

プロフサイトの内容解析による非行逸脱行為判定手法の検討 A Detection Method for Juvenile Delinquency and Deviant Behavior by Analyzing Profile Website

嘉村 準弥[†]
Junya KAMURA

中村 健二[‡]
Kenji NAKAMURA

小柳 滋[‡]
Shigeru OYANAGI

1 はじめに

携帯電話利用者の低年齢化により、携帯電話からインターネットを利用する機能であるモバイルインターネットが普及している。モバイルインターネットには、様々なサービスがあり、中でも、中高生を中心としたプロフィールサイト（以下、プロフと略記）を利用した情報交換が盛んに行われている。

しかし、プロフに起因した問題も懸念^[1]されており、非行逸脱行為の誘発、ネットいじめや見知らぬ大人との出会いなどその問題は多岐にわたる。その問題はこれらへの対策として、インターネット上での子どもの見守り活動を支援するシステムの開発^[2]や学校公式サイトにおける有害情報検出に関する研究^[3]が行われている。前者の取り組みでは、人手でネットパトロールした結果を蓄積・共有する仕組みを構築しており、見知らぬ大人との出会いや非行逸脱行為の未然防止に貢献している。しかし、ネットパトロール業務は人手で実施しておりインターネット上の膨大な情報を網羅的に監視することは困難な状況である。後者の研究では、ネットパトロールの支援を目的として、電子掲示板の記事を対象に、SVM（Support Vector Machine）^[5]を用いて有害情報を自動判別する手法を提案しており、高精度に有害情報を判別する仕組みを実現している。

それに対し、本研究では、非行逸脱行為や危険な行動を行っている生徒（以下、非行者と略記）を検出することが目的であるため、プロフを対象に解析する必要があり、電子掲示板を対象とした手法を用いることは困難である。そのため、本研究ではプロフに記述されている内容を解析し、非行逸脱行為の有無を自動的に判別する手法を検討する。

2 研究概要

本研究では、非行逸脱行為の有無を自動判別する手法を検討する。本システムの全体構想を図1に示す。本研究は、3つの機能で構成されている。まず、非行逸脱語の出現項目判別機能では、プロフの項目（HN、嗜好品や学年など）の中で、非行逸脱行為に関する情報が頻出する項目を判別する。次に、略語推定機能では、原語と略語表現を対応付け、略語辞書の自動拡張を行う。このことによりプロフの各項目に用いられるたばこの銘柄やお酒の名称などの様々な略称に対応した非行逸脱行為の判定が可能となる。非行逸脱行為判定機能では、上述の2つの機能の結果を用いて非行逸脱度合いを算出し、非行者の判定を行う。本論文では、事前処理部の出現項目判別機能と略語推定機能における略語候補抽出処理について詳述する。

