

# 記事群の冗長度を削減するための RSS ニュースリーダ

## Attaching Reducing Articles Redundancy Facility to RSS News Reader

中渡瀬 秀一 戸田 浩之 片岡 良治  
Hidekazu Nakawatase Hiroyuki Toda Ryoji Kataoka

### 1. まえがき

近年、インターネットにおけるニュース配信の形態として、RSS形式のデータによる提供が盛んになっている。このRSSにはWebサイトの更新情報として記事タイトル、そのURL、更新時刻などが含まれている。そしてこのRSSデータを閲覧するためのユーザアプリケーションがRSS(ニュース)リーダである。ユーザはRSSリーダに関心のあるサイトのRSSアドレスを登録しておく、RSSリーダは定期的にRSSの更新を監視し、サイトの新着記事をタイムリーに知ることができる。またRSSリーダに複数の

サイトのRSSを登録しておくことにより、ひとつのアプリケーション上で同時に複数サイトの更新や新着情報を容易に確認することができるのがその利点である。しかし複数ニュースサイトの記事をひとつのGUI上に集めると、異なる報道元から同じ事件に関するほぼ同一内容の記事が多数重複していることが分かる。事件の事実内容だけを確認したい場合にはこれらのうちどれかを読めば十分であるため冗長さが問題となっていた。

我々はこの問題を改善するために同一事件に関する記事を集約することができるようなRSSリーダシステムを試作した。

### 2. RSS ニュースリーダシステムの概要

本システムはWebサーバ部とWebクライアントからなるWeb上のアプリケーションである。

#### 2.1 RSS ニュースリーダシステムの構成

システムの全体構成を図1に示す。システムは以下の部分から構成される。

- RSS クローラ
- 記事データベース
- 記事集約制御部
- GUI 生成部
- Web サーバ
- Web クライアント (ブラウザ)

RSS クローラは登録されたRSSのURLから定期的にニュースサイトのRSSを取得して新着ニュース記事の有無(サイト更新)を監視する。もし新着記事が存在すればその情報(タイトル、配信時刻、記事URL)の記事データベースに格納する。

記事集約制御部では記事データベースに格納された記事を比較して同一事件に関する報道記事をグルーピングする。グルーピングの詳細については2.2節で説明する。

GUI生成部は複数のニュースサイトRSSから収集した記事タイトルを集約されたグループ単位で閲覧できるようなGUIを生成する。GUIは図2に示すように2ページから構成され、右側に集約された記事グループの一覧が

代表タイトル(グループ中の任意の記事タイトル)の時系列で表示され、タイトルをクリックすると元記事が左ペインに表示される。またフォルダアイコンをクリックするとグループ内に含まれる記事タイトル一覧と元記事へのリンクが表示される。

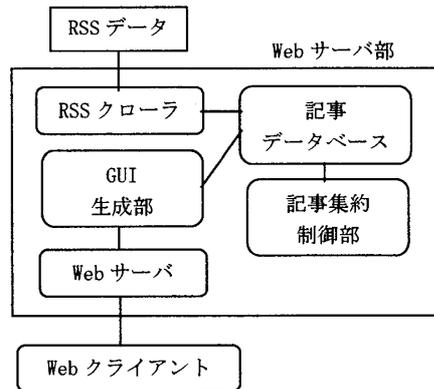


図1: RSS ニュースリーダシステム

集約ニュース 7 件	
<p><b>「操縦室に煙」緊急着陸 羽田、広島発の日航機 (共同通信)</b></p> <p>1. 「操縦室に煙」緊急着陸 羽田、広島発の日航機 (共同通信) 2005年03月22日 12時30分</p> <p>2. 広島発羽田行きJAL便の操縦席で臭臭、けが人はなし (YOMIURI ON-LINE) 2005年03月22日 12時30分</p> <p>3. &lt;日航機ラブル&gt;操縦室で「煙感知」羽田に緊急着陸 (毎日新聞) 2005年03月22日 11時45分</p> <p>4. 日航機、操縦席で煙感知 電子基盤がショートか (アサヒ・コム) 2005年03月22日 11時44分</p> <p>5. 広島発羽田行きJAL便の操縦席で臭臭、けが人はなし (読売新聞) 2005年03月22日 11時30分</p> <p>6. 「操縦室に煙」緊急着陸 羽田、広島発の日航機 (共同通信) 2005年03月22日 10時45分</p> <p>7. 「コックピットから煙」と連絡 = 日航機、緊急着陸を要請 (時事通信) 2005年03月22日 10時30分</p> <p>検索結果に依る</p>	<p>分</p> <p>①2: 非常用装置、操作し忘れ = JALまたラブル、処分へ国交省 (時事通信) (1) 2005年03月17日 12時30分</p> <p>④⑧: 操縦室に煙!緊急着陸 羽田、広島発の日航機 (共同通信) (1) 2005年03月22日 10時45分</p> <p>⑩18: 日航機、今度は戻り 福島空港 (Yahoo!ニュース) (1) 2005年03月22日 15時30分</p> <p>⑪1: &lt;ニート調査&gt; 02年推計で約85万人 内閣府 (毎日新聞) (1) 2005年03月22日 22時00分</p>

