

ニュース記事に基づく景気指標 S-APIR の開発

関 和広^{1*} 生田 祐介² 松林 洋一^{3,4}
Kazuhiro Seki¹ Yusuke Ikuta² Yoichi Matsubayashi^{3,4}

¹ 甲南大学 知能情報学部
Faculty of Intelligence and Informatics, Konan University
² 大阪産業大学 経営学部
Faculty of Business Management, Osaka Sangyo University
³ 神戸大学大学院 経済学研究科
Graduate School of Economics, Kobe University
⁴ アジア太平洋研究所
Asia Pacific Institute of Research

Abstract: This paper reports our work on developing a new business sentiment index using daily newspaper articles. We adopt a recurrent neural network (RNN) to estimate the sentiment of a given text. The RNN is initially trained on Economy Watchers Survey and then fine-tuned on newspaper articles for domain adaptation. Also, a one-class support vector machine is applied to filter out texts of irrelevant topics. Moreover, we analyze the contributions of various factors that influence the estimated business sentiment.

1 はじめに

政府や中央銀行が定期的に発表する景気ウォッチャー調査¹の現状・先行き判断 DI (diffusion index; 景気動向指数) や日銀短観²の DI などの経済指数は、金融当局の政策決定や企業の生産計画、機関投資家・個人の投資判断など、様々な経済活動の拠りどころとして重要な役割を担っている。しかしながら、これらの指数算出の基礎となる調査には大変な手間とコストがかかる。

たとえば、景気ウォッチャー調査の現状・先行き判断 DI (以降「景気ウォッチャー DI」と呼ぶ) の場合、北海道、東北、北関東、南関東、甲信越、東海、北陸、近畿、中国、四国、九州、沖縄の 12 地域を対象に、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 (小売店の店主、タクシー運転手など) 2,050 人を対象に地域別調査機関がアンケート調査を行い、取りまとめ調査機関において地域ごとの調査結果を集計・分析し、指数の算出を行っている。また、このような調査には相応の時間を要するため、日銀短観は四半期に一度、景気ウォッチャー指数は一月に一度しか発表されず、リアルタイム性が低い。

一方、店舗の商品売り上げのような統計データ、各種

ニュース記事やマイクロブログなどのテキストデータ、検索エンジンのクエリログデータ、スマートフォン等から収集される GPS の位置情報データ、あるいは人工衛星の衛星画像データなど、いわゆるオルタナティブデータが世界中で絶えず生成・収集され、大量に蓄積されている。このようなデータが利用可能になってきたこと、および深層学習 (deep learning) に代表されるデータドリブンな人工知能技術の発展から、人手による調査を要さず、すでに存在する他の大規模なデータを代替的に用いた経済・金融指数の将来予測 (forecast)、あるいは足元予測 (nowcast) への注目が高まっている [Kapetanios 18, 関 17]。具体的な取り組みとして、たとえば店舗の POS (point of sale) データを用いた消費者物価指数のナウキャスト [Watanabe 14]、金融・経済レポートからの景況感指数の予測 [山本 16]、新聞記事からの穀物の市場価格や経済指数の予測 [Chakraborty 16]、[Shapiro 17] などがある。

本研究では特にテキスト情報に着目し、日々発信されるニュース記事を利用して、新しい景況感指数 (S-APIR 指数と呼ぶ) を提案する。また、予測された指数を用いて、特定の概念 (語句) が景況感にどのように影響を与えたのか時系列で分析する。

*連絡先: 甲南大学知能情報学部知能情報学科
〒658-8501 兵庫県神戸市東灘区岡本 8-9-1
E-mail: seki@konan-u.ac.jp

¹http://www5.cao.go.jp/keizai3/watcher/watcher_menu.html

²<http://www.boj.or.jp/statistics/tk/>

表 1: 景気ウォッチャー調査（現状の景気）の例.

