Pengembangan Aplikasi Menghitung *Spam* Berbasis *Tag* pada Situs *Social Bookmarking* Menggunakan Metode *Spam Factor*: Studi Kasus *del.icio.us*

Application Development for Calculate Spam Based on Tag in Social Bookmarking site Using Spam Factor Method: Case Study del.icio.us

Arie Kurniawan, Dana Sulistyo Kusumo, S.T., M.T., Ph.D., Indra Lukmana S., S.T., M.T.

[123] Prodi S1 Teknik Informatika, Fakultas Informatika, Universitas Telkom.
[1]akarie@students.telkomuniversity.ac.id, [2]danakusumo@telkomuniversity.ac.id,
[3] indraluk@telkomuniversity.ac.id

Abstrak

Social Bookmarking **merupakan salah satu jenis** ***social tagging*** **yang digunakan untuk mengkategorisasikan sebuah tautan web. Dalam situs web** ***social bookmarking*** **seperti** ***del.icio.us*** **terdapat banyak** ***tag*** **yang digunakan oleh** ***user*** **untuk mengkategorisasikan atau merepresentasikan sebuah situs blog,** ***URL*** **dan tautan. Pada penelitian ini, sebuah** ***tag*** **mengandung** ***spam*** **apabila** ***tag*** **tersebut digunakan pada** ***bookmark*** **tetapi tidak mendeskripsikan konten / situs web** ***bookmark*** **tersebut. Ketika terjadi** ***spam*** **maka dapat terjadi ambiguitas karena penggunaan** ***tag*** **dalam sebuah** ***bookmark*** **yang tidak merepresentasikan** ***bookmark*** **tersebut. Dalam penelitian ini diimplementasikan metode** ***spam factor*** **untuk menghitung** ***spam*** **dari sebuah** ***tag*** **yang direpresentasikan dalam sebuah nilai. Untuk implementasi metode** ***spam factor*****, maka dibentuk daftar** ***tag*** **yang benar untuk setiap** ***bookmark,*** **membentuk** ***posting random good user*** **dan** ***posting random bad user,*** **mengimplementasikan** ***trusted moderator*** **untuk mendeteksi dan menghilangkan** ***posting*** **yang mengandung** ***spam,*** **dan mengurutkan pemakaian** ***tag*** **dan** ***bookmark*** **dengan** ***occurrence-based search*****. Metode** ***spam factor*** **menghitung nilai** ***spam*** **sebuah** ***tag*** **dari jumlah dan kesesuaian penggunaan** ***tag*** **tersebut dengan** ***bookmark*** **pada setiap** ***posting*****. Nilai yang dihasilkan dari** ***spam factor*** **berkisar 0-1 dimana semakin besar nilai yang didapatkan, maka semakin tinggi** ***tag*** **tersebut terindikasi** ***spam.*** **Dari penelitian ini dapat disimpulkan bahwa nilai** ***spam factor*** **yang dihasilkan lebih baik ketika menggunakan** ***trusted moderator*** **karena menghilangkan** ***spam*** **dari sistem.**

Kata kunci : tag, spam, social bookmarking, spam factor.

Abstract

Social bookmarking is a kind of social tagging that used for categorize a website. Social Bookmarking website such as del.icio.us, there's a lot of tag that user used to categorize or represent a blog, URL and link. In this research, a tag indicated spam if the tag used in a bookmark that not described bookmarks content or websites. If tag spam happened then ambiguities could happen too because the tag used but not represent the correct bookmarks. This research implement spam factor method that could count spam in a tag which is represented in score. Before implement spam factor method, first generate list of correct tags in each bookmark, then generate random good user posting and random bad user posting, implement trusted moderator which detected and removed posting that infected a spam, then rank each tag and bookmark with occurrence-based search method. This research use spam factor method for measure spam score on tag, score based on quantity and compatiblity of using a tag on a bookmark for every posting. Score for spam factor is between 0-1, the bigger score then the more tag indicated as spam. From this research we can conclude trusted moderator makes spam factor scores better because eliminating spam from system.

Keywords: tag, spam, social bookmarking, spam factor

1. Pendahuluan

1.1 Latar Belakang

Tag merupakan sebuah kata kunci, nama kategori ataupun *metadata* [1]. *Social Tagging* merupakan kegiatan pelabelan (*tagging)* bersama secara publik dan mengkategorisasikan sumber daya yang dapat dibagi (*resources sharing*) pada ruang lingkup daring [2]. Manfaat dari *tagging* juga sebagai alat komunikasi tentang informasi kontekstual dalam sebuah objek. Situs web *social bookmarking* merupakan salah satu contoh dalam pemanfaatan teknologi *social tagging* [3].

Dalam sebuah situs web *social bookmarking* seperti *del.icio.us* terdapat banyak *tag* yang digunakan oleh *user* untuk mengkategorisasikan atau merepresentasikan sebuah situs blog, *URL* dan tautan [2]. Apabila pengguna menggunakan *tag* berulang kali pada setiap situs yang sama maka akan menimbulkan *spam* pada *social tagging. Spam* pada *social tagging* juga dapat terjadi apabila pengguna memakai *tag* yang tidak mendeskripsikan konten dari sebuah situs *web* [4]. Apabila terjadi masalah dalam *tag* seperti *spam*, maka dapat terjadi ambiguitas karena penggunaan *tag* dalam sebuah *bookmark* yang tidak merepresentasikan *bookmark* tersebut. Hal tersebut dapat membuat *user* membutuhkan usaha yang lebih banyak ketika melakukan pencarian pada mesin pencari [3][5].

Dalam penelitian ini dikembangkan sebuah aplikasi yang dapat menghitung *spam* sebuah *tag* berdasarkan nilai *spam factor.* Penelitian ini menggunakan *dataset* situs *social bookmarking*, *del.icio.us*. *Dataset* yang digunakan berasal dari situs *Hetrec* dan tercantum pada *2nd International Workshop on Information Heterogeneity and Fusion in Recommender Systems (HetRec 2011)* [6].

