために、長々と込み入った説明を行う可能性がある。

4.4.2 セルサイド・アナリストの選別率の定義と弊社の仮説

セルサイド・アナリストの選別率は、決算報告会見中に質問を許可されたアクティブなセルサイド・アナリストの比率と定義される。たとえば、Apple Inc.のある決算報告の時点でのアクティブなセルサイド・アナリストの数が40人だとし、Appleの経営陣が10人のアナリストに質問を許可したとすると、アナリスト選別率は25%となり、弊社の基準では高い選別率すなわちネガティブと見なされる。

弊社の仮説では、業績がよい場合、企業はそれを広く伝えたいはずである。特にセルサイドのアナリストは、バイサイドのアナリストやトレーダーに対する重要なメッセンジャーの役割を果たす。企業の業績が順調なら、セルサイドの質問に対する回答は簡単で直接的なものになり、より多くのアナリストが質問を許可されるはずである。業績がよくない場合、2つの理由から、質問できるセルサイド・アナリストの比率は下がると考えられる。第1に、業績の悪化が一時的なものだというような説明に経営者が時間をかけるため、他のアナリストが質問できる時間がそれだけ減ることとなる。第2に、経営者が、企業に対してポジティブな見方をしているアナリストから複数の質問を受け付ける可能性がある。

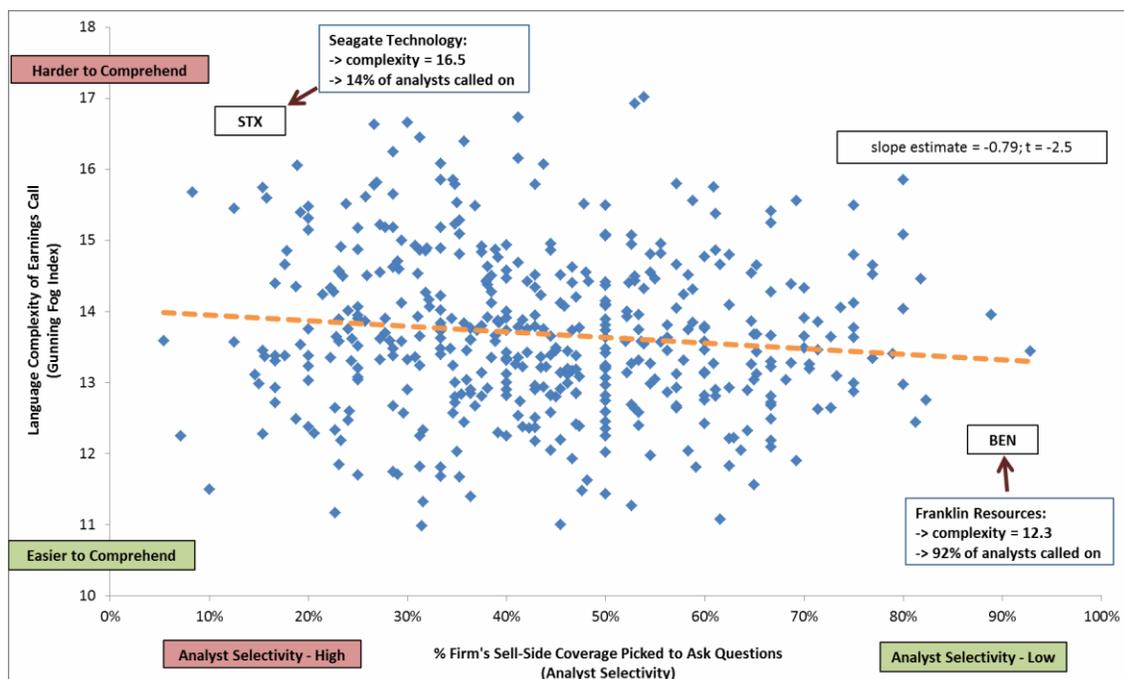
もちろん、アナリスト選別率(あるいは言語的複雑性)を測定するには、他の方法もある。たとえば、このアナリスト選別率の問題点として、時価総額によるバイアスが存在する可能性が挙げられる。企業を担当しているセルサイド・アナリストの数が非常に多い場合、アクティブなアナリストの全員に回答するのは一般的に困難である(たとえば、Apple Inc.は2017年第2暦四半期に43人のアナリストのうち7人にしか回答していない)。一般的には、時価総額が大きいほどセルサイドの担当アナリストの数も増えるため、時価総額の大きい企業ほどアナリスト選別率が高くなる傾向がある。2017年第2暦四半期について、2017年3月31日時点の時価総額を使用して、**各企業のアナリスト選別率と時価総額のスピアマン相関を調べると、値は-0.14となる。**¹⁰ -0.14という相関結果は、企業のアナリスト選別率と時価総額の間に関連がある(すなわち、時価総額の大きい企業ほどアナリスト選別率の値が小さい)ことを示しているが、関連性はそれほど強くない。したがって、ここではこれ以上考察を行わずに、この方法によるアナリスト選別率を使用し続けることにする。これは主に、説明をできるだけ単純にしたいからである。

¹⁰ 各企業のアクティブな担当アナリスト数と時価総額間のスピアマン相関は0.42である。各企業のアクティブな担当アナリスト数とアナリスト選別率間のスピアマン相関は-0.37である。

