

Web ページ間の関連性の伝播を用いた Web コミュニティ抽出手法

飯村 卓也[†] 平手 勇宇^{††} 山名 早人^{†††††}

[†]早稲田大学大学院基幹理工学研究科 〒169-8555 東京都新宿区大久保 3-4-1

^{††}早稲田大学メディアネットワークセンター 〒169-8050 東京都新宿区戸塚町 1-104

^{†††}早稲田大学理工学術院 〒169-8555 東京都新宿区大久保 3-4-1

^{††††}国立情報学研究所 〒101-8430 東京都千代田区一ツ橋 2-1-2

E-mail: {iimura, hirate, yamana}@yama.info.waseda.ac.jp

あらまし ユーザが求める情報を効率よく獲得するために、数多くの Web コミュニティ抽出手法が提案されている。これまでの研究では、関連の薄い Web ページを Web コミュニティから排除することを目的として、ある Web ページを Web コミュニティに含めるかどうかの条件を厳しくすることにより、適合率を上げることに成功している。しかし、本来 Web コミュニティに含まれるべき Web ページが含まれなくなることがあるため再現率が低下している。そこで本稿では、Web コミュニティ中の Web ページと多くリンクしている Web ページを新たなメンバに加えていくことにより、適合率を低下させることなく、再現率を向上させることができる Web コミュニティ抽出手法を提案する。比較実験の結果、提案手法は既存手法と同等の適合率を保ちつつ再現率を向上させることができることが確認できた。

キーワード リンク解析、Web コミュニティ

Web Community Extraction Method with Web Pages' Relevance Fowarding

Takuya IIMURA[†] Yu HIRATE^{††} and Hayato YAMANA^{†††††}

[†]Graduate School of Fundamental Science and Engineering, Waseda University 3-4-1 Okubo, Shinjuku-ku, Tokyo, 169-8555, Japan

^{††}Media Network Center, Waseda University 1-104 Totsuka-cho, Shinjuku-ku, Tokyo, 169-8050, Japan

^{†††}Science and Engineering, Waseda University 3-4-1 Okubo, Shinjuku-ku, Tokyo, 169-8555, Japan

^{††††}National Institute of Informatics 2-1-2 Hitotsubashi, Chiyoda-ku, Tokyo 101-8430 Japan

E-mail: {iimura, hirate, yamana}@yama.info.waseda.ac.jp

Abstract To find information from a large collection of Web-pages, several methods for extracting Web communities are proposed. In the past studies, it succeeds in improving precision score by making a rule whether or not to include a certain Web page into a Web community strictly. However, recall score might worsen because the Web page that should be included in the Web community is not included. In this paper, we propose the Web community extraction method that can improve recall score without decreasing precision score. The method adds Web pages that have many links from/to the Web pages in a same Web community. Experiments shows that the proposal method can improve recall score keeping precision score equal with existing methods.

Key words Link Structure Analysis, Web Community

1.はじめに

近年、ユーザが求める情報を効率よく獲得するために、Web コミュニティを発見する研究が活発に行われている。Web コミュニティとは意味的に関連のある Web ページの集合のことであり、任意の Web ページをシードページとして抽出された Web コミュニティの利用法として以下のような利用法が挙げられる。

- (1) ユーザが求める情報への効率的なナビゲーション や新たな知識発見[1].
- (2) Web 上での話題の抽出や、ある話題に関する Web 上での発展過程の分析[2].
- (3) スパムサイトの発見[3].

これまでに提案されている Web コミュニティ抽出手法には Web ページのドキュメントの類似度を計算する手法と Web ページ間のリンク構造を利用した手法がある。本稿ではリンク構造を利用した Web コミュニティ抽出手法について述べる。

リンク構造を利用した手法として、Web ページ間のリンク構造を有向グラフとみなしたグラフ(以後、Web グラフ)から密な 2 部グラフ (DBG: Dense Bipartite

