

潜在ディリクレ配分法を用いた話題伝播ボットの開発

Developing a Twitter bot delivering interesting topics using Latent Dirichlet Allocation

立命館大学 須藤健也, 古林邦彬, 長坂翔吾, 谷口忠大
 K. Sudo, K. Kobayashi, S. Nagasaka and T. Taniguchi
 Ritsumeikan University

Abstract In this paper, we develop an autonomous agent which encourages people communicate with each other in a social network, called “Twitter”. To achieve this, we propose a novel recommendation technique which does not only use bag of words included in a tweet which is a target document in Twitter, but also human relationships, i.e., followings, followers and mention. The method uses a topic model latent Dirichlet allocation (LDA) to extract latent topics of human relation and tweets. We show experimental results and it shows that the proposed method has better performance than simple tweet recommendation technique which does not use human relation information.

1 はじめに

我々はソーシャルネットワーキングサービス (SNS) を用いてインターネット上で不特定多数の人々とコミュニケーションをすることができる。SNS は友達関係のような人間関係をインターネット上で保持し、それに基づいた、多数のユーザによる個人の行動や体験談などの情報発信やユーザ同士での情報交換を可能にするサービスである。コミュニケーションネットワークである “Twitter” は現在、登録ユーザが増加し続けており、大量の情報が溢れている [1]。

“Twitter” 上においてユーザが主に出来る操作を Table.1 に示す。“Twitter” ではユーザは他のユーザをフォローすることにより、フォローした他のユーザのツイートがリアルタイムに、そのユーザのタイムライン (以下 TL) に流れるようになる。フォロー人数が多いユーザほど多くのツイートが TL 上を流れてくるために、過剰に多くのユーザをフォローすることは、自身の TL における有益なツイートの比率を低下させることにもなってしまう。よって、よりユーザにとって有益な情報を推薦、フィルタリングする技術が求められている。

本研究ではこのコミュニケーションメディアである “Twitter” においてユーザ間のインタラクションを活発化させるための情報推薦について検討する。“Twitter” は一般的なニュースサイトやブログと異なり文書を生産する側 (ツイートをする側) も、それを推薦される側 (ツイートを見る側) も同等にツイートを行える立場にある。ゆえに、この SNS 上でインタラクションを活発化させる推薦は、旧来の推薦と多少異なる問題を含むことになる。いくらユーザの興味に近いツイートを推薦しても、推薦されたユーザがそれに対してリアクションを取

Table. 1: Twitter 上でユーザが可能な操作

機能	意味
ツイート	自分が見たことや感じたことを “Twitter” 上で投稿した文。
フォロー	そのユーザの投稿を見るために必要なアクション。
フォロワー	自分をフォローしているユーザ。
タイムライン	自分がフォローしているユーザのツイートがホーム画面に表示され、古いツイートから下に流れていく。
リプライ	ツイートへの返信を行うこと。
メンション	ユーザ ID を含んだツイートをする。リプライはメンションの一種。
リツイート	他のユーザがしたツイートを、自分のフォロワーのタイムラインにも表示させること。
お気に入り登録	気に入った投稿を星マーク () を付けてお気に入りに登録することができる。

らなければインタラクションは活発にならない。そこで本稿では、ユーザの興味があるツイートを推薦するという旧来の見方ではなく、ユーザがそのツイートに対してリプライしたくなるというツイートの推薦を考える。このようなツイート推薦を行う話題伝播ボット (人工エージェント) を開発することでユーザ間のインタラクションを増す事を目指す。

2 研究背景とアプローチ

2.1 先行研究

一般的に情報推薦はユーザや特定の情報を特徴化した内容に基づくフィルタリング方式と、情報に対する他のユーザの評価に基づく協調フィルタリング方式の2種類に大きく分けられるが [2], そのような手法による分類とは異なり, タスクによる分類もある. 近年, 出会い系サイトでのマッチングを取り扱った RECON[3] などの相互推薦に関する研究が注目されている.