4.4.3 結果と解釈

使用例 3(資料 5)に関して、2017 年第 2 四半期の結果を見ると、決算報告会見の際の経営者の言語的複雑性が高い企業ほど、アクティブなセルサイド・アナリストからの質問を受け付ける割合が少ないように見える。この関係は、最良適合で得られた右下がりのオレンジ色の点線で示されている。この場合の t-statistic は約-2.5¹¹。

資料 5: 決算報告会見の言語的複雑性とセルサイド・アナリストの選別率の関係、S&P 500 – 2017 年第 2 四半期



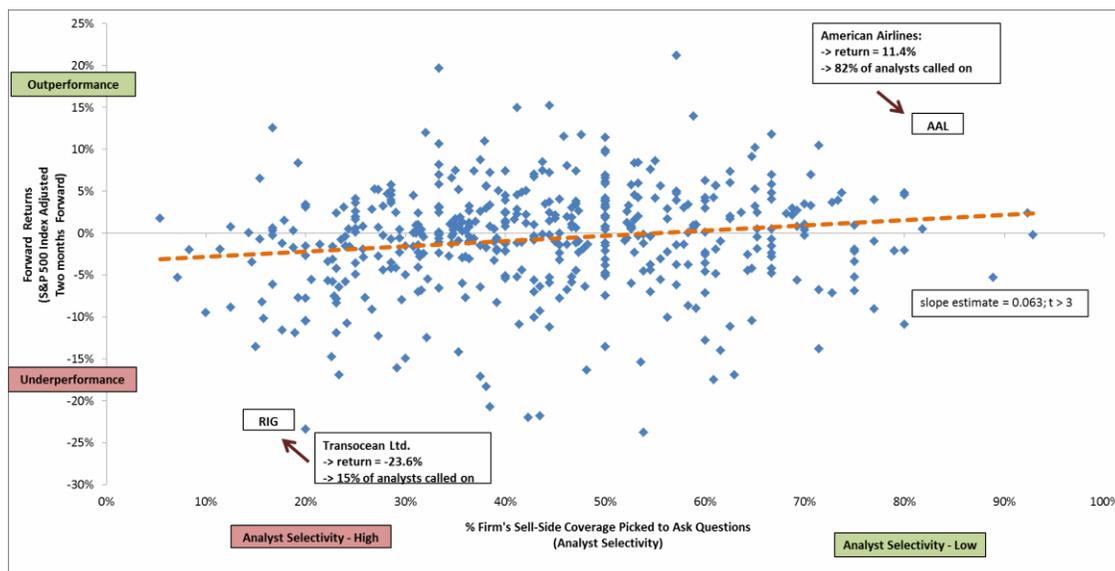
出典: S&P グローバル・マーケット・インテリジェンスのクオンツ・リサーチ。2017 年 8 月 8 日現在のデータ。

4.5 2017 年第 2 四半期に、セルサイド・アナリストの選別率が高い企業はパフォーマンスが低迷
最後の使用例 4 では、使用例 3 の説明に続いて、アクティブなセルサイド・アナリストへの回答率が低かった企業の将来リターンを調べる。S&P 500 指数の対象企業の決算報告後 2 か月の将来リターンと、当該企業のアナリスト選別率の間の関係をプロットした(資料 6)。

¹¹ 2017 年第 2 四半期にこれら 2 つの指標の間に正の相関があり、この関係が偶然によらないことに関しては、統計的に 99%の信頼度がある。

2017年第2四半期には、アナリスト選別率が高かった企業は以後2か月のパフォーマンスが2.14%下回っている(資料6)。リターンはS&P 500のリターンに対して調整され(CAPM ベータを1と仮定)、イベント・スタディ・フレームワークを使用し、結果を知った上ですべての企業を3分位ビンに分類し、アナリスト選別率を指標として、透明度が高い企業に対してロング、低い企業に対してショートの見方を取った。散布図上に直線をフィットすると、直感的に予想されるように直線は右上がりになり、傾きは0.063、t-statisticは3を超える見積もられる。この結果は、第2四半期のパフォーマンス低迷が偶然の結果でないことを示している。

