

K-016

## 「いじめ語指数」と個人名検出を併用した学校裏サイト監視支援システム Development of Monitoring System for School Unofficial Web-site with Detecting First or Second Name and Bully Word Index

浅田 太郎<sup>†</sup> 伏見 朋恵<sup>‡</sup> 吉富 康成<sup>†</sup> 田伏 正佳<sup>†</sup>  
Taro Asada Tomoe Fushimi Yasunari Yoshitomi Masayoshi Tabuse

### 1. 緒言

インターネットの利用者は年々増加し続け、若年層も利用する機会が多くなっている。また、近年、学校非公式サイトの数も増加し、インターネット上で特定の人の誹謗中傷を行う「ネットいじめ」が増えている[1]。学校非公式サイトを監視する企業も現れているが、費用等の問題で企業に依頼することができず、教職員が検索・監視を行っている学校も少なくないと言われている。そのような負担を軽減するため開発した既報のシステム[2]を基にして、本研究では、検出された「いじめ語」が人に与えるダメージの程度を表す指数(以下、「いじめ語指数」と表記)を提案し、その指数を用いて通報対象となる裏サイト検出の自動化手法の検討を行った。

### 2. いじめ語指数

既報の研究[2]では、人に与えるダメージについて「いじめ語」をすべて同等に扱っていた。しかし、システムの自動化を進めるためには「いじめ語」それぞれにランク付けが必要であると考えた。

MeCab[3]の辞書に登録されている「いじめ語」は 232 語ある。この 232 語を実質的な意味を基に 53 グループに分類した。そして、各グループの代表的な「いじめ語」53 語について人に与えるダメージを評価した。

評価には一対比較法を用い、どちらの「いじめ語」のダメージが大きいかを、大学生 10 名(男性 5、女性 5)、高校生 7 名(男性 3、女性 4)の計 17 名に判定してもらった。

まず各被験者の一対比較の結果から、それぞれの「いじめ語」に 15~45 点が与えられた。男性と女性ではダメージの受け方に違いがあったので、一般的な尺度を設けるため、男女のダメージの大きい方を採用した。具体的には、男性の評価平均点、女性の評価平均点の大きい方を採用した。そして、採用された一対比較の点数を 10 倍し、「いじめ語指数」とした。得られた「いじめ語指数」は、150~450 点となった。

また「いじめ語指数」が 330 点以上の「いじめ語」を「レッドカード」表記対象とし、それ未満を「イエローカード」表記対象とした。このボーダーラインは、男性と女性の「いじめ語指数」をそれぞれ降順に並べたとき、男性または女性の上位 2 割(53 語中 11 語)に入る全「いじめ語指数」の最低点である。つまり、男性の「いじめ語指数」上位 2 割の 11 語と、女性の「いじめ語指数」上位 2 割の 11 語はすべて、「いじめ語指数」が 330 点以上である。

### 3. 実名の登録

本研究では、個人を特定して誹謗中傷している Web ページを、後述する「通報候補」と分類している。そのため、実名を MeCab 辞書に登録する必要がある。実名の登録には「松茸用人名テキスト」[4]記載の約 80,000 語を用いた。

### 4. 処理概要

#### 4.1 開発環境

システムは以下の開発環境で構築した。

- ・ OS: Windows 7 Professional
- ・ 使用プログラム言語: Visual C# 2008
- ・ PC: DELL OPTIPLEX 780 (CPU : Intel Core 2 Duo E8400 3.0GHz メモリ 4 GB)

#### 4.2 処理

本システムの処理のフローチャートを図 1 に示す。

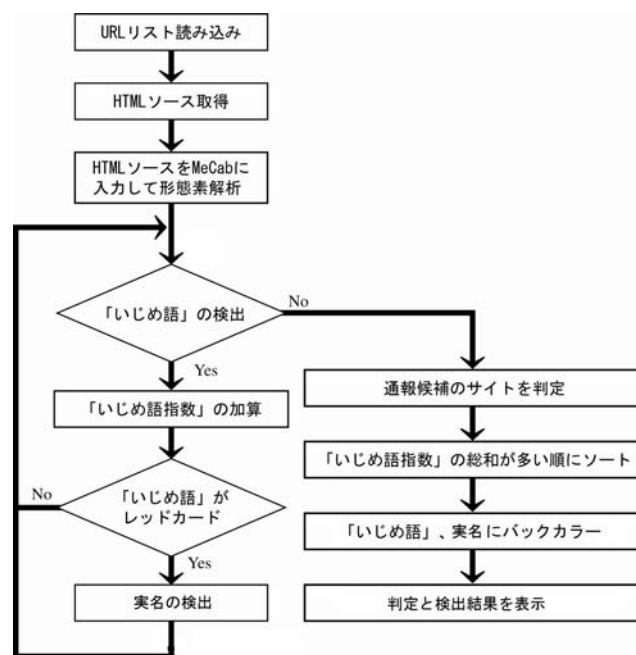


図1 処理のフローチャート

#### 4.3 「いじめ語指数」の計測

まず、「いじめ語」と実名の検出を行うために、Web ページの HTML ソースを取得する。取得した HTML ソースを MeCab に入力し、形態素解析を行う。そして、Web ページ全体での「いじめ語指数」を求める。