Pada penelitian ini, sebuah *tag* mengandung *spam* apabila *tag* tersebut tidak digunakan pada *bookmark* yang benar karena setiap *bookmark* mempunyai daftar *tag* yang benar untuk *bookmark* tersebut [7][8]. Untuk mengetahui sebuah *tag* terindikasi *spam* atau tidak, akan dibentuk sebuah daftar kumpulan *tag* yang benar untuk setiap dokumen (*bookmark)* yang disebut dengan *S(d)* [7][8]. Setelah membentuk *S(d),* maka selanjutnya dibentuk *posting* dari *random good user model* dan *random bad user model*. Selanjutnya digunakan metode *trusted moderator* untuk menghilangkan *posting* yang terindikasi *spam* [7][8]. Setelah mengimplementasikan *trusted moderator,* kemudian *tag* dan *bookmark* diurutkan dengan metode *occurrence-based search.* Untuk perhitungan nilai *spam,* digunakan metode *spam factor* yang menghitung nilai *spam* sebuah *tag* dari kesesuaian penggunaan *tag* tersebut dengan *bookmark* pada setiap *posting* [7][8]. Apabila *tag* tersebut termasuk dalam kumpulan *tag* yang benar pada *bookmark* / *S(d)* maka tidak dianggap sebagai *spam* namun jika tidak termasuk dalam *S(d)* (*T* - *S(d)*) maka dianggap sebagai *spam*. Nilai yang dihasilkan dari *spam factor* berkisar 0 - 1 dimana semakin besar nilai yang didapatkan, maka *tag* semakin terindikasi *spam* [7][8].

1.2 Topik dan Batasannya

Terkait permasalahan yang dipaparkan, dirumuskan masalah yang diangkat dalam penelitian ini, yang pertama adalah bagaimana cara menghitung nilai *spam* pada sebuah *tag* ?. Yang kedua adalah bagaimana pengaruh *trusted moderator, tag budget,* fraksi *trusted moderator,* dan persentase *good user* terhadap nilai *spam factor* yang dihasilkan ?.

Untuk batasan masalah pada penelitian ini saat pembentukan daftar *tag* yang benar pada setiap *bookmark* / *S(d)* dibentuk secara acak dan *Dataset* yang digunakan merupakan *dataset* yang diunduh dari situs web http://grouplens.org/datasets/hetrec-2011/ dan menggunakan 3 *file* yaitu *file usertaggedbookmarks-timestamps.csv* untuk *dataset user*, *file tags.csv* untuk *dataset tag*, dan *file bookmarks.csv* untuk *dataset bookmark.*

1.3 Tujuan

Tujuan yang dicapai dalam penelitian ini, yaitu mengimplementasikan metode untuk mengetahui cara menghitung nilai *spam* pada sebuah *tag* dan mengetahu pengaruh *trusted moderator*, *tag budget,* fraksi *trusted moderator*, dan persentase *good user* terhadap nilai *spam factor* yang dihasilkan.

1.4 Metoda Penelitian

Dalam pengerjaaan penelitian ini terdapat beberapa metodologi penyelesaian masalah, yaitu :

1. Identifikasi Masalah

Pada tahap ini diidentifikasi permasalahan yang dipecahkan dalam penelitian ini, diantaranya membangun set *tag* yang benar (*S(d)*) pada sebuah dokumen (*bookmark*), menerapkan metode *trusted moderator,* dan menghitung *spam* dengan metode *spam factor*. Setelah masalah ditemukan kemudian menentukan rancangan sistem untuk mengatasi permasalahan tersebut.

2. Pengumpulan Data

Pada tahap ini penugumpulan data dilakukan dengan cara mencari *dataset* yang sesuai dengan kebutuhan pada sistem yang dibangun. Data yang dibutuhkan adalah data *user*, *tag* dan dokumen. Untuk data dokumen, karena studi kasus yang diangkat pada penelitian ini adalah situs *social bookmarking del.icio.us* maka dokumen dalam penelitian ini adalah sebuah *bookmark*.

3. Perancangan Sistem

Pada tahap ini dirancang sebuah sistem yang sesuai untuk menyelesaikan permasalahan yang telah diidentifikasi sebelumnya. Sistem yang dibangun meliputi *S(d), random good user model* dan *random bad user model, join random user, trusted moderator, occurrence-based search* dan *spam factor.*

4. Pengujian Sistem

Pada tahap ini sistem yang telah dirancang diuji sesuai dengan kebutuhan dan parameter – parameter yang telah ditetapkan untuk pengujian. Mengubah parameter pada sistem yang telah dibangun, implementasi metode *trusted moderator* dan menghitung nilai *spam* pada kumpulan *posting* dengan metode *spam factor.*

5. Analisis Hasil

Untuk analisis maka dibandingkan nilai *spam factor* pada kumpulan *posting* yang mengimplementasikan *trusted moderator* dan kumpulan *posting* yang tidak mengimplementasikan *trusted moderator*. Selain itu, analisis hasil juga membandingkan nilai *spam factor* apabila parameter – parameter pada *tagging system* diubah.

2. Dasar Teori dan Metodologi

2.1 *Tag*

Tag atau label merupakan sebuah kata kunci, nama kategori atau metadata. *Tag* merupakan kata kunci tekstual yang dibentuk secara bebas [1]. *Tag* dibentuk oleh seorang *user* dan tidak dibentuk oleh seseorang yang ahli pada bidang tersebut, sehingga tidak mengikuti acuan formal manapun.

2.2 *Social Tagging* dan *Social Bookmarking*

Social Tagging merupakan sebuah proses pengguna menambahkan sebuah *metadata* dalam bentuk kata kunci (*tag*) untuk membubuhi keterangan dan mengkategorisasikan kumpulan *item* informasi seperti lagu, gambar, tautan web, produk dan sebagainya [9]. *Social bookmarking* merupakan salah satu jenis *social tagging* yang digunakan untuk mengkategorisasikan sebuah tautan web atau *URL* [3].

