

観点を反映した深層学習および強化学習による 学術論文の自動要約生成

Li Jinghong ^{*1}, 太田 光一 ^{*1}, 長谷川 忍 ^{*1}

^{*1} 北陸先端科学技術大学院大学

Automatic Summarization for Academic Articles using Deep Learning and Reinforcement Learning with Viewpoints

Li Jinghong ^{*1}, Koichi Ota ^{*1}, Shinobu Hasegawa ^{*1}

^{*1} Japan Advanced Institute of Science and Technology

The purpose of this research is to develop an automatic summarization system for research articles that reflects the viewpoints such as the research background, purpose, method, and evaluation to support surveys by researchers and students. Since there are limited datasets on the summary reflecting the viewpoints, we adopt supervised machine learning, reinforcement learning, and dynamic programming to extract the critical sentences in each viewpoint. The agent automatically extracts summary sentences based on the reward function to test the potentials of improving summarization accuracy.

キーワード: 学術論文要約, 自動要約, 観点, 深層学習, 強化学習, 動的計画法

1. はじめに

研究者や学生が新たな研究を始める際には、関連研究のサーベイを通じて当該研究分野の最前線を理解することが不可欠である。特に近年では、膨大な量の学術論文がオンラインまたはオープン化されており、それらの中から必要な情報を収集・整理することは、研究活動の初期段階において重要な役割を果たす。また、研究の進捗状況によって関連研究で注目すべき箇所が異なることもしばしばあり、学術論文を構成する背景や目的、方法、実験、評価などといったサーベイの観点を反映する情報を収集することは、効果的に研究を進めるうえで重要である⁽¹⁾。

一方で、インターネットの普及によって膨大なテキストデータから重要な情報を把握するための技術として自動要約が注目されている。従来の学術論文に対する自動要約に関する研究では、主にアブストラクトの生成が対象となってきた⁽²⁾。しかしながら、関連研究に基づく背景や、研究方法として利用される技術等といった観点に基づいて要約を行う場合には、アブストラ

クトにそれらの情報が十分に含まれておらず、対応する要約文が既知でないため、自動生成は容易ではない。

これらの問題に対し、本稿では観点を反映した深層学習の分類タスクをベースとし、強化学習により抽出要約文を作成するアプローチを提案する。これを実現するために、研究者や学生の学術論文サーベイに対する観点を反映した自動抽出要約を生成するシステムを開発することを目指す。

Cheng らは抽出要約のための教師あり機械学習の手法を提案している⁽³⁾。しかしながら、観点を反映した自動要約を実現するには、あらかじめ十分な規模のデータセットを準備することが困難である。そこで本研究では、少数のデータセットを用意し、深層学習による分類手法と強化学習による重要文抽出手法を組み合わせることで、小規模な教師データによる自動要約抽出タスクにおける精度向上を目指す。

2. 関連研究

単一文書に対する自動要約の研究は、文書全体の内容を代表する文章や語を抽出する抽出要約(Extract

Summarization)と、文書全体の内容を表す文章を新たに生成する抽象要約(Abstract Summarization)に大別される⁽⁴⁾。本研究では学術論文の情報量をサーベいの観点を反映しながら削減することで、研究者や学生がより多くの関連研究を把握できるようにすることを目的としているため、主に学術論文および抽出要約を対象とする関連研究について述べる。

2.1 学術論文に対する自動要約

学術論文に対する自動要約の関連研究としては、Contractor らによる論文構造に注目した分類器を用いた抽出要約の生成が挙げられる⁽²⁾。ここでは、文章情報を分類器でクラスタリングすることで冗長性の緩和を達成している点に特徴がある。中須賀らは談話構造を利用した特徴量を利用して、学術論文要約において談話構造が精度の向上に有用であるかどうかについて検証している⁽⁵⁾。平井らは、論文の構成要素を Conditional Random Field (CRF)により、実験の図、表、段落に分類することで、実験情報を論文構成要素に基づいて抽出する手法を提案した⁽⁶⁾。

