

BERTを用いたWeb文書からの用語検索

池内 省吾^{1,a)} 南條 浩輝^{2,b)} 馬 青^{1,c)}

概要: 具体的な事物や概念などについての説明テキストから、それを表す語（用語）を見つけだす用語検索について述べる。説明テキストが与えられたとき、まず Web 検索を行い、その Web 検索結果（文書）の中から用語候補を抽出しユーザに提示することで用語検索を行う手法を提案する。BERT を用いた文章読解では、検索質問と文書を BERT の入力として与え、文書中から答えとなる区間を求めている。本研究でも BERT を用いて検索質問とその答えとなる用語を含むと考えられる Web 文書から用語を抽出することで用語検索を行えるか調査を行う。その際、複数の Web 文書からの用語候補の統合も行う。さらに、検索質問についても文章読解で扱われていた論理的に答えを導き出せる「整った検索質問」ではなく、ユーザが生成する「整っていない検索質問」での用語検索も調査する。実験の結果、Wikipedia のような比較的整った文書に限らない一般の Web 文書から用語の検索は難しいタスクであること、クエリが整ったものではない場合はさらに難しいことを確認した。また、複数文書からの用語候補の抽出を行い、頻度に基づいて単純にランク付けすることで、1 位に用語を 20~30%程度の精度で、10 位以内に用語を 40%程度の精度で見つけられることが分かった。

1. はじめに

コミュニケーションや情報検索において、伝えたい概念を表す適切な用語がわからないと十分な結果が得られないことがある。例えば、“BERT”を調べたいがその用語が思い浮かばない場合、“BERT”について正確な情報を得ることができない。しかし、調べたい“BERT”が表す概念についてある程度理解しており、「自然言語処理で使われる汎用モデル」などと説明することで“BERT”という用語を得ることができれば、“BERT”について正確な情報を得ることができるようになる。専門用語に限らず、一般的な用語であってもその用語が思い浮かばないことがあり、このような説明からの用語検索は重要である。特に、外国人や子ども、高齢者などは、用語がわからない可能性が高く、情報の利活用において不利である。用語検索はこのような人の支援にもつながる重要な技術である。

用語検索においては、辞書や Wikipedia のような、用語

に対する見出しと定義文が与えられている形式の文書（構造化文書と称する）では説明テキストに似た定義文を選べば用語を検索できる [1], [2]。しかし、新語や専門用語はこのような構造化文書の形で定義されていないことがある。この問題に対して、見出しと定義文がペアになっているという構造を持たない文書（非構造化文書）からの用語検索が研究されている [3]。本論文は、一般の Web ページを非構造化文書とし、そこからの用語検索を研究する。これは、Web サイトには、辞書などに登録されてない新しい用語が含まれている可能性が高いためである。

一般的に Web 検索では、ユーザは用語に相当する検索語のセットからなる検索クエリを入力し、関連した Web 文書が検索結果として返される。説明テキストを検索クエリとして入力とすることもできるが、出力されるものは Web 文書であり、直接的に説明テキストが表している用語の検索は行えない。一方、得られた Web 文書の中には目的とする用語が含まれている可能性もあり、検索結果の Web 文書を読めば用語を得られることもある。このような背景に基づき、本論文では、説明テキストが与えられたとき、まず Web 検索を行い、その Web 検索結果の中から用語候補を抽出しユーザに提示することで用語検索を行う手法を提案する。

本研究が目指す用語検索は、事実や数値、名称などについて答える factoid 型の質問応答 [4], [5] といえる。factoid

¹ 龍谷大学理工学研究科
Graduate School of Science and Technology, Ryukoku University, Otsu, Shiga 520-2194, Japan

² 京都大学学術情報メディアセンター
Academic Center for Computing and Media Studies, Kyoto University, Kyoto 606-8501, Japan

a) t20m002@mail.ryukoku.ac.jp

b) nanjo@media.kyoto-u.ac.jp

c) qma@math.ryukoku.ac.jp

型の質問応答では一般的に、初めに検索質問を解析して答えのタイプ（名前、場所、時間など）を決定し、検索質問に近い文書の選択とその文書からの答えの抽出を行う。本研究では、質問者が事物や概念はある程度思い浮かんでいるものの、用語そのものがわかっていないことを想定しており、質問者として、外国人や高齢者、子どもなどをも想定している。したがって、検索質問として「答えを導き出せるだけの情報を含んだ整った文」ではなく、事物や概念を説明する誤りを含みうる説明テキストを想定しており、この点で従来の質問応答よりも難しいタスクである。このようなことから本研究では、質問タイプの解析は行わない手法を研究する。

