

SNS を利用した TV 番組の共感的視聴を支援するインタフェースの研究

代表研究者

牛尼剛聡

九州大学 大学院芸術工学研究院 准教授

1 研究の目的

近年, Twitter や Facebook に代表されるソーシャルネットワーキングサービス (SNS) が爆発的に普及した。SNS は様々な目的で利用されており, 多くの新しい活用方法が生まれている。近年注目されている活用方法の一つにソーシャルビューイングがある。ソーシャルビューイングでは, TV 番組を視聴しながら, 視聴者は SNS 上で番組に関するコミュニケーションを行う。ソーシャルビューイングは SNS を活用したパブリックビューイングと考えることができる。パブリックビューイングとは, 注目度が高いスポーツの試合等で, 遠隔地の競技場等に設置された大画面で実況中継を, 多くの観客で視聴するものである。パブリックビューイングの参加者は, 実況中継を視聴するだけでなく, 大勢の他者その体験を共有することを重要視している。同様に, ソーシャルビューイングのユーザは, SNS から新しい価値のある情報を取得することよりも, 気が合う他者と「共感」しながら楽しく TV 番組視聴体験を共有することを目的としていると考えられる。

本研究では「共感」という観点から, ユーザにとって快適なソーシャルビューイングを実現する SNS インタフェースを実現するために必要な要素技術の開発を目的とする。具体的には以下の研究課題に取り組んだ。

1. ユーザの共感的視聴を行うための, 基本的なフレームワークを設計する。具体的には, ユーザのフィードバックを利用してユーザの嗜好を推定して, ユーザが共感できる可能性が高いユーザ群を推定する手法を開発する。
2. ユーザが「共感」できる投稿を取得したとしても, 候補の数が多く, それらの全てを表示することは現実的でない。そこで, 単純に個々の投稿を提示するのではなく, 投稿の全体的な傾向を分析し, 類似した投稿を集約して, 場の雰囲気伝えるための表現手法を開発する。
3. TV 番組の共感的視聴を行うためには, シーンの特徴を適切にモデル化し, ユーザがどのようなシーンに反応したのかに基づいて, ユーザの嗜好を推定することが必要である。そのために, ソーシャルビューイングに基づいた大量の投稿に基づいて, トピックモデルを利用してシーン特徴のモデル化する手法を開発する。
4. 共感に基づいた TV 視聴を行うためには, ユーザが共感できる可能性が高い TV 番組を選択することが重要である。そのために, ユーザが他のユーザと共感する可能性が高い TV 番組を推薦する手法を開発する。

2 ソーシャルビューイングにおける共感ユーザ推定手法

2-1 アプローチ

本研究では, TV ドラマを対象に, 気が合う他者と「共感」に基づいたソーシャルビューイングを「共感ビューイング」と呼ぶ。共感ビューイングを行うために, 我々は以下の手順でツイートのフィルタリングを行うことでユーザに提示する。

1. 対象とする TV ドラマのタイトルをハッシュタグとして有するツイートの投稿者の中から, 「気が合う」投稿者同士のクラスタを構成する。
2. ユーザの視聴を妨げない一定の頻度で, クラスタ化されたユーザが発したツイートをユーザに提示する。ユーザに提示されるツイートを発するクラスタは, 順序付けられる。どのクラスタが選ばれる確率は, そのクラスタがユーザとどの程度「気が合う」と推定されるかによって異なる。なお, ユーザとクラスタがどの程度「気が合う」と推定されるかは, ユーザのフィードバックによって決定する。
3. システムから提示されたツイートに対して, ユーザが共感する場合は, 「だよね」ボタンを押すことによって, ユーザと「気が合う」可能性が高いことをシステムにフィードバックする。このフィードバックに基づいて, システムは, ユーザに提示するツイートを選ぶクラスタを最適化する。

2-2 提案手法

2-2-1 ユーザのクラスタリング

共感ビューイングでは、ユーザの趣味嗜好にあったユーザからのツイートをリアルタイムに提示する。この目的のために、同一のハッシュタグが含まれるツイートを投稿するユーザを、それらのユーザの趣味嗜好に基づいてクラスタリングする。このクラスタリングのためには、ツイートを投稿するユーザの特徴をモデル化する必要がある。従来、Twitter における、ユーザの特徴をモデル化するためには、投稿したツイートに対して形態素解析を利用して単語に分割し、それらの出現頻度から tf-idf 法などでユーザの特徴をモデル化する手法が広く利用されている。しかし、ドラマ放送中に呟かれる実況ツイートは、ひとつひとつが短いため、単語を利用しても適切にモデル化ができない事がある。さらに、本システムは、リアルタイムにツイートを配信する必要があるため、ユーザのクラスタリングにもリアルタイム性が求められる。しかし、個々のツイートを形態素解析して、集計する処理はコストが大きく現実的ではない。そこで本研究ではユーザの「気が合う」という観点から、投稿タイミングの類似性に基づいてユーザのクラスタを構成し、そのクラスタを単位としてツイートのフィルタリングを行う。