Graph)を形成する部分グラフを抽出する手法が挙げられる。DBG を用いた手法は、「多数の共通する Fun によってリンクされている Center には何らかの関連がある」ということを前提としている。しかし、単に DBG を Web グラフから抽出するだけではトピックを共有しない Web ページも Web コミュニティに含まれてしまうことがある。そこで、DBG を用いた手法の既存研究[10][11][12]では、ある Web ページを Web コミュニティに含めるかどうかを決定する際の条件(以後、抽出条件)を厳しくすることにより適合率の向上を目指している。ここで、本研究では、沈らの研究[12]と同様にディレクトリサービスを用いた手法により適合率の比較を行っており、「ディレクトリサービスにおいて、Web コミュニティ中の各 Web ページが他の Web ページと同一のディレクトリに登録されている割合」を適合率としている。適合率については 4 節で詳しく述べる。

斎田らは、トピックを共有しない Web ページを判別する手法として PlusDBG を提案している[10][11]。PlusDBG はある Web ページと Web コミュニティとの関連の強さを示す尺度として「距離量」を定義し、Web

コミュニティとの距離量が一定以上 Web ページを排除することにより適合率の向上を図った。

沈らは、ある Web ページと Web コミュニティとの関連の強さを示す尺度として「連結度」を定義している[12]。連結度とは、Web コミュニティ中の任意の 2 つの Center に対して定義される値であり、その 2 つの Center に同時にリンクしている Fun の数を指す。ここで、同時にリンクしている Fun を連結子という。沈らは、Web コミュニティ中の任意の 2 つの Center が N 以上の連結度を持つような 2 部グラフを抽出することにより、齊田らの手法よりも高い適合率を有する Web コミュニティを抽出することに成功している。以下に Center 集合を T, Fun 集合を S として、沈らの手法の手順を示す。

- (1) シードページ t を選び、 $T = \{t\}$, $S = \emptyset$ とする。
- (2) T に含まれる Web ページにリンクしている Web ページ集合を S' とする。
- (3) S' がリンクしている Web ページ集合から T に含まれる Web ページを除いたものを T' とする。
- (4) $t' \in T'$ において、 t' が T に含まれる全ての Web ページと N 以上の連結度を持つかを判定。
 - (a) N 以上の連結度を持つならば、 $T = \{t'\} \cup T$, $S \cup \{\text{連結子}\}$ とし、(2)へ。
 - (b) N 以上の連結度を持たないならば、他の t' を選び(4)へ。
- (5) $|S| > p, |T| > q$ ならば Web コミュニティとして Web グラフから削除する。
- (6) ウェブグラフにノードが残っていれば(1)へ。

ここで、Step. (5)の p は各 Fun が持つエッジの数の閾値であり、 q は各 Center が持つエッジの数の閾値である。DBG の構造については 2 節で詳しく述べる。

沈らは適合率に関する評価実験としてディレクトリサービスを用いた評価実験と TF-IDF を用いた評価実験を行い、齊田らの手法によって抽出される Web コミュニティよりも高い適合率を有する Web コミュニティを抽出できることを示した。しかし、沈らの研究では適合率は向上しているが再現率は低下していると言える。表 1 に沈らの研究[12]における再現率の比較実験の結果を示す。

表 1. Web コミュニティ数、平均ページ数、抽出された Web ページ数(文献[12]より引用)

抽出手法	Web コミュニティ数	平均ページ数	抽出された Web ページ数
PlusDBG(1.2)	7,527	122	923,100
PlusDBG(1.0)	8,077	114	922,053
PlusDBG(0.8)	22,902	38	865,945
沈らの手法(N=2)	50,065	14	648,626
沈らの手法(N=3)	45,027	13	568,939
沈らの手法(N=4)	37,234	13	501,329

表 1 の結果は文献[12]より引用したものであり、沈らが独自に収集したデータセットを用いて行った実験で示された値をトレースしたものである。ここで、文献[12]では Web コミュニティとして抽出された Web ページを Web グラフから取り除いているため、同一の Web ページが複数の Web コミュニティに含まれること