2.3 Situs *Social Bookmarking del.icio.us*

Situs *del.icio.us* merupakan salah satu contoh *social tagging* dengan memanfaatkan situs *social bookmarking*. Situs *del.icio.us* digunakan untuk melakukan *bookmark* terhadap sebuah situs yang akan kita kunjungi kembali [10]. Untuk tampilan situs *del.icio.us* dapat dilihat pada gambar 2-1.

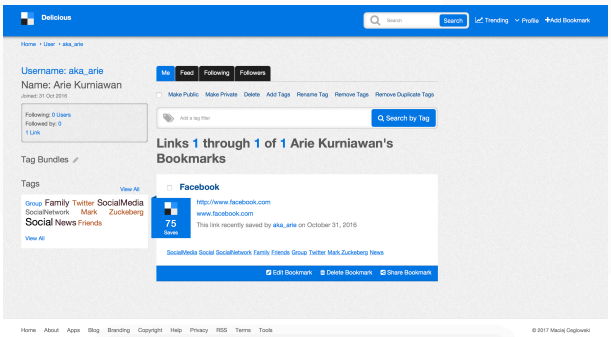

Gambar 2-1 Tampilan Home Del.icio.us

2.4 *Metadata*

Metadata merupakan pendefinisan data yang menyediakan informasi atau dokumentasi dari data lainnya yang diatur dalam aplikasi atau *environment* yang sama. Sebagai contoh, *metadata* akan mendokumentasikan data tentang elemen data atau atribut (nama, ukuran, tipe data, dan sebagainya) [11].

2.5 *Spam* dan *Spamming*

Spam adalah penyalahgunaan sistem kirim pesan pada elektronik untuk mengirimkan pesan dalam jumlah yang besar yang tidak diinginkan dan mengirimkan pesan tersebut secara acak [12]. Sedangkan *spamming* adalah kegiatan dalam menyebarkan konten yang tidak diinginkan dan tidak bersangkutan pada *e-mail, instant messaging,* halaman web, dan lainnya [13]. *Spam* dan *spamming* dapat terjadi pada media dan sarana apapun [12][13].

2.6 *Spam* pada *Social Tagging*

Spam pada *social tagging* merupakan salah satu masalah dalam pemanfaatan teknologi *social tagging* pada situs web *social bookmarking*. Situs *social bookmarking* seperti *del.icio.us* sangat rentan terhadap *spam* [10]. *Spam* dapat terjadi ketika terdapat *tag* yang menimbulkan ambiguitas karena pemakaian *tag* tersebut yang tidak merepresntasikan konten dari sebuah situs web [4]. Pada penelitian ini, sebuah *tag* mengandung *spam* apabila *tag* tersebut tidak digunakan pada *bookmark* yang benar karena setiap *bookmark* mempunyai daftar *tag* yang benar untuk *bookmark* tersebut [7][8].

2.7 *Tagging System Model* (Definisi *Posting* dan *S(d)*)

Untuk *Tagging System Model* terbuat dari kumpulan $\mathcal{D}$ / *d* yang berisikan dokumen (*bookmark*), kumpulan $\mathcal{T}$ / *t* atau *tag* dan kumpulan $\mathcal{U}$ / *u* yang berarti pengguna atau *user*, serta $\mathcal{P}$ untuk relasi *posting* dalam kumpulan elemen atau *tuple* [*u, d, t*] dalam *P* yang menunjukkan bahwa *user u* terdaftar pada *tag t* untuk *bookmark d* [7][8]. Contoh sebuah *posting* dideskripsikan pada tabel 2-1.

Tabel 2-1 Contoh *Posting*

User	***Bookmark***	***Tag***
1	San Francisco Symphony | Keeping Score: Revolutions in Music	Quality

Untuk setiap dokumen $d \in \mathcal{D}$ mempunyai set $S(d) \subseteq \mathcal{T}$ untuk *tag* yang yang betul-betul mendeskripsikan dan sesuai dengan *bookmark* tersebut, selain itu untuk *spam* dapat didefinisikan dalam $\mathcal{T} - S(d)$ dalam dokumen *d* [7][8]. Untuk *tag* yang benar / *S(d)* setiap dokumen (*bookmark)* dibentuk secara acak dan digunakan parameter untuk menentukan jumlah *tag* dalam setiap *S(d)* [8]. Untuk contoh *S(d)* dapat dilihat tabel 2-2.

Tabel 2-2 Contoh *S(d)*

Bookmark	***Tag***
San Francisco Symphony | Keeping Score: Revolutions in Music	Quality, share, dropbox, music

Setiap *posting* yang dihasilkan tiap *random user model* sesuai dengan *tag budget* yang telah ditentukan pada parameter. *Tag Budget* digunakan untuk membatasi seberapa banyak *posting* yang dihasilkan oleh seorang *user* pada setiap *random user model. User* pada penelitian ini dibedakan menjadi dua jenis yaitu pengguna baik atau *good user* (menggunakan *tag* sesuai dengan *bookmark / S(d*)) dan pengguna buruk atau *bad user* (menggunakan *tag* tidak sesuai dengan *bookmark* / $\mathcal{T} -$ *S(d*)). Untuk sistem ini maka *tag budget good user* disimbolkan dengan *pg* dan *tag budget bad user* disimbolkan dengan *pb* [8].

