

音声中の検索語検出における単語共起情報の利用

小田原 一成^{†1} 山下 洋一^{†2,a)}

概要：本論文では、音声中の検索語検出において、音声ドキュメントと検索語の記号列照合に加えて、検索語に関する共起単語情報と検索語候補区間の単語信頼度を用いる手法を提案する。音素単位でのDPマッチングにより音声ドキュメント中から検索語の候補区間を検出し、検出した候補区間をWebテキストから学習した共起単語情報と候補区間の単語信頼度に基づき再評価する。共起単語情報として、TF-IDF値、候補区間前後に出現した共起単語の数、音声認識時に得られる単語信頼度の3種類の手法を比較する。共起単語情報を用いることによりSTDの性能を改善でき、候補区間前後に出現した共起単語の数がSTDの精度向上に最も有効であることがわかった。共起情報に加え候補区間の単語信頼度を組み込んだ場合、更に精度の向上が見られた。

キーワード：STD, DPマッチング, 共起単語, TF-IDF

Spoken Term Detection Using Information of Collocation

ODAWARA KAZUNARI^{†1} YAMASHITA YOICHI^{†2,a)}

Abstract: This paper proposes a new spoken term detection method which uses collocation information for a query word and word reliability of candidate segments, in addition to word matching score of phoneme sequences between spoken documents and a query word. This method detects candidate segments from spoken documents using DP matching in phoneme unit. The detected candidate segments are re-evaluated based on collocation information trained with web text and word reliability. We compared three measures for collocation information ; TF-IDF value, the number of the collocation word appeared before and after the candidate segment and word reliability scores obtained in speech recognition. Experimental results show that the introduction of collocation information improves STD performance and that the measure using number of the collocation word is most effective to improvement of STD. In addition to collocation information, word reliability of candidate segments improves STD performance.

Keywords: STD, DP Matching, Word Collocation, TF-IDF

1. はじめに

現在、音声ドキュメントを検索する際、そのコンテンツの作成者が付加したタイトルやタグなどのメタデータを用いる手法が一般的であるが、メタデータが与えられていないかたり、コンテンツの内容を十分に表現していなかった

りすると、求めている音声ドキュメントを得ることは難しい。音声ドキュメントに対する検索では、コンテンツ作成者が与えるメタデータに依らず目的のコンテンツを効率良く見つける検索技術が求められている。

この音声ドキュメントに対する検索として、与えられた検索語を音声ドキュメント中から自動的に検出する音声中の検索語検出（STD : Spoken Term Detection）の研究が盛んに行われている [1], [2]. STDは、対象の音声ドキュメントを大語彙連続音声認識して得られる単語列と検索語を照合することによって実現できるが、音声認識の辞書に登録されていない単語である未知語や音声認識時に認

^{†1} 現在、立命館大学大学院情報理工学研究科
Presently with Graduate School of Information and Engineering, Ritsumeikan University

^{†2} 現在、立命館大学情報理工学部
Presently with College of Information and Engineering, Ritsumeikan University
a) yama@media.ritsumei.ac.jp

識誤りとなった単語が検索できない。この問題を解決するため、単語より短い音素や音節などのサブワードを単位として音声認識し、検索語と類似した系列を検出する手法が広く用いられ、未知語に対しても一定の性能が得られている[3], [4], [5], [6]。この手法では、検索語のサブワード列と類似したサブワード系列を音声ドキュメントから検出するため、湧き出し誤りの発生が問題となるものの、音声を種類の限られるサブワード単位で表現するため、未知語の問題は避けられる。一方で、STDで発声された検索語の区間を漏れなく検出する、すなわち検出率を上げるために、音声ドキュメントにおける音響的な多様性をどのように考慮して検索語と照合するのかが大きな問題となる。これまでに、複数の音声認識結果を用いることで音響的多様性を考慮する手法[7]や、音素の替わりに音響特徴をベクトル量化した得られる記号列によって音声ドキュメントを表現する手法[8]などが提案されている。以上の手法は、音声認識によって音声ドキュメントを変換して生成された記号列と検索語との照合によって検索語を検出するため、音声ドキュメントにおける音響的な特徴のみを用いて検索語を検出していると言える。