RECON が取り扱った出会い系サイトの相互推薦においては, A さんを B さんに紹介した際には, B さんが A さんを気に入るのみならず, 推薦された B さんも A さんを気に入る必要がある. RECON ではこの双方の評価関数を共に取り込むことにより, 相互推薦の性能を高めた. 本稿で取り扱うタスクにおいてもこれと類似した点がある. ユーザの興味の近いツイートをユーザに推薦するだけでは不足であり, これに対してユーザが実際にリプライを行うかどうかについての評価も考慮に入れる必要がある.

“Twitter” 上のユーザに対して他ユーザを推薦することでコミュニケーション支援を目指す研究がある. 古賀らは潜在トピック推定手法である潜在ディリクレ配分法 (Latent Dirichlet Allocation, LDA) を用いてユーザの人間関係やリプライ情報などからフォロー関係に潜む潜在的なトピックを推定することで, ユーザ同にフォローする候補ユーザを推薦する研究を行った [4]. 具体的には LDA を用いて各ユーザをトピックの多項分布で表現し, そのトピックのカルバックライブラー情報量によりユーザ間の類似性を定義した. この人間関係に着目したユーザ推薦は良好な結果を得た. ユーザがインタラクションしたいと考えるユーザの特定には人間関係, つまりソーシャルネットワークのリンク構造を情報源として利用することが有用であると示唆される.

本研究ではツイートの文書情報からユーザの興味に合っているかを評価にに入れるだけでなく, そのツイートに対してユーザがリプライを返すかどうかについての評価も推薦の指標に組み込むことにより, インタラクションを活発化させる話題伝播ボットの開発を目指す.

2.2 研究のアプローチ

本研究の目的は Twitter 上のインタラクションを活発化させる話題伝播ボットを作成することである. ボットとは人ではなくプログラムがツイートを投稿する, 機械による自動発言システムのことである. 本研究ではあるユーザのツイートを, そのツイートに対してリプライを

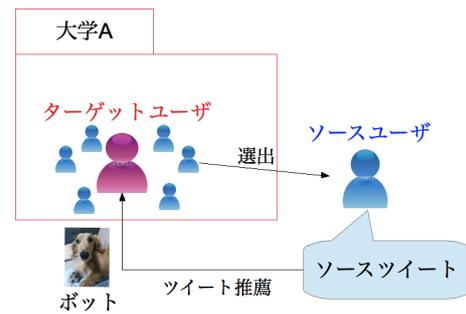


Fig. 1: ソースユーザとターゲットユーザの関係

行うであろうユーザに推薦することを目的とする. ここでその被推薦ツイートをつぶやいたユーザをソースユーザと呼ぶことにする.

本稿で提案するツイート推薦手法のアプローチを説明する. Fig. 1 に本稿におけるソースユーザとターゲットユーザの関係を示す. ターゲットユーザはツイート推薦を受けるユーザを表し, ソースユーザは推薦されるツイートをつぶやいたユーザを表す. 例えば, ターゲットユーザが “大学 A” に所属し, “研究” に関連するツイートを行うユーザであるとする. ボットはターゲットユーザと人間関係が近いユーザをソースユーザとして選出し, ソースツイートからターゲットユーザの話題に近いと考えられるツイートを選出する. しかし, 話題の近さだけに基づいてツイートを推薦したのでは, 必ずしもターゲットユーザがソースユーザにリプライするとは考えにくい. 日頃まったくインタラクションの無い, 若しくは知らないユーザのツイートを推薦されても, ターゲットユーザはリプライしにくいだろう. リプライは通常, 近いコミュニティの人間に対して行う傾向がある. そこで, 古賀らの研究 [4] を参考にし, フォローやメンション関係から推定される人間関係を考慮に入れるとターゲットユーザが高い確率でリプライすると期待されるツイートを推薦することを目指す.