(a) 投稿時刻に基づいた類似度

本研究ではユーザの嗜好を表す1つの要因として、ツイートのタイミングに着目する。我々は、似たタイミングでつぶやくユーザは同じシーンに反応している可能性が高く、似た嗜好を持っている、という仮説を立てた。具体的には、番組放送中のツイートに関して、2人のユーザのツイートの内容と時間を取得し、ツイートの時間を比較する。ツイートの時間が近いツイートが多いほど2人のユーザは類似度が高いと考える。ユーザの類似度を求める具体的な手順を以下に示す。

- ① Twitter API を用いて放送中のドラマのハッシュタグの検索結果を取得し、実況ユーザのツイートの id, 内容, 時間をデータベースに格納する。なお、放送中、ツイート回数が多いユーザを実況ユーザと呼び、実況ユーザのみを対象とする。
- ② 実況ユーザの中から、2ユーザ A と B を選択し、A がツイートした前後 20 秒以内に B のツイートがあれば、そのツイートは B と似たタイミングでつぶやいたと判断し、その数を $syncA$ とする。B に関しても同様に $syncB$ を求める。
- ③ 上記で取得した $syncA$ と $syncB$ をユーザ自身の全体のツイート数で割り正規化する。
- ④ 2つの値のコサイン値を取り、これを2人のユーザ間の類似度とする。
- ⑤ この計算をユーザすべての組み合わせに対して行い、データベースに格納する。

$userA$ と $userB$ の類似度 $sim(userA, userB)$ を、以下の式で定義する。

$$sim(userA, userB) = \sqrt{\frac{syncA}{allA} \times \frac{syncB}{allB}}$$

ここで、 $allA$ は $userA$ がドラマ放送中に投稿したツイート数を表し、 $allB$ は $userB$ がドラマ放送中に投稿したツイート数を表している。

(b) ユーザのクラスタリング

上記の類似度をもとに、k-method 法を用いてユーザのクラスタリングを行う。k-method 法では、medoid と呼ばれるクラスタの重心に最も近いオブジェクトを代表オブジェクトとしてクラスタリングに用いる。クラスタリングの手順を以下に示す。

- ① 初期 medoid として k 個のオブジェクトを任意に選び、medoid オブジェクトの集合を作る。
- ② オブジェクトをそれが最も近い medoid オブジェクトを持つクラスタに割り当てる。
- ③ それぞれのクラスタ内で medoid でないオブジェクトを選ぶ(ランダムオブジェクトという)
- ④ ランダムオブジェクトと medoid オブジェクトを交換するのに必要となる全コストを計算する。コストは以下の式で求める。
- ⑤ もし交換する方が、コストが小さければ、交換を行い、新しい medoid オブジェクトの集合を作る。
- ⑥ オブジェクトの再配置によって出来るクラスタが直前と同じクラスタになるまで②～⑤を繰り返す。

(c) 共感フィードバック

ユーザクラスタを構成した後に、システムはランダムにクラスタを選択し、選択されたクラスタから発せられたツイートをユーザに提示する。ユーザは番組を見ながら、共感したツイートに「だよね」ボタンを押

す。この行為を「共感フィードバック」と呼ぶ。共感フィードバックを繰り返すことで、ユーザが共感するクラスタからのツイートの割合が増え、ユーザは波長の合う人とソーシャルビューイングを楽しむことができる。具体的には、上記のユーザクラスタからランダムにツイートを選び、一定時間毎に1ツイートずつ表示させる。

ユーザが共感したツイートに対して「だよね!」を押すと、そのユーザを含むクラスタに共感フィードバックが送られると考え、共感数に基づいた確率で、クラスタを選択し、選択したクラスタからツイートを提示する。いま、得られたクラスタ集合を C とすると、時刻 t においてクラスタ $c \in C$ を選択する確率 $p(c, t)$ を以下の式で定義する。

$$p(c, t) = \frac{\text{fnum}(c, t)}{\sum_{i \in C} \text{fnum}(i, t)}$$

ここで、 $\text{fnum}(c, t)$ は、番組開始から時刻 t までにクラスタ c に対する共感フィードバックの総数を表す。共感フィードバックを繰り返すことで、ユーザと嗜好が合うと推定される度合いに応じた割合で、クラスタが選択される用になる。

