

国会会議録を利用した議員の発言特性の抽出

有田智也 松井くにお

金沢工業大学工学研究科情報工学専攻

C6000578@planet.kanzawa-it.ac.jp

概要 本論文では Web 上に公開されている国会会議録を利用し、TF-IDF を用いた議員ごとの発言特性の抽出及び TF-IDF 値を用いた議員の関係性分析と、機械学習を用いて議員の発言を評価した結果を述べる。機械学習では議員の応答文を学習データとして seq2seq で学習させることで応答文を作成し、生成された応答文を利用し議員の発言の一貫性の分析を試みた。議員の発言をトークン分割する際には、Sentence Piece を利用することで、複合語を考慮しつつ特徴語の抽出ができる。また少数のデータを seq2seq で学習する際には、トークン分割に Sentence Piece を用いることで、トークン分割に MeCab を利用した場合に比べて、より自然で文法的に正しい応答文の作成が可能になり、高品質な関係分析が可能になる。

1 はじめに

近年、Apple 社の「Siri」や、Google 社の「Google Assistant」などの、知能的な対話システムの研究が活発化している。また女子高校生を模した、日本マイクロソフト社の「りんな」や、NTT 先端技術総合研究所が精華町役場と共同で研究している「京町セイカ」など対話システムに、ある特定の個性を持たせようとする研究も活発化している。しかしながら個人的な文章にするために、どの単語が役に立つのか、という研究は積極的になされていない。そこで本研究では個性付与の役に立つ言葉の抽出方法に着目した。

特徴語を抽出する研究として木村ら[1]は TF-IDF を用いて各地方議員の発言から、議員が重点を置いている政策を抽出しているが、抽出対象は名詞のみであり、助動詞や助詞などの議員の発言特性を抽出できそうな品詞を利用していない。また大南ら[2]は最大エントロピー法を用いて短命議員と長期議員に特徴的な単語を抽出し、「つばい」などの短い個性を表す語の抽出には成功しているが、「であります」といった複数の単語から構成される意味を持つ語(複合語)を抽出することは出来ていない。そこで本研究では複合語での特徴語の抽出、抽出した特徴語での関係性の分析、及び複合語でトークン分割した文章を学習させたモデルでの応答文生成の評価を試みた。

2 利用した技術とデータ

• TF-IDF

TF-IDF(TermFrequency-InverseDocument Frequency)

とはKaren Sparck Jones(1972)によって提唱された重みづけ手法であり、2種類の重みづけ手法を組み合わせることで実現されている。TFでは「ある文章において出現回数の多い語はより重要な単語」という考え方に基いて重みづけを試みる。IDFでは「ほかの文章中での出現回数が少ないほど重要な単語」という考え方に基いて重みづけを試みる。つまりTF-IDF の値が大きければ大きいほどその文章にとって重要な語である。

• SentencePiece

SentencePiece[3]とは 2018 年に工藤拓らにより提案された入力文章をサブワードにトークン分割する手法である。SentencePiece では辞書を利用せず、コーパスから教師無し学習で文章をトークン分割するためのモデルを生成し、文章のトークン分割を行える。SentencePiece で国会会議録を分割した結果の一部を表 1 に示す。

表 1. sentencePiece での分割結果

原文	技能実習制度は今既にあり機能しているわけでありす
トークナイズ後	技能実習制度/は/今/既に/あり/機能/しているわけでありす
原文	考え方については先ほど法務大臣から答弁させていただいております
トークナイズ後	考え方/については/先ほど/法務大臣/から/答弁/させていただいております
原文	みずから根を正して職責を全うしてもらいたいと考えております
トークナイズ後	みずから/根/を/正/して/職責/を/全/う/してもらいたい/と考えております

• Seq2Seq

Seq2Seq(Sequence to Sequence)[4]とは 2014 年に Ilya Sutskever らによって提案された、入力された系列を別の系列に変換するモデルである。Seq2seq は Encoder と Decoder の二つの RNN から構成され、Encoder では入力系列を読み込み隠れ層の最後の状態を Decoder に渡す。Decoder では Encoder から与えられた隠れ層をもとに、入力出力終了を表す「<eos>」が現れるまで単語を出力する。RNN の部分を LSTM[5]や GRU[6]にすることで離れた語の依存関