**資料6: 将来リターンとセルサイド・アナリストの選別率の関係、
S&P 500 - 2017年第2四半期**

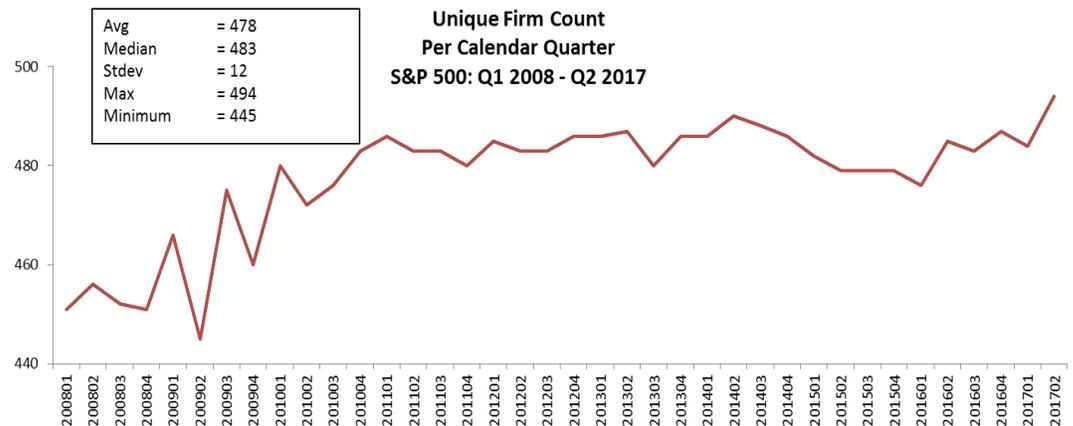


出典: S&P グローバル・マーケット・インテリジェンスのクオンツ・リサーチ。2017年8月8日現在のデータ。

5. 決算報告会見の議事録データ・セット

決算報告会見の議事録データ・セットは、S&P グローバル・マーケット・インテリジェンスの Xpressfeed およびデスクトップ・プラットフォームに新たに追加されたものである。このデータ・セットは、2008年第1暦四半期を起点としており、S&P 500 指数に含まれる米国企業を広く網羅している(資料7)。データ・セットの主な機能としては、発言者タイプ(経営者、セルサイド・アナリスト、株主など)やセクション(発表セクションと質疑応答セクションなど)による決算報告会見の分割が挙げられる。

資料 7: 暦四半期ごとの S&P 500 企業数



出典: S&P グローバル・マーケット・インテリジェンスのクオンツ・リサーチ。2017年8月28日現在のデータ。

6. 各種ツールとコード・スニペットの説明

本ガイドの分析は、PythonとMatlabを使用して行われている。NLPの処理はすべてPythonで行っている。Pythonはこの分野で広く用いられている無料のツールであり、ある程度の学習は必要であるが、使いこなせば威力を発揮する。計算と行列操作はMatlabで行っている(PythonにもMatlabと同様の機能を持つnumpyというライブラリがあるが、ここでは個人的な好みからMatlabを使用している)。

6.1 例とコード・スニペットの利用手順

このセクションでは、第4セクションで紹介した3つのNLPの例について、重要な部分に対応するコード・スニペットを示しながら詳しく説明する。コード全体についてはこちらを参照のこと。以下に手順を示す。

-
- **ステップ 1:** Python 統合開発環境 (IDE) をダウンロードする。ここでの説明には Anaconda を使用している。<https://www.anaconda.com/download/>

-
- **ステップ 2:** センチメント単語リストを入手し、Python コードで読み込めるようにテキスト・ファイルに保存する。ここでの説明では、Loughran and McDonald (2011) のセンチメント単語リスト (https://www3.nd.edu/~mcdonald/Word_Lists.html) を使用して、各決算報告会見の議事録のセンチメントを判定している。

-
- **ステップ 3:** 決算報告会見の議事録データを必要な形式に変換する。入力ファイルには5つの列が必要で、各列は左から順に、株式銘柄識別子、決算報告日付、時間、分、各決算報告のシーケンス識別子、各決算報告の内容である。

-
- **ステップ 4:** 必要な Python ライブラリをロードする(22~35 行目)。

```
#####
import os # import the os module
import pandas as pd # using pandas to create data type 'DataFrame' use
import time # time module can be used now e.g., time.time()
import nltk

#####
fpath = 'C:/Users/fzhao/Desktop/NLP/rawData'
os.chdir(fpath) # chg working directory to fpath
```

-
- **ステップ 5:** Loughran and McDonald(2011) 単語リストを読み込む(43~69 行目)。

```
fn = 'wordLists\\lmMasterList.txt' # input file
tmpWordListPandaObj = pd.read_csv(fn, sep='\t', header=None) # read in tab-delimited
tmpWordListPandaObj.columns = ['master'] # rename cols
master_list = list(tmpWordListPandaObj.master)
master_list = [itr for itr in master_list if not isinstance(itr, float)]
master_list = [itr.lower() for itr in master_list] # make all lowercase
```

-
- **ステップ 6:** 使用する関数を定義する。次に示す1つの関数は、単語の頻度を出力する(84~160 行目)。

```
def _out_word_freq1(list1, list2):
    wordFreqDictObj = {}
    for item in list2:
        if item in list1:
            wordFreqDictObj[item] = wordFreqDictObj.get(item, 0) + 1
    return wordFreqDictObj
```

- ステップ 7:** すべての期間と企業を処理するための制御構造を作成する。ここでは、四半期を 1 つずつ処理し、その中でその四半期に関するすべての企業の処理を行うことにした。ここでは **while** ループ制御構造を使用しましたが、**for** ループ制御構造を使用することもできる。Matlab や C++などの他の言語と比べて、Python の **for** ループは非常に強力な多機能であり、そのために **for** ループ構文がわかりにくくなる場合もある。この例で **for** を使用する場合には、**enumerate** キーワードを使用するとよい。これにより、**for** ループ内で反復インデックスを参照して利用できるようになる(173~213 行目)。

```

start_time                = time.time(); # record time when a piece of code is executed
yrItr                     = 0
while yrItr < len(yrVec):

    qtrItr                 = 0
    while qtrItr < len(qtrVec):

        #creating filename to read in
        fn                  = str('transcriptsAll\sp9_q' + str(qtrVec[qtrItr]) +

        #print(yrVec[yrItr], qtrVec[qtrItr])

        #check file exists
        if os.path.isfile(fn) and os.stat(fn).st_size != 0:

            tmpPandaObj     = pd.read_csv(fn, sep='\t', header=None)           # read
            tmpPandaObj.columns = ['stockId', 'dt', 'hhmm', 'seq', 'ecalls']     # read