検索語は音声ドキュメント中では文の一部として発声され、前後の単語との関連性が見られる。音声ドキュメントにおける単語間の関係をこのような言語情報として使用することによって、湧き出し誤りを抑制し STD の性能を向上させられる可能性がある。言語情報を使用した STD 手法としては、検索語の前後に格助詞を付与し検索する手法[9]や、単語ラティスで表現された音声ドキュメントに対して、話題推定に基づいた単語共起情報を用い既知語の検出を行う手法[10]などが提案されている。また、音声ドキュメントを連続単語認識した際、単語毎に単語信頼度が算出される。この単語信頼度は、音声認識器が正しい結果と判断した場合高くなるが、検出すべき単語が未知語や認識誤りの場合、検出すべき区間の単語信頼度は低くなる傾向にある。検索語の候補区間の単語信頼度を見る事で誤検出を軽減できる可能性がある。

本論文では、単語の共起情報と候補区間の単語信頼度を利用して STD の性能を改善する手法について述べる。従来から用いられている音素列の照合に基づいた STD によって検索語の候補区間を生成し、候補区間の前後に出現する単語と検索語との共起情報、音声認識時に得られる候補区間の単語信頼度を用いて候補区間を再評価したスコアに基づいて検索語を検出する。以下、2章では提案する検索語検出手法の概要、3章では共起単語情報と候補区間の単語信頼度の具体的算出方法、4章では評価実験、5章に結論と今後の課題について述べる。

2. 検索語検出手法

本論文で提案する STD 手法では、従来から用いられる

音響情報に基づいたサブワード列による連続 DP マッチングにより検索語の候補区間を検出し、共起単語情報を用いてスコアを再評価することにより検索語を検出する。

2.1 共起単語情報と候補区間の単語信頼度を用いた検索語検出の処理の概要

提案する STD 手法の処理の流れを Fig. 1 に示す。以下にその手順を述べる。

(1) 音声ドキュメントの認識

検索対象の音声ドキュメントを音声認識することによって、音素列と単語列の 2 種類の音声認識結果を得ておく。

(2) 検索語候補区間の生成

検索語が入力されると、音声ドキュメントの音素列での認識結果を対象にして、連続 DP マッチングによって検索語検出を行い、結果を検索語の候補区間とする。ここで、検索語が発声されている区間が候補区間からなるべく漏れないよう、検索語が検出されやすいよう高めのしきい値設定をしておく。

(3) 共起単語リストの生成

検索語を web 検索し、検索語に関する web 文書を収集する。事前に web 検索を行って作成しておいた web 文書集合と検索語に関して収集した web 文書を用いて、検索語と関連性が高いと考えられる共起単語リストを生成する。詳細は 3.1 節で述べる。

(4) 検索語との共起を考える単語集合の生成

音声ドキュメントの単語列での認識結果において、検索語候補区間の位置を決定する。検索語候補区間に先行する M 個、および後続する M 個（計 $2M$ 個）から成る単語集合のうち、(3) で生成した共起単語リストに含まれる単語集合 $U = u_1, \dots, u_K$ （ここで、 $K \leq 2M$ ）を再評価に用いる共起単語集合とする。この単語集合を用いて候補区間にに対する共起単語情報を算出する。詳細は 3.2 節で述べる。

(5) 候補区間における単語信頼度の算出

検索語の候補区間 \tilde{w} は、音声ドキュメントの音素列と検索語の音素列で記号列照合するため、得られる候補区間は単語単位ではなく、音声ドキュメント中のいくつかの単語にまたがっている検出される場合がある。候補区間に含まれる単語を $b_i (1 \leq i \leq B)$ とし、候補区間 \tilde{w} に含まれる単語 b_i のフレーム数を d_i とする。音声認識時に得られる単語 b_i の単語信頼度を c_i とすると、候補区間の単語信頼度 $J_{\tilde{w}}$ は