2.2 抽出要約に関する最近の手法

神谷らは、レビューから重要語を抽出し、深層学習の LSTM 時系列ネットワークを利用して要約を生成する実験を行っている⁽⁷⁾。文書量に頼らず重要な内容を含む要約の生成が期待できるが、本研究で対象としている学術論文とは文章構造や観点が異なっている。梁らは自動要約問題を文圧縮に関する強化学習問題として定式化し、報酬に要約長を用いて新聞記事要約を生成できることを示した⁽⁸⁾。しかしながら、要約長の制御のみを扱っており、要約の内容と可読性は保証されていない。また、Lee らは、文章の内容と位置をベクトル化し、候補文の選択を行動として学習することにより、深層強化学習による自動抽出要約を提案している⁽⁹⁾。しかしながら、本研究で対象とするサーベいの観点は扱われておらず、アブストラクトのような Gold Standard が存在していないため、そのまま適用することは困難である。富田らは、整数計画法を用いた重要文抽出と文圧縮の両方を同時に行う抽出要約モデルを提案し、文中の冗長な表現を削除できることを示した

⁽¹⁰⁾。しかしながら、本研究で要求される観点を代表するような重要文が無視される可能性がある。泉田らは制約付き線形強化学習の最適化問題として抽出要約を定式化した⁽¹¹⁾。しかしながら、複雑で大規模な文章要約の環境で報酬関数を設定することが困難であり、自動要約に適用するには課題がある。

3. 提案手法

本研究では、学術論文におけるサーベいの観点を反映した自動抽出要約というタスクに対し、まず深層学習を適用することにより、論文の本文を観点に分類する。そして、観点ごとの重要文を抽出するため、熟練者が付けた各文章の重要度情報を利用して、要約長制御の最適化手法を組み合わせた強化学習を行う。

3.1 前処理

対象となる学術論文のファイルフォーマットは PDF とする。まず、Java ベースのドキュメント分析・抽出ツールである Apache Tika を利用して PDF から未正規化テキストを抽出した。

次に、Python の自然言語処理モジュールである re を利用して、テキストを文章単位に分割し、表 1 に示す正規化処理を行った。なお、完全に削除できない固有表現については手作業で処理した。

表 1 テキスト正規処理

Step	説明
1	アブストラクト以前を削除
2	参考文献以降を削除
3	章節の番号を削除
4	固有表現(メール, URL など)を削除
5	日本語を含まない行を削除
6	図と表を削除

正規化後の各文章に対して、熟練者が背景、目的、方法、実験、結果評価、知見、関連研究、その他からなる論文内の観点を定義した観点クラスを付与した。また、文章の論文内における位置情報は要約に重要であると考えられるため、各論文の文章を m 等分にし、

各文章の先頭部分に文字列フォーマットの pos 1, pos 2, ..., pos m まで番号を付与して位置情報とした。また、熟練者により、以下の基準により重要度ラベルを設定した。

- (1) 観点クラス内で重要な文章に 1~m のランク
- (2) 同程度に重要な文章には同じランク
- (3) 最大で m=4, 観点クラスの文章数の 2/3 以内

3.2 深層学習による観点クラス分類

ここでは、図 1 に示すような手順で深層学習を利用して文章を観点クラスに分類する。本研究では形態素解析ツール mecab を利用して形態素解析を行い、Python ライブラリである gensim を利用して Skip-Gram ベースの Word2vec(単語埋め込み)⁽¹²⁾と PV-DM(文書埋め込み)⁽¹³⁾によるベクトル化を行い、分類器への入力として利用する。単語ベースの Word2vec に対しては系列情報を反映可能な LSTM を、文章ベースの PV-DM に対しては汎化性能の高い SVM を分類器として、各文章に対するそれぞれの観点の予測確率を出力する。さらに、単語ベースと文章ベースの異なる特徴を反映させるため、双方のモデルの出力の最大値により分類結果を決定する Combined-method モデルを構築する。

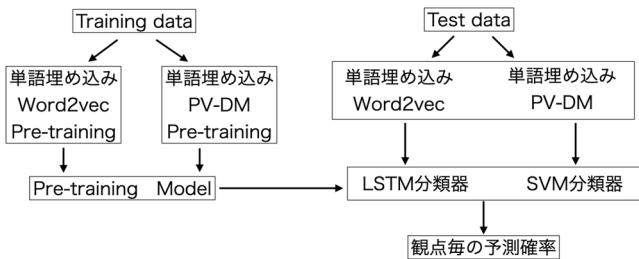


図 1 深層学習モデル

3.3 強化学習による重要文抽出

本研究では、3.2 節により分類された観点クラス毎の文章群を重要文抽出要約の対象として扱う。具体的には、3.1 節で熟練者により付与されたアノテーションを利用することで、強化学習に必要なエージェントの状態遷移方策と報酬期待値を設定する。