地域	回答者	景気	判断理由
北海道	タクシー 運転手	×	売上が減少しているが、季節要因に加えて、景気が下向していることも影響している。
北関東	輸送用機械器具製造業	◎	自動車は米国への輸出が増えている。

2 関連研究

経済・金融分野では、失業率や物価指数などの統計値や個別企業の売上高など多くの数値データに加えて、新聞記事や決算短信、金融レポート等、関連するテキストデータが豊富に存在する。通常、これらのテキスト情報は人が読み込み、他の情報・状況と考えあわせ、総合的な意思決定を行うために利用される。しかしながら、すべての関連するテキスト情報を限られた時間で咀嚼・勘案することは、熟練した専門家であっても現実的には困難である [関 17]。そこで、このようなテキスト情報を用いて経済・金融指数を予測する試みが広く行われている。ここでは、本研究に関連が深い景況感指数（ビジネスセンチメント）の予測について代表的な研究をいくつか紹介する。

2.1 景況感指数の予測

1 節で述べた内閣府の景気ウォッチャー調査では、集計された指数（景気ウォッチャー DI）に加えて、個々のアンケート回答者が判断した現状および先行きの景気の状態（「◎（良い）」から「×（悪い）」までの 5 段階評価）とその理由（自然言語文）が公開されている。いくつかの例を抜粋して表 1 に示す。

景気ウォッチャー DI は、表 1 の「景気」の 5 段階の判断にそれぞれ点数を与え、これらの点数を各判断区分の構成比（%）に乗じた和で算出されている。算出された DI は、50 を基準（景気に変化なし）として 0 から 100 の値を取る。なお、景気ウォッチャー調査では、景気の実況判断と先行き判断を区別して回答させるため、それぞれに指数が算出される。

山本ら [山本 16] は、この景気判断理由文を説明変数、景気判断を被説明変数とした回帰モデルを学習し、景況感（野村 AI 景況感指数）の予測を行った。回帰モデルとしては、Long Short Term Memory (LSTM) ユニット [Hochreiter 97] から構成される両方向・多層の RNN (Recurrent Neural Network) を用い、学習・検証・テストデータとして、景気ウォッチャー調査の回答およそ 200,000 件を用いた。実験の結果、個別の景気判断の推定精度は平均二乗誤差 (Mean Squared Error;

MSE) で 0.346 と報告している。また、政府の月例経済報告と日銀の金融経済月報から抽出したテキストを同モデルを用いてそれぞれ指数化し、これらの結果が日銀短観 DI および景気ウォッチャー DI（現状）と高い相関 (0.782~0.843) にあることを示した。

類似の研究として、饗場ら [饗場 18] は Twitter から景気に関するツイートを抽出し、同様のモデルで景況感 (SNS×AI 景況感指数) を予測した。近藤ら [近藤 19] は、金融機関の社員が取引先企業との面談を通して作成したテキストを入力として、同様のモデルで景況感を予測した。五島ら [五島 19] は、曇み込みニューラルネットワークを利用し、ロイターのニュース記事から景況感を予測した。

3 景況感の推定と要因の分析

2 節で述べたように、景気ウォッチャー調査にはアンケート回答者が判断した景気（現状および先行き）とその判断理由文とが含まれる。いずれも人手で作成された質の高い貴重な資源であり、これを基に経済指数を推定する試みが行われている。本研究では、五島ら [五島 19] と同様に新聞記事に着目して景況感指数の推定を行う。一方、五島らが景気ウォッチャー調査から学習したモデルにそのままニュース記事を入力して景況感指数を推定したのに対して、本研究では、3.1 節で述べるように記事のフィルタリング、およびモデルのドメイン適応を行う。なお、将来的には景況感指数のナウキャスト（足元予測）を目指しているが、本稿では既存の月次の景気指標（景気ウォッチャー DI）との比較のため、推定した指数を月次に集約して利用する。

続いて 3.2 節では、景況感に影響を与える要因の時間的な分析を行う手法について述べる。一般的に、景況感は、金融政策や物価、為替、雇用、賃金、海外情勢など、様々な要因から形成されている。しかしながら、全ての要因が経済に等しく影響を与えているわけではない。経済の情勢判断を行う上では、経済を上向きあるいは下向きに動かす要因が何であるのかを知ることが重要である。本研究では、どのような要因（語句）が、「いつ」、「どの程度」景況感に影響を与えたのか、推定した指数を基に分析を行う。

3.1 S-APIR 指数

新聞記事を利用した景況感指数 (S-APIR) の予測を行うにあたり、必要となる 3 つのコンポーネントについて述べる。1 つ目は指数の予測自体を行う回帰モデル、2 つ目は新聞記事から無関係な記事を取り除くフィルタリング、最後に学習データ（景気ウォッチャー調査の景気判断説明文）と指数の予測に用いるデータ（新