```

- ステップ 8:** このステップでは、決算報告のトークン化と前処理を行っている。次のスクリーンショットでは、「**nlTK**」という NLP ライブラリが使用されている。これはネイティブではないが、よく知られているライブラリである。具体的には、「**word_tokenize**」というメソッドを使用して、決算報告をトークンに分割している。この関数は、(ユーザー定義の)句読点または空白を区切りとして解析を行える。ここではその他のテキスト前処理として、i) 句読点の除去、ii) 単語間の空白の除去、iii) すべてのテキストの小文字への標準化なども行われている(234~240 行目)。

```

#####
# nltk mthds
tokensListObj         = nltk.word_tokenize(dsRawSeriesObj) # tokenize all words
tokensListObj         = [itr.lower() for itr in tokensListObj] # make all lowercase

# punct
punct                 = string.punctuation # native punctutation string
punct                 = '!"%$%&&\()*+,-./:;<=>?@[\\]^_`{|}~'; # string.punctuation less '-'
tokensListObj         = ["".join([j for j in i if j not in punct]) for i in tokensListObj]
tokensListObj         = [itr for itr in tokensListObj if itr] # keep on concat if item in list isnt empty

```

-
- ステップ 9:** ユーザー定義関数を使用して、Loughran and McDonald (2011) 辞書で定義された全単語とネガティブ単語の頻度を数える。最初に、決算報告とマスター単語リストの両方に含まれる単語のベクトルの共通部分を求める。その結果は、単に重複のない単語のベクトルである。次に、共通する単語のベクトルと決算報告を、先ほどのユーザー定義関数に与えて、単語をキーとし、その使用頻度を値とするハッシュ・テーブルを生成する。最後に、1つの暦四半期内ですべての企業について処理を行い、それぞれの結果を **panda** というデータ構造に出力する。データ・セットがすべて出力されたら、各議事録内のネガティブ単語の数をその議事録の単語の総数で割って、ネガティブ・センチメントのレベルを算出し、そこから四半期の間のセンチメント・レベルの変化を求めることができる(246~255行目)。

```

tmpWordsList          = list(set(tokensListObj) & set(master_list))
tokensNmasterList     = tmpWordsList
# tmpWordsList2      = set

if not tmpWordsList:
    tmpInt             = 0
else:
    tmpDfObj          = _out_word_freq1(tmpWordsList, tokensListObj)
    masterWordsDsDictObj = tmpDfObj
    tmpInt             = sum(tmpDfObj.values())
    masterCnt          = tmpInt

```

参考文献

Antweiler, W., Frank, M. Z., 2004. “Is all that talk just noise? the information content of internet stock message boards.” *Journal of Finance* 59, 1259 -1293.

Bansal, S. (2017, Jan. 12).Ultimate Guide to Understand & Implement Natural Language Processing (with codes in Python) [Web log post].Retrieved Aug. 8, 2017, from <https://www.analyticsvidhya.com>

Bradley, M., Lang, P., 1999. “Active norms for English words (ANEW):Stimuli, instruction manual and active ratings.” Technical report C-1, The Center for Research in Psychophysiology, University of Florida.

Copeland, M. (2016, Jul. 29).What’s the Difference Between Artificial Intelligence, Machine Learning, and Deep Learning?[Web log post].Retrieved Aug. 8, 2017, from <https://blogs.nvidia.com>

DeAngelis, S. F. (2014, Feb.).The Growing Importance of Natural Language Processing [Web log post].Retrieved Aug 8, 2017, from <http://www.wired.com>

Drozd, A., Gladkova, A., Matsuoka, S. “Word Embeddings, Analogies, and Machine Learning:Beyond King – Man + Woman = Queen”.Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics:Technical Papers, pages 3519–3530

Feldman, R., Govindaraj, S., Livnat, J., Segal, B., 2010. “The incremental information content of tone change in management discussion and analysis.” *Review of Accounting Studies* 15, 915-953.

Griffin, P., 2003. “Got Information?Investor Response to Form 10-K and Form 10-Q EDGAR Filings.” *Review of Accounting Studies* 8, 433-460.

Hanley, K. W., Hoberg, G., 2010. “The information content of IPO prospectuses.” *Review of Financial Studies* 23, 2821-2864.

Khoso, M. (2016, May 13).How Much Data is Produced Every Day?Retrieved from <http://www.northeastern.edu>

LaFrance A. (2017, June 15).An Artificial Intelligence Developed Its Own Non-Human Language. <https://www.theatlantic.com>.

Loughran, T., AND B. McDonald. “When is a Liability not a Liability?Textual analysis,

Dictionaries, and 10-Ks.” *Journal of Finance* 66 (2011):35-65.

Loughran, T., AND B. McDonald. "IPO First-day Returns, Offer Price Revisions, Volatility, and Form S-1 Language." *Journal of Financial Economics* 109 (2013):307-326.

Loughran, T., AND B. McDonald. "Measuring Readability in Financial Disclosures." *Journal of Finance* 69 (2014):1643-1671.

Loughran, T., AND B. McDonald. "The Use of Word Lists in Textual Analysis." *Journal of Behavioral Finance* 16 (2015):1-11.