次に、用語検索における後段、「検索質問に近い文書から答えとなる単語を抽出する」という処理は文書読解 [6], [7], [8] に近いといえる。文書読解は、与えられたコンテキスト（文書）と検索質問（文）から、文書中の答えとなる単語列を特定することを目指している。文書には答えが存在しない、文書からは根拠がある答えが得られない（解答不能）といったことを見つけることも求められることがある。文書読解では「計算機が論理的に正しく答えを導き出せるか」を研究することに焦点が当てられており、検索質問は答えを導き出せるだけの情報を含んだ整った文といえる。本研究での検索質問は、事物や概念を説明する誤りを含みうる説明テキストを想定しており、文書としては Wikipedia や辞書などの用語に対する説明がきちんとされている文書に限定せず、一般の Web ページを想定している。したがってこれまでの文書読解が扱っていたものに比べて検索質問も文書も難しいものといえ、本研究はこのようなものを扱う点において新しいといえる。

2. 実験のデータ

2.1 解答可能性付き読解データセット

はじめに、一般の Web ページからの用語検索がどの程度難しいかを調査する。そこで文書読解タスクで用いられていたデータである解答可能性付き読解データセット [7] を使用して比較を行う。このデータセットは、（質問、解答、文書）の組に対して、解答可能性スコアがつけられたものである。なお解答可能性スコアは、文書読解によって質問に答えることができるかについて人手で判断されたスコアである。また、質問と解答はクイズの問題と正解からなる。

このデータセットを RC_{orig} とし、これを実験に用いる。テストデータもこの一部から作成する。学習に用いない 100 例の検索質問 (Q_{RC})、解答 (A_{RC}) とそれに対応する文書 (D_{RC}) の組 $Evalset_{RC-DocRC} = (Q_{RC}, A_{RC}, D_{RC})$ をテストデータとして使用する。

このデータセットは読解を目的としたものである。検索質問に対する文書の中に目的とする語（本研究での用語）は必ず含まれている。一方、解答可能性を表すスコアが

表 1 学習データ

	単語含むが根拠なしデータ	単語を含まないデータ
RC_{orig}	解答不能	-*
RC_{prop}	解答可能	解答不能

*: データに存在しない

いており、読解タスクにおいては解答可能性スコアが低い文書は解答根拠が存在しないとして解答不能文書として扱われる。さらに語が含まれていない文書は解答不能文書としては存在していない。本研究では用語の検索を目的としており、解答根拠は不要である。Web ページを求め、そこからの用語抽出を行うため、求めた Web ページに用語が存在しない場合もあると考えられる。そこで、本研究では別の学習セットを作成する。具体的には、文書 D_{RC} において根拠なしのため解答不能とされていた文書を解答可能な文書とし、用語を含まない文書を解答不能な文書として追加する。本研究では、解答不能な文書として、同データセットの他の（質問、解答）に対する文書を選んだ。なおこの文書に用語が含まれていないこともチェックした。このデータセットを RC_{prop} とし、これも実験に用いる。新たなテストデータもこの一部から作成する。検索質問 (Q_{RC}) は同一とし、検索質問 (Q_{RC})、解答 (A_{RC})、文書 (D_{RC}) の組 $Evalset_{RC-DocRC} = (Q_{RC}, A_{RC}, D_{RC})$ をテストデータとして使用する。

