

E-002

## 実験的評価に基づくユーザ固有 Splog 空間の検証 -ユーザ適応型 Splog フィルタリングに向けて-

芳中 隆幸<sup>†</sup> 福原 知宏<sup>††</sup> 増田 英孝<sup>†</sup> 中川 裕志<sup>‡</sup><sup>†</sup>東京電機大学 未来科学部 <sup>††</sup>東京大学 人工物工学研究センター <sup>‡</sup>東京大学 情報基盤センター

### 1 はじめに

今日、ブログツールやブログサービスの普及に伴い、多くの人々がブログサイトを開設し、情報発信できるようになった。一方、ブログサイトの中には価値の低いブログサイト(スパムブログ, Splog(スプログ))が増加し、検索エンジンにおける不当な順位操作や検索結果における精度低下の原因となっている。

Kolariらは英語圏の Splog 空間について調査を行っている [1] が、日本語圏の Splog 空間は英語圏とは異なる傾向にある。また、日々新たな種類の Splog が出現し、いたちごっこ状態が続いており、効果的な Splog フィルタリングの実現には、Splog 空間についての十分な知見が必要である [2]。また、我々は万人に共通する Splog 空間と、ユーザごとに異なる Splog 空間の 2 種類が存在すると考えている。このため、Splog フィルタリングには、ほぼ普遍的であるが随時更新可能なフィルタリング部と個人適応型フィルタリング部が必要となる。

そこで、本稿では日本語圏の Splog 空間に関する基礎的な知見の獲得と、ユーザ固有のフィルタリングの必要性の検証を目標とし、Splog 空間調査支援システム SplogExplorer を開発した。本ツールは 3 つのサブシステムから構成されており、それぞれのサブシステムが Splog 空間を分析するために種々の機能を提供する。

本論文の構成は次の通りである。2 では、本稿で用いる Splog 定義について考察する。3 では、開発した SplogExplorer の機能とその利用方法について述べる。4 では、SplogExplorer を用いた Splog 定義検証実験を行った。最後に、5 では、本稿のまとめと今後の展開について述べる。

### 2 Splog 定義

この章では日本語圏における Splog 定義がどういったものかについて考察し、定義付けを行うことで、Splog 空間の実態を明確にする。

Experimental Study of Individual Splogosphere-Toward a Personalized Splog Filtering-

<sup>†</sup> Takayuki Yoshinaka

<sup>††</sup> Tomohiro Fukuhara

<sup>†</sup> Hidetaka Masuda

<sup>‡</sup> Hiroshi Nakagawa

Tokyo Denki University (†)

The University of Tokyo (††)

The University of Tokyo (‡)

### 2.1 日本語圏における Splog とその定義

Kolariらは研究における Splog 定義を Wikipedia<sup>†</sup>から採用している [3] が、本稿では、独自の Splog 定義を提案する。これは Splog フィルタリングを進めるにおいて、対象を明確化するという狙いがある。以下は、本稿で用いる Splog 定義である。

商品の宣伝や広告、アダルトコンテンツを含んだブログ記事を生成し、本来のブログ目的とは異なるアフィリエイト目的など、ユーザにとって決して有益でないと思われるブログ

また、この本 Splog 定義から考えられる、実際の日本語圏における Splog 空間に存在する Splog 例を以下に示す。

#### 1. アフィリエイト型 Splog

記事内に多数のアンカーテキストを含ませ、訪問ユーザにそのリンクを辿らせることでアフィリエイトとして発生する広告収入を得ることを目的としているブログサイト

#### 2. コピー&ペースト(コピペ)型 Splog

話題のホットトピックを含んだ記事を他サイトからコピー&ペーストすることで、サイトアクセスの誘導、アフィリエイトを目的とした順位操作を行う。コピー&ペーストという単純作業により記事の大量生成が可能といった特徴がある。

#### 3. ワードサラダ型 Splog

話題のホットトピックを含んだキーワードを使用して、文書としては成り立っているのだが文書自体には全く意味がない記事を生成しそれを記事として公開する。記事本文自体は自動で生成されているためこのワードサラダ型もコピー&ペースト型同様、記事を大量に生成することが可能。

この Splog 定義と Splog 例を本稿で用いる共通の Splog 定義とし研究を進めていくこととする。

### 3 調査支援システム:SplogExplorer

本稿では Splog 空間を調査、分析するために支援システム SplogExplorer を開発した。図 1 に SplogExplorer

<sup>†</sup> <http://wikipedia.org/>




図 1: SplogExplorer 全体構成図




図 3: SplogChecker ユーザインタフェース




図 2: SplogExplorer ユーザインタフェース

の全体構成図, 図 2 にユーザインタフェースを示す. 本システムは以下 3 つのサブシステム [2] で構成されており, それぞれのサブシステムが Splog 空間を調査, 支援するための機能を提供する. また, 本システムはユーザ固有の Splog 空間を確認するために, ユーザごとによる Splog 判定を行えるサブシステム SplogChecker を用意しており, ユーザはシステムにログインし各自で Splog 判定を行うことができる.