3 推薦アルゴリズムの提案

3.1 トピックについて

本稿では LDA を用いて, ツイートに含まれる語から話題に関するトピックを, フォローやメンション関係から人間関係についてのトピックを推定する. LDA においてはトピックは単語, もしくは, ユーザ ID の多項分布として表現される. 文書中の単語が確率的にそれぞれのトピックから出力されると仮定しており, これを逆に推定することで文章の話題や人間関係からコミュニティを推定することができる. 詳細は Griffiths らの [5] を参

照されたい．トピックの説明で用いる変数を Table . 2 に示す．

本稿では，ユーザのツイート群に対して LDA を適用することで，ツイートの話題に関するトピックを抽出し，また，ユーザのフォローやメンション関係から Twitter 上の人間関係に関するトピックを抽出する．これら両方を用いることでリプライしやすいツイートを推薦することを旨とする．

3.1.1 話題トピック

話題は我々の日常会話や新聞記事などに存在し，文書中のキーワードもしくは文脈から推定できる．例えば“阪神，サヨナラ勝ち”という文書があるとすれば，この文書の話題は“阪神”と“サヨナラ勝ち”から“野球”であると推定することが出来るだろう．これは話題を直接指し示す“野球”が文書中出现しなくてもその話題に関連のある単語から推定できることを示している．このことから単語は潜在的な話題を持ち，同じ話題を持つ単語は同じ文書中出现しやすい性質があると考えられる．この話題をトピックと呼ぶ．本稿では LDA を用いて推定した同じ話題を持つと考えられる名詞の多項分布を話題トピックと定義する．

名詞のみを用いる理由は以下である．例えば“投手”，“野手”，“盗塁”といった単語には“野球”という話題を潜在的に持つと考えられ，同じ話題トピックに含まれやすい．一方“こと”や“もの”といった名詞ではあるが単語単体から話題を推定しにくい単語は LDA 推定時に除外している．詳しいデータセットについては 3.2 節のコーパスの構築方法で説明する．

3.1.2 人間関係トピック

本稿では LDA を用いて推定した“Twitter”上で同じ繋がりのあると考えられる人間関係の多項分布を人間関係トピックと定義する．例えばユーザ A，ユーザ B，ユーザ C をフォローしているユーザがいるときに，別のユーザもこれら三人のユーザをフォローしているとすると，これらのユーザは同じ人間関係のグループに属すると考えられる．本稿ではこのようなフォロー関係にメンション関係を加えた人間関係から推定されるトピックを人間関係トピックと呼ぶ．

3.1.3 トピック推定から得られる分布

トピックの推定結果から各ターゲットユーザの文書 d_i 毎におけるトピック分布 $P(z|\theta^{d_i})$ が得られる．これは文書 d_i がどのトピックを含んでいるかを表す．また，ト

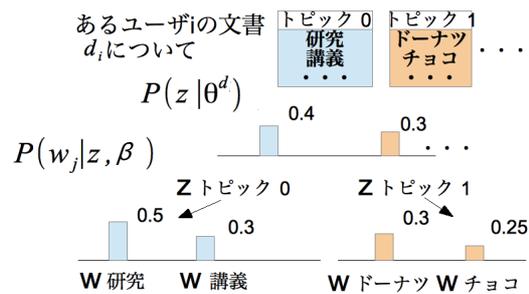


Fig. 2: 話題トピックについてのトピック出力分布と単語出力分布の概略図

Table. 2: トピック推定の変数とその意味

パラメータ	意味
d_i	話題コーパス中のユーザ i の文書
b_i	人間関係コーパスのユーザ i の文書
i	ユーザ (文書のインデックス)
z	トピック
T	トピック数
w	単語
j	単語のインデックス