学習データを表 1 に、テストデータ一覧を表 2 に示す。表 2 の他のテストデータについては後述する。

2.2 Google スニペットに基づく Web 文書データ

本論文では、一般の Web ページからの用語抽出に基づく用語検索を提案する。そこで、Web ページの文書からなるデータセットを評価データとして作成した。一般の Web 文書として、Google スニペットを採用した。Google スニペットは、Google 検索エンジンに検索質問を入力して得られる検索結果ページにおいて、検索結果の Web ページのタイトルや URL の下に表示される短い説明のことである*1。Google スニペットの取得は、Google API Client Libraries [9] を用いて行う。本論文では、テストセットの検索質問 Q_{RC} について Google スニペットを最大 10 件取得し、それに基づく Web 文書データを用いる。 D_{RC} をこの文書 $D_{RC-GS10}$ で置き換えたデータセット $Evalset_{RC-DocGS10} = (Q_{RC}, A_{RC}, D_{RC-GS10})$ もテストデータとする。これも表 2 に示されている。

2.3 用語検索用の検索質問

解答可能性付き読解データセットの検索質問はクイズの問題文であるため、用語検索における検索質問とは性質が異なる。用語検索において想定される検索質問とは「その

*1 文書中の検索質問に関連する箇所をつなげたもので、必ずしも文書中の連続した文字列とはなっていない。

表 2 テストデータ

テストデータ	検索質問	解答 (用語)	文書	データ数	(解答可能, 解答不能)
Evalset _{RC-DocRC}	Q_{RC}	A_{RC}	D_{RC}	914	(457, 457)
Evalset _{RC-DocGS10}	100 例	100 例	$D_{RC-GS10}$	952	(315, 637)
Evalset _{TE-DocGS10}	Q_{TE}	A_{TE}	$D_{TE-GS10}$	230	(67, 163)
Evalset _{TE-DocGS100}	23 例	23 例	$D_{TE-GS100}$	2206	(411, 1795)

用語が思いつかない人が用語を知るために、整った形式ではなく行う検索質問である。このような検索質問として、表 A.1 に示す 23 例を作成した (Q_{TE})。これらの検索質問については、一部主観的表現も含むものの正解にたどり着ける程度の情報が含まれたものであると本研究では判断した。なお構文的な誤りは含まれていない。

Q_{TE} を用い検索質問ごとに Google スニペットを最大 10 件、100 件取得した。それぞれ $D_{TE-DocGS10}$, $D_{TE-DocGS100}$ とし、検索質問、解答、Web 文書の集合からなるデータセットのそれぞれ $Evalset_{TE-DocGS10} = (Q_{TE}, A_{TE}, D_{TE-GS10})$, および $Evalset_{TE-GS100} = (Q_{TE}, A_{TE}, D_{TE-GS100})$ もテストデータとする。これらも表 2 に示されている。

3. 実験手順

3.1 BERT に基づく用語検索

はじめに、BERT を用いた質問応答の枠組みを用語検索に用いることを考える。具体的には、SQuAD 2.0 [10] で用いられた方法 [11] を用いる。これは、事前学習された BERT について、図 1 に示す通り、検索質問 (Question) q と文書 (Paragraph) d を連結させた string “[CLS] q [SEP] d ” に対して、解答可能な場合には文書中の正解の開始位置と終了位置 (Start/End) を出力するように、解答不可能な場合には開始位置と終了位置として [CLS] の位置を出力するように学習 (fine-tuning) するものである。

BERT の日本語 Pretraining モデルとして、京都大学より提供されているもの (BERT-BASE-WWM 版) [12] を用いた。語彙の大きさ (token size) は 32k である。

はじめに、 RC_{orig} を BERT の fine-tuning に用いてベースラインのモデル ($BERT_{base}$) を構築する。本研究では既存研究 [7] と同様に、質問の元となったクイズ問題の出題年によってデータセットの学習データ、検証データ、テストデータへの分割を行った。 RC_{orig} のデータのうち、出題年が 2009 年より前のもの (質問・解答 9311 件、文書 43610 件) を学習データ、2009 年のもの (質問・解答 1454 件、6863 件) を検証データ、2010 年以降のもの (質問・解答 1321 件、6178 件) のうちの質問・解答の 100 件 (文書 457 件) をテストデータとした。次に、 RC_{prop} を用いて BERT を fine-tuning したモデル ($BERT_{prop}$) を構築する。データ分割は RC_{orig} と同一である。