はない。表 1 中の各手法における括弧内の値は、PlusDBG では距離量を、沈らの手法では連結度を示している。

表 1 より、沈らの手法による Web コミュニティの平均サイズは齊田らの手法による Web コミュニティの平均サイズよりも小さく、あるシードページに対して沈らの手法は齊田らの手法よりも低い再現率を有する Web コミュニティを抽出していると考えられる。また、抽出された Web ページ数を比較しても齊田らの手法の方が沈らの手法よりも多くの Web ページを抽出していることがわかる。Web コミュニティに含まれる Web ページ数(以後、コミュニティサイズ)が大きくなるごとに、Web コミュニティとトピックを共有しない Web ページが Web コミュニティに含まれる可能性が高くなることを考えると、適合率だけであれば抽出ルールを厳しくすることによって向上させることができると考えられる。しかし、単に抽出ルールを厳しくするというアプローチでは、本来 Web コミュニティの含まれるべき Web ページもトピックを共有しない Web ページとともに Web コミュニティから排除されてしまうと考えられる。

そこで、本研究では、Web コミュニティの適合率を下げるこなく再現率を向上させることを目的として、新たな Web コミュニティ抽出手法を提案する。

以後、2 節では関連研究について述べる。3 節では提案する Web コミュニティ抽出手法について説明する。4 節では提案手法と沈らの手法の比較実験と評価について述べる。5 節でまとめを行う。

2. 関連研究

リンク構造を利用した代表的な Web コミュニティ抽出手法として、Web グラフから MaxFlow アルゴリズムを用いて最小カットを抽出する手法[4][5]と、2 部グラフを用いる手法[6][7][8][9][10][11][12]が挙げられる。本節では、これらの研究について説明する。

MaxFlow アルゴリズムを用いた手法は Flake ら[4][5]によって提案された。Flake らは Web コミュニティを「同じ Web コミュニティに含まれる Web ページ間のリンク数が、同じ Web コミュニティに含まれない Web ページへのリンク数よりも多い Web ページの集合」と定義している。そして、MaxFlow アルゴリズムを用いて Web グラフからシードページを含む最小カットを求めるこによって、Flake らが定義しているような Web コミュニティを抽出する手法を提案している。

2 部グラフを用いる手法には 2 部グラフに HITS を適応する手法と 2 部グラフを形成する部分グラフを抽出する手法がある。

2 部グラフに HITS を適応する手法は 豊田[6]によって提案された。豊田はシードページを含む 2 部グラフに HITS を適応し、Authority スコアが上位の Web ページ集合を Web コミュニティとした。

2 部グラフを形成する部分グラフ抽出する手法は Kumer ら[7]によって提案された。Kumer らは Web グラフに含まれる完全 2 部グラフ(CBG: Complete Bipartite Graph)を形成する部分グラフを Web コミュニティと定義している。Kumer らが提案した trawling により、Web グラフに含まれる全ての完全 2 部グラフ抽出することができる。

Kumer の研究以降, Web グラフから 2 部グラフを構成する部分グラフを見つけることにより Web コミュニティを発見する手法が数多く提案され, 現在までに様々な改良が行われてきた[8][9][10][11][12].

Reddy ら[8][9]は, Kumer らの手法の抽出条件を緩め, DBG を Web コミュニティとして抽出している. ここで, DBG とは以下のような条件を満たした有向グラフを指す.

- (1) ノードを各エッジ始点 (以後, Fun) と終点 (以後, Center) の 2 つのグループに分けたとき, 同グループ中のノード間にエッジが存在しない.
- (2) 各 Fun が自然数 p 以上のエッジを持ち, かつ, 各 Center が自然数 q 以上のエッジを持つ.

Reddy らの手法により, Kumer らの手法よりもコミュニティサイズの大きな Web コミュニティを抽出することができるようになった.

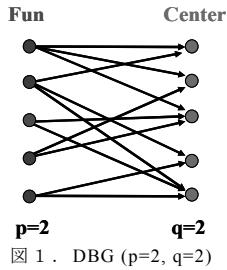


図 1. DBG ($p=2, q=2$)

斎田ら[10][11]は PlusDBG を提案している. PlusDBG では, まず, 距離量を用いて Web コミュニティとトピックを共有しない Web ページを判別し, Web コミュニティとの距離量が一定以内にある Web ページのみを, Web コミュニティの候補とする. そして, 候補となつた Web ページ集合から Reddy らの手法を用いて DBG を抽出する.