図2: Webクライアント概観

#### 2.2 同一事件記事集約方法

与えられた2記事が同一事件に関する報道記事であるかどうかを判断するために本システムが使用可能な情報はRSSから得られる記事タイトルと配信日時である。したがってタイトルの類似度が高く、双方の配信日が同じ2本の記事は同一事件の記事とみなすこととした。

タイトルの類似度を測るのには従来の代表的手法であるベクトル空間[2][3]に基づいた手法を用いた。これは文から特徴語を抽出して、それらの組による特徴語ベクトル

†日本電信電話株式会社 NTTサイバーソリューション研究所

の演算によって類似度を計算するものである。処理手順の概略を以下に説明する。

#### (1) 特徴語の抽出

特徴語を抽出するためにまず記事のタイトル文を形態素解析する。解析器には日本語形態素解析システム JTAG ( $\alpha$ -Tagger) [1] を用いた。これによってタイトル文を分かち書きして形態素に分解する。その結果得られた形態素の品詞属性が名詞もしくは未知語(ただし記号類は除く)であるものを特徴語として抽出する。

#### (2) 特徴語の正規化

表記が異なるが意味の等しい特徴語を表現の正規化によって統一する。ここでは漢数字とアラビア数字の表現を統一するなどの処理を行う。

#### (3) 特徴語ベクトルの類似度計算

抽出された特徴語の組によるベクトルがその記事を表現する特徴語ベクトルとなる。このときベクトル間の類似度をそれらベクトルが共有する特徴語の数(ベクトルの内積に相当)とする。この値が大きいほど類似度が高い。以下に計算例を示す。

(A) “ヤフーが JASRAC と契約締結、音楽無料配信サービスを拡大へ”

(B) “ヤフーと JASRAC が音楽ネット配信契約、610 万曲利用可能に”

文(A), (B)はある記事のタイトル文である。これを JTAG で形態素解析した結果を特徴語ベクトルに変換すると以下のようになる。

(A') (ヤフー, JASRAC, 契約, 締結, 音楽, 無料, 配信, サービス, 拡大)

(B') (ヤフー, JASRAC, 音楽, ネット, 配信, 契約, 610, 万, 曲, 利用)

この場合、(A')と(B')が共有する特徴語は

{ヤフー, JASRAC, 契約, 音楽, 配信}の5個であるのでこの場合の(A)と(B)の類似度は5となる。

#### (4) グルーピング

2本の記事を比較する際、類似度に閾値を設けて、それらの類似度がその閾値以上であるならば1つにグルーピングする。そのためにあらかじめ任意の2本の記事について類似度を計算しておく。これによってある記事と集約されるべき他の記事を決定することができる。この閾値が小さいほど集約の効果が大きい。しかし小さすぎると同一事件でない記事がグルーピングされることがあり、また大きすぎるとグルーピングされた記事であれば同一事件に関するものである可能性は高くなるが一方、同一事件にもかかわらずグルーピングできないものも増加する。

### 3. 使用結果

朝日新聞、日本経済新聞など大手全国紙やスポーツ誌、コンピュータ専門誌が運営するサイトなどから20サイトのRSSを選び本システムに登録してシステムの運用実験を行った。期間は2005年3月1日～3月20日の20日間である。その結果を表1に示す。実験の結果、1日当たり約2200記事を収集することができた。これを集約して同一事件記事のグループに集約すると平均約1250グループであった。この集約で1グループの記事1本に換算することによって約42%の記事数を削減したことになる。また集約グループのサイズとその度数との関係も調査した。そ

の結果、2本以上の記事が集約されてグループ化されたケースが1日平均300グループ以上、5本以上でも60グループ以上あることが確認された。この分布状況を図3に示す。今回の集約結果を見ると図2に見られるように同一事件の報道元による表現の差異にかかわらず集約が成功している例は多かった。しかし過度に集約されてグループのサイズが70を超えるような例も見られた。以下はそのような記事グループに含まれる3記事のタイトルである。

“松井稼は3打数1安打 大リーグオープン戦”

“田口、1安打と盗塁 大リーグオープン戦”

“松井秀、右翼に3点本塁打 大リーグオープン戦”

この3記事の内容は厳密には別の事実である。同様の例としては1日に類似した短いタイトルの記事が何本も配信される市況ニュースが挙げられる。

	値
新着記事数(総数) A	43474
新着記事数(1日平均)	2174
集約グループ数(総数) B	25020
集約グループ数(1日平均)	1251
B/A	0.575516

表1: 記事数など(2005年3月1日～20日)




図3: 集約グループサイズとその度数

### 4. まとめ

我々はニュース記事の冗長度を記事のグループ化によって削減できるRSSニュースリーダーの設計と構築を行い、その動作を確認した。その結果、RSS情報から新着記事を収集し同一事件記事を集約することができた。今後の課題として集約精度の評価、誤集約の改善などが挙げられる。また記事グループのサイズは事件の注目度に相当することからこの利用も検討したい。

### 参考文献

- [1] 日本語形態素解析システム  $\alpha$ -Tagger, [http://www.nihongo-solution.info/product/alpha\\_tagger.html](http://www.nihongo-solution.info/product/alpha_tagger.html)
- [2] 徳永健伸: “情報検索と言語処理”, 東京大学出版会(1999)
- [3] W. B. Frakes and R. Baeza-Yates Eds.: “Information Retrieval: Data Structures & Algorithms”, Prentice Hall(1992).