2.8 *Random User Model*

Random user model merupakan model dalam membangun sebuah *posting*. Untuk *random user model* diciptakan dua model, yaitu *Random Good User model* dan *Random Bad User model*. Untuk membangkitkan populasi *random good user* maka *tag* yang digunakan pada saat membentuk *posting* merupakan *tag* yang sesuai dengan *bookmark* / *S(d)* pada *posting* tersebut sedangkan untuk membangkitkan populasi *random bad user* maka saat membuat *posting* akan digunakan *tag* yang tidak sesuai dengan *bookmark* yang telah dipilih / $\mathcal{T} -$ *S(d*) pada *posting* tersebut [8].Untuk penggunaan *random user model* pengguna baik disimbolkan oleh G dan pengguna buruk disimbolkan oleh B, maka $\mathcal{U} = G \cup B$ tetapi $G \cap B = \emptyset$. Untuk menghasilkan / membangkitkan *posting* digunakan algoritma pembangkitan seperti yang dijelaskan pada algoritma 2.1 dan 2.2.

```
Random Good User Model
for each user u ∈ G do
        for each posting j = 1 to pg do
                select at random a document d from D;
                select at random a tag t from S(d);
                record the posting: user u tags d with t.        (2.1)

Random Bad User Model :
for each user u ∈ B do
        for each posting j = 1 to pb do
                select at random a document d from D;
                select at random an incorrect tag t from T − S(d);
                record the posting: user u tags d with t.        (2.2)
```

Keterangan :
u = User, B = Bad User, G = Good User, pg = tag budget untuk *good user, pb = tag budget* untuk *bad user, d =* dokumen yang dipilih, *D* = kumpulan dokumen, *t = tag, S(d) = tag* yang sesuai dengan *bookmark* pada *posting* tersebut*, T- S(d) = tag* yang tidak sesuai dengan *bookmark* pada *posting* tersebut

Untuk *Random Bad User Model* menghasilkan *posting* yang mengandung *spam* pada sistem [7][8].

2.9 Algoritma *Trusted Moderator*

Trusted Moderator dapat mengurangi *posting* buruk dengan mengecek *posting* dari pengguna. Sebuah *posting* dikatakan buruk jika merupakan *posting* yang dihasilkan oleh *random bad user model*. Algoritma ini

akan mendeteksi dan menghilangkan *spam* pada kumpulan *posting (*gabungan *posting random user)* sesuai dengan fraksi (*f)* yang telah ditetapkan pada parameter [7][8]. Fungsi dari algoritma *trusted moderator* dideskripsikan pada algoritma 2.3.

let Df ⊆ D containing a fraction f of D's documents;
for each document d ∈ Df do
for each incorrect posting [u, d, t]
*eliminate all entries [u, *, *].* (2.3)

2.10 Algoritma *Occurrence-Based Search*

Algoritma ini mengurutkan *tag* dan *bookmark* berdasarkan jumlah *tag* dan *bookmark* yang paling banyak digunakan pada kumpulan *posting* kemudian algoritma menampilkan semua hasil pencarian [7][8]. Selain itu pada penelitian ini, untuk algoritma *occurrence-based search* akan menampilkan detail dari *tag* dan *bookmark* yang dipakai. Model pencarian ini dideskripsikan pada algoritma 2.4.

Occurrence-Based Search:
rank documents by decreasing number of postings in P that contain t;
return top K documents. (2.4)

2.11 *Spam Factor*

Spam Factor digunakan untuk mengukur *spam* untuk setiap *tag (t)* [7][8]. Cara menghitung *spam* direpresentasikan dalam bentuk nilai yang dihitung pada persamaan 2.5.

$$SpamFactor\ (t) = \frac{\sum_{\forall d_i \in D_K} w(d_i) * \frac{1}{i}}{H_K} \quad (2.5)$$

dimana

$$D_K = [d1, d2, \ldots . dk], \text{dengan peringkat } (di - 1, t), 2 \leq i \leq K$$

K = Jumlah *Document*

dan

$$w(d_i) = \begin{cases} 1 \text{ ketika } d_i \text{ merupakan dokumen yang buruk} \\ 0 \text{ ketika } d_i \text{ merupakan dokumen yang baik} \end{cases}$$

dan H_K merupakan K^{th} *harmonic number* yang merupakan urutan dari penjumlahan jumlah parsial deret harmonik [14] dari jumlah kebalikan dari nilai awal K seperti dijelaskan pada persamaan 2.6.

$$H_K = \sum_{i\ \varepsilon\ [1..K]} \frac{1}{i} \quad (2.6)$$

Untuk perhitungan *spam factor* untuk setiap *tag,* diurutkan terlebih dahulu *bookmark* yang paling banyak menggunakan *tag* tersebut *(D_K).* Apabila terdapat penggunaan *tag* pada jumlah yang sama tetapi pada dokumen / *bookmark* yang berbeda maka akan diurutkan dokumen baik terlebih dahulu kemudian dokumen buruk [8]. Sebuah dokumen *d* dikatakan buruk jika *t* bukan *tag* yang benar dari *bookmark* atau dengan kata lain $t \notin S(d)$ dan sebaliknya. *Spam Factor* memberikan nilai *spam* setiap *tag*. Nilai dari *Spam Factor* berkisar antara 0 sampai 1 [7].

3. Pembahasan

3.1 Gambaran Umum Sistem

Sistem yang dibangun pada penelitian tugas akhir ini adalah sebuah sistem yang dapat menghitung nilai *spam* untuk setiap *tag* pada kumpulan *join posting*. Tahapan untuk membangun sistem ini terbagi atas enam proses utama, yaitu membentuk *S(d)*, membangkitkan *posting random good user model* dan *random bad user model, join random user model, trusted moderator*, *occurrence-based search*, dan *spam factor.* Pada gambar 3-1 merupakan *flow chart* dari gambaran umum sistem.