2016~2019年の議員の特徴語を抽出した結果を表3に示す。黄色で示された部分は2012~2015年と2016~2019年で共通の特徴語である。

表3. 2016~2019年の特徴語

特徴語	麻生太郎	福田康生	福山哲郎	蓮舫	福島みずほ
おかげでございます	様々	というところでございます	じゃ	んですが	社説の
いねば	私どもとしては	目標	実は	立憲民主党	福島みずほ
おかげであります	につきましては	海スーダン	んですけど	じゃ	お聞き
おねば	そういった	でございます	お答えください	つまり	をいたします
おかげでございますが	というものを	訓練	んですね	あるいは	厚生労働省
おかげであります	期待するように	お争	でございます	国許学園	専任に
おかげでございます	いらぬ	訓練	おはようございます	文科省	んですが
おかげでございます	というものを	訓練	分と	んですけれども	専念
議員にお答えいたします	おら	保護とサイル	んです	んですね	労働
こう	いかに	我が国	いいですか	野田	訓練です
おかげでございます	と聞いております	である	外務大臣	安倍総理	あるいは
あるいは	ですけれども	委員のご指摘	分からない	訓練	過労死
このように思います	私どもとしては	おら	僕は	野党委員会	専念
ところでございますが	お願い	まきしく	労働関係	学生	んですね
でございます	に申しましては	本業	さっき	労働省の	題目
中において	私どもは	労働者の	あった	僕は	労働者
というところでございます	なんだと思います	知識をいたしております	だって	お会い	労働者
ところでございます	と存じます	警察	立憲民主党	んです	じゃ
教えてください	なにか	ところでございます	憲法的な問題	んです	というふうに思います
教えてください	んです	または	何で	会社	
でございます	という話	警察	いやいや	二十	おかし
たいてい	というのを	警察	ちょっと	分からない	分かります
当然	んだと思います	労働者	まあ	訓練は	労働関係
につきましては	なん	済み	答えてください	ヒアリング	というふうに思います
でございます	おります	飛行機	お問い合わせ	である	という
でございます	きちんと	に対する	書かれている	メモ	ということよろしいですか
こう思う	だと思っております	訓練	よろしくお願ひしたい	分りました	訓練者
である	というものは	で例	富文会	富永候補地区	分からない
んです	訓練	出来	訓練者	富永	訓練者
に対する	訓練	陸上自衛隊	という	に伺います	労働関係

次に単語の2012~2015年と2016~2019年での特徴語の一致率を表4に示す。

表4. 特徴語の一致率

所属政党	議員名	一致率
自由民主党	安倍晋三	0.63
自由民主党	麻生太郎	0.5
自由民主党	福田朋美	0.1
立憲民主党	福山哲郎	0.23
立憲民主党	蓮舫	0.03
社会民主党	福島みずほ	0.3

2012~2015年と2016年~2019年の特徴語一致率を比較すると、与党議員の安倍晋三議員と麻生太郎議員の特徴語一致率は0.63, 0.5と高く特徴語が変化していない。これは質問に答える際に深く言及することを避け、抽象的な内容で返答したもしくは、多くの質問に答えているため、特徴語として特定の名詞が現れにくかったためである。しかし福田朋美議員は与党議員にも関わらず、特徴語の一致率が0.1である。これは2016年に公務員精度改革を担当する国務大臣の職を退き、防衛大臣の職に就き、答える質問の内容が変化したためである。また野党議員の福山哲郎議員、蓮舫議員、福島みずほ議員の特徴語一致率は0.23, 0.03, 0.3と小さく、特徴語が大きく変化していた。これはその時ホットな話題について集中して質問することが多く、その質問した事柄が特徴語として現れたためである。

3.2 Seq2Seq を用いた応答文生成と評価

2012年1月1日から2019年12月31日までの安倍晋三議員の答弁25,459件をMeCab+neologd辞書で分割した後に他議員からの質問を入力、安倍晋三議員の応答を出力としてSeq2Seqで学習させ、学習済みモデルを作成した。本研究で用いたSeq2Seqの中間層は256、単語埋め込み次元は300である。学習させたモデルに対して、議員の発言からランダムに選んだものを学習済みモデルに入力し、生成された応答文を図4に示す。

入力	応答
全く納得いきません	先ほど申し上げましたようにこれはまさにこれはまさにこれはまさに
時間ですのでまとめて下さい	現在の交渉の中においてこれはまさにこれはまさにこれはまさに
ちょっと待って	現在の交渉の中においてこれは日本の国益を確保するために必要
お聞きしたいと思います	個別具体的な問題であります
よろしいでしょうか	当然のことであります
それはいつごろでしょうか	そうができません
静粛におねがいします	緩めていきたいと考えています

図4. MeCabで分割したデータをSeq2Seqで学習させたモデルから得られた応答文

MeCabで分割し、先頭の単語をランダムにサンプリングし、以降の単語を貪欲法でサンプリングすることで生成した応答文の問題は次の2つである。

- ・複合語が細かく分割されるため、学習することが難しく、複合語が出力の途中で崩壊してしまう。
- ・出力の内容が”これはまさにこれはまさに”のようにループし文章として成立しない。