$$J_{\tilde{w}} = \frac{\sum_{i=1}^B c_i d_i}{\sum_{i=1}^B d_i} \quad (1)$$

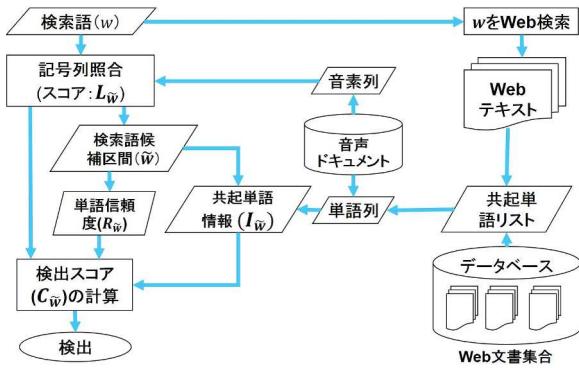


図 1 単語共起を用いた STD 手法の流れ

Fig. 1 Flow of STD method using information of collocation.

として算出する。

(6) 検索語の検出

検索語 w に対する候補区間 \tilde{w} に対して、(2) で得られる照合スコア $L_{\tilde{w}}$ と (4) で算出した共起単語情報 $I_{\tilde{w}}$ と (5) で算出した候補区間の単語信頼度 $J(\tilde{w})$ を用いて、候補区間を再評価したスコア $C_{\tilde{w}}$ を

$$C_{\tilde{w}} = \frac{1}{L_{\tilde{w}}} + \alpha I_{\tilde{w}} - \beta J(\tilde{w}) \quad (2)$$

のように求める。ここで、 α は共起単語情報の重み、 β は候補区間の単語信頼度の重みである。このスコア $C_{\tilde{w}}$ に対するしきい値処理によって、最終的に検索語を検出する。

3. 共起単語情報

本章では、共起単語リストの生成と検索語候補区間にに対する共起単語情報の算出手法について述べる。

3.1 共起単語リストの生成

本手法では、検索語と共に検索される単語の集合として共起単語リストを生成する。共起単語リスト作成の流れを Fig. 2 に示す。検索語 w が与えられると、検索語を web 検索し、検索語に関する web 文書を収集する。文書を形態素解析し、出現した名詞だけを抽出し、各名詞の TF-IDF の値を計算する。TF-IDF は、文書数 N 、語頻度 tf (term frequency)、文書頻度 df (document frequency) から

$$\text{TF-IDF} = tf \times \log \frac{N}{df} \quad (3)$$

のように算出され、TF-IDF の上位 T 個の単語によって共起単語リストを構成する。

TF-IDF の算出には、一般に、文書集合が必要であり、本研究では、Fig. 3 に示すように単語を web 検索し上位 S 件の web ページを連結したものを 1 つの文書と考える。ここで、ある単語 x を検索して得られる文書を $D(x)$ と表記することとする。検索語 w 以外の単語

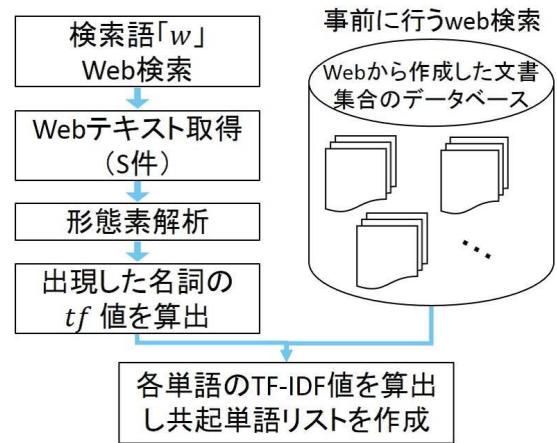


図 2 共起単語リスト作成の流れ

Fig. 2 Flow of making collocation information list.

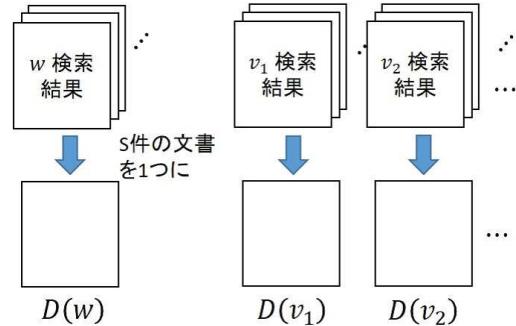


図 3 TF-IDF 算出のための文書

Fig. 3 Document of calculating TF-IDF.