3.2 Parameter Pengujian

Parameter yang digunakan pada penilitan ini dapat dilihat pada tabel 3-1. Parameter ini merupakan parameter yang mengacu pada jurnal "*Combating spam in tagging systems: An evaluation*" [8]. Persentase *good user* ditentukan untuk menentukan seberapa banyak *good user* dari total *user. tag budget* ditentukan untuk jumlah *posting* setiap *user* pada jenis *posting.* Parameter *fair average* digunakan untuk menentukan apakah memukulratakan nilai *S(d)* atau tidak. Untuk *fair average* dapat bernilai *true* atau *false.*

Pada penelitian ini beberapa parameter bersifat *random* dalam implementasi maka model yang dibangun akan menggunakan iterasi. Iterasi dilakukan untuk mendapatkan nilai rata-rata dari semua nilai yang didapatkan, untuk penetapan jumlah iterasi sendiri dilakukan agar nilai analisis yang didapatkan lebih dari 1 kali. Pada penelitian ini tidak dihitung akurasi karena data yang digunakan pada penelitian sesuai dengan data yang dipilih pada *dataset* sehingga tidak akan terjadi kemunculan *data* diluar dari *dataset*.

Tabel 3-1 Parameter Pengujian

Simbol	Deskripsi
$\mathcal{D}$	Jumlah Dokumen / *bookmark*
T	Jumlah *tag*
$\mathcal{U}$	Jumlah *user*
G	Persentase *good user*
pg	*Tag budget good user (posting)*
pb	*Tag budget bad user (posting)*
s(d)	Ukuran *S(d)* tiap dokumen (*tag)*
fair average	Penentuan jumlah *S(d)* adil atau tidak *(true* atau *false)*
f	Persentase fraksi yang dicek oleh *trusted moderator*
i	iterasi / jumlah percobaan

3.3 Hasil Pengujian

Untuk hasil pengujian, diberikan beberapa skenario dengan nilai parameter yang berbeda. Untuk beberapa skenario diimplementasikan dua sistem, yaitu sistem yang menggunakan metode *trusted moderator* dan tidak menggunakan *trusted moderator*. Berikut beberapa pengujian dan skenario yang dihasilkan :

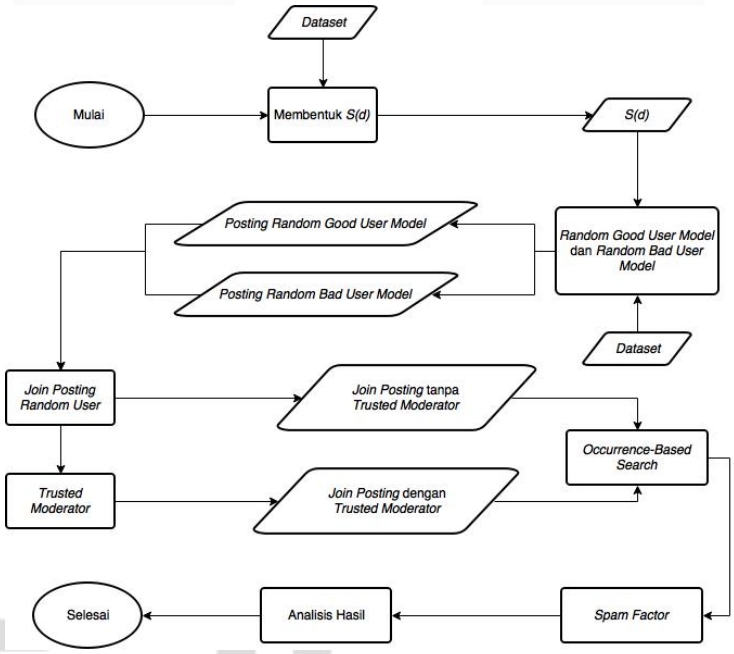

3-1 Gambaran Umum Sistem

3.3.1 Skenario 1 (Pengaruh *Trusted Moderator*)

Pada skenario pertama ini akan ditampilkan hasil *spam factor* sistem yang menggunakan *trusted moderator* dan sistem yang tidak memakai *trusted moderator*. Selain itu, tidak diperlihatkan hasil tiap prosesnya tetapi langsung ke *file summary* dan *file avg summary* dimana pada *file avg summary* tersebut akan menampilkan hasil akhir, seperti parameter yang digunakan, nilai maksimum dari semua iterasi, nilai minimum dari semua iterasi dan nilai *mean* dari jumlah nilai *mean* tiap iterasi. Untuk file avg_summary dijelaskan pada tabel 3-2

Tabel 3-2 *File Avg_Summary* Skenario 1

Parameter	dengan *trusted moderator*	tanpa *trusted moderator*
Total *User*	1.000	1.000
Total *Document*	10.000	10.000
Total *Tag*	500	500
Set Tag / S(d)	25	25
Fair_Average	*True*	*True*

Good User Percentage	90 %	90 %
Tag Budget Good User	10	10
Tag Budget Bad User	10	10
Trusted Moderator Fraction	5 %	5 %
Max Score	0.16	0.16
Min Score	0	0
Mean	0.0193	0.0299

Ketika sistem menggunakan *trusted moderator* maka nilai rata-rata *spam factor* dari tiap iterasi adalah 0.0193 sedangkan sistem tanpa *trusted moderator* 0.0299. Dapat disimpulkaan bahwa dengan menggunakan metode *trusted moderator* nilai *spam factor* yang dihasilkan akan berkurang sehingga indikasi sebuah *tag* bersifat *spam* dapat dikurangi.

3.3.2 Skenario 2 (Pengaruh *Tag Budget*)

Pada skenario ini menguji nilai *spam factor* ketika sistem menggunakan *trusted moderator* tetapi menggunakan *tag budget* yang berbeda. Dimana nilai *tag budget* yang dipakai adalah 20, 40, 60, dan 80. Selain itu *tag budget* ini berlaku untuk *good user* dan *bad user*. Nilai *spam factor* yang dibandingkan adalah nilai rata – rata *spam factor* 5 kali iterasi. Untuk hasil yang didapatkan, terdapat pada gambar 4-15. Untuk hasilnya dapat dilihat pada gambar 3-2.