Mikolov T., Yih W., Zweig G. "Linguistic Regularities in Continuous Space Word Representations." *Proceedings of NAACL-HLT* (2013), 746-751.

Mozur, P. (2017, May 25).Google's A.I.Program Rattles Chinese Go Master as It Wins Match.Retrieved from <http://www.nytimes.com>.

Turing A.M."Computing Machinery and Intelligence." *Mind* 49 (1950), 433-460

最近のリサーチレポート

2017年7月:自然言語処理文献調査

昨今のマーケットでは、自然言語処理(NLP)や非構造化データの分析が頻繁に話題に上がっている。S&P グローバル・マーケット・インテリジェンスでは、いくつかの非構造化データセットを提供しており、注目を集めている。1つは決算報告会見の議事録データで、発言者を特定するための固有の発言者IDが記録されている。もう1つのデータ・セットは、10-Kのテキスト内容である。この文献調査は、近い将来に刊行されるクオンツ・リサーチに関するNLP入門ガイドに先立って提供されるものである。この入門ガイドでは、非構造化データの処理とセンチメント・スコアの生成のプロセスについて解説する。その後、この主題に関して投資家が特に興味を持つと思われる内容を扱った10件の文書が刊行される予定である。

2017年6月:リサーチ概要:金利上昇局面で銀行について知っておくべき4つの重要なこと

FRBが将来のさらなる金利引き上げを示唆している今、銀行セクターに投資するにあたっては、過去の金利上昇局面でどのような投資戦略が効果を上げたかが参考になるはずである。この文書では、SNL銀行ファンダメンタル・データに関する当社の経験的研究を利用して、金利上昇時の銀行株式銘柄の選択に役立つ情報を投資家向けに提供する。

2017年4月:アルファの活用:SNL銀行データを利用した投資シグナルの発見 この研究では、S&P グローバル・マーケット・インテリジェンスのSNL金融データを利用して、銀行投資に関する3つの重要な質問に答える。1.広く用いられている投資戦略のうち、過去に最も利益を上げたものはどれか。2.あまり知られていない戦略のうち、もっと注目されてよいものはどれか。3.これらの戦略は、さまざまなマクロ環境、すなわち金利上昇局面または下降局面、平均以上または平均以下の金融ストレスといった状況で、どのようなパフォーマンスを示すのか。

2017年3月:スピノフの資本市場における意味

スピノフは近年増加傾向にある。2015年には、全世界で2500億ドル以上のスピノフ案件が実行された。これは過去20年間においてもっとも高いレベルである。このレポートでは、米国市場とグローバル市場でのスピノフ企業とその親会社の短期および長期パフォーマンスを分析する。さらに、これと関連するが異なる会社再建手法である株式カーブアウトについても検討する。これは、株式公開を通じて子会社を分離する方法である。

2017年1月:2016年米国株式銘柄選択モデル・パフォーマンス・レビュー

2016年は、アクティブ投資にとって困難な1年だった。年頭の株式市場の急落と、1年を通じた政治的不確実性を背景として、正の超過リターンを生み出したファンダメンタル投資スタイルはバリュエーションただ1つだった。このレポートでは、S&P グローバル・マーケット・インテリジェンスの4種類のU.S. 株式銘柄選択モデルの2016年におけるパフォーマンスを評価する。

2016年11月:米国公益事業での株式リターンの確保

米国の公益事業セクターは、ここ何年か特に高いパフォーマンスを示している。これは、FRB や全世界の中央銀行が、成長を促進するために協調的金融政策を実施してきたことによる。

世界中のアクティブ投資家たちが収益と高いリスク調整後リターンを求めて米国公益事業セクターに殺到する中で、この文書では、公益事業セクター専用の独自データベースである S&P グローバル・マーケット・インテリジェンス・エネルギー(出典: SNL Energy) から得られた公益事業に固有のいくつかの指標を使用して、過去において投資家がこのセクター内の株式銘柄選択の決定により超過リターンを得られたかどうかを検討する。

2016年10月:新しいセクターの誕生:REIT 業界でのリターンの追求 - 第2部

SNL Financial(SNL)のグローバル不動産データベースには、物件レベルの情報や地理的市場別の統計情報といった、投資家がなかなか入手できない情報が含まれている。このような独自のデータ・ポイントは、物件レベルの情報と将来の株価動向の間の関係を理解しようとしている投資家にとって有用である。このレポートでは、これらのデータ・ポイントをアルファ戦略として利用する方法を解説する。当社のバックテストによれば、物件レベルの情報から作成された指標は、ファンダメンタル・データや評価データからは得られない将来の株価動向に関する洞察を提供してくれる。投資家は、健全な REIT 戦略を構築するために、REIT の物件ポートフォリオに関する情報の採用を検討すべきである。

2016年9月:新しいセクターの誕生:REIT 業界でのリターンの追求 - 第1部

今月、GICS(世界産業分類基準)の金融セクターから、REIT(不動産投資信託)が分離されて独自のセクターとなった。セクターの再編に先立って、投資家はすでに REIT の堅調なパフォーマンスと魅力的な収益に注目していました。REIT は、いくつかの重要な点で一般の企業とは異なっている。株式銘柄の魅力を評価するために投資家が通常使用する益回りや簿価/株価比といった指標は、REIT に対してはあまり意味がない。自分の REIT ポートフォリオを理解しようとしているアクティブ投資家にとっては、REIT の財務比率と株価上昇の間の関係を理解することが有用である。配当利回りは意味があるのでしょうか。最も広く用いられている指標の1つである FFO(Funds From Operations)はどうか。