聞記事)の違いを吸収するドメイン適応である。以下それぞれについて説明する。

3.1.1 回帰モデル

テキストデータを用いた回帰モデルでは、従来、各単語を独立した一つの説明変数としてモデルを学習することが一般的に行われてきた。そこでは、文脈を無視して、テキストは単語の集合 (Bag of Words; BoW) として表現される [Manning 08]。しかしながら、テキストの意味をより適切に表現するためには、文脈による単語の意味の違いや単語間の係り受け関係を把握する必要がある。

近年、このようなテキストの文脈を考慮したモデル化の方法として、RNN がよく用いられている。ただし、RNN は勾配消失問題から長期の依存関係をうまく学習できないという欠点があるため、RNN の隠れ層を構成するニューロンとして、入力信号の依存関係を扱う特別な機構を持つ LSTM 等のユニットを用いるのが一般的である。本研究でも、テキストの文脈をより適切に表現するため、LSTM と同様の機構を持つ Gated Recurrent Unit (GRU) [Cho 14] を用いて RNN を構成する。そして、景気ウォッチャー調査のデータを学習データとして利用し、景気判断理由文を説明変数、景気判断の結果を被説明変数とする。ただし、現状判断と先行き判断とは理由文の特徴が異なると考えられるため、本稿では現状判断のデータのみを用いる。また、景気判断は◎, ○, □, △, × の記号で表現されているため、これらをそれぞれ 2, 1, 0, -1, -2 として扱う。

なお、先行研究 [山本 16] と同様に入力テキストの両方向から指数の推定を行う bidirectional LSTM (あるいは GRU)、および近年注目されている Bidirectional Encoder Representations from Transformers (BERT) [Devlin 19] を利用した実験も行ったが、新聞記事から景気指標を推定するという本タスクにおいては、単純な GRU-RNN の方が総合的に良い結果が得られたため、本稿では他の結果は割愛する。

3.1.2 フィルタリング

前述のように学習した回帰モデルを利用することで、任意のテキストデータから景況感指数の予測が可能となる。しかしながら、本実験で利用するデータは新聞記事であるため、景気ウォッチャー調査の景気判断理由文とは異なり、入力される文章は経済に関係しないことも多い。そこで、経済や景気に関する記事だけを選択的に利用することを目的に、異常値検出に用いられる 1 クラス SVM (One-Class Support Vector Machine)

[Manevitz 02] を利用する。学習データとして景気ウォッチャー調査の景気判断理由文を与えることで、景気判断理由文と類似していない文 (新聞記事) を外れ値として指数の算出から除外する。

景気判断理由文の表現方法としては、tf-idf (term frequency-inverted document frequency) [Manning 08] で重み付けした単語ベクトル、BERT を用いた文の分散表現を比較し、予備実験でより良い結果が得られた前者を用いる。

3.1.3 ドメイン適応

RNN の学習に用いる景気ウォッチャー調査の景気判断理由文と、指数の推定に用いる新聞記事とでは、文章中の語彙や表現、文体 (合わせて「ドメイン」と呼ぶ) が異なると考えられる。学習時と予測時におけるドメインの違いは、回帰モデルの予測性能に悪影響を与えるため、指数の推定に用いる新聞記事のドメインにモデルを適応させることができれば、より適切な指数の推定が可能になるものと期待できる。

そこで、景況感指数予測モデルのドメイン適応の可能性を探るため、処理対象の新聞記事から新たな学習データを自動生成し、ドメイン適応を試みる。具体的には、まず、景気ウォッチャー調査から学習した初期的な回帰モデル (3.1.1 節参照) を用いて新聞記事の各文の指数を予測する。そして、予測値が高い事例は景気動向をよく表していると仮定し、あらかじめ設定した閾値に基づいて、高スコアの文を正例、低スコアの (負で絶対値が大きい) 文を負例として学習データとする。

このように構築した学習データを用いて、モデルのドメイン適応を行う。ドメイン適応は、ここでは単純に学習済みのモデルを新たな訓練データを用いて再学習 (fine tuning) することで行う。