沈ら[12]は, Center に含まれる Web ページ間の関連の強さを示す連結度を定義し, Center 中の任意の 2 つの Web ページが一定以上の連結度を持つ Web ページ集合を Web コミュニティとして抽出する手法を提案した. 沈らは Fun によって強く結ばれた Center のみを Web コミュニティとして抽出することによって, 斎田らの手法によって抽出される Web コミュニティよりも高い適合率を有する Web コミュニティを抽出できることを示した.

沈らの手法では, 抽出条件を厳しくすることにより適合率を向上させることに成功している. しかし, 再現率の低下を考慮していないため, 本来 Web コミュニティに含まれるべき Web ページを Web コミュニティから除外してしまっている可能性がある. 実際に, 沈らの手法によって抽出される Web コミュニティは, 既存手法によって抽出される Web コミュニティと比べて高い適合率を有しているが, コミュニティサイズを比較してみると既存手法のコミュニティサイズよりも小さくなっている. Web コミュニティの精度を決定する尺度として再現率も重要な意味を持つことを考えると, 適合率を低下させることなく再現率を向上させる必要があると考えられる. 従って, 本研究では沈らの手法の適合率を保ちつつ再現率を向上できるような Web コミュニティ抽出手法を提案する.

3. 提案手法

本節では, 提案手法が抽出する Web コミュニティの定義と抽出アルゴリズムについて述べる.

3.1 定義

提案手法は, Web グラフを無向グラフとして扱い, 以下のようなアプローチで Web コミュニティを抽出する. まず, シードページと直接リンクで繋がれている Web ページを Web コミュニティに加える. 以後, Web コミュニティのメンバ (以後, コミュニティメンバ) である Web ページから 1 ホップで到達できる Web ページ集合のうち, L 個以上のコミュニティメンバと繋がれている Web ページを再帰的にコミュニティメンバに加えていくことにより, Web コミュニティを抽出する. ここで, L は最低リンク数と呼ばれる閾値であり, 抽出過程で増加するコミュニティサイズ $|C|$ と, 定数 M によって以下のように定義される.

$$L = \frac{|C|}{M} + 1 \quad (1)$$

定義式(1)中の M は Web コミュニティの適合率と再現率のバランスを決定する定数である. コミュニティサイズ $|C|$ が小さい場合は最低リンク数 L も小さな値になるため, 新規ページがコミュニティメンバになりやすく, 逆に, コミュニティサイズ $|C|$ の増加にともなって最低リンク数 L も増加するため, 新規ページがコミュニティメンバになりづくなる. 定数 M を変化させて比較実験を行った結果, M の値が小さいほど再現率が低く, 適合率が高い Web コミュニティが抽出されることが確認できている. 4 節で述べる比較実験では, $M=30$ と $M=50$ における実験結果を用いる.

最低リンク数を設けた理由は, コミュニティメンバの増加にともない以下に挙げるような弊害が起こるからである.

- (1) Web コミュニティ中にコミュニティメンバとトピックを共有しない Web ページが含まれる可能性が高くなる.
- (2) コミュニティメンバが持つリンクの総数がコミュニティサイズに比例して増える.

コミュニティサイズに比例して抽出条件を厳しくすることによって, コミュニティメンバとトピックを共有しない Web ページを Web コミュニティから排除することができ, さらに, コミュニティサイズの爆発を防げる.

提案手法は「互いに関連を持つ Web ページ集合中の複数の Web ページとリンクで繋がれている Web ページは Web ページ集合と深い関連を持つ」という仮定に基づいている. ここで, リンクの向きを考慮しないのは, リンクで繋がれている Web ページ同士はリンクの向きに関わらず何らかの関連を持っていると考えたからである. つまり, 提案手法は「コミュニティメンバとどの程度リンクで繋がれているか」ということのみを抽出条件としている.

図 2 は提案手法により抽出されるグラフ構造を描画した図ある. 図 2 を有向グラフで描画したのは, 2 部グラフを用いた手法によって抽出される Web コミュニティのグラフ構造との違いを説明するためである.