2016年8月:M&A:よい買収、悪い買収、最悪の買収(それを 見分ける方法)

この調査では、ラッセル 3000 企業のうち、企業価値の 5%を超える買収を行った企業は、買収後のリターンが同業他社に比べて低かったことを示す。具体的には、次のことがわかった。

- 買収を行った企業は、買収後長期間にわたって、さまざまなファンダメンタル指標に関して同業他社を下回っている。

- 株式による買収の場合は、現金による買収に比べてパフォーマンスが大幅に低くなる。株式の割合が高い買収を行った企業のパフォーマンスは、買収から1年後で3.3%、3年後で8.1%同業他社を下回っている。
- 買収前に急速に成長していた企業は、買収後にパフォーマンスが低下することが多くある。
- バランスシート上の余剰現金はM&Aにとって有害である。その理由は、現金支出に関する規律の欠如にあると思われる。

2016年7月：石油価格下落への備え -- 歴史に学ぶ

WTI(West Texas Intermediate)価格が40ドル台半ばを付ける中で、供給過剰への懸念と、以前からの世界的な景気後退の兆しから、多くの人々が石油価格下落の再来を警戒している。石油・ガス関連の企業、特に総合石油・ガス企業の年初来のパフォーマンスは堅調であり、そのことがさらに石油価格下落への懸念を高めている。

2016年6月：ソーシャル・メディアと株式リターン：サイバースペースに価値は存在するか

このソーシャル・メディア文献のレビューは、当社が特に有用あるいは興味深いと判断した記事を対象としている。当社はソーシャル・メディアの分野に関するリサーチを行ったことはないが、興味深い情報の探索は常に行っており、これらの文章を読者の方々の賢明な考察に委ねたいと思う。

2016年4月：「スマート・マネー」のIQテスト - 機関投資家の評判は正当か

このレポートでは、機関所有(Institutional Ownership、IO)に関する4種類の株式銘柄選択シグナル、すなわち所有レベル、所有の幅広さ、所有レベルの変化、所有ダイナミクスについて検討する。そして、これらのシグナルを金融機関の分類(ヘッジファンド、 뮤チュアルファンド、年金基金、銀行、保険会社)別にセグメント化する。この研究は、過去の研究(米国だけでなくもっと広い地理的範囲における)で得られた、機関所有が株価に影響を与えるという結論の多くを裏付けている。ここではさらに、既存の文献を基にして、「IO」シグナルとファンダメンタルに基づく従来の株式銘柄選択シグナルを混用することの利点について調べている。

2016年3月：株式銘柄レベルの流動性 - アルファかリスクか - 流動性が増加中の株式は世界的に高パフォーマンス

ほとんどの投資家は、株式銘柄レベルの流動性を、株式銘柄選択のシグナルではなく、大きな取引コストや価格への悪影響を与えずに容易に取引を行えるかどうかの尺度と捉えている。ここでは、Bali, Peng, Shen, Tang (2012)といった最近の文献に着想を得て、1年間の株式銘柄レベル出来高の変化が最も大きかった銘柄を購入するという戦略が、過去において市場全体より高いパフォーマンスを示しただけでなく、価格モメンタムの強さ、魅力的なバリュエーション、ハイクオリティといった基準を使用する戦略をもパフォーマンスにおいて上回っていたことを、全世界的に証明する。1年間の株式銘柄レベル出来高の変化は、一般的に用いられている株式銘柄選択シグナルとの間に低い相関(0.15未満)を示す。これらのシグナルと組み合わせることで、各シグナルを単独で使用するよりも高い超過リターンと情報レシオ(IR)を実現できる。

2016年2月:米国株式銘柄選択モデルのパフォーマンス・レビュー - 2015年に最も効果的だった投資戦略

2011年1月に4種類のS&P Capital IQ[®]米国株式銘柄選択モデルが発表されて以来、4つのモデル(グロース・ベンチマーク・モデル、バリュー・ベンチマーク・モデル、クオリティ・モデル、価格モメンタム・モデル)のパフォーマンスは毎年すべてポジティブでした。これらのモデルの主要な差別化要因としては、大型株と小型株に対する異なる定式化、金融セクターに関する産業固有の情報の反映、ターゲット銘柄の固有アルファに対するセクター中立性、ファクターの多様性などが挙げられ、これによってさまざまに異なる市場環境を通じて高いパフォーマンスを発揮できたと考えられる。このレポートでは、2015年と導入(2011年)以降の各モデルのパフォーマンスを支える要因を評価し、1987年1月以降のモデルの完全なパフォーマンス履歴を示す。

2016年1月:収益ガイダンスが教えてくれること- 経営陣からの好材料に注目

この研究では、2003年1月から2015年2月までの米国企業のEPS(1株あたり純利益)ガイダンス前後の株価の動きを、S&P Capital IQの予測データベースを使用して調べる。ポジティブなガイダンス・ニュース(楽観的ガイダンス、すなわちコンセンサス予想よりも高いガイダンスの発表や、ガイダンスの上方修正など)があった企業では、正の超過リターンが発生した。ここでは、ガイダンス開示の市場への影響を明確に理解するため、決算発表と同時に行われたガイダンスは除外した。またここでは、投資家が年次および四半期ガイダンス情報を活用するための実用的方法も紹介する。