3.2 景況感に影響を与える要因の分析

景況感は、日銀の金融政策や消費増税などの税制、インバウンドや貿易・紛争などの海外情勢等々、様々な要因から形成されている。本節では、前節の方法で推定した指数に対する語の寄与を考えることで、どのような要因 (語句) が、いつ、どの程度景況感に影響を与えたのかを分析する簡便な方法を提案する。具体的には、ある期間 t における語 w の寄与 $p_{t,w}$ を以下のように定義する。

まず、文 s の指数 p_s は、文 s を構成する語 $w \in s$ の指数 $p_{s,w}$ の総和であると仮定する。

$$p_s = \sum_{w \in s} tf_{s,w} \cdot p_{s,w} \quad (1)$$

$tf_{s,w}$ は、文 s における語 w の出現頻度である。さらに、すべての単語 $w \in s$ が等しく文 s の指数に貢献するというナイーブな仮定を導入すると、指数 $p_{s,w}$ は次式で表せる。

$$p_{s,w} = \frac{p_s}{|s|} \quad (2)$$

$|s|$ は文 s を構成する単語数である。ここで、期間 t 内の文の集合を S_t とする。そして、単語 w についてすべての文 $s \in S_t$ で指数 $p_{s,w}$ の総和を取り、総文数 $|S_t|$ で除することで、期間 t における語 w (のみ) の指数 $p_{t,w}$ を次式で定義する。

$$p_{t,w} = \frac{1}{|S_t|} \sum_{s \in S_t} tf_{s,w} \cdot \frac{p_s}{|s|} \quad (3)$$

直感的には、期間 t の記事に現れたすべての語 w の指数 $p_{t,w}$ の総和が、期間 t における S-APIR 指数であるというように解釈できる。

4 評価実験

4.1 データと実験設定

RNN モデルの学習のため、内閣府のホームページ³から、2000年～2018年9月分の景気ウォッチャー調査の景気判断理由文(現状)計216,741件を収集した。そして、無作為に選んだ90%を学習データ(検証データを含む)、10%をテストデータとして用いた。なお、景気判断理由文は形態素解析器 MeCab⁴で分かち書きし、GRU-RNN への入力とした。GRU-RNN のパラメータは、学習データを用いた予備実験に基づき、GRU のユニット数を512、RNN のレイヤー数を2、語彙数を40,000とした。また、入力の単語は Wikipedia の記事であらかじめ学習された300次元の分散表現 [Bojanowski 17] を用いて表現した。

S-APIR 指数の予測には、日経新聞2013～2018年度版(本紙朝刊および本紙夕刊)の記事見出しと記事本文を用いた。また、モデルのドメイン適応には、日経新聞2010年度版を用いた。いずれのデータも、各記事は句点「。」に基づいて文分割し、(記事単位ではなく)文単位で指数の予測を行った。モデル学習時と同様に、各文は MeCab を用いて形態素に分割してモデルへの入力とした。

4.2 景気ウォッチャー調査によるモデルの検証

景気判断理由文で学習した RNN を用いてテストデータで指数の予測を行い、実際の景気判断(-2～2)と

³http://www5.cao.go.jp/keizai3/watcher/watcher_menu.html

⁴<http://taku910.github.io/mecab/>

の平均二乗誤差(MSE)を算出した。結果を表2に示す。比較のため、テキストデータを tf-idf で重み付けした単語ベクトルで表現し、リッジ回帰で指数の予測を行った結果も示す。リッジ回帰と比較し、RNN では誤差が大きく減少し、指数の予測がより正確に行えていることが確認できる。なお、この結果は山本ら [山本 16] の報告等とほぼ同様である。

表 2: 景気ウォッチャー指数の推定結果。

モデル	平均二乗誤差
tf-idf & リッジ回帰	0.509
GRU-RNN	0.351

4.3 景況感指数 S-APIR の予測

本節では、提案する景況感指数 S-APIR を既存の景気ウォッチャー DI と比較する。ただし、S-APIR 指数は、必ずしも景気ウォッチャー DI を置き換えることを目的としているわけではなく、ニュース記事をソースとした新しい景況感指数という位置づけである点に注意を要する。景況感には正解は無く、景気ウォッチャー DI も 2,050 名の限られた回答者の景気判断に基づく指数でしかない。本節での景気ウォッチャー DI との比較の目的は、あくまで S-APIR 指数がある程度既存の景況感指数と類似したトレンドを持っていることを確認すること、またどのような局面で既存の指数とは異なる動きをするのか、その特性を探ることにある。