3 ツイートの集約化手法

3-1 アプローチ

対象とする TV 番組が多くユーザに注目されていると、取得される実況ツイートの量が多くなってしまい、視聴中にタイムラインを閲覧するユーザはツイートの全てを読むことが困難になる。この問題を解決するために、本研究では、実況タイムラインにおいて同一事象に対するツイートが、複数のユーザによって集中的に投稿される現象に着目する。この現象を、同一トピックに対しての盛り上がりと定義する。盛り上がりの発生をリアルタイムに検出して、トピック毎に要約することでタイムラインの内容を集約する手法を提案する。本手法では実況タイムラインに対して一定期間毎にツイートの収集解析を行う。期間中の全てのツイートに含まれる bigram の出現頻度を利用して、盛り上がりを検出する。その後、同一トピックに含まれやすい bigram 同士は期間中の出現頻度の時間推移のパターンが類似する点に着目し、トピック毎に、それを表す高頻度 bigram の集合を得る。その時の実況タイムラインから、トピック毎に、それを表す bigram を最も純度高く含んでいるツイートを代表として1つ選び、トピックの要約とする。以上の手順で、ユーザに提示する為の実況タイムラインの要約をリアルタイムに生成する。

本研究では実況タイムラインにおいて盛り上がっているトピックを、リアルタイムに発見する。そのため実況タイムライン上のトピック抽出とトピックの変遷を把握する必要がある。

従来、ドキュメント集合からトピック抽出を行うには TFIDF 法による重要単語の抽出や潜在的ディリクレ配分法 (LDA: Latent Dirichlet Allocation) によるトピック抽出が行われてきた。それらを利用し特定期間毎に生成されたトピックの追跡を行いトピックの変遷を把握する研究は、TFIDF 法を利用した手法や、LDA を利用した手法が提案されている。しかし、これらの手法では特徴語となる単語を抽出する必要があり、そのために MeCab などを利用した形態素解析を行う必要がある。しかし、Twitter におけるツイートは表記ゆれが多い、加えてソーシャルビューイングにおけるツイートでは、キャラクター名や作品内造語等々の辞書に無い単語が多く存在する可能性が高い為、適用することが難しい。本手法では上記の理由から、文字 bigram を用いたトピックの盛り上がり抽出とその変遷の把握を行う。そのために対象時間区間ごとに以下の2つの処理を行う。

1. 対象時間区間中の頻出度の高い bigram を、DBScan を利用してトピック毎にクラスタリング
2. コサイン類似度を利用して、複数の時間区間をまたぐ同一トピックの盛り上がりを示す bigram クラスタを追跡する

3-2 提案手法

3-2-1 対象とする時間区間中の bigram のクラスタリング

対象とする時間区間中の実況タイムラインからトピック別に盛り上がりを見出す為に、本手法では時間区間中のツイートに bigram の出現頻度の時間変化に着目する。実況タイムラインにおいて、あるトピックについての盛り上がりが発生している場合、そこには集中的に使用されているフレーズやキーワードが存在する。盛り上がりが発生するとその期間は、特定の bigram の出現頻度が上昇し、フレーズやキーワードに含ま

れやすい bigram は類似した推移波形をとる．これを利用し，対象時間区間中の実況タイムラインからトピックの盛り上がりの検出を行う．

n 番目の対象時間区間中のツイートを $T_n = \{t_n^1, t_n^2, \dots, t_n^k\}$ とする．また T_n に存在した Bigram を $B_n = \{b_n^1, b_n^2, \dots, b_n^k\}$ とする．それぞれの bigram の n 番目の時間区間中の出現頻度を $\text{freq}_n(b_n^k)$ とする．まず期間中にトピックの盛り上がりが発生しているかどうかを検出するために，出現頻度が閾値 A_{\min} 以上の bigram を得る．

$$B_n' = \{x \mid x \in B_n, \text{freq}(b_n^k) \leq A_{\min}\}$$

$|B_n'| > 0$ であった場合に盛り上がりが発生していると判定する．それらから推移パターンが類似している bigram のクラスタを発見し，トピックを表す bigram の集合とする．bigram の系列データ $x[k], y[k] (k = 1, 2, \dots, n)$ があるとして，推移パターンの類似性を，ピアソンの相関係数を利用して下記の式のように定める．

$$\text{distance} = 1 - \text{Pearson}(x, y)$$

この式を利用し，高頻出の bigram 集合 B_n' を DBScan を用いてクラスタリングを行う．これにより，一つの要素が盛り上がっているトピックを表す bigram のクラスタである，クラスタ集合 $C_n = \{c_n^1, c_n^2, \dots, c_n^k\}$ を得る．通常の DBScan では条件から外れたノードを，クラスタに含めない外れ値 Border Point として扱う．しかし，実況タイムラインでは2文字のフレーズで盛り上がりが発生することもあるため為，本手法では Border Point として判定された bigram も単独でトピックを表す bigram のクラスタとして扱う．