3 出現項目判別機能

非行逸脱行為の判定において、文章全体を非行逸脱行為の判定処理にかけた場合に、誤判定が多く発生し、

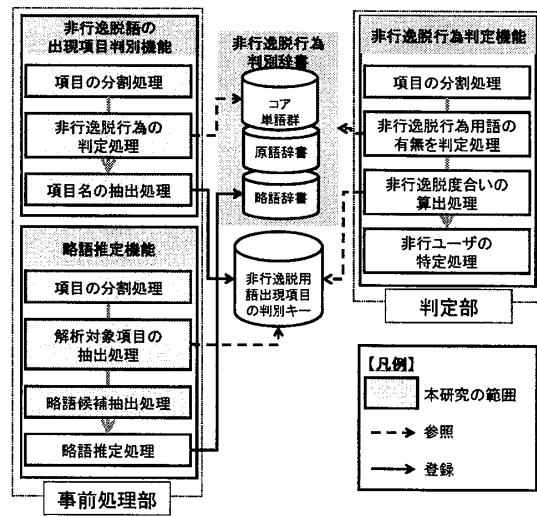


図1：非行逸脱行為判定システムの全体構想図

適合率が低下すると考えられる。そのため、本機能では非行逸脱語の出現する範囲を限定するため、非行逸脱語が頻出する項目を特定する。まず、項目の分割処理では、VIPSアルゴリズム^[5]を用いて、プロフページをブロック単位に細分化する。次に、非行逸脱行為の判定処理では、非行逸脱語のコア辞書を用いて、各ブロックに非行逸脱語が含まれるかを判別する。そして、項目名の抽出処理では、非行逸脱語が含まれているブロックの記述内容を文字列に分割し、DF値を算出する。ここで、頻出する項目に偏る傾向が見られる場合は、DF値が高い値を示すと考えられる。最後に、項目名の抽出処理で得られた文字列から、ストップワードと記号を除去した結果を非行逸脱用語出現項目の判別キーとし、DF値と共にデータベースへ登録する。

4 略語推定機能

略語推定機能では、非行逸脱行為の出現項目判別機能にて取得した判別キーを用いて、略語候補が含まれる項目の文章を抽出する。そして得られた文章と原語辞書を用いて、略語候補と原語の対を対応関係候補として抽出する。最後に、対応関係候補を元に、略語推定を行い、略語と原語の対を辞書に登録する。本章では略語候補抽出処理について詳述する。

略語候補抽出処理では、解析対象項目の抽出処理にて得られた項目の文書を入力として、略語辞書の語句と検出した略語候補の一一致率を算出し略語候補を抽出する。辞書には非行逸脱行為に関係する原語が単語区切りで登録されている。処理の詳細は図2の通りである。

まず、略語の多くは、単語の頭文字を含む特性があるため、辞書に登録されている各原語の頭文字を用いて略語の先頭文字を検索する。次に、一致した先頭文字の次文字が、原語に含まれるかを再帰的に検索し、略語範囲を推定する。略語に含まれる文字は原語中に含まれ

[†]立命館大学大学院理工学研究科、Graduated School of Science and Engineering, Ritsumeikan University
[‡]立命館大学、Ritsumeikan University

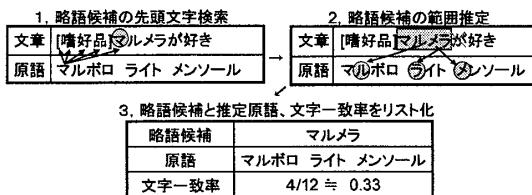


図2: 略語候補抽出手法の流れ

る確率が高く、その中でも単語区切りの頭文字である可能性が高いと考えられる。一文字ずつ検索を進め、原語中に含まれない文字が出現した時点で略語範囲の推定を終了する。最後に、推定された略語と原語の文字一致率を計算し、略語推定候補として抽出する。

5 略語候補抽出手法に関する評価実験

5.1 実験内容

本評価実験では、プロフの記述内容から適切に非行逸脱行為の原語に対応した略語候補の抽出が可能であるか評価をする。また、本実験では、出現項目判別機能の有効性を証明するため、出現項目判別機能で項目を限定した場合と、項目全体を対象とした場合の精度について比較検証する。ここでは、非行逸脱行為の判定として、喫煙行為の有無の判定を想定し、たばこの略称候補と原語との対応付け精度を評価する。

本実験で用いるデータは、楽天社が運営する「前略プロフィール[6]」から抽出したたばこの銘柄の略称が含まれているプロフページ500件とする。また、原語辞書には、「たばこの銘柄」190件を人手で登録した。

略語候補抽出処理の精度は、500名のプロフページ内のたばこの銘柄の略語を原語と対応付けて正確に抽出した割合で評価する。ここで、抽出した略語候補の中で、最も文字一致率の高い候補を代表語とし、その代表語と略語候補の対が同一の内容を指していると判断できた場合に抽出成功とする。なお、各ユーザのプロフデータに複数のたばこの銘柄の略語が存在する場合、一組でも正しく抽出できていれば正解とする。また、実験結果の精度を評価するために、評価指標としてF値(F-measure)を用いる。F値は適合率(precision)と再現率(recall)の調和平均であり、F値の値が大きいほど正確性と網羅性を持った結果であることを示す。

