

カテゴリー分類にもとづく FAQ の自動生成

松崎 友洋[†] 富澤 真樹[†]

前橋工科大学工学部[†]

1. はじめに

本研究の目的は、Q&A 掲示板から FAQ を自動生成することである。本研究で対象とする Q&A 掲示板は、スレッドの先頭が質問文で、それに回答を投稿していくものである。また、ここで考えている FAQ は、類似文書検索手法に基づきスレッドをカテゴリー分類したものである。スレッドのカテゴリー分類の手順は、まず電子掲示板から各スレッドを単語に分け、統計情報を得る。その統計情報を元にキーワードとなる単語から類似文書検索手法に基づきカテゴリー分類する。本報告では、錦鯉の Q&A 掲示板を対象にカテゴリー分類をした結果を示す。

2. スレッドのカテゴリー分類

2.1 対象とする Q&A 掲示板

対象とする Q&A 掲示板は、コイパーク ([URL:<http://www.koipark.net/>](http://www.koipark.net/)) の『錦鯉 疑問 質問掲示板 (Q&A)』にある過去ログを選んだ。スレッドの数は 407 件である。また、全スレッドの投稿数は 2220 件 (2007 年 1 月現在) である。

スレッドの先頭の投稿が質問文であるものは全体の 9 割であったため、スレッドの先頭の投稿（以下スレッド質問文とする）は質問文であると仮定して、スレッド質問文についてカテゴリー分類した。

2.2 スレッド質問文からキーワードの取得

キーワードは FAQ 作成者が事前に手動でスレッド質問文から取得する。表 1 に取得したキーワードの一部を示す。キーワードには代表語と関連語があり、合わせて一つのキーワードとする。例えば表 1 の場合、水槽、金魚鉢、容器、FRP、池を合わせて一つのキーワードで「水槽」とみなす。代表語とは、金魚鉢や容器といった

Automatic generation of FAQ based on category classification
† Tomohiro MATSUZAKI, Masaki TOMISAWA

† Dept. of Engineering, Maebashi Institute of Technology.

表 1 キーワードの一部抜粋

キーワード	
代表語	関連語
水槽	金魚鉢、容器、FRP、池
病名	えら病、眠り病、風邪、カラムナリス
濾材	スポンジ、ウールマット、ドライボール、
酸素	エアーレイション、ぶくぶく、ぶくぶく
成長	でかい、発育

類似した意味の単語の集合を総称する単語を指しており、ここでは水槽となる。関連語は、代表語から総称される単語の集合であり、水槽に総称される単語の集合は金魚鉢や容器となる。関連語を用意しておくことにより、代表語だけでは拾いきれない単語も拾えるのでカテゴリー分類がしやすくなる。

今回取得したキーワードは 105 語（そのうち代表語は 23 語、関連語は 83 語）である。カテゴリー分類の仕方は、FAQ 作成者によって様々であり、キーワードを FAQ 作成者が用意することで FAQ 作成者の意図をカテゴリー分けに反映できると考えた。

2.3 TF・IDF による重み付け

キーワードの重み付けとして、TF・IDF[1]を用いる。TF・IDF は、キーワードの重み付け方法として情報検索によく用いられる。TF・IDF を用いると、スレッド質問文 d におけるキーワード t の重み $\text{weight}(d, t)$ は次のようにになる。

$$\text{weight}(d, t) = \text{TF}(d, t) \cdot \text{IDF}(t)$$

$\text{TF}(d, t)$ は、あるスレッド質問文 d における、キーワード t の頻度である。例えば、スレッド質問文 d が「錦鯉は水槽と池のどちらのほうが飼いやすいですか？」である場合、表 1 より水槽と池は同じキーワードとして扱うのでキーワード t が水槽である場合、 $\text{TF}(d, t) = 2$ となる。

$\text{IDF}(t)$ は、次のようになる。

$$\text{IDF}(t) = \log_{10} \frac{N}{\text{DF}(t)}$$

ここで N は全スレッド質問文の数、 $\text{DF}(t)$ はキー

ワード t が 1 回以上出現するスレッド質問文の数である。よって、この方法により 1 つのスレッド質問文に同じキーワードが多く出現すれば、TF・IDF の値は大きくなる。また、多くのスレッド質問文にキーワードが出現すれば値は小さくなる。