4.3.1 実験結果

4.2 節で学習した RNN モデルを用いて、日経新聞2013～2018年度版の記事見出しと記事本文を対象に景況感指数 S-APIR を算出した。なお、前述のように指数は文単位で推定されるため、発行月ごとにまとめて指数の推定値の平均を算出して景況感指数とした。比較のため、図1に、日経新聞から算出した景況感指数 S-APIR と内閣府発表の景気ウォッチャー DI (現状) を示す。おおまかには、S-APIR 指数は景気ウォッチャー DI のトレンドに近い動きを示しており、両者の相関係数も 0.546 と正の相関で見られた。

つづいて、1クラス SVM で異常値検出を行い、景気ウォッチャー調査の景気判断理由に似ていない文を除外した上で、再度指数の推定を行った。結果を図2に示す。未だ景気ウォッチャー指数と異なる部分はあるものの、全体的にはさらに類似の動向を示すようになり、両者の相関係数は 0.546 から 0.686 に上昇した。この結果から、1クラス SVM を用いたフィルタリングの効果が確認できる。

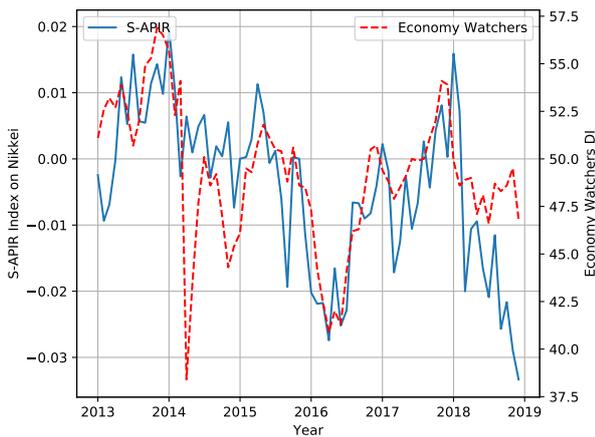


図 1: 日経新聞から算出した S-APIR 指数と景気ウォッチャー DI (現状) の比較 (相関係数=0.546)。

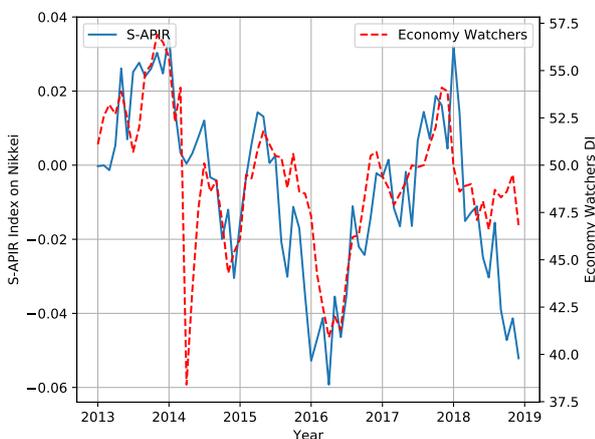


図 2: フィルタリング後の日経新聞から算出した S-APIR 指数と景気ウォッチャー DI (現状) の比較 (相関係数=0.686)。

上で示したように、フィルタリングを用いて景気判断理由文と類似の文だけを対象に指数を算出することで、景気ウォッチャー DI との相関が顕著に向上した。しかしながら、景気判断理由文と新聞記事では文章の特徴が異なると考えられるため、前者で学習したモデルは後者には必ずしも適しているとは言えない。そこで、3.1.3 節で述べた方法でドメイン適応を試みた。具体的には、次の手順にしたがって実験を行った。

1. 日経新聞 2010 年版 (本紙朝刊・本紙夕刊) の見出し・記事本文を抽出し、文ごとに MeCab で形態素に分割。
2. 1 クラス SVM を用いて異常値の文を検出・除去。
3. 学習済みの GRU-RNN で、残った各文の指数を予測。