複合語をそのまま利用し、複合語生成の学習を省略させるため、SentencePieceを用いて対話データを分割し、Seq2Seqで学習させた結果を図5に示す。

入力	応答
全く納得いきません	去年の三月の閉会審査において既に今治市の運営については猪瀬元秘書官が説明させていただきました
時間ですのでまとめて下さい	ホームページで議論する招致をしたところでございます
ちょっと待って	確認をいたしました
お聞きしたいと思います	厳しい受け止められると何處もところわかりやすく役割を担ってと認識しております
よろしいでしょうか	申し上げられないと思っております
それはいつごろでしょうか	当時の十九万人につきましては明確にできません
静粛におねがいします	立場にはないことでございますのでそのことは受け止めておきたいと思っております

図5. SentencePieceで分割したデータをSeq2Seqで学習させたモデルから得られた応答文

対話データを SentencePiece でトークン分割し学習させることで、MeCab でトークン分割した場合、17.7%で発生していた応答文の崩壊と応答文のループを、6.7%に減少させることに成功した。

学習させたモデルに、議員の発言をランダムに 30 件抽出したものを入力し、生成された応答文に対して、文法的に正しい応答が生成される確率、自然な応答文が生成される確率、生成された応答文に TF-IDF 上位 30 件の単語がマッチする確率を評価した。

2012~2015 年の評価結果を表 5 に示す。

表 5. 2012~2015 年の応答文の評価

所属政党	議員名	文法的な正しさ	応答文の自然さ	TF-IDF 上位 30 件
自由民主党	安倍晋三	55%	40%	35%
自由民主党	麻生太郎	50%	35%	35%
自由民主党	福田朋美	45%	30%	20%
日本民主党	福山哲郎	50%	25%	25%
日本民主党	蓮舫	50%	35%	20%
社会民主党	福島みずほ	40%	5%	50%

2012 年~2015 年の評価の結果、自然な応答文が生成される確率は、与党議員に比べて野党議員の方が平均で 13%低かった。これは野党議員の発言内容は様々な分野への質問が多く、学習が困難であるのに対して、与党議員の発言内容は回答一辺倒であり、内容に一貫性が生まれ学習しやすかったためである。また応答文に TF-IDF 上位 30 件の単語が含まれる確率は与党議員に比べて福島瑞穂議員を除く野党議員の方が平均で 8%低かった。これは与党議員の特徴語に複合語が多く、複合語の方が名詞に比べて応答文に反映させる余地が多いためである。福島みずほ議員の応答文に含まれる単語が TF-IDF 上位 30 件にマッチする確率が高いのは”~の福島みずほです”という応答文が頻繁に生成されたためである。

2016~2019 年の評価結果を表 6 に示す。

表 6. 2016~2019 年の応答文の評価

所属政党	議員名	文法的な正しさ	応答文の自然さ	TF-IDF 上位 30 件
自由民省	安倍晋三	55%	50%	35%
自由民主党	麻生太郎	55%	40%	40%
自由民主党	福田朋美	45%	30%	10%
立憲民主党	福山哲郎	40%	20%	30%
立憲民主党	蓮舫	35%	20%	5%
社会民主党	福島みずほ	50%	20%	5%

2012~2015 年と 2016~2019 年を比較すると蓮舫議員の応答文の文法的な正しさ、応答文の自然さ、応答文が TF-IDF 上位 30 件にマッチする確率が減少している。これは 2012~2015 年に比べて 2016~2019

年の方が、より様々な政治的事柄について質問するようになったため、学習が難しくなったためである。

4 おわりに

本論文では、国会会議録を用いて議員の発言特性の分析と抽出を TF-ID を用いた手法と対話モデルを作成する手法で行った。SentencePiece を用いることで複合語の抽出が可能になり、高品質な個性抽出、応答文生成ができる。

参考文献

1. 地方議会会議録コーパスプロジェクト(引用日:2010 年 12 月 20 日)<http://local-politics.jp/>
2. 大南勝, 掛谷秀紀. 国会会議録に基づく短命大臣の特徴分析第 2 報. 言語処理学会第 23 回年次大会論文集, pp. 1167-1170, 2018
3. Taku Kudo, John Richardson. SentencePiece: A simple and language independent sub word tokenizer and tokenizer for Neural Text Processing. <https://arxiv.org/pdf/180806226.pdf>
4. Ilya Sutskever, Oriol Vinyals, Quoc V. Le. Sequence to Sequence Learning with Neural Networks <https://arxiv.org/abs/1409.3215>
5. Sepp Hochreiter, Jurgen Schmidhuber. Long Short-term Memory. https://www.researchgate.net/publication/13853244_Long_Short-term_Memory
6. Kyunghyun Cho, Bart van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, Yoshua Bengio. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. <https://arxiv.org/abs/1406.1078>
7. 国会会議録検索システム検索 API(引用日:2020 年 12 月 20 日) <https://kokkai.ndl.go.jp/api.html>
8. 工藤拓, 山本薫, 松本裕治. Conditional Random Fields を用いた日本語形態素解析. Applying Conditional Random Fields to Japanese Morphological Analysis. <https://ci.nii.ac.jp/naid/110002911717>