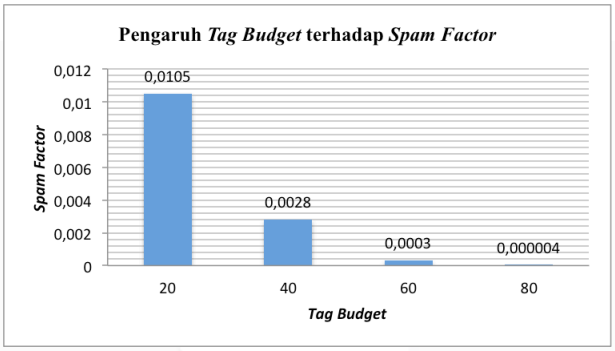

Gambar 3-2 Grafik nilai *spam factor* skenario 2

Pada hasil diatas memperlihatkan bahwa semakin besar nilai *tag budget* maka semakin kecil pula nilai *spam factor* yang dihasilkan, ini terjadi akibat *posting* yang dihasilkan oleh kedua jenis *user* bertambah dan khususnya untuk *good user* dimana semakin banyak *posting* yang *good user* hasilkan maka semakin banyak *posting* yang bersifat *good posting (spam free)*. Sebagai contoh pada parameter ini, digunakan *user* sebanyak 1.000, dimana persentase *good user* sebanyak 90 % (900 *user)*. Apabila *tag budget* sebesar 20 maka total *posting good user* adalah sebanyak 900 * 20 = 18.000 *posting*. Sedangkan untuk *posting bad user* hanya sebesar 2.000 posting (100 * 20 = 2.000). Sehingga ketika melakukan pencarian menggunakan *occurrence-based search* maka setiap *tag* lebih banyak berperan sebagai *posting good user*. Ketika populasi *posting good user* lebih banyak maka ketika melakukan perhitungan *spam factor* nilai yang dihasilkan lebih kecil karena *good document* lebih banyak ditemukan.

3.3.3 Skenario 3 (Pengaruh fraksi *Trusted Moderator*)

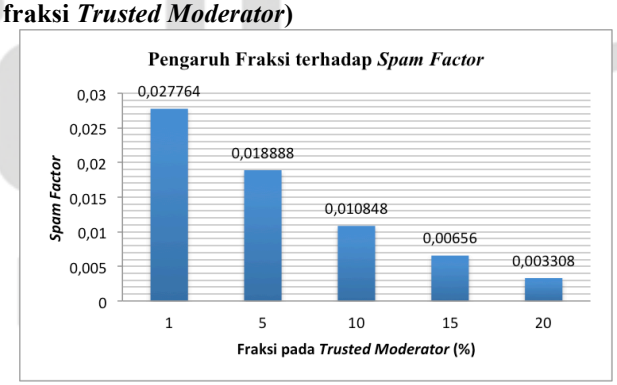

Gambar 3-3 Grafik nilai *spam factor* skenario 3

Skenario ketiga ini menggunakan parameter skenario pertama dan menggunakan fraksi 1 %, 5 %, 10 %, 15 %, 20 %, dan 50 %. Hasil nilai *spam factor* yang didapatkan dipaparkan pada gambar 3-3.

Semakin besar persentase fraksi maka semakin kecil nilai *spam factor* yang dihasilkan atau dengan kata lain, sistem akan semakin terbebas dari *spam*. Hal tersebut membuktikan bahwa semakin besar nilai fraksi yang "dicek" oleh *trusted moderator* maka semakin besar peluang *posting bad user* akan ditemukan dan dihapus dari sistem sehingga membuat nilai *spam factor* semakin kecil.

3.3.4 Skenario 4 (Pengaruh persentase *good user*)

Untuk skenario keempat akan diuji ketika nilai persentase *good user* sebesar 90%, sebesar 50 % atau dengan kata lain persentase *good user* dan *bad user* sama dan ketika persentase *good user* hanya sebesar 10 %.

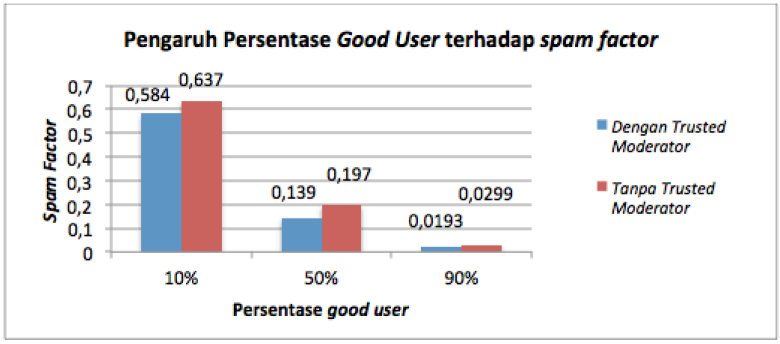

Gambar 3-4 Grafik nilai *spam factor* skenario 4

Dari gambar 3-4 diketahui bahwa semakin kecil persentase *good user* maka nilai *spam factor* yang dihasilkan semakin besar. Untuk penjelasan hal tersebut diberikan contoh ketika sistem menggunakan *trusted moderator* dan persentase *good user* sebesar 50 %. Ketika persentase *good user* 50 % maka jumlah *bad user* dan *good user* sama yaitu 500 *user* (total 1000 *user*) sehingga setiap *good user* dan *bad user* mempunyai jumlah *posting* yang sama yaitu sebesar 5.000 *posting* (*user* * *tag budget*). Pada iterasi - 1 didapatkan 218 *bad user* berbeda dalam fraksi, jika 1 *bad user* menghasilkan 10 *posting* maka sistem menghilangkan 2.180 *posting* dari total 5.000 *posting bad user* (43,6 %). Berbeda ketika persentase *good user* 90 % (skenario 1), pada iterasi - 1 ditemukan 35 *bad user* berbeda dalam fraksi, jika 1 *bad user* menghasilkan 10 *posting* maka dihilangkan 350 *posting* dari total 1.000 *posting bad user* (35 %). Untuk penetuan jumlah *bad user* yang didapatkan, dilakukan dengan cara mengurangi jumlah awal *posting* pada *file join posting random user* dengan *file result trusted moderator* yang merupakan *posting* setelah sistem melalui proses *trusted moderator*.