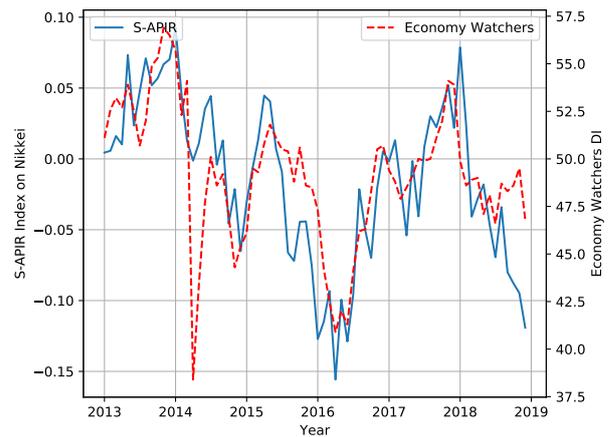


図 3: 回帰モデルの推定値によって構築した学習データでドメイン適応したときの景況感指数の推定結果 (相関係数=0.701)。

4. 指数の絶対値が大きいものだけを学習データとして抽出。ここでは、指数の分布を目視で確認し、試みとして -1.0 以下に教師信号 -2 、 0.8 以上に教師信号 2 を与えて学習データとした。

この結果、正例 (教師信号 = 2) 18,947 文、負例 (教師信号 = -2) 10,868 文のデータが学習データとして獲得できた。続いて、このデータを用いて、それぞれの新聞ごとにモデルの再学習を行った。そして、再学習したモデルを用いて再度指数の推定を行った。結果を図 3 に示す。ドメイン適応の結果、 0.686 から 0.701 に相関係数が微増し、一定の効果が見られた。

なお、2014 年の前半に景気ウォッチャー DI は大きく落ち込んでおり、S-APIR 指数と大きな乖離がある。これは消費税が 8% に増税された時期であり、景気ウォッチャー DI と比較して、S-APIR 指数では増税の影響が小さいことは興味深い。この原因として、景気ウォッチャー調査の対象の約 7 割が家計動向関連業従事者であることが考えられる。すなわち、増税のように家計に与える影響が大きい要因はより強く景況感に影響を与えられられる。そこで、企業動向関連業従事者のみから算出された景気ウォッチャー DI (現状) と S-APIR 指数を比較したところ、相関係数は 0.819 と大きく上昇した。この結果は、日経新聞から算出した S-APIR 指数は、より企業動向を反映している指標であることを示している。

4.3.2 ドメイン適応によるモデルの変化

前節で、モデルの再学習を通じたドメイン適応によって、S-APIR 指数と景気ウォッチャー DI の相関係数が向上することを実験的に示した。ここでは、モデル自

体が再学習によってどのように変化したのか調べるため、再学習前のモデルと再学習後のモデルそれぞれに対して、(新聞記事の文ではなく) 単語のみをモデルの入力として与え、指数の予測を行った。表3に、それぞれのモデルで指数が大きかった10単語を上位から順に示す。上向きの矢印「↑」が付してある語は順位が上昇したもので、下向きの矢印「↓」は順位が下降したものを示す。「好調」、「享受」、「復調」などの語の順位が上昇する一方、「最高」、「絶好調」などの順位は降下している。

表3: 単語のみで予測した景況感指数(上位10件)。

再学習前		再学習後	
快調	0.738	好調(↑)	1.591
絶好調	0.688	享受(↑)	1.503
好調	0.671	復調(↑)	1.502
最高	0.659	好転(↑)	1.488
上々	0.654	向上(↑)	1.485
好転	0.654	最高(↓)	1.484
伸	0.632	刺激(↑)	1.469
売れれ	0.630	絶好調(↓)	1.456
上向い	0.624	伸(↓)	1.449
着実	0.617	凶り(↑)	1.437

同様に、表4で指数が小さかった10単語を比較する。「悪化」、「激減」などの順位が上昇する一方、「舗装」、「壊滅」の順位が下降している。モデルの再学習の結果、両者とも、ニュースで使われるような語彙が表の中でより上位に、アンケート回答で使われるような語彙がより下位にシフトしていることが確認できる。

表4: 単語のみで予測した景況感指数(下位10件)。

再学習前		再学習後	
舗装	-1.543	悪化(↑)	-2.029
不通	-1.441	激減(↑)	-2.028
最悪	-1.355	最悪(-)	-2.026
壊滅	-1.334	舗装(↓)	-2.026
急変	-1.303	急変(-)	-2.019
全滅	-1.285	壊滅(↓)	-2.018
追い打ち	-1.282	低落(↑)	-2.017
激減	-1.278	減益(↑)	-2.017
エスカレート	-1.257	損失(↑)	-2.013
漁船	-1.232	急落(↑)	-2.011