図 2 中の点線で囲まれた部分グラフは沈ら手法に

よって抽出させる Web コミュニティのグラフ構造を示している。提案手法によって抽出される Web コミュニティは、シードページが持つリンク数が最低リンク数の定義式(1)中の M 未満である場合は、図 2 のように、沈らの手法によって抽出されるコミュニティメンバを 100 パーセント包含する。

また、2 部グラフを抽出する手法では抽出できなかった Web ページもコミュニティメンバに含めることができる。例えば、図 2 中の Web ページ r は 2 部グラフを形成しないため 2 部グラフを用いた既存手法ではコミュニティメンバになりえなかった。しかし、Web ページ r もコミュニティメンバとトピックを共有している可能性があり、提案手法では、沈らの手法で抽出される Web ページ以外に Web ページ r のような Web ページを抽出することにより、再現率の向上を図っている。

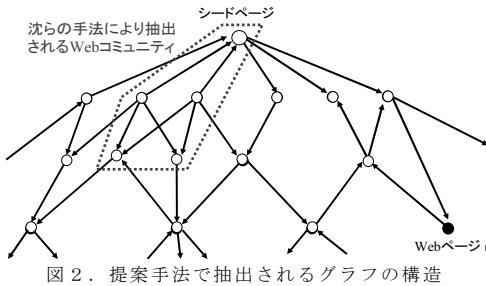


図 2. 提案手法で抽出されるグラフの構造

さらに、2 部グラフを構成するような部分グラフは密な部分グラフであるため、2 部グラフを用いた既存手法では、シードページが持つリンク数（以後、次数）が小さい場合は Web コミュニティを抽出することができなかつた。一方提案手法では、次数の小さい Web ページがシードページとして与えられた場合でも Web コミュニティを抽出することが可能であり、この点の改善も図っている。

3.2 アルゴリズム

提案手法では、リンクデータより無向の Web グラフを作成し、Web グラフ中の任意のノードをシードノードとして、再帰的にコミュニティメンバを増やしていくことにより Web コミュニティを抽出する。以下に手順を示す。

- (1) シードノード t を選ぶ。
- (2) t から 1 ホップで到達できるノード集合を T_1 とし Web コミュニティ C を $C = t \cup T_1$ とする。
- (3) 最低リンク数 L を $L = |C|/M+1$ とする。
- (4) C 中の各 c から 1 ホップで到達できるノード集合のうち、L 個以上のコミュニティメンバと繋がれているノード集合を C_{new} とし、 $C = C \cup C_{\text{new}}$ とする。
- (5) $|C_{\text{new}}| > 0$ であれば(3)へ。
- (6) C を Web コミュニティとして出力する。

Step. (3)において、最低リンク数 L を設けたのは、コミュニティサイズが大きくなるごとに関連の低い Web ページが Web コミュニティに含まれる可能性が高くなるためである。コミュニティメンバ数 $|C|$ の増加に比例して抽出条件を厳しくすることにより、コミュニティ

メンバとのリンクが少ない Web ページを排除することができる。次節の比較実験において最低リンク数の定義式(1)中の M の値を 30, 50 と変化させた場合の Web コミュニティを示す。

4. 比較実験と評価

本節では、提案手法と沈らの手法との比較実験と評価を行う。

4.1 データセット

データセットとして NTCIR-4 WEB task test collection [13]を用いた。なお、実験では、ページ単位ではなくサイト単位で実験を行った。ここで、サイトとは Web ページをドメイン名ごとにまとめた Web ページの集合を指し、ある 2 つのサイト間に複数のリンクがある場合はそれらのリンクを 1 つのリンクとして扱う。サイト単位で実験を行った理由を以下に示す。

- (1) ページよりもホストの方が扱うトピックが明確なため[14][15]。
- (2) Yahoo!ディレクトリを用いた比較実験において、トップディレクトリから深さが 3 までのディレクトリしか用いておらず、細かい分類での評価を行わないため。（比較実験に関する詳細は次項を参照）

