



Twitter上のあるユーザの 意外な情報抽出手法の提案

甲南大学 知能情報学部

◎大原 啓詳 灘本 明代

背景



Twitter

140文字以内の短文の投稿

文章が短い

様々なデバイスで利用可能

リアルタイム情報発信

多くのユーザーが気軽に投稿

愚痴

ジョーク

ニュース

意見


会話

今している事

テーマに
囚われない
多種多様な投稿

背景


Twitterにおけるユーザ同士の繋がり



ツイートの投稿と閲覧

背景


タイムライン上の
ツイート



全て確認

時間がない
フォローが多い

困難



効率化が必要

閲覧者が
欲しい情報


変化のあった情報

新鮮味のある情報

フォローしている
あるユーザの...


予想外の
行動・言動

背景



目的

既知の情報から
予測できない
行動や言動の変化



意外な情報

情報（ツイート）の発信者の
意外な情報



抽出

有益・貴重なツイートの発見



意外な情報の分類

アトリビュート意外情報

ツイートの持つ投稿時間や頻度
位置情報に関する意外な情報

コンテンツ意外情報

ツイートの文そのものに含まれる
感情や行動に関する意外な情報



アトリビュート意外情報

アトリビュート意外情報

- Tweetの投稿時間
- Retweet数
- Favorite数
- 位置情報



コンテンツ意外情報

コンテンツ意外情報

ツイートの文に含まれる

- ・ 位置変化の分かる地名 ・ イベント名
- ・ 感情や気分の変化
- ・ 普段は行わない行動
- ・ 興味・嗜好の変化



アトリビュート意外情報の抽出手法

アトリビュート意外情報

- Tweetの投稿時間
- 位置情報

完全に
データのみから
判断可能

- Retweet数
- Favorite数

内容についても
考慮する必要がある



ツイートの分析 ツイート数



1時間ごとのツイート数をグラフ化

**対象データ：ユーザ5名の5週間分のツイート
計21161ツイート**

**目的：ユーザごと、曜日ごとの
ツイートの投稿パターンの規則性
が存在するかの調査**



ツイートの分析 ツイート数



ツイートの分析 ツイート割合

ユーザのツイートはある程度の規則性を持つ
例：昼間のツイート数が平日は多い
深夜のツイート数が土日は多い


同じ曜日でもツイート数にはばらつきがある

曜日ごとのパターンの分析

⇒一日における各時間でのツイート割合


ツイートの分析 ツイート割合

日曜日5週間分のツイート



各曜日ごとの
パターンの明確化

週間分のツイート



コンテンツ意外情報の抽出手法

コンテンツ意外情報

- ・ 位置変化

アトリビュート
意外情報と
合わせて考慮

- ・ 感情や気分
- ・ 行動
- ・ 興味・嗜好

判断の為
膨大なツイートを
読む必要がある


ツイートのみで判断

コンテンツ意外情報の抽出手法


行動・興味に関する意外情報



普段のツイートとは異なる話題に関するツイート



ツイートを話題ごとにクラスタリングし意外な話題に関するツイートのクラスタを抽出



Tweetのクラスタリングによる 意外情報ツイートの抽出

あるユーザのツイート



形態素解析 名詞抽出



LDAによりクラスタリング



内容の類似した
クラスタが存在


日常的な興味ツイート群A-1

日常的な興味ツイート群B-1


意外情報ツイート群

日常的な興味ツイート群A-2

日常的な興味ツイート群B-2



Tweetのクラスタリングによる 意外情報ツイートの抽出



コンテンツ意外情報の抽出手法

・ 評価実験

実験データ


- ・ 実験対象アカウント 3アカウント
- ・ ツイート数 各2000ツイート（計6000ツイート）

正解データ

- ・ 意外情報の定義に基づき人手で判断

各パラメータ（予備実験により決定）

- ・ LDAによる分類 20クラスタ
- ・ cos類似度の閾値 0.3以上
- ・ 意外情報クラスタとする基準
含まれるツイート数が100ツイート以下



コンテンツ意外情報の抽出手法

・ 実験結果

ユーザ	意外情報 クラスタ数	意外情報 ツイート数	適合率	再現率	F値
A	3	199	0.18593	0.11315	0.140684
B	2	167	0.08982	0.060241	0.072115
C	1	49	0.163265	0.041522	0.066207

・ 考察

適合率・再現率、共に低い

- ・ 適合率が低い原因

⇒ ツールからの定型ツイートのクラスタの発生

- ・ 再現率が低い原因

⇒ LDAによるクラスタリングの失敗

⇒ 根本的な原因はツイートの短さと考えられる

まとめと今後の課題

まとめ

- ・ ユーザの意外情報の定義と分類を行った
- ・ アトリビュート意外情報抽出のための分析
- ・ コンテンツ意外情報抽出のためのシステムの作成と評価実験

課題

- ・ 大規模なツイートの分析
- ・ 分析データに基づくアトリビュート意外情報の抽出手法の具体的なロジック構成
- ・ コンテンツ意外情報抽出システムの為のクラスタリング手法やクラスタの類似比較手法の再検討
- ・ 複合的な意外情報の抽出手法の考案



ツイートの分析


投稿パターン分析のための時間の分割方法

候補


- (a) 6時間ごと4等分
- (b) 3時間ごと8等分（気象庁準拠）
- (c) 1時間ごと24等分

各区間時間ごとの1日に占めるツイート割合について、グラフの比較


ツイートの分析 時間区分



(a)6時間ごと



(b)3時間ごと



(c)1時間ごと

コンテンツ意外情報の抽出手法

・ 適合率を著しく下げた例

愛のある質問をして下さい。 [http～](#)

理想形の質問をして下さい。 [http～](#)

落ち着いて質問して下さい。 [http～](#)

△△音楽室光の結晶

△△音楽室未来への帰り道

△△音楽室 ザギンデビュー

△△音楽室億万笑者