Meskipun secara persentase, ketika persentase *good user* 50 %, lebih besar dalam mengurangi *bad user posting* tetapi secara keseluruhan berbeda karena pada sistem dengan persentase *good user* 50 %, jumlah *bad user posting* setelah menggunakan *trusted moderator* tersisa sebesar 2.820 *posting bad user* (282 *bad user*) dari total 7.820 *posting* (36 % dari total *posting*) sedangkan pada skenario pertama tersisa sebesar 650 *posting bad user* (65 *bad user*) dari total 9.650 *posting* (6,75 % dari total *posting)*. Secara keseluruhan jumlah *posting bad user* sistem dengan persentase *good user* 50 % lebih banyak sehingga menghasilkan nilai *spam factor* lebih besar.

3.3.5 Skenario 5 (Percobaan *G* = 50 % & jumlah *pb* > *pg*)

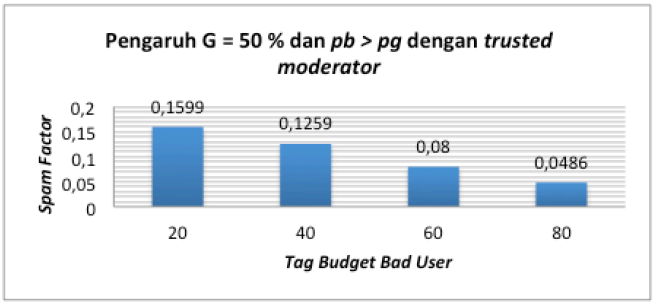

Gambar 3-5 Grafik nilai *spam factor* skenario 5 sistem dengan *trusted moderator*

Pada gambar 3-5 diketahui bahwa nilai *spam factor* dari sistem yang menggunakan *trusted moderator* semakin kecil ketika *tag budget bad user* semakin besar meskipun persentase *good user* sebesar 50 % (*bad user* 50 %). Sebagai contoh ketika *pb* = 20 pada iterasi - 1, dari 500 *bad user* maka jumlah *posting* yang didapatkan sebesar 10.000 *posting* (500 *bad user* * 20 *tag budget*). Meskipun jumlah *posting bad user* 66,66 % dari total *posting* (15.000 *posting)* tetapi pada saat digunakan *trusted moderator* terpilih sebanyak 329 *bad user* berbeda

dalam fraksi. Jika *pb* = 20, maka terdapat 6.580 *posting* yang dihilangkan atau sekitar 65,8 % dari total *posting bad user*. Setelah melalui *trusted moderator* maka tersisa sekitar 8.420 *posting*. Dari total *posting* tersebut, tersisa 3.420 *posting bad user* dari 171 *bad user* (40,6 % *posting bad user* dari seluruh *posting*).

Selanjutnya ketika *pb* = 40 pada iterasi – 2, dari 500 *bad user* maka jumlah *posting* yang didapatkan sebesar 20.000 *posting* (500 *bad user* * 40 *tag budget*). Jumlah *posting bad user* 80 % dari total *posting* (25.000 *posting)* tetapi pada saat digunakan *trusted moderator* terpilih sebanyak 438 *bad user* berbeda dalam fraksi. Jika *pb* = 40, maka terdapat 17.520 *posting* yang dihilangkan atau sekitar 87,6 % dari total *posting bad user*. Setelah melalui *trusted moderator* maka tersisa sekitar 7.480 *posting*. Dari total *posting* tersebut, tersisa 2.480 *posting bad user* dari 62 *bad user* (33,15 % *posting bad user* dari seluruh *posting*).

Dari persentase yang didapatkan dari kedua *tag budget* tersebut maka dapat disimpulkan ketika *tag budget* semakin besar maka persentase hilangnya *posting bad user* dalam sistem semakin besar. Hal ini terjadi karena metode *trusted moderator* mendeteksi *bad user* lebih banyak ketika *tag budget* bertambah atau secara keseluruhan persentase *posting bad user* yang dihilangkan lebih besar dari total *posting,* terbukti pada saat *tag budget* = 20, maka sistem memiliki 40,6 % *posting* yang bersifat *spam* (65,8 % *posting bad user* dihilangkan) dan pada saat *tag budget* = 40, sistem hanya memiliki 33,15 % *posting* bersifat *spam* (87,6 % *posting bad user* dihilangkan). Nilai *spam factor* pada saat tidak menggunakan *trusted moderator* dideskripsikan pada gambar 3-6.

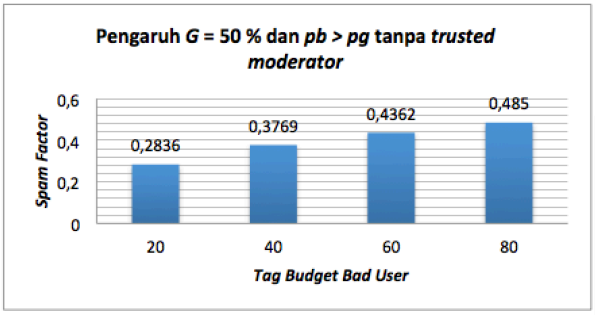

Gambar 3-6 Grafik nilai *spam factor* skenario 5 sistem tanpa *trusted moderator*

Ketika tidak menggunakan *trusted moderator* nilai yang dihasilkan bertambah seiring bertambahnya *tag budget*. Ini diakibatkan karena populasi dari *posting bad user* semakin banyak. Sebagai contoh ketika *tag budget bad user* = 20 maka *posting bad user* sebanyak 10.000 *posting* atau sekitar 66,66 % dari total *posting* (total *posting* 15.000). Ketika *trusted moderator* tidak digunakan maka *posting bad user* tidak dapat dikurangi sehingga nilai *spam factor* yang dihasilkan sesuai dengan persentase *posting bad user* dari total *posting*.