本研究では、前処理として以下のようなサイトを削除した。まず、既存研究[7][8][9][10][11][12]に倣い、有名なサイトを削除する。本研究では有名なサイトとして、インリンク数がデータ全体の上位約 1 % に相当する 200 以上のインリンクを有するサイトを削除した。Kumer らは文献[7]にて、非常に多くのインリンクを有する Web ページはリンク元の Web ページ集合が扱うトピックの種類が多くなると述べている。さらに、非常に多くのインリンクを有する Web ページを Web グラフから削除しないで Web コミュニティ抽出を行うと適切な Web コミュニティが抽出されないと述べている。1 節で述べた Web コミュニティの使用法を想定した場合においても、有名なサイトを Web コミュニティのメンバとして抽出する利点は少ないと考えられる。以上のようなことを考慮し、本研究では有名なサイトの削除を行った。次に、リンク先が複数のトピックを扱うサイトとして、リンク集を削除した。本研究ではリンク集として、アウトリンク数がデータ全体の上位約 1 % に相当する 200 以上のアウトリンクを有するサイトを削除した。リンク集についても、有名なサイトと同様の理由から、リンク集を削除しないで Web コミュニティ抽出を行うと適切な Web コミュニティが抽出されないと考えられる。

以上のような前処理を行った結果、サイト数は約 26.7 万、リンク数は約 494 万となった。

4.2 実験結果と評価

本項では、Web コミュニティの適合率の評価として Yahoo!ディレクトリ[16]を用いた比較を行い、再現率

の評価として Web コミュニティ数と Web コミュニティの平均サイト数を用いた比較を行った。

4.2.1 適合率の評価

適合率の比較を行うために Yahoo!ディレクトリを用いた評価を行った。本研究では、沈らの研究と同様に抽出された Web コミュニティ内の各サイトが Yahoo!の同一のディレクトリに登録されている割合を調べることより評価を行う。ここで、全サイト中 Yahoo!ディレクトリに登録されているサイト数は 91,197 個であった。以下に、評価手法の詳細を示す。

まず、サイト a, b に対して $score(a,b)$ を以下のように定義する。

$$score(a,b)=1, \text{ サイト } a, b \text{ が同一のディレクトリに登録されている} \quad (2)$$

$$score(a,b)=0, \text{ サイト } a, b \text{ が同一のディレクトリに登録されていない} \quad (3)$$

ここで同一のディレクトリとは、トップディレクトリから深さ D までのディレクトリが共通していることを指す。例えば、D=2 の場合、Yahoo!ディレクトリの「トップ/趣味とスポーツ/ゲーム/オンラインゲーム」に登録されているサイトと、「トップ/趣味とスポーツ/ゲーム/パソコンゲーム」に登録されているサイトは、トップディレクトリからの深さが 2 である「ゲーム」までが共通しているので $score$ は 1 となる。

次に $score$ を用いて、Web コミュニティ C の適合率 $P(C)$ を以下のように定義する。

- (1) Web コミュニティ C 中のサイトで Yahoo!ディレクトリに登録されているサイトの集合を YC とした場合、 YC に含まれるサイト数 $|YC|$ が 3 未満の場合は評価を行わない。
- (2) YC 中のサイト r に対して、 r のスコア $Pscore(r)$ を以下のように定義する。

$$Pscore(r) = \frac{\sum_{x \in (YC-r)} score(r,x)}{|YC-r|} \quad (4)$$

- (3) Web コミュニティ C の適合率 $P(C)$ を以下のように定義する。

$$P(C) = \frac{\sum_{r \in YC} Pscore(r)}{|YC|} \quad (5)$$

図 3 に $D=2$ 、図 4 に $D=3$ の場合の適合率を示す。図 3 と図 4 の横軸は $P(C)$ の値の閾値であり、縦軸はその閾値以上の $P(C)$ を有する Web コミュニティの割合である。また、図 3 と図 4 中の各手法における括弧内の値は、沈らの手法では連結度を、提案手法では最低リンク数の定義式(1)中の定数 M を示している。

図 3、図 4 より、高い適合率を有する Web コミュニティの割合は提案手法よりも沈らの手法の方が高い結果となった。しかし、両手法の適合率に大きな差はない、低い適合率を有する Web コミュニティも含めた比較では、沈らの手法よりも提案手法の方が高い適合率を有する Web コミュニティの割合が高い。これは、沈

らの手法では、高い適合率を有する Web コミュニティを高い割合で抽出できる一方で、低い適合率を有する Web コミュニティも高い割合で抽出してしまっているためだと考えられる。一方、提案手法では、抽出される Web コミュニティの適合率の高低差が沈らの手法に比べて小さく、低い適合率を有する Web コミュニティの割合が低いと言える。