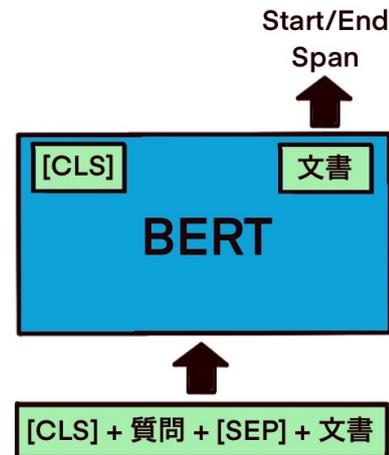


図 1 bert の fine-tuning

3.2 評価基準と方法

本実験での評価基準について述べる。本実験では、用語を抽出する対象の複数の文書それぞれについて、検索質問と各文書の組を作成し、BERT により単語区間候補を求め、次に、検索質問と複数の文書ペアから単語区間候補をランク付けして出力する。したがって、以下の評価基準でそれぞれの評価を行う。

- (1) Web 検索結果 (文書) のうちに用語が含まれてるものの割合
- (2) 検索質問と各文書の組に対して BERT が出力する単語区間候補と正解単語列の一致率
- (3) ランク付けした上位 N 件中に正解単語列が含まれる割合

4. 実験結果と考察

4.1 BERT による用語抽出

解答不能文書の定義が異なる二つの学習データで学習したモデル $BERT_{base}$ と $BERT_{prop}$ を用いて、用語抽出が行えるかを調べた。結果を表 3 および表 4 に示す。

$Evalset_{RC-DocRC}$ については、いずれのモデルでも解答不能文書を解答不能と正しく答えられている。これは、解答不能文書として全く別の検索質問に対する答えの文書を与えており、検索質問と文書が遠かったためと考えられる。一方、他のテストセットに対しては、 $BERT_{prop}$ は正しく解答不能であると判断はできていない。これは $BERT_{prop}$ は検索質問と遠い文書で解答不能な場合を学習している一方、テストセットでの解答不能文書は検索質問と関連する

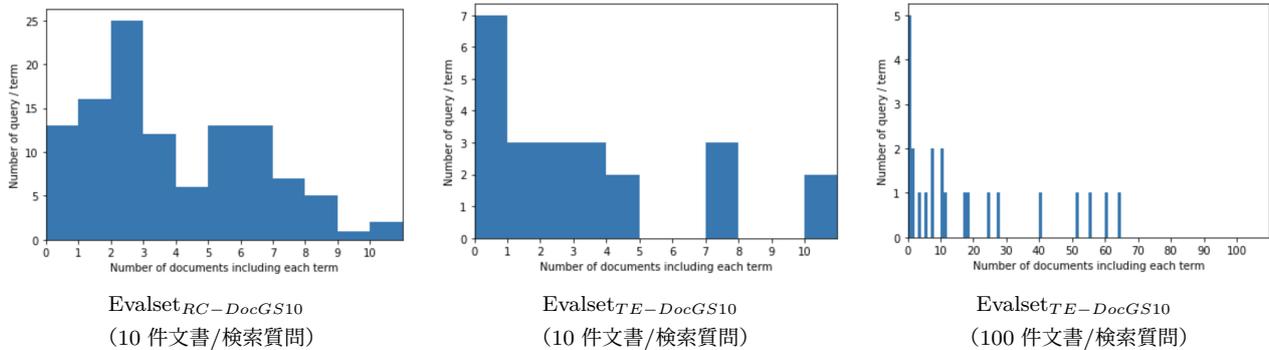


図 2 用語を含む文書数 (ヒストグラム)

表 3 BERT_{base} による用語抽出

テストデータ	解答可能 (F1 スコア)	解答不能
Evalset _{RC-DocRC}	36%	100%
Evalset _{RC-DocGS10}	54%	75%
Evalset _{TE-DocGS10}	33%	77%
Evalset _{TE-DocGS100}	32%	84%

表 4 BERT_{prop} による用語抽出

テストデータ	解答可能 (F1 スコア)	解答不能
Evalset _{RC-DocRC}	67%	100%
Evalset _{RC-DocGS10}	67%	11%
Evalset _{TE-DocGS10}	62%	4%
Evalset _{TE-DocGS100}	69%	7%