2.4 ベクトル空間法による類似スレッド質問文の取得

ベクトル空間法[2]とは、スレッド質問文中にどのキーワードがどの程度出現しているかをベクトルの形で表現する情報検索手法のひとつである。スレッド質問文ベクトル V_1, V_2 の類似度 $\text{sim}(V_1, V_2)$ は次の式になる。

$$\text{sim}(V_1, V_2) = \frac{\overrightarrow{V_1} \cdot \overrightarrow{V_2}}{\|\overrightarrow{V_1}\| \cdot \|\overrightarrow{V_2}\|}$$

ここで、スレッド質問文ベクトルとはキーワード数を次元として、各次元の値を TF・IDF から求めたものである。

3. 分類結果

荒らしや本来の趣旨とは関係のないスレッド質問文は遮断するため、スレッド質問文にキーワードが一つもないものは省いた。省かれたスレッド質問文は 407 個中 68 個であり、残り 339 個のスレッド質問文についてカテゴリ一分類を行った。カテゴリ一数を 9 とした場合のカテゴリ一分類結果を表 1 に示す。

評価方法は、あらかじめスレッド質問文すべてにカテゴリラベルを付加しておき、自動で分類した結果と比べた。カテゴリラベル数はカテゴリ一数と同じく 9 とした。

この分類ではまず、スレッド質問文の数をカテゴリ一数とみなして、設定したカテゴリ一数になるまで前述したベクトル空間法を用いてもつとも類似したスレッド質問文の組を見つけ、それをあらたなカテゴリーとみなすという作業を続ける。一つのカテゴリーにスレッド質問文が集中しすぎないように、全スレッド質問文数を設定したカテゴリ一数で割った値以下に制限した。

各カテゴリー内で最も多い割合のカテゴリラベルをそのカテゴリ自身のラベルとした場合の正解率は、平均 38%，最高値が No.4 の繁殖で 78% だった。

4. 考察、課題

各カテゴリーが、あるカテゴリラベルに集中

表 2 カテゴリー分類結果（カテゴリ一数 = 9）

ラベル No	病気	通過	水質	繁殖	鑑賞	体調	水槽	池	その他	合計
1	27	0	0	0	1	3	0	0	11	42
2	3	2	0	0	2	1	2	2	24	36
3	1	23	2	0	0	2	1	0	11	40
4	8	0	0	7	5	3	0	0	18	41
5	7	1	0	0	8	3	0	0	9	28
6	10	2	1	1	3	1	0	0	22	40
7	17	3	2	0	0	4	1	0	10	37
8	4	17	2	0	0	1	1	1	9	35
9	2	3	2	1	7	1	0	0	24	40
合計	79	51	9	9	26	19	5	3	136	339

することが理想であるが、分類結果では低い精度であったため、FAQ 作成者の意図をキーワードの取得のみで反映することは困難であることが分かった。カテゴリ一分類の正解率は、カテゴリにより差があったため、その精度は、キーワードの取り方により変わってくると考えられる。

今後は、分類精度を上げるために、FAQ 作成者があるスレッド質問文に対し誤ったカテゴリ一分類結果を正しいと判断したカテゴリに加えることで以後処理するスレッド質問文の分類精度を上げる仕組みを持ったフィードバック機能を検討する必要があると考えられる。

5. 参考文献

- [1] 関洋平, 原田賢一: tf/idf 重み付けに基づく動的文書生成, 情報処理学会研究報告デジタルドキュメント, Vol. 2001, No. 120, pp. 25-32 (2001).
- [2] 技術資料 単語意味属性を使用したベクトル空間法
http://unicorn.ike.tottori-u.ac.jp/murakami/paper/JOURNAL/NLP_2003_04/main/ (2008/1/8 アクセス).
- [3] 鈴木雅実, 村松茂樹, 松本一則, 井ノ上直己, 橋本和夫: 類似文書クラスタリング手法における新聞記事分類コード推定実験, 第 61 回全国大会, データマイニングと情報フィルタリング.