3-2-2 時間区間をまたぐ盛り上がりの追跡

提案手法で， n 番目の時間区間における実況タイムラインから，トピックの盛り上がりを検出し，トピック毎にそれを表す bigram クラスタの集合 C_n を得ると，設定した時間区間を超えて，トピックの盛り上がりが発生することがある．クラスタリング結果 C_n は時間区間毎に独立しているため，長く盛り上がっているトピックが存在する場合は，各時間区間の C_n 中から同一のトピックを表すクラスタを発見する必要がある．そのために本手法では，ひとつ前の対象時間区間のクラスタリング結果 C_n を利用し，トピックの追跡を行う．

n 番目の対象時間区間におけるクラスタリング結果 C_n のトピック毎の bigram 集合を $C_n = \{c_n^1, c_n^2, \dots, c_n^k\}$ と

し，含まれる bigram の個数は $|c_n^i|$ とする．この時， $C_{n-1} = \{c_{n-1}^1, c_{n-1}^2, \dots, c_{n-1}^l\}$ の各クラスタに対して C_n の各クラスタとコサイン類似度で集合類似度を得る．

$$\text{sim}(c_n^i, c_{n-1}^j) = \frac{|c_n^i \cap c_{n-1}^j|}{\sqrt{(|c_n^i| * |c_{n-1}^j|)}}$$

これを組み合わせ毎に行い，閾値 B_{\min} 以上かつ上の式が最大値になる c_{n-1}^j と c_n^i 組を，同一のトピックを示す bigram のクラスタとして同定する．また， c_{n-1}^j と同一トピックと判定された C_n の要素が複数ある場合は，それら C_n の要素の和集合をとる．そして， n 番目の時間区間において盛り上がっているトピックを表す bigram のクラスタ集合 $C_n = \{c_{n-1}^1, c_{n-1}^2, \dots, c_{n-1}^m\}$ とする．

3-2-3 盛り上がり別の要約生成

n 番目の対象時間区間における実況タイムラインから，トピックの盛り上がりを検出し，トピック毎にそれを表す bigram のクラスタの集合 C_n を利用してユーザに提示するための盛り上がりの要約を生成する．要約には n 番目の対象時間区間の実況タイムラインに存在するツイート T_n からトピックを端的に示すツイートを一つ代表として抽出し，そのツイートをトピックのラベルとする方法をとる．

C_n の各トピックを表す bigram のクラスタに対して，各 bigram の区間中の出現頻度を利用した以下の式によりツイート t_n^j のスコアリングを行う．この時， t_n^j に含まれる bigram を $b_{t_n^j}$ とする．

$$\text{score}(t_n^j, c_n^m) = -|b_{t_n^j} \cup c_n^m - c_n^m| + \sum_{x \in (b_{t_n^j} \cap c_n^m)} \text{freq}_n(x)$$

これにより各トピックに対して，それを表す bigram をより多く含み，且つその他の bigram を含まないツ

イートのスコアが高くなる。上記の式が最大となるツイートを、各トピックを端的に表す代表ツイートとして選択する。また c_n^m が $n-1$ 番目の時間区間において既に検出されていたトピックであるならば、過去に選択された代表ツイートとスコアを比較し、処理時点で最大のものを c_n^m のトピックの代表ツイートとする。以上を対象時間区間ごとに実行し、リアルタイムに盛り上がっているトピックを発見し、トピック毎に内容を端的に表すツイート 1 つを要約として抽出する。

4 投稿ツイートに基づいたシーンの特徴づけ

4-1 アプローチ

TV ドラマには、ユーザに対して特定の印象を与えるいくつかのパターンが存在し、それらの組み合わせにより TV ドラマは構成されていると考えられる。このように考えるとき、TV ドラマに対するユーザの反応パターンを規定することが重要である。これまでに、ユーザの反応を「喜・怒・哀・楽」に代表されるセンチメントとして分類することが考えられている。関連研究でも示したように、このアプローチに基づいた多くの研究が行われている。しかし、TV ドラマに対するユーザの印象は、それらのセンチメントの組み合わせとして表現することは困難であると考えられる。その理由として、TV ドラマは、日常生活の中での息抜きとしての役割が期待されているものが少なからず存在していることが挙げられる。それらは必ずしも、「喜・怒・哀・楽」に代表されるセンチメントの要素の分布に還元するのが適切でない場合があるのではないかと考える。上記の問題を解決するために、本研究では、複数のドラマに対するユーザの実況ツイートを分析することにより、様々なドラマの様々なシーンに共通して表れるユーザの典型的なパターンを、ボトムアップ的に抽出する。そして、ボトムアップ的に抽出した反応パターンの分布を利用して、ドラマのシーンの特徴をモデル化する。