Web 検索結果のうちの用語を含まないものであり、学習時との不一致が生じたためと考えられる。解答可能な文書については、いずれも BERT_{prop} が高いスコアを示している。BERT_{base} では用語を含んでも根拠がない場合は解答不能と答えるためスコアが低いと考えられる。本研究では、ユーザに用語を提示することが目的であるため、何も提示しないよりも誤りを含んでも用語候補を提示できるほうが重要である。したがって、本研究では BERT_{prop} のほうが目的に合致しているといえる。

次に、テストセット間での差について考察を行う。Evalset_{RC-DocRC} と Evalset_{RC-DocGS10} では、検索質問は同一であるものの文書が Wikipedia と Web ページ (スニペット) と異なる。解答可能なものに対する抽出では、比較的整っていると考えられる Wikipedia 文書よりも、Web ページ (スニペット) からの抽出のほうがやや難しいことを示している。また、検索質問が異なる Evalset_{RC-DocGS10} と Evalset_{TE-DocGS10} を比較すると、検索質問がクイズの問題文のように整えられたものに比べると、今回のような検索質問では難しい可能性があることが分かった。しかし、Evalset_{TE-DocGS100} では同等の結果となっており、今後詳細を調査していく。BERT を用いた Web ページ (スニペット) からの整った形式でない検索質問での用語検索は、整った文書からの整った形式での検索質問での用語検索よりもやや難しいことが分かった。

4.2 用語を含む Web 文書数

検索質問 Q_{RC} と Q_{TS} でそれぞれ Web 検索した結果 $D_{RC-GS10}$, $D_{TE-GS10}$, $D_{TE-GS100}$ に目的とする用語が含まれている文書数を調べた。結果を図 2 に示す。

Q_{RC} の 100 の検索質問のうち 13 の検索質問については、取得した最大 10 件の Web 文書 $D_{RC-GS10}$ に一つも用語を含むものはなかった。同様に Q_{TE} の 23 の検索質問のうちで、取得した最大 10 件の Web 文書 $D_{TE-GS10}$ に一つも用語を含むものがなかった検索質問は 7 である。最大 100 件取得した場合 ($D_{TE-GS100}$) では 5 つの検索質問で用語が一つも含まれなかった。これらのことより、これらの文書からの用語検索 (精度) の上限は、それぞれ 87 件 (87%), 16 件 (70%), 18 件 (78%) である。また、用語を含むものについては複数文書に含まれるものが多くあることが確認できた。これは、複数文書それぞれからの用語抽出結果を統合することで用語検索精度を向上できる可能性を示している。

4.3 複数文書からの用語抽出結果の統合

本研究は用語検索を目的としているので、4.1 節の実験ように各 (検索質問, 用語, 文書) の組に対して上手く用語抽出できることよりも、各 (検索質問, 用語) の組に対し、文書データ全てを考慮して、正しい用語を提示できるかが重要である。

そこで、各 (検索質問, 用語) の組に対して、本研究では用語抽出結果の統合を行った。具体的には、各文書から出力される用語候補 (合計 N 個) についてランク付けを行い、出力することとした。本実験では、単純に出力された数をスコアとし、スコア順に並べて上位 k 件を出力する。この時、上位 k 件に正解の用語が含まれたときに検索成功とみなす。ランク付けの様子を図 3 に示す。

結果を表 5 に示す。BERT_{prop} のほうが BERT_{base} よりもより多く正しい用語を検索できることがわかる。これは BERT_{prop} では解答根拠がなくても用語を出力する (解答不能と答えない) ためと考えられる。ここでも、BERT_{prop} が本手法に適していることが確認できる。次に、BERT_{prop}

表 5 複数文書からの用語候補の統合 (検索成功用語数)

テストデータ (用語数)	BERT _{base}			BERT _{prop}			(上限)
	k = 1	k = 10	k = 100	k = 1	k = 10	k = 100	
Evalset _{RC-DocRC} (100)	54	59	-	66	74	-	100
Evalset _{RC-DocGS10} (100)	46	55	-	40	58	-	87
Evalset _{TE-DocGS10} (23)	4	5	-	5	8	-	16
Evalset _{TE-DocGS100} (23)	6	8	8	7	10	11	18