2015年12月:エクイティ・マーケット・パルス - 四半期ごとの株式市場情報誌、第6号

2015年11月:遅すぎた提出 - 10-Q および 10-K 企業報告書の提出遅れのコスト

2015年10月:グローバルなカントリー・アロケーション戦略

2015年9月:エクイティ・マーケット・パルス - 四半期ごとの株式市場情報誌、第5号

2015年9月:リサーチ概要:スマート・ベータ・ポートフォリオの構築

2015年9月:リサーチ概要 - 航空産業固有のファクター

2015年8月:ポイント・イン・タイムのファンダメンタルと遅れのあるファンダメンタル - 時間がもたらす違い

2015年8月:S&P Capital IQ 日本市場向け株式銘柄選択モデルの紹介

2015年7月:リサーチ概要 - 流動性のもろさ

2015年6月:エクイティ・マーケット・パルス - 四半期ごとの株式市場情報誌、第4号

2015年5月:投資家アクティビズムが増加する世界での投資

2015年4月:石油・ガス産業のアルファの採掘 - 産業固有のデータと企業財務情報から得られる洞察

2015年3月:エクイティ・マーケット・パルス - 四半期ごとの株式市場情報誌、第3号

2015年2月:米国株式銘柄選択モデルのパフォーマンス・レビュー - 2014年に最も効果的だった投資戦略

2015年1月:リサーチ概要:世界の年金制度 - 完全積み立て式年金制度は過去の遺物か

2015年1月:利益率:グロースのような戦略、バリューのようなリターン - 強い競争優位性を持つ企業から利益を得る

2014年11月:エクイティ・マーケット・パルス - 四半期ごとの株式市場情報誌、第2号

2014年10月:貸し手が導き、所有者が従う - 信用指標と株式リターンの関係

2014年8月:エクイティ・マーケット・パルス - 四半期ごとの株式市場情報誌、第1号

2014年7月:ファクター・インサイト:トレンド追従戦略の欠点の緩和

2014年5月:S&P Capital IQ のファンダメンタル中国 A 株株式リスク・モデルの紹介

2014年4月:アクティビスト投資家に便乗 - 短期および長期の高パフォーマンスを実現

2014年3月:学術文献からの洞察:企業の性格、トレーディングに関する知見、新しいデータソース

2014年2月:新興国市場で優位を得る

2014年2月:米国株式銘柄選択モデル・パフォーマンス・レビュー

2014年1月:高パフォーマンスを買う:自社株買いの発表はリターン増加につながるか

2013年10月:インサイダー取引の情動的価値 - 企業のインサイダー報告に隠された利益

2013年9月:負担の押し付け合い - リサーチ概要: 年金制度の研究

2013年8月:S&P Capital IQ 先進国市場向けグローバル株式銘柄選択モデルの紹介: 高パフォーマンスの基盤

2013年7月:革新的トピックに関する示唆に富む文書: アセット・アロケーション、インサイダー取引、イベント・スタディ

2013年6月:サプライチェーンの相互作用、第2部: 企業 - 関連する企業のリターンイベント・シグナルとしての研究

2013年6月:異常な資産増加の背景 - 過大な約束、過小な成果

2013年4月:複雑な企業をわかりやすく - 専門企業を利用した複合リターンの予測

2013年3月:必要ときに役立つリスク・モデル - 短期リスク・モデルの強化

2013年3月:スマート・マネーに追随 - アクティビスト投資家に便乗

2013年2月:株式銘柄選択モデル・パフォーマンス・レビュー: 2012年のパフォーマンスの要因の評価

2013年1月:リサーチ概要: 1月効果の利用 - さまざまなトレンド追随戦略の検証

2012年12月:CEO や CFO の退任は重要か - CEO および CFO の交代のシグナルとしての意味

2012年11月:11種類の産業、70種類のアルファ・シグナル - 産業固有の指標の価値

2012年10月:S&P Capital IQ のファンダメンタル・カナダ株式リスク・モデルの紹介

2012年9月:ファクター・インサイト: 収益発表時リターン - リターンに基づくサプライズは収益に基づくサプライズより優れているか

2012年8月:サプライチェーンの相互作用、第1部: 業界 - 業界における進み遅れ関係から利益を得る

2012年7月:S&P Capital IQ 地域株式リスク・モデルのリリースと、グローバルおよび米国モデルの更新

2012年6月:業界のモメンタムに乗る - 残存リバーサル・ファクターの改良

2012年5月:石油・ガス産業 - グローバルなポイント・イン・タイム産業データを利用したアルファの探掘

2012年5月:事例研究: S&P Capital IQ - 投資の意思決定のためのプラットフォーム

2012年3月:証券貸付市場からのアルファの探求 - データの改良から生まれた新しいアルファ

2012年1月:S&P Capital IQ 株式銘柄選択モデルのレビュー - 2011年のパフォーマンスの要因の理解

2012年1月:インテリジェントな予想 - 収益サプライズの優れたモデル

2011年12月:ファクター・インサイト - 残存リバーサル

2011年11月:リサーチ概要: リターンの相関とばらつき - 全か無か

2011年10月:銀行業界

2011年9月:動的重み付けの手法

2011年9月:リサーチ概要: リターンの相関とばらつき

2011年7月:リサーチ概要 - 投資戦略のヒント - テーマ別概要

2011年6月:小売産業に関する戦略: 産業固有データは異なる情報をもたらすか

2011年5月:S&P Capital IQ のグローバル・ファンダメンタル株式リスク・モデルの紹介