提案する強化学習モデルでは、5 つのメモリを以下のように設定する。

- (1) 候補文メモリ：深層学習で分類された文章群。
- (2) 要約メモリ：状態 s の時刻で抽出された要約。
- (3) 価値メモリ：状態 s の時刻の各文章の価値の保存。
- (4) ペナルティメモリ：冗長性を解消するための文章遷移のペナルティ情報の保存。
- (5) Q メモリ：熟練者が重要度ラベルを付与した文章の各単語を重要度とみなしたときの目的関数。

3.3.1 文章類似度に基づくペナルティの設定

TF-IDF とは、文書に含まれる単語の重要度から文書の特徴を判別する手法である。TF(Term Frequency)は単語の出現頻度、IDF(Inverse Document Frequency)は各単語のレア度を示し、次式により表現される。

$$TF - IDF = TF * IDF \quad (1)$$

TF-IDF ベクトルを利用して文章間の Cos 類似度を計算することにより、文章間の類似度を算出できる。本研究では、冗長な要約が生成されることを防止するため、要約候補文中の類似度を計算し、類似度が高ければ高いほどそれに対応したペナルティをペナルティメモリに保存する。

3.3.2 文章価値の推定

文章価値の推定フローを図 2 に示す。トレーニング用データセットから対象となる観点クラスの文章群を収集し、その中で重要度ラベルが付与された文章を抽出する。これらの文章から固有表現を削除し、名詞・動詞・形容詞を取り出したものを重要語とする。

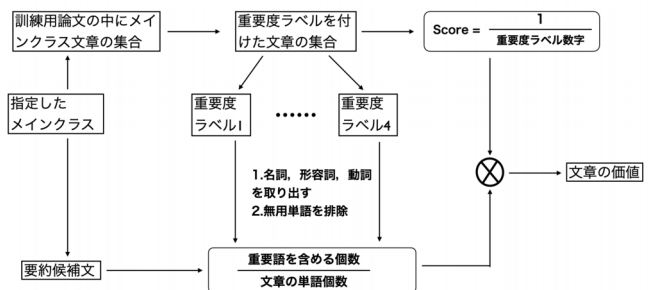


図 2 文章価値の推定フロー

要約の候補文に含まれる重要語と単語総数の割合を求め、これに重要度ラベルの逆数を乗じたものを当該候補文の文章価値として取り扱う。

3.3.3 報酬の期待値

強化学習の基本的なアルゴリズムは、ある時刻 t の状態 s がその時刻 t の動作 a により遷移先 s' に到達し、報酬 R を獲得するといった流れで表現できる。本研究においては、状態 s は時刻 t における重要文、動作 a は候補文からの文章の選択、遷移先 s' は追加後の重要文とみなすことができる。遷移先 s' の文章価値を $V_{s'}$ 、 s の文章価値の平均値を $avg(V_s)$ 、 sim_s を遷移先に移動した際のペナルティとすると、報酬期待値 $R_{s'}$ は以下の式で表現される。

$$R_{s'} = V_{s'} - avg(V_s) * sim_s \quad (2)$$

3.3.4 要約長の制限

抽出要約の文章数を制御するため、トレーニングデータから重要度が付与された文章数と観点クラスの文章総数との割合を求め、要約の抽出率を決定する。こうして得られた観点クラス毎の重要文の平均抽出率を要約対象文の文章数に乘じ、マージンを設定することで、文章数の許容範囲を制約条件として設定した。

3.3.5 組み合わせナップサック動的計画法

要約の対象となる価値を付与した文章群は組み合わせ最適化の要素群とみなすことができ、一定な要約長の範囲を超えないという制約条件を加え、最も適切な組み合わせ結果を要約として抽出する。本研究では、要約の短縮化をしながら重要な情報を保留することを目的として、強化学習と組み合わせ最適化ナップサック DP(Dynamic Programming)を結合した動的計画法を提案する。

n 個の文章 $x_0, x_1, x_2, \dots, x_n$ が与えられ、それぞれの価値が $v_0, v_1, v_2, \dots, v_n$ であるとき、これらの文章から何個かの文章を選択して総価値の最大値を求めることが目的となる。各文章の長さをそれぞれ $w_0, w_1, w_2, \dots, w_n$ としたとき、以下の制約条件を超えない範囲で文章を選択する。