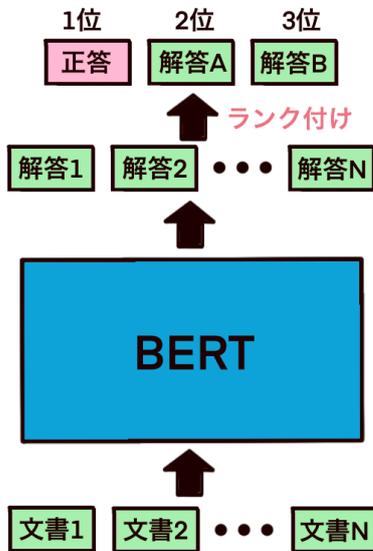


図 3 複数文書からの用語抽出とランク付け

の結果の比較を行う。

まず、検索対象文書が比較的整った Wikipedia 文書 (Evalset_{RC-DocRC}) と一般の Web 文書 (Evalset_{RC-DocGS10}) を比較する。Evalset_{RC-DocGS10} では Web 文書に正解が含まれる用語 (上限値=87 件) のうちの 46% (40 件) を 1 位に、67% (58 件) を 10 位までに出力できている。これは、Evalset_{RC-DocRC} の 1 位での検索成功率 66% (66/100) と 10 位までの検索成功率 74% (74/100) に比べて低い。解答可能な文書からの BERT による用語抽出の F1 スコアは、Wikipedia 文書と Web 文書での差は小さかったが、ここでは大きな差が見られた。この原因については今後分析をしていく予定である。次に、検索質問の違いについて調べた。検索質問が整っているもの (Evalset_{RC-DocGS10}) と整っていないもの (Evalset_{TE-DocGS10}) を比較した。前者は 46% (40/87) を 1 位に、67% (58/87) を 10 位までに出力できていたのに対し、後者は Web 文書に正解が含まれる用語 (上限値=16 件) のうちの 31% (5 件) を 1 位に、50% (8 件) を 10 位までに出力できていた。解答可能な文書からの BERT による用語抽出の F1 スコアは RC と TE の検索質問での差は小さかったが、ここでも TE の検索質問のほうが難しかった。この原因についても今後分析していく予定である。一方、TE の検索質問でも Web を 100 件検索することで、より多くの正しい用語を見つけることができるよう

になった (1 位に 7/18=39%, 10 位までに 10/18=56%)。

課題をまとめる。提案手法では、検索質問から用語を含む Web 文書を求めるところで 20~30%程度 (23 件中 5 件, 7 件) の用語検索漏れが、用語を含む Web 文書が与えられた中から用語を抽出するところで 40~50%程度 (18 件中 7 件, 16 件中 8 件) の用語検索漏れがあることがわかった。さらに詳しく分析すると、表記の揺れの問題もあることがわかった。例えば “twitter” が正答であった場合、“ツイッター”、“Twitter” は本実験では誤答として扱われている。これらを人手で確認して正答とみなした場合 (表記揺れを考慮する)、検索精度が 5%程度高くなることがわかった。今後は、これらそれぞれについて改善を行い、用語検索の精度を高めていく予定である。

5. まとめ

質問応答のデータセットで学習した BERT を用いて、Web 文書からの用語検索を試みた。

Wikipedia のような比較的整った文書に限らない一般の Web 文書から用語の検索は難しいタスクであること、クエリが整ったものではない場合はさらに難しいことを確認した。複数文書からの用語候補の抽出を行い、頻度に基づいて単純にランク付けすることで、1 位に用語を 20~30% (5/23=22%, 7/23=30%) 程度の精度で、10 位以内に用語を 40%程度 (8/23=35%, 10/23=43%) の精度で見つけられることが分かった。

今後は、誤りの分析、Web 文書の取得の方法、BERT の学習方法の改善、ランキング手法および表記ゆれ問題への対応などを行って用語検索の高精度化を目指す予定である。