ピック z に含まれている単語 w_j の分布 $P(w_j|z, \phi^z)$ が得られる．

Fig . 2 に話題トピックの例を示す．ユーザ i に関してトピック 0 には $P(z|\theta^{d_i}) = 0.4$ ，トピック 1 には $P(z|\theta^{d_i}) = 0.3$ が割り振られている．これはユーザ i が，4 割の確率でトピック 0 に相当する多項分布に基づいて単語を出力する傾向があることを示している．各トピック毎に単語分布 $P(w_j|z, \beta)$ が含まれている．

3.2 コーパスの構築方法

話題トピック推定と人間関係トピック推定に用いる文書をそれぞれ話題コーパス，人間関係コーパスとする．それぞれのコーパスは文書集合，文書は単語集合で構成されている．

話題コーパスはコーパスに含める 1 ユーザについて 1 つの文書とする．その文章は，そのユーザの最新ツイート 200 件で構成する．LDA での推定結果の精度を上げるため，代名詞を除く名詞のみをツイートから抽出し，bag-of-words 形式にしている．

人間関係コーパスについてもコーパスに含める 1 ユーザについて 1 文書とする．その文章は，そのユーザの最新ツイート 200 件に含まれるメンション先ユーザ ID とフレンド ID (ユーザがフォローしているユーザ ID) で構

Table. 3: 推薦アルゴリズムの変数とその意味

変数	意味
β	各話題トピックでの単語分布
α	各人間関係トピックでのユーザ ID 分布
s_{word}	話題トピックに基づく推薦スコア
s_{human}	人間関係トピックに基づく推薦スコア
$s_{recommend}$	提案手法の推薦スコア
θ^{d_i}	d_i での話題トピックの生成確率
ϕ^{b_i}	b_i での人間トピックの生成確率
e	ソースツイート
e	ソースユーザ
u	ターゲットユーザ

成する．

3.3 ツイート推薦方法

ソースツイートの中からターゲットユーザへ推薦するツイートを決定する方法について説明する．以下で述べる説明に含まれる各変数を Table. 3 に示す．

話題トピックに基づくスコアではターゲットユーザのいつもの発言と推薦するソースツイートの類似性を測るために，ターゲットユーザ u がソースツイート e を生成する確率を計算する．ターゲットユーザ u がソースツイート e と同じツイートを生成する確率 (s_{word}) は話題トピック t^w を用いて

$$s_{word} = p(e|\beta, \theta^{d_u, w}) \quad (1)$$

$$= \sum_{t^w} p(e, t^w|\beta, \theta^{d_u, w}) \quad (2)$$

と求められる．このスコアが高くなるほどターゲットユーザがソースツイートに近い話題のツイートを生成する傾向があると考えられる．

人間関係トピックに基づくスコアの計算ではターゲットユーザがソースユーザのフォローとメンション関係を生成する確率を計算することで，人間関係の類似性を調べる．ターゲットユーザ u がソースユーザ i をフォローもしくはそのユーザを対象としたメンションをしている確率 (s_{human}) は人間関係トピック t^h を用いて

$$s_{human} = p(b_i|\alpha, \theta^{b_u, h}) \quad (3)$$

$$= \sum_{t^h} p(b_i, t^h|\alpha, \theta^{b_u, h}) \quad (4)$$

と求められる．このスコアが高くなるほどターゲットユーザとソースユーザが同じコミュニティに属することになり，ソースユーザに対してリプライをしやすくなると考えられる．

さらに s_{word} と s_{human} を組み合わせることで，話題と人間関係の両方を考慮した推薦ができると考える．

$$s_{recommend} = p(b_i, e|\theta^{b_u}, \phi^{d_u}) \quad (5)$$

$$\approx s_{word} \times s_{human} \quad (6)$$

この式はターゲットユーザ u がソースツイート e を生成する確率とターゲットユーザ u がソースユーザ i をフォローしている確率の同時確率であり，話題と人間関係を考慮した推薦評価基準になっている．また，人間関係と話題の独立性を仮定している．この $s_{recommend}$ を用いることで，よりユーザがリプライしやすいツイートの推薦を行うことができると期待される．