表 1 検索語ランキング上位語

Table 1 An example of top words in retrieval term rank.

NISA	パズドラ	あまちゃん
堺雅人	安藤美姫	滝川クリステル
富士山	iPhone	東京スカイツリー

セット $V = v_1, \dots, v_{49}$ を考え、TF-IDF を算出するための文書集合として、 $D(w)$ の他 $D(v_1), \dots, D(v_{49})$ の計 50 文書を用いる。 $D(v_1), \dots, D(v_{49})$ は、事前に作成しておくこととする。これより、式 (3) の tf は $D(w)$ 、 df は $D(w), D(v_1), \dots, D(v_{49})$ から計算され、 N は 50 となる。 V として、2013 年の google 検索語ランキング上位 49 語を用いた。その一部を Table. 1 に示す。文書 $D(x)$ を得るために検索エンジンとしては google を用い、取得する web ページ数 S は 500 とした。ただし、文書をうまく取得できない URL が一部存在するため、実際に取得できた web ページ数は 500 より少ない場合がある。形態素解析器として「茶筌」を用い、共起単語リストの単語数 T は予備実験の結果から $T = 150$ とした。検索語「安保理」に対して得られた共起単語のうち、上位 5 位までの単語を Table. 2 に示す。

表 2 検索語「安保理」に対する共起単語の例

Table 2 An example of collocation words for a query term "Anpori".

順位	単語	TF-IDF 値
1	安保理	8.2
2	決議	2.4
3	国連	2.3
4	常任	1.6
5	採択	1.4

表 3 平均共起単語数の比較

Table 3 Comparison of average number of collocation words.

M	正解区間	不正解区間
10	0.48	0.0001
100	2.61	0.0007

3.2 共起単語情報の算出

共起単語情報の算出手法として、以下で述べる 3 種類の手法を試みる。

3.2.1 手法 1 : TF-IDF を用いた手法

検索語 w に対して、候補区間の前後 M 語内に出現した共起単語 u_i の TF-IDF 値を $F_{\tilde{w}}(u_i)$ とするとき、共起単語情報を式 (4) によって算出する。

$$I_{\tilde{w}} = \sum_{u_i \in U} \frac{F_{\tilde{w}}(u_i)}{2M} \quad (4)$$

3.2.2 手法 2 : 共起単語出現数を用いた手法

検索語候補区間の前後に出現する単語に関して、共起単語がどの程度で出現するかを予備的に分析した。検索語が実際に話されている正解区間と候補区間が湧き出し誤りである不正解区間に分けて、前後の単語数 M を変えたときの平均共起単語数を Table. 3 と Fig. 4 に示す。これより、前後の単語数 M に依らず、正解区間と不正解区間では共起単語の出現数が大きく異なることがわかる。そこで、候補区間の前後 M 語内に出現した共起単語の単語数 K を用いて、共起単語情報を

$$I_{\tilde{w}} = \sum_{u_i \in U} \frac{1}{2M} = \frac{K}{2M} \quad (5)$$

によって算出する。

3.2.3 手法 3 : 単語信頼度を用いた手法

音声ドキュメントを連続音声認識したときに得られる単語信頼度を用いて単語共起情報を算出する。候補区間の前後 M 語内に出現した共起単語 u_i の単語信頼度を $R_{\tilde{w}}(u_i)$ とするとき、共起単語情報を

$$I_{\tilde{w}} = \sum_{u_i \in U} \frac{R_{\tilde{w}}(u_i)}{2M} \quad (6)$$

によって算出する。

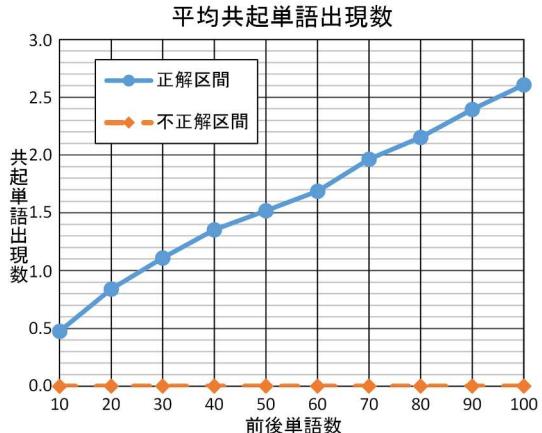


図 4 平均共起単語数の変化

Fig. 4 Change of average number of collocation words.