なお、ここではモデルの再学習の効果を調べるために単語ごとの指数を予測したが、このようにして得られた語と指数の組は、単語とその極性値(感情値)とも見なせる。すなわち、この結果は経済ドメインの極性辞書としても利用することができる。一般ドメインにおいてはTakamuraら[Takamura 05]の極性辞書など利用可能な資源がいくつか存在するものの、経済ドメインかつ日本語で自由に利用できる極性辞書は少ない。よって、この結果は、経済分野のテキストの感情分析に用いる言語資源としても有用であると考えられる。

4.4 景況感に影響を与える要因の分析

続いて、3.2節に述べた方法で景況感に影響を与える要因について分析した。この方法では任意の語句について分析が可能であるが、ここでは例として「中国」、「貿易」について景況感指数への寄与を算出した結果を図4、図5に示す。いずれも上側のグラフはドメイン適応したモデルで算出したS-APIR指数であり、比較のために示している。

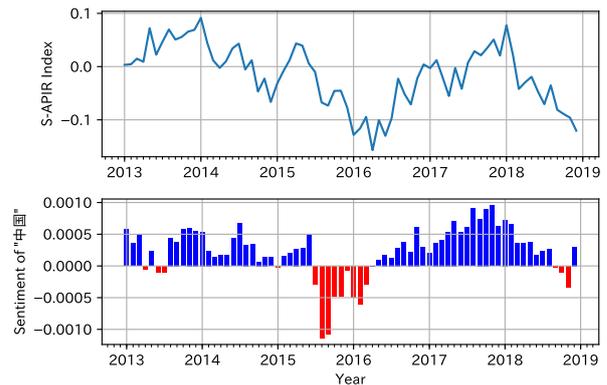


図4: 景況感への「中国」の寄与。

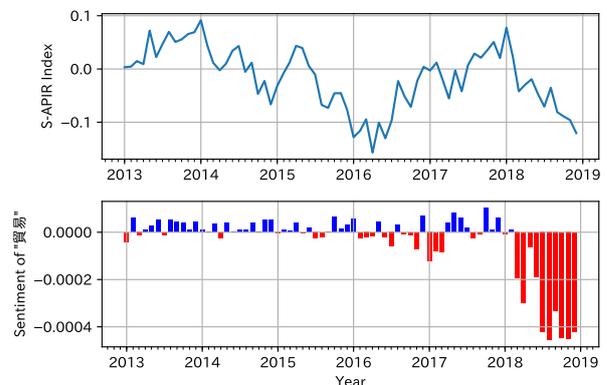


図5: 景況感への「貿易」の寄与。

図4を見ると、S-APIR指数と中国の寄与は似た動きをしており、中国に関する情勢が景況感に影響を与えていることが観察できる。特に、2015年半ばから2016年初頭にかけては、中国の寄与度がマイナス側に大きく出しており、景況感を押し下げる一因となっていることが分かる。なお、この時期は、中国の景気が急速に悪化した時期である。

続いて図5を見ると、貿易に関する記事は、2013年から2018年始めまで長らく景況感にほとんど影響を与えていなかったことが分かる。しかしながら、その後急速に寄与が低下し(マイナス方向に増加し)、景況

感にマイナスの影響を与えている。これは、2018年後半に始まった米中貿易摩擦を反映しているものと考えられる。

5 おわりに

本研究では、低コストで速報性の高い景況感指数を開発すること、および景況感に影響を与える要因を分析することを目的として、日々発信されるニュース記事を用いた指数予測の枠組みについて検討した。具体的には、1クラスSVMによる景気関連文の同定、GRU-RNNによる指数の推定(回帰)、新聞記事を用いたモデルのドメイン適応について実験的にそれぞれの効果を検証した。その結果、指数の予測に用いる入力を景気関連文に限定し、さらに新聞記事を用いてモデルを再学習することで、既存の景気ウォッチャーDIとより高い相関が得られることを確認した。なお、比較対象を企業動向に限定した場合、相関係数が大きく向上した。この結果は、本研究で開発したS-APIR指数が、企業動向をより強く反映した指数であることを示唆している。そして、文単位で予測した指数を単語単位に分割して再集計することで、任意の要因(語句)が景況感に与える影響を時間軸に沿って分析できることをいくつかの例とともに示した。