3.4 ボットの動作アルゴリズム

本研究で開発したボットのアルゴリズムを説明する．

1. ソースツイートとユーザ ID を取得する．
2. ソースツイートを形態素解析 [6] する．ツイートを単語単位に分割し，話題コーパスに含まれている単語とマッチングできるようにする．
3. LDA を用いて話題トピックと人間関係トピックを推定する．
4. ターゲットユーザごとにソースツイートの単語から s_{word} ，ソースユーザのユーザ ID から s_{human} を計算する．さらにこれら 2 つのスコアを掛け合わせて $s_{recommend}$ を計算する．

4 実験

4.1 実験目的

本実験では提案手法が話題トピックのみを用いたツイート推薦よりもユーザのリプライを受けやすいことを，被験者実験を通して示す．実験のために，ソースユーザとターゲットユーザとなる被験者は固定し，被験者に回答してもらった推薦の良し悪しと，提案した指標の相関について検討する．

4.2 実験条件

ターゲットユーザとなる被験者を 5 名，ソースユーザを 6 名設定する．ソースユーザの内訳は，被験者全員がフォローしている知人 2 名 (ソースユーザ 1,2)¹，著名人 2 名 (3,4)，被験者全員がフォローしていないユー

¹これらのソースユーザと被験者群は現実世界でも同一のコミュニティに含まれるため，実験結果の解釈においてはその影響も考慮にいれられるべきである．

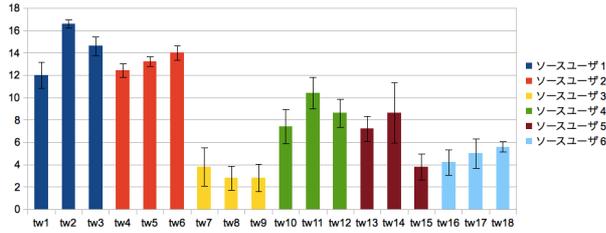


Fig 3: 全被験者の各ソースツイートへの評価平均

ザ 2 名 (5,6) で構成されている。6 名のツイートから名詞が含まれていないツイートと、ツイートの中にリプライが含まれているものを除外したそれぞれ 3 個ずつのツイートを抜粋し、合計 18 個のツイートを被験者に提示する。提示する内容は、ツイート内容とそのツイートのソースユーザ名で 1 セットとなっている。被験者にはソースユーザについて、“Twitter” のプロフィールとツイートからそのソースユーザについて知ってもらう。被験者は 18 個のツイートに対して総当りで二肢強制選択法により解答を行う。二肢の選択基準は、“どちらのツイートに対してリプライしたいか”としている。リプライしたいと選ばれた場合は 1、選ばれなかった場合は 0 とし、被験者ごとに各ツイートの合計点を求め、合計点の高い順に順位を決定する。これを評価基準とする²。

次に本手法の有効性を示すため、18 ツイートに対して“*sword* のみ”、“*srecommend*” の各手法による順位を決定する。この結果と評価基準を比べ、その実際の被験者群が示した順位との類似度を調べる。

LDA でのトピック推定で用いたユーザの総文書数は 900、話題トピック数は 20、人間関係トピック数は 10、イテレーションは 50 回とした。

4.3 実験結果

Fig. 3 に全被験者の各ソースツイートへの評価平均を示す。これは被験者の回答結果から二肢強制選択法の一回の選択を 1 点として合計点を求め、その全ユーザでの平均を求めたものである。各ツイートの平均的な評価を表している。図の横軸の *tw* は各ソースツイートを指す。

被験者群の性質を示すための参考情報程度に Fig. 4 に各ターゲットユーザ毎に *s_{human}* を計算し、それを昇順に並び替えたものの全ターゲットユーザに対する順位

²実際にツイート単体では本当に「リプライしたい」とおもわれるツイートを選別することは難しく、二肢強制選択法を用いない場合、比較しうる順位を得ることが困難であったため本実験では二肢強制選択法を用いている。