表 4 未知語 50 語の例

Table 4 An example of 50 unknown words.

コンテキストディペンデント	名犬ラッキー	知床
スティーブンキング	石川島造船所	安保理
ユニバーサルスタジオ	談洲楼焉馬	NATO 軍

4. 評価実験

4.1 実験条件の設定

実験データには、NTCIR-9 Spoken Doc[13] のテストコレクションを用いた。実験データに含まれる検索対象の音声ドキュメントは、日本語話し言葉コーパス (CSJ : Corous of Spontaneous Japanese) のコア 177 講演 (男性 99 講演、女性 78 講演) [14], [15] を用い、検索対象の音声ドキュメントの認識結果は、NTCIR-9 Spoken Doc のタスクオーガナイザから配布されている単語音声認識結果（単語正解率 76.68%）と音節 trigram での音節認識結果（音節認識率 81.8%）を用いた。また、評価用の検索語は、コア講演用未知語セット 50 検索語を用いた [13]。未知語 50 語の一部を Table. 4 に示す。未知語 50 語の平均音素数は 11.8、最大音素数は 21、最小音素数は 6 である。評価尺度として、再現率、適合率、F 値、MAP を用いる。これらの評価尺度は全て 0 ~ 1 の値をとり、1 に近いほど精度が高いことを示す。ベースラインとして、2.1 節で述べたサブワード列に基づく連続 DP マッチングの結果を用いる。共起単語リストに用いる単語数 T は 150 とし、前後単語数 (M) は 0 ~ 300 まで 10 間隔、共起単語情報の重み (α) は 0 ~ 100 まで 5.0、単語信頼度の重み (β) は 0 ~ 2.0 まで 0.2 間隔で変化させた。

4.2 実験結果

実験の結果の再現率、適合率、F 値、MAP を Table.5 に示す。 M , α は、F 値が最も高い値を示したときの値であ

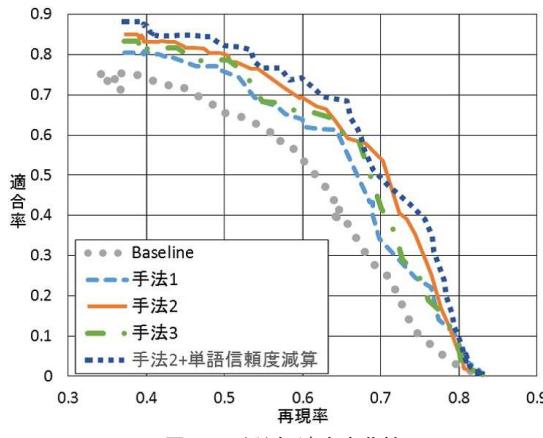


Fig. 5 Recall - Precision curve.

り、Fig.5には、ベースライン、手法1-3の再現率-適合率曲線を示している。手法1ではベースラインに比べ、F値で4.6%，MAPで13.5%の精度向上、手法2ではベースラインに比べ、F値で7.0%，MAPで17.1%の精度向上、手法3ではベースラインに比べ、F値で5.8%，MAPで15.4%の精度向上が見られた。手法2が最も向上したため、手法2に候補区間の単語信頼度減算を組み込んだ場合、手法2に比べ更にF値で1.9%，MAPで6.7%の精度向上が見られた。全ての手法で精度の向上が見られたことから、提案手法の有用性が確認できた。また、それぞれの手法で最適F値を取るときの前後単語数Mを固定し重みαを変化させたグラフをFig.6に、重みαを固定し前後単語数Mを変化させたグラフをFig.7に示す。それぞれ、 $\alpha=0$ 、 $M=0$ がベースラインの性能を示しており、手法1-3において、 $M=100, \alpha=50$ までに最適F値が出現したため、 $M=100, \alpha=50$ までを示す。Fig.6から共起単語情報として共起単語出現数を用いる手法2で、他の2つの手法よりどの α に対してもF値が高いことがわかる。Fig.7から、どの提案手法においても、共起情報の算出に用いる候補区間前後の単語数Mを増加させるとF値が上昇するが、 $M=40 \sim 60$ を越えて増加させてもそれほどF値の情報は見られないことがわかる。これは、発話の内容が変化し、それに伴い関連性のある単語も変化しているからだと推測できる。