1. SplogAnalyzer

リンク数や文字数などの特徴量に着目した Splog 空間分析 [2] を様々な検索から行うことが可能なサブシステムである.

2. SameArticleIdentifier

コピー型 Splog の検知に特化したサブシステムである.

3. SplogChecker

効率的なデータセット作成支援を目的としたサブシステムである. ユーザ固有の Splog 空間を形成, 確認することができる.

以下データセットの説明後, 本稿では評価実験に用いる SplogChecker に焦点を絞って説明する.

3.1 データセット

本稿で使用するデータセットは 2007 年 4 月 30 日, 実際に Web 上で公開されたブログ記事 8462 件を使用する. 記事 8462 件に相当するサイト数は 5467 サイトである.

3.2 SplogChecker

SplogChecker(SC) システムは Splog の機械学習用データセット作成支援を目的としたシステムであり, ユーザ固有の Splog 空間を形成し, 確認することが可能なシステムとなっている. 研究を行う上で, Splog データセット作成という作業は必要不可欠かつ重要なプロセスである [5]. 図 3 に SplogChecker システムのユーザインタフェースを示す.

SC システムにはデータセット作成支援のために様々な機能が提供されており, その上でユーザ固有の Splog 空間を形成することができる. 以下に SC システムが提供する機能を示す.

1. Splog フラグ一括送信機能
2. アノテーション機能
3. 他ユーザとの情報共有機能
4. データセット内における Splog 空間情報

3.2.1 Splog フラグ一括送信機能

複数記事における判定フラグ情報を一括で送信できる機能である. 1 記事ごとにフラグを情報を送らなくて良いため効率の良いフラグ判定を行うことが可能となっている.

3.2.2 アノテーション機能

記事に対しコメントを付加できる機能である. 気になる記事, 判定が困難な記事に対しその旨を書き留めておくことが可能で, ユーザは SplogExplorer トップ画面 (図 2) で実際にコメントした記事を確認することができるためどの記事に対して, どのようなコメントをしたかが一目でわかるようになっている.

3.2.3 他ユーザとの情報共有機能

システム利用者が他ユーザと Splog 判定情報を共有できる機能である. この機能により, ユーザが判定に手間取っている, 困惑している時に他のユーザの情報を共有することで, 判定を効率的かつ正確に行うことを可能としている.

### 3.2.4 データセット内における Splog 空間情報

SplogAnalyzer システムでは検索結果において Splog 空間が持つ特徴量の統計情報を提示 [2] しているが、SC システムにおいては、データセット内全てにおける Splog 空間情報を一目で把握することができる。またデータセット内に現在どれくらいの Splog が存在しているかの割合情報も提示するためリアルタイムに Splog 空間情報を実感することが可能となっている。

## 4 評価実験：ユーザ固有 Splog 空間の検証

我々は Splog 定義というものが共通した一つの定義だけではなく個々のユーザごとに存在していると考えている。そのため本研究ではその存在の有無について証明、検証するために SplogChecker システムを用いた評価実験を行った。

以下、実験環境および実験方法について説明した後、結果と考察を述べる。

### 4.1 評価実験環境および実験方法

#### ● 被験者

実験を行う被験者は日常的に Web を利用している工学系学生 12 名で、男女比は 11:1、年齢は全員 20 代である。また、被験者へは事前に本稿 Splog 定義と実際の Splog 例についての説明を 10 分程度行った。

#### ● 評価実験に用いるブログ記事

被験者に判定してもらったブログ記事は 50 件で共通の範囲を設ける。また、共通記事 50 件の内容は我々が事前に選定し、その内訳を Splog:notSplog=35:15 とした。この 50 件の共通記事内には本稿で示した Splog 例（アフィリエイト型、コピー型、ワードサラダ型）も含まれている。

#### ● 実験方法

50 件の共通ブログ記事に対して被験者 12 名が SplogChecker システムを実際に使用して Splog か notSplog かのフラグ判定を記事に対して付与する。