$N=2$ と比べて $N=3$ の方が、提案手法よりも沈らの手法が高い割合で高い適合率を有する Web コミュニティを抽出している理由は、 $N=3$ の場合のディレクトリが $N=2$ の場合のディレクトリよりも狭いトピックで分類されているためだと考えられる。このことから、沈らの手法は細かい分類での Web コミュニティ抽出に適しており、提案手法は広い分類での Web コミュニティ抽出に適していると言える。

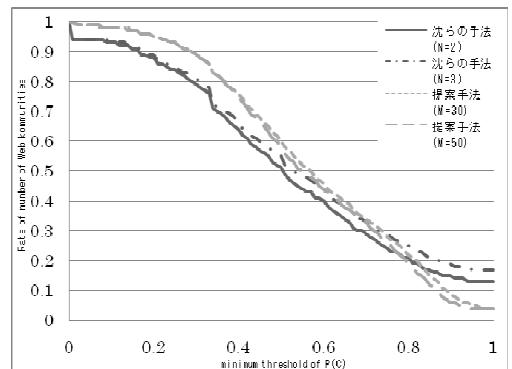


図 3. 適合率ごとの Web コミュニティの割合($D=2$)

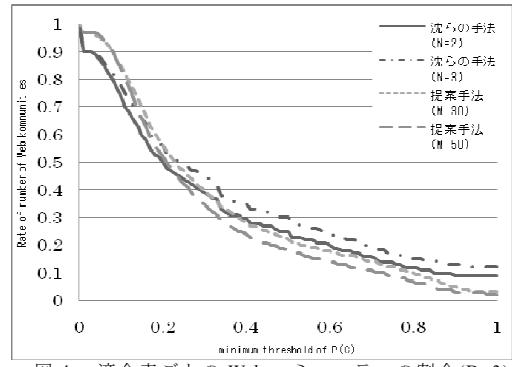


図 4. 適合率ごとの Web コミュニティの割合($D=3$)

Yahoo!ディレクトリを用いた比較実験の結果、高い適合率を有する Web コミュニティの割合は沈らの手法の方が高いものの、提案手法でも沈らの手法と同等の適合率を有する Web コミュニティを抽出できることが確認できた。

4.2.2 再現率の評価

表 2 に、Yahoo!ディレクトリに登録されている 91,197 個のサイトを用いた比較実験における、提案手

法と沈らの手法の Web コミュニティ数、平均サイト数、コミュニティサイズの合計を示す。ここで、コミュニティサイズの合計の値は Web コミュニティ数と平均サイト数を乗算した値であり、複数の Web コミュニティに属するサイトは属する Web コミュニティの数だけ重複して数えられている。表 2 中の各手法における括弧内の値は、沈らの手法では連結度を、提案手法では最低リンク数の定義式(1)中の定数 M を示している。

表 2 に示した 1 つの Web コミュニティ当たりの平均サイト数を比較すると、提案手法の方が沈らの手法よりも大きく、大きな Web コミュニティが抽出できていることがわかる。これは、提案手法が沈らの手法では抽出することができなかつた DBG を構成しないサイトを Web コミュニティのメンバに加えているためである。適合率の比較実験により、提案手法によって抽出される DBG を構成しないサイトを含んだ Web コミュニティの適合率は沈らの手法によって抽出される Web コミュニティの適合率と同等であることが確認できた。これにより、DBG を構成しないサイトにもシードサイトとトピックを共有するサイトが存在することが示された。そして、提案手法を用いることにより、シードサイトとトピックを共有し、かつ、DBG を構成しないサイト集合を抽出できることが示された。以上のことから、提案手法を用いることにより、沈らの手法では Web コミュニティから排除されていたシードサイトとトピックを共有するサイトもコミュニティメンバとして抽出できることが確認できた。

表 2. Web コミュニティ数、平均サイト数、コミュニティサイズの合計

抽出手法	Web コミュニティ数	平均サイト数	コミュニティサイズの合計
沈らの手法(N=2)	47,423	91	4,315,493
沈らの手法(N=3)	34,060	66	2,247,960
提案手法(M=30)	63,859	171	10,919,889
提案手法(M=50)	63,893	292	18,656,756