謝辞: 本研究は科研費基盤研究 (C) 19K12241 の補助を受けた。

参考文献

- [1] 粟飯原俊介, 長尾 真, 田中久美子: 意味的逆引き辞書『真言』, 言語処理学会第 19 回年次大会発表論文集, pp. 406-409 (2013).
- [2] 内木賢吾, 佐藤理史, 駒谷和範: 日本語クロスワードを解く: 性能向上の検討, 2013 年度人工知能学会全国大会, vol.27, pp. 1-4 (2013).
- [3] 森田直樹, 南條浩輝, 山本凌紀, 馬 青: 音声ドキュメントを検索対象とした用語検索, 情報処理学会論文誌, Vol. 58, No. 3, pp. 762-767 (2017).
- [4] 金井 明, 佐藤 充, 石下円香, 森 辰則: factoid 型質問応答における異なる Web 検索エンジンの組合せの効果, 14 回言語処理学会年次大会発表論文集, p. 1013-1016 (2008).
- [5] Karpukhin, V., Oguz, B., Min, S., Lewis, P., Wu, L., Edunov, S., Chen, D., and Yih, W.: Dense Passage Retrieval for Open-Domain Question Answering, *EMNLP*, p. 6769-6781 (2020).
- [6] Zhang, Z., Yang, J. and Zhao, H.: Retrospective Reader for Machine Reading Comprehension, *AAAI*, Vol. 35, No. 16, pp. 14506-14514 (2021).
- [7] 鈴木正敏, 松田耕史, 岡崎直観, 乾健太郎: 読解による解答可能性を付与した質問応答データセットの構築, 言語処理学会第 24 回年次大会, pp. 702-705 (2018).
- [8] 鈴木正敏, 松田耕史, 大内啓樹, 鈴木 潤, 乾健太郎: オープンドメイン質問応答における解答可能性判別の役割, 言語処理学会第 27 回年次大会, pp. 847-852 (2021).
- [9] Google: Google API Client Libraries, <https://developers.google.com/api-client-library>.
- [10] Rajpurkar, P., Jia, R., and Liang, P.: Know What You Don't Know: Unanswerable Questions for SQuAD, *ACL*, Vol. 2, p. 784-789 (2018).
- [11] Devlin, J., Chang, M.-W., Lee, K. and Toutanova, K.: BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, *NAACL*, Vol. 1, p. 4171-4186 (2019).
- [12] 柴田知秀, 河原大輔, 黒橋禎夫: BERT による日本語構文解析の精度向上, 言語処理学会第 25 回年次大会, pp. 205-208 (2019).

付 録

表 A.1 作成した検索質問 23 件

用語	検索質問
猫	ペットの動物。部屋で飼うことが多い。かわいい。
バナナ	黄色の果物。細長くて甘い。皮をむいて食べる。
ウインドブレイカー アイドリング	寒い時に着る服。風を通しにくい。 止まっているのに、エンジンをかけたままのこと。
海賊版 カバディ	偽物のこと。DVD とかに使われる。 インドのスポーツ。鬼ごっこみたいなもの。
サブスク	定期的にお金を払うことで、サービスを使い放題になること。
GPU	パソコンのグラフィックをきれいにする。研究とか仮想通貨にも使われる。
GPS	人工衛星を使って自分の位置を知る。
GPA	学校などの成績の一種。ポイントの平均点みたいなもの。
GDP	国の中で作られた価値。外国が国内で作ったものも含む。
GNP	国として作った価値。外国で作ったものも含む。
CPU	パソコンの計算部分。速さとコア数で計算速度が変わる。
鬼滅の刃	鬼を倒す漫画。映画の中で一番お金を稼いだ。
ティンパニー ドーピング	大きめのたたき楽器。置いて使う。 薬を飲んで能力をあげること。悪い意味で使う。
コールドゲーム マンホール 湯たんぼ	雨で中止になった試合。 道路にある穴のふた。 寒い時にお湯を入れて使う道具。
エキストラ	テレビや映画に出る人で、その他一般の人。
アイシャドー	目の上に塗る化粧品。青が多い気がする。
メトロノーム	音楽の時にリズムをとる装置。揺れて音が鳴る。
夏至	一年の内で一番昼が長くなる日。