$$Max. f(x) = \sum_{i=0}^n v_i x_i \quad (3)$$

$$Subject\ to. \sum_{i=1}^n w_i x_i \leq num \quad (4)$$

$$Subject\ to. \sum_{i=1}^n x_i \leq m \quad (5)$$

$$x \in [0, 1] \quad (i = 0, 1, 2, \dots, n) \quad (6)$$

(6)式において、文章 x_i が選択されている場合は'1'、

選択されていない場合は'0'とする。このように、選択した文章の価値の総和を目的関数として最大化したものを、強化学習の方策 π として使用する。

3.3.6 重要文抽出の流れ

本研究で提案する強化学習の流れを図3に示す。まず、観点クラスの中で最も文章価値が高い候補文は必ず抽出するものとする。次は候補文のうち i 番目の文章を選出し、各行動の報酬期待値を更新する。そして、ナップサック DP システムにその文章を追加して、最適化調整により得られた目的関数を Q メモリに保存し、組み合わせの結果を方策 π として要約メモリに保存する。文章数の許容範囲に到達するまで動的計画法を繰り返す。文章数が許容範囲を超える場合は、文章価値を初期化し、状態 $i+1$ 番目から次のループとなる。候補文メモリにある文章を全て走査したら、Q メモリと要約メモリの状態更新が終了し、Q メモリにある最大 Q 値に対応する組み合わせ結果を最終要約の抽出とする。

4. 実験

4.1 データセット

本研究で準備したデータセットは、日本語で記述された 100 編の学術論文であり、分野の内訳は表2に示す通りである。また、3.1 節の前処理の手続きに従って論文を文章に分解し、熟練者によりラベルを付与した。各ラベルの文章数は表3に示すとおりである。なお、本研究では 8 つの観点を設定したが、関連研究については論文毎に位置が大きく異なっていることが観測された。そこで、分割数 $m=6$ と設定し、各論文を 6 等分して文章の位置番号を割り振った。

4.2 観点クラス分類

4.2.1 実験タスク

本稿では、Word2vec/LSTM と PV-DV/SVM による分類に加えて、これらを混合した Combined-method による分類精度について比較する。

論文の観点として、背景、目的、方法、実験、結果評価、知見、関連研究の 7 つを設定した。100 編の論文の各文章をランダムに 8 割を Training データ、2 割

表 2. データセット内の論文の研究分野分布

研究分野	論文数
深層学習	28
強化学習	25
画像認識	20
自然言語処理	15
音声認識	10
教育工学	2
合計	100

表 3. データセット内の観点クラスの分布

観点クラス	文章数
背景	820
目的	347
方法	3,856
実験	1,755
結果評価	1,798
知見	553
関連研究	1,021
その他	161
合計	10,311

を Validation データとして利用した。

最終的な検証は上記に含まれない論文を対象とした。結果の安定性を保証するため、データを 10 回ランダムに取得して得られた再現率、適合率、F1 スコアにより評価を行った。

$$Acc = \frac{True\ positive}{Total\ positive} \quad (7)$$

4.2.2 学習パラメータ

Word2vec と PV-DM の事前学習の単語埋め込み次元数は 300 次元とした。LSTM の出力層の活性化関数は softmax を使用し、batch size は 512、epochs は 40、過学習を抑制する dropout は 0.3 とした。SVM の kernel は linear とし、マージン C=0.1、境界線の複雑性を表す gamma を 1 と設定した。

4.2.3 結果

表 4 に Word2vec/LSTM, PV-DV/SVM, Combined-method による再現率、適合率、F1 スコアの 10 回の試行の平均値を示す。全体として、Combined-method によりやや精度が向上した。

表 4 観点クラス分類の結果

手法	適合率	再現率	F1
Word2vec/LSTM	0.709	0.714	0.710
PV-DV/SVM	0.666	0.671	0.669
Combined-method	0.713	0.723	0.717

4.3 重要文抽出

4.3.1 実験タスク

データセットの 100 編の論文のうち、90 編を Training データとし、Combined-method で観点クラス分類のトレーニングを行い、残りの 10 編に対して観点クラス分類を実行し、その分類結果を要約の対象文として強化学習による重要文抽出を行った。表 5 に熟練者が付与した重要度ラベルに基づく観点クラス毎の文章および文字列の抽出率を示す。

表 5 観点クラス毎の重要文抽出率

観点	文章抽出率	文字列抽出率
背景	0.314	0.341
目的	0.440	0.494
方法	0.084	0.101
実験	0.142	0.174
結果評価	0.143	0.169
知見	0.425	0.457
関連研究	0.200	0.224

