

## WWW 情報の重要度に基づく自動収集の試み\*

4Aa-9

松岡 淳子 鈴木 悦子 来住 伸子 小川 貴英†

津田塾大学 数学科‡

## 1 はじめに

WWW(World Wide Web)とは、インターネットの広域情報検索システムの一つであり、WWWの情報量は急速に増加している。そのため、全ての情報を把握することや、必要な情報を探ることが困難になってきた。

WWWで必要な情報を検索するには、検索ツールが必要である。最近の検索ツールは、ロボットで情報を自動収集し、キーワード検索を行なっている。既存のロボットでは、大規模な計算機環境・高速ネットワークのもとでは、網羅的に情報を収集している。

しかしながら、限られた環境下で情報を収集する場合は、情報の選択を行わなければならない。ここでは、情報の重要度・関心度を動的に計算しながら、情報の重要度を自動的に評価し、重要度の高い情報を効率的に収集することに試みた。

## 2 重要度・関心度

HTML(Hypertext Markup Language)ドキュメントAの中に、ドキュメントBのURL(Uniform Resource Location)の記述があるとき、AがBを参照していると言う。また、Bを参照しているドキュメントの個数をBの被参照回数と言い、Aが参照するドキュメントの個数をAの参照回数と言う。

重要度とは公共性や関心の高さであり、被参照回数の多いものを重要度が高いとする。しかし、全体からの被参照回数を求めることは、莫大な数のドキュメントから相互参照の統計をとることなので、不可能である。そこで、参照回数の多いもの関心度が高いとし、その関心度を用いることによって、被参照回数を推定し、重要度を定義することにした。

関心度とは、ドキュメントに書かれた参照タグの個数をもとに計算する。関心度は、

- 同一 Server 内のドキュメントへの参照回数
- 外部 Server 上のドキュメントへの参照回数

\*Automatic retrieval of WWW resources based on importance estimation

†Junko Matsuoka, Etsuko Suzuki, Nobuko Kishi, Takahide Ogawa

‡Tsuda College, Department of Mathematics

を用いて計算する。

参照元ドキュメント*i*の関心度  $f(i)$  を、

$$f(i) = \log_2(a * (\text{同一 Server 内のドキュメントへの参照回数}) + b * (\text{外部 Server 内のドキュメントへの参照回数}) + 1) \\ (0 \leq a, b, a, b \text{ は実数})$$

とする。

重要度は、参照元ドキュメントの関心度に重み付をしたものの和である。被参照ドキュメント*j*の重要度  $X(j)$  を、

$$X(j) = \sum_i g_{ij} * f(i)$$

(*i* は既に内容入手したドキュメントの全て)

$$g_{ij} = \begin{cases} 0 & (i \text{ から } j \text{ への参照が無い場合}) \\ c & (i \text{ から } j \text{ への参照が有り、} \\ & i \text{ と } j \text{ が同一サーバの場合}) \\ d & (i \text{ から } j \text{ への参照が有り、} \\ & i \text{ と } j \text{ が異なるサーバの場合}) \end{cases} \\ (0 \leq c, d, c, d \text{ は実数})$$

とする。

## 3 アルゴリズム

ドキュメント収集の順番は、以下のアルゴリズムで行なう。

1. サーバAのドキュメントA1を入手(GET)する。
2. ドキュメントA1の関心度を計算する。
3. ドキュメントA1から参照しているドキュメントの重要度を計算する。
4. まだGETされていないドキュメントのうち、最も重要度の高いドキュメントをGETする。
5. 新しくGETしたドキュメントについて、2~4を繰り返す。

例として、 $c=1, d=2$ の場合を図1,2に示す。図1の状態から、最も重要度の高いdocument-B1をGETすると図2の状態になる。

Step1 GET document-A1




図 1: document-A1 が、3 まで終了した状態

Step2 GET document-B1




図 2: document-B1 が、3 まで終了した状態

#### 4 実装

収集する対象は、HTML ドキュメントのみとした。プロトコルは、HTTP (Hypertext Transfer Protocol) を用いた。具体的には、以下の 1 または 2 の Request を用いた。

1. HEAD *URI* HTTP/1.0  
GET *URI* HTTP/1.0
2. GET *URI* HTTP/1.0  
If-Modified-Since: *HTTP-date*

#### 5 評価

1つの研究機関内の Server 数 4, ドキュメント数 1000 を対象に実験を行なった。同一 Server への参照を重視し、 $a = 0.2$ ,  $b = 0.1$ ,  $c = 1$ ,  $d = 0.5$  と設定し、図 3 の結果を得た。太線は重要度にもとづく収集を行なった場合で、細線は幅優先の収集を行なった場合である。重要度にもとづく収集を用いると、前半は被参照回数の多いドキュメントを GET する確率が高いが、後半は確率が低くなっている。しかし、全体からの被参照回数が多いにもかかわらず、GET された時点が遅いドキュメントは、ある特定のユーザが自分のドキュメントの間で相互参照を行ない被参照回数




図 3: GET 回数と、被参照回数の多いドキュメントの GET 率

$x$  軸 Request GET を行なった回数  
 $y$  軸 被参照回数の多いドキュメントを GET した回数  
 / 被参照回数の多いドキュメントの個数

が多くなったものであり、公共性・他人からの関心を考えると重要性が高いとは言えない。よって、本方式では、公共性や他人からの関心の高いドキュメントは早い時点で GET し、全体からの被参照回数は多くても公共性・他人からの関心の低いドキュメントは遅い時点で GET すると言える。

情報収集空間を狭めた場合には、 $0 \leq b < a$ ,  $0 \leq d < c$  と設定し、同一 Server への重みを重くすることによって、効率的な情報収集を行なうことが出来た。現在は、情報収集空間を広げて、 $0 \leq a < b$ ,  $0 \leq c < d$  と設定し、実験中である。

#### 6 まとめと今後の展望

以上の評価から、重要度の高い情報を優先的に収集することが、WWW 情報の効率的な収集に有効であると言える。

今後は、重要度・関心度の評価式の見直しと、目的に見あった定数の決定を行ない、実用性を高めていく。

#### 参考文献

- [1] T. Berners-Lee, R. Fielding, and H. Frystyk  
 "Hypertext Transfer Protocol-HTTP/1.0",  
<http://www.ics.uci.edu/pub/ietf/http/draft-ietf-http-v10-spec-04.txt>
- [2] "Guidelines for Robot Writers"  
<http://info.webcrawler.com/mak/projects/robots/guidelines.html>