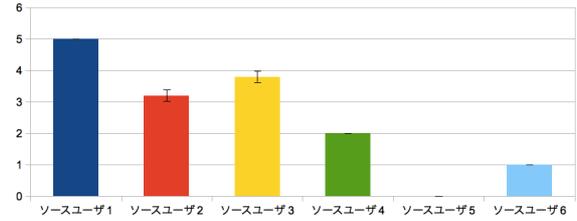


Fig 4: 被験者全員の *s_{human}* の順位

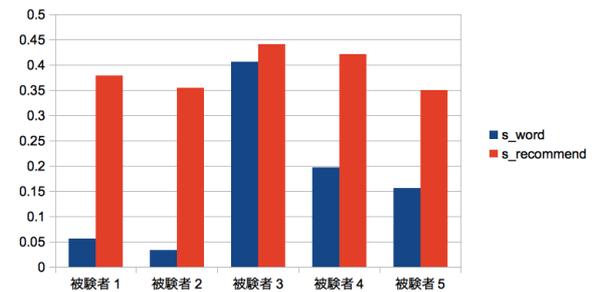


Fig 5: 評価基準と各推薦方法の相関

平均を示す。この Fig. 4 からソースユーザ 1 とソースユーザ 2 の得点が高く、被験者と人間関係が近いソースユーザを推定できていることがわかる。著名人であるソースユーザ 3 の得点がソースユーザ 2 よりも高いのは、ソースユーザ 2 とソースユーザ 3 のフォローしている人数の差が影響していると考えられる。ソースユーザ 2 がフォローしている人数は 480 人に対してソースユーザ 3 がフォローしている人数は 28 人である。さらにソースユーザ 2 は被験者が含まれやすい人間関係トピック以外のユーザを多くフォローしていることから、ソースユーザ 3 の得点がソースユーザ 2 の得点を上回ったと考えられる。この点の修正は今後の課題であろう。

次に順位相関係数を用いて被験者毎の各ソースツイートへの評価点（二肢強制選択法の得点合計）と各推薦指標によって得られる順位の種類度を求めた。Fig. 5 に各被験者の評価基準の順位と *s_{word}* で計算した順位、各被験者の評価基準の順位と *s_{recommend}* で計算した順位の間を示す。*s_{word}* は被験者 3 以外は相関が低いが *s_{recommend}* では全ての被験者の相関が *s_{word}* と比較して高くなっている。これから、*s_{recommend}* は *s_{word}* よりも評価基準に近く、ユーザがリプライしたいと思うツイートの推薦に繋がると考えられる。