具体的には、以下の手順により、シーンの特徴をモデル化する。

- ① 対象とする TV ドラマに対する実況ツイートを収集する。具体的には、対象とするドラマのタイトルをハッシュタグとして含むツイート、もしくはドラマのタイトルの略称をハッシュタグとして有するツイートを収集する。収集の対象となるのは、ドラマの放送時間中に投稿されたツイートである。収集には Twitter API を利用する。
- ② TV ドラマに対して時間的なセグメンテーションを行う。具体的には、窓関数を利用してドラマ中の特定の時間区間を規定し、規定された時間区間に投稿されたツイートを抽出する。それぞれの時間区間に投稿されたツイートを連結して一つの文書として扱う。
- ③ それぞれの文書に対して形態素解析を行う。
- ④ 形態素解析の結果に基づいて文書を BoW (Bag of Words) として表現する。ここで、すべての単語を使用するわけではなく、使用する品詞のフィルタリングを行う。
- ⑤ Latent Dirichlet Allocation (LDA) を用いて文書からトピックモデルを作成し、それぞれの時間区間に対するトピック分布を求める。それぞれの時間区間のトピック分布の推移をドラマのシーン特徴として捉える。

4-2 提案手法

4-2-1 TV ドラマのモデル化

本研究では、TV ドラマ放送中の実況ツイートをを用いてシーンの特徴抽出を行うため、放送されているシーンと同時に投稿されたツイートの対応付けを行う必要がある。そのため、TV ドラマのハッシュタグによって集められた実況ツイートを投稿時刻に基づいて時系列化する。次に、この時系列に対して、あらかじめ設定しておいた幅の時間窓を適用して、時系列をセグメントに分解する。このセグメントを、ドラマを構成する原始的な単位としてモデル化を行う。このセグメントをシーンセグメントと呼ぶ。排他的なセグメント化を行うと、一つの意味のあるまとまりが分断されてしまい、ドラマの特徴が適切に抽出できない場合がある。この問題に対応するために、窓幅の半分が次の窓と重複するようにしてセグメント化を行う。

4-2-2 シーンセグメントに対する反応のモデル化

シーンセグメントに対応する反応をモデル化する。モデル化のためには Twitter に投稿された実況ツイートを利用する。それぞれのシーンセグメントが放送された時間区間上に設定した時間幅の窓で区切って作ら

れた文書に含まれるツイートを、MeCab による形態素解析を行い、ツイートに含まれる単語を抽出する。それぞれのシーンセグメントに対応して、その特徴を BoW としてモデル化する。

本研究では、ユーザの反応を抽出するための BoW として、全ての品詞を利用するわけではない。本研究では、個々のドラマの題材に依存せず、ユーザに対して与えた印象を表す単語を抽出したい。そのため、ドラマのタイトルや登場人物といった固有名詞だけでなく、ユーザの反応とは考えにくい単語を極力省きたい。

そこで、BoW を構成する単語を、品詞に基づいてフィルタリングする。形態素解析により分類した品詞の中から、シーンの特徴を抽出するために適切であると思われる、視聴者の反応が現れやすい品詞を選択して使用する。品詞の選択には、MeCab での形態素解析時に割り振られる、品詞 ID を用いる。品詞 ID には、名詞や形容詞といった品詞名だけでなく、名詞の中でも一般名詞なのか、固有名詞なのかといった、より細かい分類が含まれている。

4-2-4 シーンセグメントに対する反応のトピックモデルの構築

本研究では、ドラマのシーン特徴を抽出する際、前述の手法によって得られる BoW を利用して、シーンセグメントに対する反応のトピックモデルを構築する。本研究ではトピックモデルとして LDA を使用する。LDA を用いることで、文書中に一緒に出現する可能性のある単語の集合をトピックとして得ることができる。

トピックモデルをジャンルとは異なるシーン特徴を見出す指標とし、文書ごとにそれぞれのトピック分布を算出する。トピック分布とは、それぞれのトピックが出現する確率である。シーンセグメントのトピック分布を利用してシーン特徴を決定する。