謝辞

本研究は、一般財団法人アジア太平洋研究所(APIR)の自主研究プロジェクト「テキストデータを利用した新しい景況感指標の開発と応用」、JSPS科研費18K11558、平成30年度私立大学等経常費補助金特別補助「大学間連携等による共同研究」により行った。実験に使用した日経新聞データはAPIRから提供を受けた。APIRの宮原秀夫氏、岩野宏氏、本多佑三氏、稲田義久氏、木下祐輔氏の御支援に感謝する。

参考文献

- [饗場 18] 饗場 行洋, 山本 裕樹: データサイエンスと新しい金融工学, 財界観測, Vol. 81, No. 2, pp. 30–41 (2018)
- [Bojanowski 17] Bojanowski, P., Grave, E., Joulin, A., and Mikolov, T.: Enriching Word Vectors with Subword Information, *Transactions of the Association for Computational Linguistics*, Vol. 5, pp. 135–146 (2017)
- [Chakraborty 16] Chakraborty, S., Venkataraman, A., Jagabathula, S., and Subramanian, L.: Predicting Socio-Economic Indicators Using News Events, in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 1455–1464 (2016)
- [Cho 14] Cho, K., Merriënboer, van B., Bahdanau, D., and Bengio, Y.: On the properties of neural machine translation: Encoder–decoder approaches, in *Proceedings of the 8th Workshop on Syntax, Semantics and Structure in Statistical Translation*, pp. 103–111 (2014)
- [Devlin 19] Devlin, J., Chang, M.-W., Lee, K., and Toutanova, K.: BERT: Pre-training of deep bidirectional transformers for language understanding, in *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pp. 4171–4186, Minneapolis, Minnesota (2019), Association for Computational Linguistics
- [五島 19] 五島 圭一, 高橋 大志, 山田 哲也: 自然言語処理による景況感ニュース指数の構築とボラティリティ予測への応用, 金融研究, Vol. 38, No. 3 (2019)
- [Hochreiter 97] Hochreiter, S. and Schmidhuber, J.: Long Short-Term Memory, *Neural Computation*, Vol. 9, No. 8, pp. 1735–1780 (1997)
- [Kapetanios 18] Kapetanios, G. and Papailias, F.: Big Data & Macroeconomic Nowcasting: Methodological Review, Economic Statistics Centre of Excellence (ESCoE) Discussion Papers ESCoE DP-2018-12, Economic Statistics Centre of Excellence (ESCoE) (2018)
- [近藤 19] 近藤 浩史, 與五澤 守, 成瀬 道紀, 森 正和: 金融機関のテキストデータを活用した景気センチメントの計測, 人工知能学会全国大会論文集, pp. 1P2J1302–1P2J1302 (2019)
- [Manevitz 02] Manevitz, L. M. and Yousef, M.: One-class SVMs for Document Classification, *The Journal of Machine Learning Research*, Vol. 2, pp. 139–154 (2002)
- [Manning 08] Manning, C. D., Raghavan, P., and Schütze, H.: *Introduction to information retrieval*, Cambridge University Press, New York, NY, USA (2008)

- [関 17] 関 和広, 水田 孝信, 八木 勲, 落合 友四郎, 酒井 浩之, 和泉 潔: 金融情報学:ファイナンスにおける人工知能応用, 人工知能, Vol. 32, No. 6, pp. 905–910 (2017)
- [Shapiro 17] Shapiro, , Hale, A., Sudhof, M., and Wilson, D.: Measuring News Sentiment, Federal Reserve Bank of San Francisco Working Paper 2017-01, Federal Reserve Bank of San Francisco (2017)
- [Takamura 05] Takamura, H., Inui, T., and Okumura, M.: Extracting semantic orientations of words using spin model, in *Proceedings of the 43rd Annual Meeting of the Association for Computational Linguistics (ACL2005)*, pp. 133–140 (2005)
- [Watanabe 14] Watanabe, K. and Watanabe, T.: Estimating Daily Inflation Using Scanner Data: A Progress Report, in *CARF Working Paper Series*, No. CARF-F-342 (2014)
- [山本 16] 山本 裕樹, 松尾 豊: 景気ウォッチャー調査を学習データに用いた金融レポートの指数化, 第 30 回人工知能学会全国大会 (JSAI 2016) (2016), 4 pages