次に被験者の中でも *s_{word}* と *s_{recommend}* で相関の差が大きい被験者 2 に着目した。Fig. 6 に被験者 2 の評価

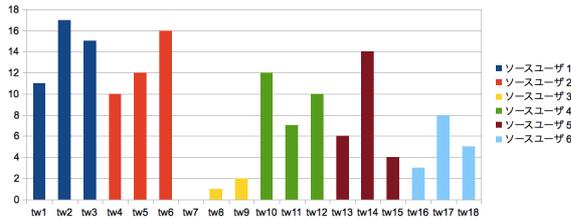


Fig 6: 被験者 2 の評価の合計値

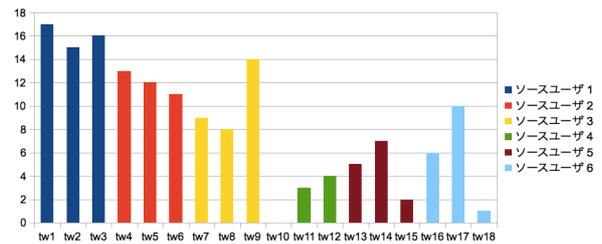


Fig 8: 被験者 2 の $s_{recommend}$ の順位

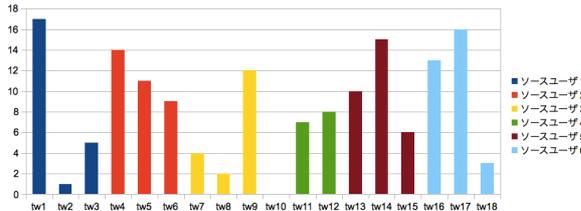


Fig 7: 被験者 2 の s_{word} の順位

基準, Fig. 7 に被験者 2 の s_{word} の順位, Fig. 8 に被験者 2 の $s_{recommend}$ の順位を示す. s_{human} の順位に関しては Fig. 4 とほとんど同じであったため省略する³. tw2 と tw3 に着目すると評価基準となる被験者実験結果では順位が最も高く, s_{word} より $s_{recommend}$ が s_{human} の影響を受けて, 順位が高くなっており評価基準と近い結果となった. また tw16~tw18 についても s_{word} より $s_{recommend}$ が評価基準に近い結果となった. これらから s_{word} の相関が低く, $s_{recommend}$ の相関が高くなること がわかる.

s_{word} から $s_{recommend}$ にかけて tw1~tw9 は全体的に順位が上昇し, tw10~tw18 は下降していることから話題に人間関係を付加することにより, 話題のみの推薦と比べてユーザのリプライしたいツイートを推薦できると考えられる.

5 まとめ

本研究では話題トピックと人間関係トピックを考慮したツイート推薦手法を提案した. ユーザの興味のある話題に関するツイートを抽出するため話題トピックを LDA により推定した. また, ユーザによるリアクションのしやすさを推薦に反映するために話題のみではなくツイートしたユーザの人間関係を付加することで, ユーザがリプライしやすいツイートを推薦する手法を提案した.

³しかし, これは s_{human} による補正が殆どターゲットユーザに依存したものになっていないことを意味しており, 本実験では結局は

今回の実験では話題のみに基づく推薦, 話題と人間関係を考慮した推薦の 2 つの推薦結果を比較した. その結果, 話題に人間関係を付加することで, ユーザがどちらかというリプライしたいと思うツイートをよりうまく推定できることがわかった. しかし, フォローしているユーザの数が少ないユーザと多いユーザを両方含めることで結果に大きな影響が出ることから, フォロー人数が大きく異なるユーザ同士でも人間関係の影響を少なくする方法を考えることが必要である. また, 本研究では具体的な話題伝播ボットの実装, サービス運用には至らなかった, その点についても今後進めて行きたい.

参考文献

- [1] 榊剛史, 松尾豊. ソーシャルブックマークとしての twitter リスト機能の応用. In *The 24th Annual Conference of the Japanese Society for Artificial Intelligence*, 第 2010 巻, 2010.
- [2] 土方嘉徳. 情報推薦・情報フィルタリングのためのユーザプロファイリング技術. *人工知能学会論文誌*, Vol. 19, No. 3, pp. 365–372, 2004.
- [3] Luiz Pizzato, Tomek Rej, Thomas Chung, Irena Koprińska, and Judy Kay. Recon: a reciprocal recommender for online dating. In *Proceedings of the fourth ACM conference on Recommender systems*, pp. 207–214. ACM, 2010.
- [4] Hiroyuki Koga and Tadahiro Taniguchi. Developing a user recommendation engine on twitter using estimated latent topics. In *14th International Conference on Human-Computer Interaction (Human-Computer Interaction, Part I, HCII 2011, LNCS 6761)*, pp. 461–470, 2011.
- [5] T.L. Griffiths and M. Steyvers. Finding scientific topics. *Proceedings of the National Academy of Sciences of the United States of America*, Vol. 101, No. Suppl 1, pp. 5228–5235, 2004.
- [6] 工藤拓. Mecab: Yet another part-of-speech and morphological analyzer. <http://mecab.sourceforge.net/>, 2005.