(1) コーパス

本研究では、対象とするドラマ集合の実況ツイートをコーパスとして、LDA を利用しトピックモデルを構築する。具体的には、ドラマの実況ツイートを特定の時間幅で区切り、文書化したものを形態素解析することによって得た BoW を、コーパスとして使用する。

(2) シーンセグメントを特徴づけるトピックの抽出

コーパスを利用して、トピックを抽出する。抽出するトピックの個数はパラメータとして明示的に指定する。ここで抽出したトピックは、様々な種類に含まれる様々なシーンにおいて一般的に存在するトピックであり、ドラマに対するユーザ反応トピックと呼ぶ。

(3) ユーザ反応トピックを利用したシーンセグメントの特徴付け

抽出したユーザ反応トピックを利用して、シーンセグメントの特徴付けを行う。具体的には、上記の手法で抽出したユーザ反応トピックを利用し、それぞれのシーンセグメントに対するユーザ反応トピックの出現確率に、そのシーンセグメントに対応する窓区間に含まれるツイート数をかけ合わせ、得られる数値の分布を求める。この分布をベクトルとしたものをシーンセグメントに対する特徴ベクトルとする。

LDA によって得られるユーザ反応トピックの分布からは、対象とする文書中でそれぞれのトピックが出現する確率を得ることができる。しかし、その時点でのドラマの盛り上がりがどの程度かを知ることはできない。そのため、本研究ではシーンセグメントに対するユーザ反応トピックの分布に対し、対応する窓区間に含まれるツイート数をかけ合わせる。これにより、実況ツイートの数の推移から得ることのできるドラマの盛り上がりの様子を含んだ、シーンセグメントの特徴ベクトルを作成する。

4-3 評価

提案手法に沿ってドラマ 1 話分のトピック分布を求め、実際のドラマに対する視聴者の反応を適切に表しているかを確認した。具体的には、ドラマ内のどのようなシーンで何が起きているかを 30 秒毎に書き出したもの（シーンリストとする）と、提案手法によって得られた特徴ベクトルとを、対応する時間においてトピック通りにユーザの反応を表すことができるかを比較する。

前述の予備実験の結果により、窓の時間幅・使用する品詞・トピックの数を以下のように設定する。

(ア) 窓の時間幅：2 分

(イ) 使用する品詞：形容詞，副詞

(ウ) トピックの数：30


検証対象とした TV ドラマを表 1 に示す。

シーンリストと特徴ベクトルの比較の際、表 1 で記述した 3 つのドラマについて、得られた 30 個の特徴ベクトルの中から、特徴ベクトルの数値が高いものを 5 つ選出し、グラフ化したものを使用した。

表 1 検証で比較に使用した TV ドラマ

タイトル	放送日時	総ツイート数
逃げるは恥だが役に立つ	2016年10月11日22時	20467
IQ246～華麗なる事件簿～	2016年12月4日21時	9670
THE LAST COP/ラストコップ	2016年12月10日21時	26673

「逃げるは恥だが役に立つ」では、「かわいい」が含まれたトピックが軒並み高い数値を示していた。中でも、トピック中の「かわいい」の確率が 0.351 と非常に高いトピック 3 は、1 話を通して波を示しているだけでなく、開始 49～54 分や、開始 61～63 分の小さな「かわいい」が現れるシーン、そして開始 66 分頃に流れたエンディングの「恋ダンス」において数値が非常に高くなっている。また、情熱大陸のパロディが取り入れられた開始 21～24 分と、男性の仕事場でハプニングが起きた開始 35～38 分では、「かわいい」だけでなく「楽しい」「おもしろい」が含まれるトピック 20 が高くなっていた。これは、トピックモデルによりドラマの特徴を捉えたからこそ表れたものである。全体を通して、「逃げるは恥だが役に立つ」では「かわいい」という感想が非常に高かったが、シーンによって「かわいい」にも少しずつ違いがあることが確認できる。



5 共感に基づく TV 番組推薦手法

5-1 アプローチ

共感に基づいた TV 視聴を行うためには、ユーザが共感できる可能性が高い TV 番組を選択することが重要である。そのために、ユーザが他のユーザと共感する可能性が高い TV 番組を推薦する機構が重要である。TV 番組を推薦するためには様々な手法が考えられるが、近年多くのサービスに於いて協調フィルタリングに基づく推薦が提供されている。協調フィルタリングは一般的に、「同一のアイテムに興味を持つユーザ同士はアイテム選別における嗜好が似ている」という仮定に基づいて推薦を行っている。しかし、アイテムを選別する際、人はそれぞれの立場から評価や考察を行う。従来の協調フィルタリングでは、このようなユーザの評価における観点を考慮しないため、ユーザの嗜好に合わないアイテムが推薦される可能性がある。そこで、オンラインレビューを利用した協調フィルタリングに基づくアイテム推薦の際に、対象ユーザの評価観点を考慮し、対象ユーザが支持する評価観点とレビュー者の評価観点の類似性に基づいて推薦を行う手法を提案する。