5. まとめ

音声中の検索語検出(STD: Spoken Term Detection)において、音声ドキュメントの音響的な特徴に加えて、言語的な特徴を利用する手法を提案し、その有効性を検証した。言語的な特徴は、検索語候補区間の前後に出現する単語と検索語との共起に基づいて表現される。単語共起情報を定量化する手法として、3つの手法を比較した。これらの手法の違いは、出現した共起単語を加算する時の重みの違いであり、共起単語の重みとして手法1ではTF-IDFの値、

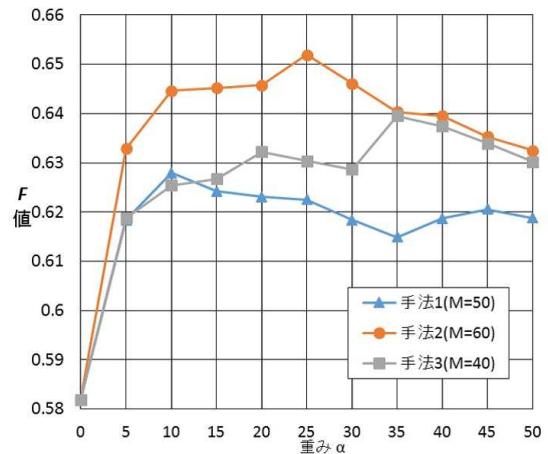


Fig. 6 重み α の変化による F 値の変化

Fig. 6 F-mesure change curve by weight “ α ”.

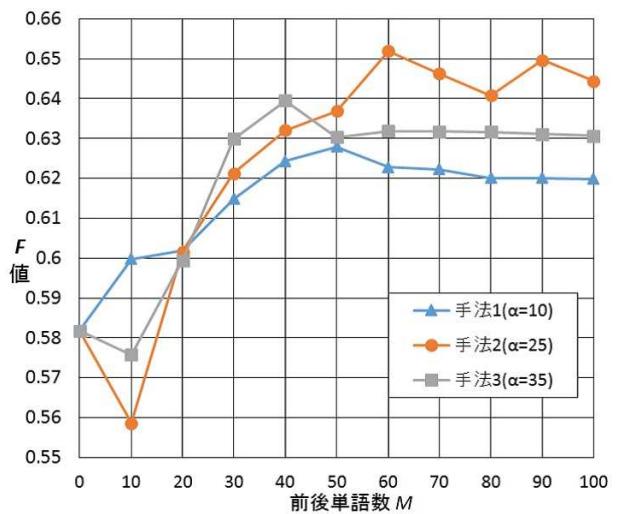


Fig. 7 前後単語数の変化による F 値の変化

Fig. 7 F-mesure change curve by number of context words.

手法2では等しい値、手法3では音声認識を行ったときの単語信頼度を用いていると考えることができる。共起単語の加算において、単語別に異なる重みを与えることによってより適切な共起単語情報を得ることを期待したが、結果としてはどの単語にも等しい重みを与える、すなわち単語数だけを考慮する手法2が最も良い性能を示した。手法2によって、音響情報をのみを用いるベースラインの手法に比べて、F値で7.0%，MAPで17.3%向上した。更に、手法2に対し、候補区間の単語信頼度の減算を加えたところ手法2からF値で1.9%，MAPで6.7%精度が向上した。本論文では、検索語と共に単語を名詞だけに限定しTF-IDFによって選択している。この選択方法の変更や別の重み付けを考えることによって、共起単語の重み付けが有効となる可能性もあり、今後、検討していきたい。また、候補区間前後に出現する単語と検索語との共起をコープスから直接的に学習する手法なども今後の検討課題として挙げられる。

表 5 STD の結果
Table 5 Results of STD.