次に、表 2 に示すように Web コミュニティ数でも、提案手法の方が沈らの手法に比較し多くのコミュニティ抽出に成功している。これは、提案手法は次数の少ないサイトがシードサイトとして与えられた場合でも、シードサイトとトピック共有するサイト集合を Web コミュニティとして抽出できることを示している。これにより、提案手法を用いることで沈らの手法よりも多くのサイトをシードサイトとして Web コミュニティ抽出を行うことができることが確認できた。

5. おわりに

本論文では、Web コミュニティの適合率を低下させることなく再現率を向上させることを目的とし、新たな Web コミュニティ抽出手法の提案を行った。比較実験の結果、提案手法は既存手法と同等の適合率を保ちつつ再現率を向上させることができることが確認できた。具体的には以下のようなことが再現率向上の要因となっている。

- (1) 提案手法では沈らの手法よりも多くのサイトをシードサイトにすることでき、それによって多くの Web コミュニティを抽出できる。

- (2) 提案手法では沈らの手法では抽出することができなかつたシードサイトとトピックを共有するサイトもコミュニティメンバとして抽出できる。

今後は、高い適合率を有する Web コミュニティの割合を増やすための改善を行うとともに、提案手法により抽出される Web コミュニティの特徴を活かした Web コミュニティ利用法を提案していきたい。

謝辞

本研究の一部は、文部科学省リーディングプロジェクト「e-Society」及び情報爆発プロジェクトとして実施した。

文献

- [1] 高野明彦、西岡真吾、今一修、岩山真、丹羽芳樹、久光徹、藤尾正和、徳永健伸、奥村学、望月源、野本忠志. 汎用連想計算エンジンの開発と大規模文書分析への応用. 第 19 回 IPA 技術発表会, 2000.
- [2] 谷口智哉、松尾豊、石塚満. Blog コミュニティの抽出と分析. 人工知能学会 SIG-SWO, 2004.
- [3] 小野拓史、豊田正史、喜連川優. リンク解析を用いたウェブ上のスパム発見手法に関する一考察. DEWS, 2006.
- [4] G.W.Flake, S.Lawrence, and C.L. Giles. Efficient identification of Web communities. Proc. of 6th ACM SIGKDD KDD2000, 2000.
- [5] G.W.Flake, S.Lawrence, C.L. Giles, and F.Coezee. Self-organization of the Web and identification of communities. IEEE Computer, 2002.
- [6] 豊田正史. WWW における関連コミュニティ群の発見. DBS, 2000.
- [7] S. Ravi Kumar, P. Raghavan, S. Rajagopalan and A. Tomkins. Trawling the Web for Emerging Cyber-Communities. WWW8 / Computer Networks, 1999.
- [8] P.Krishna Reddy and Masaru Kitsuregawa. An Approach to Relate the Web Communities through Bipartite Graphs. Proceeding of the Second International Conference on Web Information Systems Engineering, IEEE Computer, 2001.
- [9] P.Krishna Reddy and Masaru Kitsuregawa. Building a Communityhierarchy for the Web Based on Bipartite Graphs. DEWS, 2002.
- [10] 斎田直幸、山名早人. リンク構造解析による不要 Web コミュニティの判別. DEWS, 2006.
- [11] Naoyuki Saida, Akira Umezawa and Hayato Yamana. Plus(DBG: Web Community Extraction Scheme Improving Both Precision and Pseudo-Recall. both Precision and Pseudo-Recall. In Proc. of 7th Asia-Pacific Web Conference, 2005.
- [12] 沈垣甫、田浦健次朗、近山隆. ウェブコミュニティ抽出アルゴリズムの改良. DEWS, 2007.
- [13] NTCIR Project, <http://research.nii.ac.jp/ntcir/>
- [14] Loren Terveen, Will Hill and Brian Amento. Constructing, organizing, and visualizing collections of topically related Web resources. ACM Transactions on Computer-Human Interaction, 1999.
- [15] Krishna Bharat, Bay-Wei Chang, Monika Henzinger and Matthias Ruhl. Who links to whom: Mining linkage between web sites. IEEE International Conference on Data Mining, 2001.
- [16] Yahoo! カテゴリ, <http://dir.yahoo.co.jp/>