4. Kesimpulan

Berdasarkan hasil pengujian dan analisis pada penelitian ini, maka dapat diambil beberapa kesimpulan sebagai berikut :

1. Untuk menghitung nilai *spam* untuk setiap *tag* maka digunakan *spam factor*. Untuk mengimplementasikan *spam factor* maka dibangun sebuah sistem yang membangun *s(d)* untuk setiap *bookmark*. Setelah membentuk *s(d)* maka dibentuk *posting* dari *random good user* dan *random bad user*. Setelah membentuk *posting* kemudian dilakukan *join posting*. Kemudian digunakan metode *trusted moderator* dimana setiap *posting* yang terdeteksi dan dihasilkan oleh *bad user* dihilangkan dari *join posting*. Setelah itu dilakukan *occurrence-based search* dimana metode tersebut melakukan pemeringkatan untuk setiap *tag* dan *bookmark* berdasarkan intensitas pemakainnya.
2. Nilai *spam factor* yang dihasilkan bervariasi dan bergantung pada pemakaian *trusted moderator* dan parameter yang digunakan. Ketika sistem menggunakan *trusted moderator* maka nilai *spam factor* yang dihasilkan lebih kecil dibandingkan sistem yang tidak menggunakan *trusted moderator*. Semakin besar nilai fraksi *trusted moderator* yang digunakan maka semakin kecil nilai *spam factor* yang dihasilkan.
3. Untuk parameter *tag budget,* ketika sistem menggunakan *trusted moderator,* persentase *good user* sebanyak 90 % dan *tag budget good user* dan *bad user* sama, maka menghasilkan nilai yang semakin kecil seiring bertambahnya nilai dari *tag budget*.
4. Untuk persentase *good user* ketika *tag budget good user* sama dengan *tag budget bad user* maka nilai *spam factor* yang dihasilkan akan semakin kecil seiring dengan bertambahnya persentase *good user* baik sistem dengan *trusted moderator* maupun tidak.
5. Nilai *spam factor* ketika *tag budget good user* < *tag budget bad user* dan persentase *good user* 50 % bergantung pada pemakaian *trusted moderator*. Ketika sistem menggunakan *trusted moderator* maka nilai yang dihasilkan akan semakin kecil seiring dengan bertambahnya *tag budget*. Tetapi jika tidak menggunakan *trusted moderator,* nilai *spam factor* bertambah seiring dengan bertambahnya *tag budget.*

5.2 Saran

Berikut ini adalah beberapa saran dari penulis untuk pengembangan penelitian ini ke depannya :

1. Sebaiknya menggunakan *dataset* yang mempunyai data *S(d)* untuk setiap *bookmark* (tidak dibangun secara acak) sehingga hasil nilai *spam factor* yang didapatkan dapat dianalisis untuk rekomendasi pemakaian *tag* yang benar untuk sebuah *bookmark*.
2. *Dataset* (*user, bookmark,* dan *tag*) dapat ditambahkan ke dalam skala yang lebih besar.

Daftar Pustaka

[1] Guy, M., & Tonkin, E. (2006). Tidying up tags. D-lib Magazine, 12(1), 1082-9873.
[2] Trant, J. (2009). Studying social tagging and folksonomy: A review and framework. Journal of Digital Information, 10(1).
[3] Gupta, M., Li, R., Yin, Z., & Han, J. (2010). Survey on social tagging techniques. ACM Sigkdd Explorations Newsletter, 12(1), 58-72.
[4] Heymann, P., Koutrika, G., & Garcia-Molina, H. (2008, February). Can social bookmarking improve web search?. In Proceedings of the 2008 International Conference on Web Search and Data Mining (pp. 195-206). ACM.
[5] Song, Y., Zhuang, Z., Li, H., Zhao, Q., Li, J., Lee, W. C., & Giles, C. L. (2008, July). Real-time automatic tag recommendation. In Proceedings of the 31st annual international ACM SIGIR conference on Research and development in information retrieval (pp. 515-522). ACM.
[6] Cantador, I., Brusilovsky, P. L., & Kuflik, T. (2011). Second workshop on information heterogeneity and fusion in recommender systems (HetRec2011).
[7] Koutrika, G., Effendi, F. A., Gyöngyi, Z., Heymann, P., & Garcia-Molina, H. (2007, May). Combating spam in tagging systems. In Proceedings of the 3rd international workshop on Adversarial information retrieval on the web (pp. 57-64). ACM.
[8] Koutrika, G., Effendi, F. A., Gyöngyi, Z., Heymann, P., & Garcia-Molina, H. (2008). Combating spam in tagging systems: An evaluation. ACM Transactions on the Web (TWEB), 2(4), 22.
[9] Symeonidis, P., Nanopoulos, A., & Manolopoulos, Y. (2008, October). Tag recommendations based on tensor dimensionality reduction. In Proceedings of the 2008 ACM conference on Recommender systems (pp. 43-50). ACM.
[10] Wetzker, R., Zimmermann, C., & Bauckhage, C. (2008, July). Analyzing social bookmarking systems: A del. icio. us cookbook. In Proceedings of the ECAI 2008 Mining Social Data Workshop (pp. 26-30).
[11] Rosenfeld, L., & Morville, P. (2002). Information architecture for the world wide web. " O'Reilly Media, Inc.".
[12] Whitworth, B., & Whitworth, E. (2004). Spam and the social-technical gap. *Computer*, *37*(10), 38-45.
[13] Hayati, P., Potdar, V., Talevski, A., Firoozeh, N., Sarenche, S., & Yeganeh, E. A. (2010, April). Definition of spam 2.0: New spamming boom. In *4th IEEE International Conference on Digital Ecosystems and Technologies* (pp. 580-584). IEEE.
[14] Rochowicz Jr, J. A. (2015). Harmonic Numbers: Insights, Approximations and Applications. Spreadsheets in Education (eJSiE), 8(2), 4.