手法	共起情報	単語信頼度	M	α	β	再現率 (%)	適合率 (%)	F 値 (%)	MAP (%)
ベースライン	なし	なし	0	0	0	55.9	60.6	58.2	48.9
手法 1	TF-IDF 値	なし	50	10	0	64.3	61.3	62.8	62.4
手法 2	共起単語出現数	なし	60	25	0	56.6	76.8	65.2	66.0
手法 3	単語信頼度	なし	40	35	0	63.5	64.5	64.0	64.3
手法 2	共起単語出現数	あり	180	65	1.6	65.7	68.5	67.1	72.7

謝辞 本研究を行うにあたり「日本語話し言葉コーパス」及び、「NTCIR-9 Spoken Doc タスク」の「CSJ Spoken Document Retrieval Collection」を使用した。

参考文献

- [1] T.Akiba, K.Aikawa, Y.Itoh, T.Kawahara, H.Nanjo, H.Nishizaki, N.Yasuda, Y.Yamashita and K.Itou, "Construction of a test collection for spoken document retrieval from lecture audio data", Journal of Information Processing, Vol.17, pp. 82-94, 2009.
- [2] 秋葉友良, “音声ドキュメント検索の現状と課題”, 情報処理学会研究報告, Vol.2010-SLP-82, No.10, pp.1-6, 2010.
- [3] 岩田耕平他, “語彙フリー音声検索手法における新しいサブワードモデルとサブワード音響距離の有効性”, 情報処理学会論文誌, Vol.48, No.5, pp.1990-2000, 2007.
- [4] T.Akiba, H.Nishizaki, K.Aikawa, T.Kawahara, T.Matsui, "Overview of the IR for Spoken Documents Task in NTCIR-9 Workshop", Proceedings of NTCIR-9 Workshop Meeting, pp.223-235, 2011.
- [5] 坂本渚, 山本一公, 中川聖一, “距離つき音節トライグラムを用いた音声入力による音声ドキュメントの検索語検出法の評価”, 第 7 回音声ドキュメント処理ワークショップ, SDPW2013-05, pp.1-4, 2013.
- [6] 大野哲平, 秋葉友良, “音節継続時間を利用した直線検出に基づく STD 手法”, 第 8 回音声ドキュメント処理ワークショップ, SDPW2012-02-01, pp.1-8, 2012.
- [7] 名取賢, 西崎博光, 関口芳廣, “複数音声認識システムを用いた音声中の検索語検出の検討”, 情報処理学会研究報告, Vol.2009-SLP-79, No.19, pp.1-6, 2009.
- [8] 坂本伊織, 松永徹, 趙國, 山下洋一, “音響情報のベクトル量子化を用いた音声ドキュメントからの検索語検出”, 情報処理学会論文誌, Vol.55, No.12, pp.2537-2545, 2014.
- [9] 南條浩輝, 前田翔, 吉見毅彦, “音声検索語検出のためのクエリ拡張の検討”, 情報処理学会研究報告, Vol.2014-SLP-101, No.16, pp.1-6, 2014.
- [10] Haiyang LI, Tiean ZHENG, Guibin ZHENG, Jiqing HAN, "Confidence Measure Based on Context Consistency Using Word Occurrence Probability and Topic Adaptation for Spoken Term Detection", IEICE TRANSACTIONS on Information and Systems, Vol.E97-D, No.3, pp.554-561, 2014.
- [11] 川崎祥, 秋葉友良, “単語共起を用いた疑陽性誤りに頑健な音声ドキュメントの検索モデル”, 日本音響学会 2014 年春季研究発表会講演論文集, 3-Q5-5, pp.193-196, 2014.
- [12] 角地良太, 芹野美紗子, 土屋誠司, 渡部広一, “単語の共起情報に基づいた音声認識誤り単語の補正手法”, 電子情報通信学会技術研究報告, AI2012-44, pp.19-24, 2013.
- [13] 西崎博光, 胡新輝, 南條浩輝, 伊藤慶明, 秋葉友良, 河原達也, 中川聖一, 松井知子, 山下洋一, 相川清明, “音声中の検索語検出のためのテストコレクションの構築と分析”, 情報処理学会論文誌, Vol.54, No.2, pp.471-483, 2013.
- [14] 前川喜久雄, “「日本語話し言葉コーパス」の概要”, 国立国語研究所, Ver.1.2.
- [15] http://www.ninjal.ac.jp/corpus_center/csj/