5.2 実験結果と考察

実験結果を表1、表2に示す。表1は、略語候補抽出の結果の一例である。この結果から、特徴的な略語を抽出出来ていることが分かる。表2は、略語候補抽出の対象を項目全体とした場合と出現項目判別機能を用いた場合の精度を表している。出現項目判別機能を用いて解析項目を限定した場合、F値0.76と項目全体を対象とした場合と比較して良好な結果を得ることができた。一方、全項目を対象とした場合、「ラーメン」を「ラーク メンソール」の略語候補と抽出するなど、原語の頭文字を含み似ている語を略語候補に挙げる誤抽出が多くみられた。このことから、略語候補を抽出するにあたり出現項目判別機能を用いることで、より精度の高い候補を求めることが可能と考えられる。これらの結果から、略語候補の抽出には出現項目判別機能を用いることで、精度の高い候補を抽出可能であることが分かった。

また、共通して精度を低下させる要因は、原語の頭文字が含まれない略語や原語には含まれない語句が用いられる略語であることが分かった。前者は、「マルボ

表1: 略語候補抽出処理の結果（一部抜粋）

抽出略語	原語
マイセン	マイルド セブン
マルライ	マルボロ ライト
マルメラ	マルボロ ライト メンソール
ゴルバ	ゴールデン バット
キャスマイ	キャスター マイルド

表2: 略語候補抽出処理の精度

	precision	recall	F-measure
項目全体	0.40	0.40	0.40
項目限定	0.74	0.79	0.76

ロ ブラック メンソール」に対して「ラーメン」と略される場合である。後者は、「マルボロ ライト」が「金マル」と略される事があるが、原語にない「金」という単語はパッケージの色によってもたらされている。

6 おわりに

本研究では、非行逸脱行為判定システムの全体構想を述べ、事前処理部の「出現項目判別機能」と「略語推定機能」の手法を提案した。評価実験の結果、プロフページの文章全体を用いた場合と比較し、略語候補を高精度に抽出できることが分かった。この結果から、本提案手法は、非行逸脱行為判定システムの略語候補抽出処理に有効であることが分かる。今後は評価実験にて明らかとなった原語の頭文字を含まない略語と原語に含まれない語句が用いられている略語の抽出の課題を解決した略語推定処理の実現に取り組む。

謝辞

本研究の一部は、平成21～22年度独立行政法人科学技術振興機構社会技術研究開発センター研究開発プログラム「犯罪からの子供の安全」(研究課題:「子どもの犯罪に関わる電子掲示板記事の収集・監視手法の検討」)から助成を受け、その成果を公表するものである。

参考文献

- [1] 下田博次：学校裏サイト，東洋経済進報社，2008
- [2] 下田博次：子供のインターネット利用問題解決のための社会システム開発，産学官連携ジャーナル，No.8, pp.29-31, 2009
- [3] 松葉達明，里見尚宏，榎井文人，河合敦夫，井須尚紀：学校非公式サイトにおける有害情報検出，言語理解とコミュニケーション研究会技術研究報告，電子情報通信学会，Vol.109, No.142, pp.93-98, 2009
- [4] Cortes, C. and Vapnik, V.: Support-Vector Networks, Machine Learning, Vol. 20, No.3, pp.273-297, 1995.
- [5] Cai, D., Yu, S., Wen, J. and Ma, W.: Vips: A Vision Based Page Segmentation Algorithm, Microsoft Technical Report, Microsoft, No.MSR-TR-2003-79, 2003.
- [6] 前略プロフィール：<http://pr.cgi boy.com/>