<sup>†</sup> 京都府立大学 大学院 生命環境科学研究科, Graduate School of Life and Environmental Sciences, Kyoto Prefectural University

<sup>‡</sup> 楽天株式会社, Rakuten, Inc

#### 4.4 実名の検出

HTMLソースを形態素解析した後、実名の検出を行う。2010年8月26日～2011年1月21日の期間中に既報のシステム[2]を用いて通報された25件のうち、「レッドカード」表記のいじめ語の近傍に実名が書かれているものが17件あった。

そのため、近傍に「いじめ語」と実名が存在している場合、後述する「通報候補」とした。近傍の大きさは実験的に決定した。検出された「いじめ語」が「レッドカード」表記対象の場合、前後10形態素以内における実名の存在を調べる。

#### 4.5 通報候補判定

監視対象のWebページが、通報対象のサイトなのかを判定する基準を作成するために、まず「いじめ語」が検出され、通報された例と通報されなかった例の「いじめ語指数」を比較した。

通報したサイトのほとんどは、一回の書き込みで「いじめ語指数」の総和が900点以上であったことから、この900点を「通報候補」とする下限値とした。また一回の書き込みでは、10回以内の改行が行われていたことから、「いじめ語」が検出されてから改行が10回行われるまで「いじめ語指数」を加算していくものとした。

Webページの分類は以下の(1)～(4)の基準を順に適用して行うものとする。(1)～(4)は深刻度の高い順になっており、いずれにも該当しない場合は(5)ブルー(「いじめ語」なし)と分類する。図2にWebページの判定表示を示す。

##### (1)通報候補

実名と「レッドカード」表記の「いじめ語」が前後10形態素以内で存在していること。もしくは、「いじめ語」から後10回の改行が行われるまでの「いじめ語指数」の総和が900点以上であること。

##### (2)レッド

「レッドカード」表記の「いじめ語」があること。

##### (3)オレンジ

「イエローカード」表記の「いじめ語」があり、そこから10回の改行が行われるまでの「いじめ語指数」の総和が760点以上であること。(この760点は「イエローカード」表記の「いじめ語指数」の平均の3倍)

##### (4)イエロー

「イエローカード」表記の「いじめ語」があること。



図2 Webページの判定表示

#### 4.6 「いじめ語」未更新サイトの取扱い

検出された「いじめ語」が、その検出順番も含め前回の検出とすべて同じであったサイトについては、判定表示(図2)に「済」印を付加する。

## 5. 適用例

### 5.1 URLリストの収集

京都市教育委員会と京都府立大学情報環境学グループが連携して京都市内の小中高校の個人サイト・プロフを含むサイトの監視を行っている。「いじめ語」が検出されたWebサイトについては、深刻度の高いものは即座に京都市教育委員会に通報する。

指定されたモデル校は、小学校4校、中学校4校、高等学校4校である。その学校に在籍する生徒のサイトを収集した。

### 5.2 性能評価実験

2010年8月26日～2011年1月21日の期間中に既報のシステム[2]を用いて通報された25件の書き込みを本システムを用いて判定した。結果として、「通報候補」と判定されたものが21件(84%)、「レッド」と判定されたものが4件(16%)であった。

### 5.3 動作確認実験

本システムを用いて、監視対象のサイト341件について5日間の監視(1日1回の「いじめ語」検出)を2回(計10回)行った。1回目の5日間の実験では、実際に通報された2件に対して本システムで「通報候補」と判定されたのが1件、「レッド」と判定されたのが1件あった。通報事例の「通報候補」判定割合は50%であった。通報事例以外で「通報候補」と判定されたのが4件であった。「通報候補」と判定され、実際に通報された割合は、20%であった。2回目の5日間の実験では、実際に通報された4件は本システムですべて「通報候補」と判定された。通報事例以外で「通報候補」と判定されたのが10件あった。「通報候補」と判定され、実際に通報された割合は、28.6%であった。

## 6. 結言

本研究では、「いじめ語指数」と実名の検出を併用した学校裏サイト監視支援システムを開発した。このシステムでは、通報対象となるサイトを判別するために誹謗中傷の深刻度を判定する基準を設けた。

今後の展開を以下に示す。

- ・ネット特有の言葉、表現への対応
- ・監視の負担を減らすため、より一層の自動化

### 参考文献

- [1]文部科学省, “青少年が利用する学校非公式サイトに関する調査報告書”, (2008).
- [2]浅田 太郎, 竹田 麻友子, 吉富 康成, 田伏 正佳, “「いじめ語」検出による学校裏サイト監視支援システム”, 第9回情報科学技術フォーラム講演論文集, 3, (2010).
- [3]京都大学情報学研究所-日本電信電話株式会社コミュニケーション科学基礎研究所共同研究ユニットプロジェクト, <http://mecab.sourceforge.net/>
- [4]松茸用テキスト, <http://www.vector.co.jp/soft/data/writing/se066955.html>