### 4.2 評価実験結果

評価実験の結果としてまず、共通記事 50 件がそれぞれどのような割合で被験者 12 人に判定されたのかを図 4 に示す。この図 4 から、まずユーザ間において明確に判定が一致したブログ記事が存在していることがわかる。つまり被験者 12 人全員が「Splog」または「notSplog」と判定したブログ記事が図の両端に表れている。このような判定をされたブログ記事はユーザ間で定義に差異がないものと考えられる。つまり、ユーザ共通の定義と考えてよいブログ記事である。被験者 12 人全員が「Splog」と判定したブログ記事は全部で

7 件あり、アフィリエイト、アダルト系、出会い系のブログサイトであった。また、逆に 12 人全員が「notSplog」と判定したブログ記事は「日記」であり、全部で 1 件であった。

次に、判定が割れているブログ記事も存在しているということがわかる。図 4 の中央付近の円で囲んだ部分がそれに該当し、Splog:notSplog=6:6 となっているブログ記事のことである。本稿評価実験では事前に Splog 定義と Splog 例については被験者に説明してある。そのため、これら判定が割れたブログ記事はユーザ間において Splog に対する価値観や認識に差異があり、ユーザ固有に Splog 定義が存在しているという可能性を示している。判定が 50%に割れたブログ記事は全部で 3 件あり、それらのブログ記事はアフィリエイト型であった。アフィリエイト型にも関わらずこのような結果となった原因を以下に示す。

1. アフィリエイトであったにも関わらず、そのユーザにとっては真に必要な情報であったから
2. 被験者は判定したブログ記事をアフィリエイト型だと見抜けなかった（ブログサイトに騙された）

1 はたとえアフィリエイトブログ記事であっても、全てのユーザにとって、その記事が不要であるとは限らないことを示唆している。自分が得たい情報が得られるのであれば、そのユーザにとっては有用なブログ記事となる。このため、一律にアフィリエイト記事をフィルタリングして排除してしまうことには問題がある。逆に、ほとんどのユーザが通常のブログ記事であると判断したにも関わらず、あるユーザにとってはそれが Splog になるという事例もある。

2 は、ユーザがブログ記事を読んだだけではアフィリエイト目的であることが分からない場合があることを示している。このような場合には、Splog の特徴量 [2] を用いることによってユーザにアフィリエイトの危険があることを通知する機能が有効になる。

2 つ目の評価結果として各被験者ごとによる Splog 判定の記事数の分布を図 5 に示す。図 5 からユーザ間での Splog に対する評価は異なっている。共通記事 50 件のうちもっとも多く Splog と判定した被験者は 42 件もの Splog があると判定しているのに対して、最小では 17 件しか Splog としてのブログ記事はないと判定している被験者もいる。

これらの実験結果から、Splog の有効なフィルタリングには

1. ユーザに依存しない共通的なフィルタリング
2. ユーザに固有な個人適合可能なフィルタリング

の 2 種類が必要であることがわかる。




図 4: 共通記事 50 件の Splog:notSplog 判定割合




図 5: 被験者ごとによる Splog 判定記事数の分布

5 おわりに

本研究では,Splog 空間の性質を明らかにするために,複数ユーザが同一ブログ空間内にアクセスし,個々のブログ記事に対して各ユーザの Splog 判定を付与することができる SplogChecker システムを開発した. 12 名の被験者を用いた評価実験より,ユーザに依存しない Splog 空間が存在すると同時に個々のユーザの特性に依存する Splog 空間も存在することが確認できた. 今後は,本実験で得られた知見を元に,Splog の効率的なフィルタリング機能および,個人個人に適合可能なフィルタリング,そして,ブログ記事が Splog である可能性が高い場合にはユーザに通知するアラート機能を実現していく予定である.

参考文献

[1] Pranam Kolari, Akshay Java, Tim Finin, Tim Oates, and Anupam Joshi. Detecting spam blogs: A machine learning approach. *Ph.D. Dissertation*, Dec 2007.

[2] 芳中 隆幸, 福原 知宏, 増田 英孝, and 中川裕志. スパムブログに関する定量的調査支援ツールの開発. 情報処理学会第 70 回全国大会, March 2008. 5J-7.

[3] Pranam Kolari, Akshay Java, and Tim Finin. Characterizing the splogosphere. *Proceedings of the 3rd Annual Workshop on Weblogging Ecosystem: Aggregation, Analysis and Dynamics, 15th, World Wide Web Conference*, May 2006.

[4] 石田 和成. スパムブログの定量的調査と分離の試み. データベースと Web 情報システムに関するシンポジウム DBWeb2007, Nov 2007. 5B.

[5] 佐藤 有記, 宇津呂 武仁, 福原 知宏, 河田 容英, and 神門 典子. キーワードのバースト特性を利用したスパムブログデータセットの作成と分析. 情報処理学会第 70 回全国大会, March 2008. 5J-6.