

書が作成されたコンテキストを抽出するのは難しい。作成した文書はその内容だけでなく、文書が作成されるプロセスから抽出された情報も重要であると言える[1]。

そこで文書の特徴付けを行う際に、関連文書からその文書を捉えるようにする。以下にそのイメージを示す。




図2.文書コンテキスト抽出のイメージ

1つの文書を複数の関連文書で捉える事で、複数のコンテキスト表現が可能になる。

4.2 文書登録時の特徴付け

本研究では、組織内で作成された文書を登録する際、文書の特徴付けを行う。文書が作成されたプロセスを文書の特徴付けに反映するために、本研究では登録する文書の語だけでなく関連文書の語の重みも考慮する。

関連文書の語の重みを付与する事で、文書を作成したコンテキストを考慮に入れた特徴付けを実現する。登録する文書の特徴付けのアルゴリズムは以下の通りである。

<文書の特徴付けアルゴリズム>

- ①登録文書の各語の TF(Term Frequency) 値を算出し、ベクトルを生成する。
- ②登録する文書に対する関連文書を取得する。
- ③式(1)により登録文書のベクトルを更新する。登録文書の単語の TF 値に登録文書と関連文書の TF 値の差分を加算する(登録文書と関連文書のコサイン類似度 sim により加算する TF 値を重み付ける。)

$$\vec{W}_{regist}^i = \vec{W}_{regist} + \alpha \sum_{k=1}^N \text{sim}(\vec{W}_{regist}, \vec{W}_{relationk}) \cdot |\vec{W}_{regist} - \vec{W}_{relationk}| \quad \dots(1)$$

\vec{w}_{regist} : 登録文書の特徴ベクトル

$\vec{w}_{relationi}$: 関連文書の特徴ベクトル

α : 重み

本研究では、2つの類似文書間において、重要度の差が大きい単語を重要と考える。登録文書に関連文書との重要度の差分を加えることで、文書作成というプロセスにおいて重要であろう

語の重みを大きくすることを考えている。

4.3 検索クエリの生成

従来の検索クエリ生成の支援法としては、文書から TF 値が高い語や、その語に共起する語を抽出して提示する手法が多い。しかしこの手法では、TF 値が非常に大きい語や抽象的な語の影響を受けやすく、ユーザが容易に思い浮かべる事の出来る語を多く抽出してしまうという問題点がある。

そこで本研究では、検索ユーザが入力した文書と、それに類似した組織内の文書の TF 値を算出し、その差分を単語のスコアとして算出する。これにより、低頻出であってもその文書のコンテキストを表現できるような語を抽出し、ユーザの検索クエリ想起を促す事ができると考える。検索クエリ生成のアルゴリズムを以下に示す。

<検索クエリ生成アルゴリズム>

- ①キーワードの代わりに文書 (word 文書・PDF 文書) を入力する。
- ②入力した文書から TF 値の上位 N 語の単語を抽出し、ベクトル \vec{W}_{input} を生成する。
- ③組織内の全文書から各文書 TF 値の上位 N 個の単語を抽出し、ベクトルを生成する。
- ④組織内文書と入力文書の類似度を計算し、閾値を超えた文書を類似度の降順にソートする。
- ⑤閾値を超えた文書のベクトルを $\vec{W}_{similar}$ とし、入力文書の TF 値の差分を式(2)より計算し、その値が大きい単語からリスト表示する。

$$\Delta w = |\vec{W}_{input} - \vec{W}_{similar}| \quad (2)$$

5. 評価実験と考察

本研究の検索クエリ生成システムのプロトタイプを実装し、評価実験を行った。本システムによって生成された検索クエリを使って、Google scholar[2]における検索の適合率を計測したところ、高い適合率が得られた。

6. おわりに

本研究ではナレッジマネジメントの一手法として、組織内の文書を利用した検索クエリ生成システムを提案した。1つの文書に関して、その関連文書を利用してコンテキストを抽出する事で、個人の検索に有用な検索クエリの生成が可能になった。今後さらなる検索精度の向上を図るため、キーワード抽出法などの改良を考える必要がある。

参考文献

- [1]梅木秀雄他：“ナレッジワーク支援システム Trino の構想”.情報処理学会研究報告 2005-GN-55
- [2]Google Scholar <http://scholar.google.com/>