5-2 提案手法

5-2-2 想定する推薦インターフェース

提案手法では、対象ユーザが選択したアイテムに関するページにおいて、そのアイテムに対するレビュー、アイテムを表示する。推薦アイテムの初期値は各ユーザの重要度は均一として一般的な協調フィルタリング手法に基づいて求める。対象ユーザはレビューを読み、個々のレビューに対して支持するかどうかについて

の評価を支持・不支持・中立のどれかとして入力する。評価されたレビュー集合を解析することで、対象ユーザーの評価嗜好を求める。レビューの評価観点は、あらかじめ LDA を用いて学習した、アイテムを評価するためのトピックに対する分布を推論計算することで求める。そして、対象ユーザーの評価嗜好と各レビューの評価観点との間のコサイン相関値を求め、その値をレビューに対する重みとして、推薦アイテムの再計算および再提示を行う。

5-2-2 LDA による評価観点の学習

本手法では、全ての書籍レビューに対して LDA を用いて、書籍を評価する際の多様な観点をトピックとして抽出する。このとき、書籍自体に関するトピックが抽出されるのは避けることが望ましい。そこで、書籍の登場人物名や作者名、など特定の書籍のみに出現するような単語を除外するために、以下の前処理を行う。

全レビューを Mecab を用いて形態素解析し、名詞・形容詞・形容動詞を抽出する。そして、それぞれの書アイテムごとに、そのアイテムに対する全レビュー中の単語 w を含むレビューの割合を求める。形式的には、アイテム i における単語 w を含むレビューの出現率 $r(i, w)$ を以下の式で表す。

$$r(i, w) = \frac{|\{r | r \in \text{reviews}(i), w \in \text{words}(r)\}|}{|\text{reviews}(i)|}$$

ここで、 $\text{reviews}(i)$ はアイテム i を含むレビュー集合であり、 $\text{words}(r)$ はレビュー r を含む全単語からなる集合を表す。

アイテム集合 I における、それぞれのアイテム i に対する単語 w の平均出現率が低い場合は、その単語は特定の書籍固有の単語であると考えられるため、評価観点要素の抽出には用いないこととする。アイテム集合 I における単語の w の一般度 $\text{major}(I, w)$ を以下の式で定義する。

$$\text{major}(I, w) = \frac{\sum_{i \in I} r(i, w)}{|I|}$$

上記の式によって、求められた一般度 $\text{major}(I, w)$ が設定した閾値より低い単語をトピック抽出の対象から除外する。一般度の低い単語が除外された、全レビューの全レビューに対してトピック抽出を行い、得られたトピックの集合を、アイテム評価における観点トピックの集合とする。

レビューの全レビューを一纏めにしたものを 1 つの新規文書として、LDA の推論計算により、観点トピックに対して、新規文書はどのトピックが生成しやすいかの多項分布 $\theta_{d_{new}}$ を以下の式で推定することができる。

$$\theta_{d_{new}} = \sum_{z=1}^K p(z) p(d_{new} | z)$$

$p(z)$ は混合比と呼ばれ、トピック z が選ばれる確率を表し、 $p(d_{new} | z)$ はトピック z が選ばれたときに文書 d_{new} が生成される確率を表し、これに $p(z)$ をかけることで、ベイズ推定より、文書 d_{new} においてトピック z が選ばれる確率を求めている。これをレビューの評価観点ベクトルとして扱う。

5-2-3 レビューに対する共感度を考慮した協調フィルタリング

(a) 対象ユーザーの評価嗜好の推定

ユーザーのフィードバックによって得られた評価情報のうち、ポジティブなフィードバックを受けたレビューの評価観点ベクトルを正の影響ベクトル、ネガティブなフィードバックを受けたレビューの評価観点ベクトルを負の影響ベクトルとして、対象ユーザーの評価に対する嗜好を推定する手法を述べる。フィードバックによって得られるのは、ユーザーの評価観点そのものではなく、評価観点に対する嗜好である。もし、ユーザーがレビューに対して正の評価も負の評価も行わなかった場合には、ユーザーは評価に対する嗜好が存在しないため、全てのレビューを等価に扱う。