2011年5月:興味深い内容の論文

2011年4月:配当政策の変化はアルファをもたらすか

2011年4月:2011年春期 CQA カンファレンス・ノート

2011年3月:速報データにはどの程度のアルファがあるか

2011年2月:産業インサイト - バイオテクノロジー: FDA 承認触媒戦略

2011年1月:米国株式銘柄選択モデルの紹介

2011年1月:最小分散戦略のさまざまな種類

2011年1月:2010年の注目すべき影響力のある論文

2010年11月:銀行がストレス下にあるかどうかの判定 - 動的銀行モデルの紹介

2010年10月:ポイント・イン・タイム・データの活用方法

2010年10月:アナザー・ブリック・イン・ザ・ウォール: 価格モメンタムの歴史的失敗

2010年7月:S&P Capital IQ のファンダメンタル米国株式リスク・モデルの紹介

Copyright © 2017 by S&P Global Market Intelligence, a division of S&P Global Inc. All rights reserved. (著作権 © 2017 年 S&P グローバル・インクの一部門、S&P グローバル・マーケット・インテリジェンス。不許複製・禁無断転載。)

本資料は、一般に公開されている情報および信頼できると考えられる情報源に基づき、あくまで情報提供のみを目的として作成されています。いかなる内容(指数データ、格付け、クレジット関連の分析とデータ、リサーチ、モデル、ソフトウェア、またはその他のアプリケーションもしくはそれからのアウトプットを含む)も、これらのいかなる部分(以下「内容」という。)も、S&P グローバル・マーケット・インテリジェンスまたはその関連会社(以下総称して「S&P グローバル」という。)の書面による事前許可なしに、いかなる形式と手段によっても、修正、リバースエンジニアリング、複製、配布、あるいはデータベースまたは検索システムへの保存はできません。本内容を不法または不正な目的のために使用することを禁じます。S&P グローバルもいかなる外部サービス提供者(以下総称して「S&P グローバル関係者」という。)も、本内容の正確性、完全性、適時性、または利用可能性について保証いたしません。S&P グローバル関係者は、原因のいかに関わらず、本内容の誤りまたは記載漏れ、本内容の利用により得られた結果に対し、一切責任を負いません。本内容は「現状有姿」で提供されています。S&P グローバル関係者は、明示または黙示を問わず、本内容の商品性や特定の目的または使用に対する適合性、本内容にバグやソフトウェアのエラーまたは欠陥がないこと、本内容の機能が中断されないこと、または、本内容がいかなるソフトウェアあるいはハードウェアの設定環境においても作動することについての保証をはじめとする一切の保証をいたしません。S&P グローバル関係者はいかなる場合も、本内容の利用に関連する直接的、間接的、付随的、処罰的、補償的、懲罰的、特別ないし派生的な損害、経費、費用、訴訟費用、または損失(損失利益、逸失利益、機会費用、あるいは過失により生じた損失を含みますが、これらに限定されません)について、たとえかかる損害の可能性を通知されていたとしても、いずれの当事者に対しても一切責任を負わないものとします。

S&P グローバル・マーケット・インテリジェンスの見解、見積もり、クレジット関連およびその他の分析は、それらが表明された時点の意見を示すものであり、事実の記述ではなく、何らかの証券の購入、保有、または売却を推奨するものでも、何らかの投資判断を推奨するものでも、いずれかの証券の投資適合性に言及するものでもありません。S&P グローバル・マーケット・インテリジェンスは、指数データを提供することがあります。指数に直接投資することはできません。指数によって示される資産クラスに対するエクスポージャーは、当該指数に基づく投資可能商品を通じて得られます。S&P グローバル・マーケット・インテリジェンスは、いかなる形式や形態においても、本内容を公表後に更新する義務を負いません。本内容は、利用者、その経営陣、従業員、助言者および/または顧客の技能、判断、および経験に代わるものではなく、本内容に依拠して投資やその他の経営の決断を行うべきではありません。S&P グローバル・マーケット・インテリジェンスが、受託者または投資助言者として行為することは、その旨登録されている場合を除きありません。S&P グローバルは、各事業部門の業務の独立性と客観性を保つために、それぞれの特定の業務を他と分離させています。結果として、S&P グローバルのある特定の事業部門は、他の事業部門が入手できない情報を得ていることがあります。S&P グローバルは各分析作業の過程で受領する非公開情報

決算報告会見に隠された情報の発見
の機密を保持するための方針と手順を確立しています。

S&P グローバルは、格付けや特定の分析に対する報酬を、証券の発行体または引受業者、あるいは債務者などから受領することがあります。S&P グローバルは、その見解と分析を広く周知させる権利を留保しています。S&P グローバルの公開格付けと分析は、無料サイトの www.standardandpoors.com、および購読契約による有料サイトの www.ratingsdirect.com と www.globalcreditportal.com で閲覧できるほか、S&P グローバルによる配信、第三者からの再配信といった他の手段によっても配布されます。当社の格付け手数料に関する詳細については www.standardandpoors.com/usratingsfees をご覧ください。