上記の抽出率に従い、文章数制限のマージンを設定する。研究方法と実験は候補文章数が多いため、2 個以上抽出することを必要条件として加えた上で「抽出率*候補文章数」とした。他の観点クラスでは「(抽出率*候補文章数)+1」と設定した。なお、候補文の個数が 1 文のみの場合は強化学習の計算を行わず抽出した。

4.3.2 結果

表 6 に観点クラス毎の重要文抽出の結果を示す。全体としては、重要文抽出率は 30.4%であったが、第一段階の観点クラスへの分類の時点で誤ったクラスに分類された重要文が 29%を閉めており、その影響を差し引くと 40%強の精度となった。

表 6 重要文抽出の結果

観点	分類精度	抽出精度	ROUGE-1
背景	0.651	0.423	0.580
目的	0.526	0.562	0.677
方法	0.803	0.172	0.472
実験	0.619	0.368	0.513
結果評価	0.760	0.210	0.362
知見	0.761	0.300	0.535
関連研究	0.499	0.083	0.407

特に観点クラス分類の誤認識率が高い論文の分野は音声認識と教育工学であり、訓練用データの数が少ないことによる学習不足が原因であると考えられる。

また、強化学習にはペナルティ設定を加えたため、重要度のある程度保障しながら短い文章を選択する傾向があると考えられる。背景や実験の重要文は比較的そういった特徴を持っていたため認識率が比較的良かったと考えられる。

5. おわりに

本稿では日本語の学術論文を対象として、観点を反映した要約を生成するため、小規模なデータセットを利用して深層学習による分類タスクを行った。加えて、深層学習により分類された観点クラスの内容を反映した重要文を抽出するために、強化学習および動的計画法に基づく重要文抽出手法を提案した。結果としては、全体の重要文抽出率は約 30%であり、観点クラス分類の誤認識を考慮しない場合の認識率は約 40%であった。

今後の課題としては、特定の分野のデータセットに対して適用するとともに、重要文の価値把握の手法について改善を行いたい。

参考文献

- (1) 長谷川忍, 柏原昭博: “研究活動を支援するポータルサイトの構築”, 教育システム情報学会第 31 回全国大会講演論文集, pp.325-326, (2006)
- (2) Contractor, D., Guo, Y., and Korhonen, A.: “Using Argumentative Zones for Extractive Summarization of Scientific Articles”, Proceedings of COLING 2012, pp. 638-678, (2012).
- (3) Cheng, J. and Lapata M.: “Neural summarization by extracting sentences and words”, Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, Vol. 1, pp.484-494, (2016)
- (4) 石垣達也, 高村大也, 奥村学: “複数文質問を対象とした抽出型および生成型要約”, 自然言語処理, Vol.26, No.1, pp.37-58, (2019)
- (5) 中須賀謙吾, 鶴岡慶雅: “談話構造を利用した学術論文の自動要約生成”, 言語処理学会 21 回年次大会発表論文集, pp.569-572, (2015)
- (6) 平井久貴, 新妻弘崇, 太田学, 高須淳宏: “学術論文からの実験情報抽出の一手法”, 第 7 回データ工学と情報マネジメントに関するフォーラム, F3-1, (2015)
- (7) 神谷賢太郎, 原寛紀, 青山幹雄: “深層学習によるレビュー内の重要語に着目した要約方法の提案と評価”, 情報処理学会第 82 回全国大会講演論文集, pp.463-464, (2020)
- (8) 梁成基, 阿部川武: “強化学習によるテキスト自動要約手法の提案”, 言語処理学会第 18 回年次大会発表論文集, pp.1067-1070, (2012)
- (9) Lee, G. and Lee, K.: “Automatic Text Summarization Using Reinforcement Learning with Embedding Features”, Proceedings of the Eighth International Joint Conference on Natural Language Processing, Vol. 2, pp. 193-197, (2017)
- (10) 富田紘平, 高村大也, 奥村学: “重要文抽出と文圧縮を組み合わせた新たな抽出的要約手法”, 情報処理学会研究報告, NL-189-3, pp.13-20, (2009)
- (11) 泉田啓, 天野恒佑: “強化学習における線形計画法を用いた効率的解法”, 計測自動制御学会論文集, Vol.52, No.10, pp.566-572, (2016)
- (12) 福田清人, 森直樹, 松本啓之亮: “LSTM を用いた文の分散表現の獲得手法に関する一考察”, 言語処理学会第 24 回年次大会発表論文集, pp.1195-1198, (2018)
- (13) 赤石雅典, 江澤美保: 現場で使える Python 自然言語処理入門.