対象ユーザー u のフィードバックによる評価嗜好ベクトル \mathbf{p}_u を以下の式で定義する。

$$\mathbf{p}_u = \frac{\beta}{|R_{pos}|} \sum_{r \in R_{pos}} \mathbf{v}_r - \frac{\gamma}{|R_{neg}|} \sum_{r \in R_{neg}} \mathbf{v}_r$$

R_{pos} は、対象ユーザー u がポジティブなフィードバックを返したレビュー集合である。一方、 R_{neg} は、対象ユーザー u がネガティブなフィードバックを返したレビュー集合であり、 \mathbf{v}_r はレビュー r の評価観点ベクトルである。

(b) レビュー者に対する共感度の推定

本手法では、ユーザごとにレビュー者に対する共感度が異なると考える。対象ユーザにとって共感度が高いレビュー者は協調フィルタリングの際に重要視され、共感度が低いレビュー者は協調フィルタリングの際に重要視されないものとする。本手法では、対象ユーザの評価観点に対する嗜好を適用したレビュー者の評価観点ベクトルと、嗜好を適用しないレビュー者の評価観点ベクトルとの間のコサイン相関値を求め、得られた値を対象ユーザのレビュー者に対する共感度とする。対象ユーザ u のレビュー者 r に対する共感度 $\text{emp}(u, r)$ は、以下の式で定義する。

$$\text{emp}(u, r) = \cos(\mathbf{v}_r, \alpha \mathbf{v}_r + \mathbf{p}_u)$$

ここで、 $\alpha \mathbf{v}_r + \mathbf{p}_u$ は、対象としているレビュー者 r の評価観点に対して、ユーザの評価嗜好を反映した評価観点ベクトルを表している。この式では、対象とするレビュー者の評価観点ベクトルと、ユーザの評価嗜好を反映させた評価観点ベクトルとのコサイン相関値をとることにより、対象ユーザのレビュー者に対する共感度を推定している。

(c) アイテムの予測評価値計算

対象ユーザのレビュー者に対する共感度を重みとして、協調フィルタリングによる書籍の予測評価値を計算する。アイテム i_1 を選択した時の、ユーザ u に対するアイテム i_2 の予測評価値は、以下の式で求める。

$$\text{Pred}(u, i_1, i_2) = \sum_{r \in R(i_1)} (\text{emp}(u, r) \times \text{read}(r, i_2))$$

ここで、 $R(i)$ はアイテム i に対してレビューを投稿したレビュー者集合を表し、 $\text{emp}(u, r)$ は対象ユーザ u にとってのレビュー者 r の共感度を表す。また、 $\text{read}(r, i_2)$ は、レビュー者 r がアイテム i_2 を選んだかどうかによって値が決まり、選んでいた場合は1となり、選んでいない場合は0となる。

アイテム i_1 を読んだレビュー者集合のうち、アイテム i_2 を読んだレビュー者の共感度の合計値がユーザ u に対する書籍 i_2 の予測評価値となり、これにより、ユーザ u の観点を考慮した協調フィルタリングによる推薦を行う。

6 おわりに

本研究では、Twitterを利用したTV番組の共感的視聴を行うための手法を開発した。本研究ではまず、投稿のタイミングに基づいてTwitterユーザをクラスタ化し、ユーザのフィードバックを利用して、ユーザが共感できるツイートを見ながらTV番組の視聴を行うための基本的なシステムを開発した。また、大量のツイートを集約化して、ソーシャルビューイングを行っているタイムラインの雰囲気を知りやすく提示する手法を開発した。更に、TV番組を視聴しながら投稿されたツイートのトピック分析を行うことにより、シーンの特徴をモデル化する手法を開発した。また、ユーザの共感に基づいてTV番組を推薦する手法を開発した。

今後、上記の手法を組み合わせる統合的なソーシャルビューイングの視聴環境を設計し、プロトタイプを利用した被験者実験により有効性を評価する予定である。

〈発 表 資 料〉

題 名	掲載誌・学会名等	発表年月
レビュワーに対する共感度を考慮した協調フィルタリングによるアイテム推薦手法	Web とデータベースに関するフォーラム 2016(WebDB Forum 2016)	2016 年 9 月
A collaborative filtering method based on empathy with reviewers	Proceedings of the 11th International Conference on Ubiquitous Information Management and Communication (IMCOM 2017)	2017 年 1 月
視聴者はドラマの「どこ」に「どう」反応しているのか？－実況ツイートを利用したドラマのシーン特徴の抽出－	データ工学と情報マネジメントに関するシンポジウム論文集	2017 年 3 月
How do viewers react to drama? : Extraction of scene features of dramas from live commentary tweets	Proceedings of the 12th International Conference on Ubiquitous Information Management and Communication (IMCOM 2018)	2018 年 3 月