

ソーシャルブックマークデータの 時間情報を用いた 情報フィルタリングと検索

慶應義塾大学 大学院

政策・メディア研究科

修士課程1年

上野 大樹

私、発表者について

- 修士入学当初からSBM関連の研究に関わる
- 当初、SBMデータを利用したWebページレコメンド及び視覚化の研究を実施
- 現在は、SBMデータを利用したWebページ検索関係の研究を実施

- Twitter: wilfue
- はてなID: kashihara1


目次

- ➡ 1. SBM研究全般について
- 2. 本研究背景
- 3. SBMデータ分析
- 4. セレクトブックマの開発
- 5. セレクトブックマの実験・評価
- 6. おまけ

SBM研究の種類

- SBM、FolkSonomyの分析
- Webページ推薦
- ブックマーカーの発見


• Webページ検索




本研究の位置づけ

SBM、FolkSonomyの分析

Golder,2005 "The Structure of Collaborate Tagging System"


- 
- ・ユーザ、タグ、ブックマークの性質について分析
 - ・各Webページに対する各タグの出現頻度は一定値に収束

川中,2008 “ソーシャルブックマークにおけるタグの時系列的な依存関係の解析”


- 
- ・あるタグと共起関係の強いタグを取得し、出現時期の早いほうを親タグとする
 - ・タグの時系列の関係性をグラフ化

Webページ推薦

Niwa,2006 “Web page recommender system based on folksonomy mining”


- 
- ・クラスタリングによりタグの表記のゆれの問題を解決
 - ・ユーザのブックマ情報からユーザの趣向に沿ったページを推薦

Sasaki,2006 “Web Content Recommendation System based on Similarities among Contents Cluster of Social Bookmark”

- 
- ・タグではなくコンテンツクラスタを利用したWebページの推薦
- ※第1回SBM研究会で発表


ブックマーカーの発見

Shiratsuchi,2006 “Finding unknown interests utilizing the wisdom of crowds in a social bookmark service”



- ・指定したユーザと類似した嗜好を持つブックマーカーの推薦
- ・類似した嗜好を持つブックマーカーの関係性のグラフ化

百田,2008 “ソーシャルブックマークに基づく情報発見”



- ・ α ブックマーカーの発見
- ・ α ブックマーカーを利用したWebページの推薦

Webページ検索

山家,2007 “ソーシャルブックマークの特性を利用したWeb
検索ランキング精度の向上”


- PageRankとSBRank(ブックマ数の多さ)を融合し、
PageRankの検索精度の向上を計っている

Xu,2008 “Exploring Folksonomy for Personalized Search”

- 質問の期間ベクトルと文書の期間ベクトルのコサイン類似
度を利用

目次

1. SBM研究全般について

 2. 本研究背景

3. SBMデータ分析

4. セレクトブックマの開発

5. セレクトブックマの実験・評価

6. おまけ

背景

- インターネット上の情報爆発が問題となっている
- Googleなどが利用しているPageRank
- ➡ blogやwikiなど自動的にページ間を結びつける場合、人々の意思が反映されるとは限らない

- 良サービス、良コンテンツ発見のためには
 - 目的外のページが引っかかり、Webサイト発見が面倒
 - 高い検索リテラシーが必要
 - そもそも良コンテンツ・サービスの存在に気付けない
- ➡ 知人からの紹介で気付く場合も・・・
 - RSSリーダー、SBMトップは定期的なチェックが手間

そこで

- 集合知であるSBMデータを用いた情報検索
 - 検索リテラシーを不要としたWebページの発見
 - 不要な情報をフィルタリングして取得

WHY?

- 皆が選んだ情報は、大多数の人にとって有用
- 人手による情報フィルタリングの有用性
- 他人が発見した有益な情報の発見


ただし

- SBMのブックマ数には特徴がある
 - ・トップに表示される人気のエントリーに入るとブックマ数が急激に上昇
 - ・単にブックマ数の多いページほど有用であるか？
 - ・一時的にブックマ数が増えたページが後で見ても有用かどうか？
- 各SBMによって偏りもある
- 情報検索のためのデータ数は十分か？

目次

1. SBM研究全般について

2. 本研究背景

 3. SBMデータ分析

4. セレクトブックマの開発


5. セレクトブックマの実験・評価

6. おまけ

ブックマ数と時間の関係をグラフ化したところ・・・


- 以下3つのタイプのページが存在
 - 1. 一時的に急激にブックマされ、その後はあまりブックマされないタイプのページ
 - 2. 急激にブックマ数が増える時期はあるが、長い間ブックマされ続けるページ
 - 3. 急激にブックマ数が増える時期がなく、長い間ブックマされ続けるページ

ブックマ数と時間の関係1




一時的に急激にブックマされ、
その後はあまりブックマされないタイプのページ

ブックマ数と時間の関係2



急激にブックマ数が増える時期はあるが、
長い間ブックマされ続けるページ

ブックマ数と時間の関係3



急激にブックマ数が増える時期がなく、
長い間ブックマされ続けるページ

時間情報に着目した仮説

以上の1～3のタイプのページを2つに集約

- 一時的に急激にブックマされ、その後にはブックマされないタイプのページ (Type I)

➡ 一時的に必要とされる情報

- 長期間に渡ってブックマされるタイプのページ (Type II)

➡ 長期的に必要とされる情報


時間情報に基づきWebページの種類を分析

ブックマ数100以上のページをランダムに100ページずつ取得


Type I : ブクマされた日数/ブックマ数=0.2以下

Type II : ブクマされた日数/ブックマ数=0.8以上

Type I のページ分析結果



Type II のページ分析結果



分析結果より

Type I とType II で全く異なった種類のWebページ

- 一時的に急激にブックマされ、その後にはブックマされないタイプのページ (Type I)

➡ 一度読んだら終わりのページが多い

- 長期間に渡ってブックマされるタイプのページ (Type II)

➡ 何度も利用するタイプのページが多い


Type I とType II を分類することにより、不要な種類のページをフィルタリングできる

目次

1. SBM研究全般について

2. 本研究背景

3. SBMデータ分析


 4. セレクトブックマの開発

5. セレクトブックマの実験・評価

6. おまけ

セレクトブックマの開発

- 長期間に渡ってブックマされるタイプのページ(Type II)を優先的に取得
- タグごとに検索



抽出

- 利用シーンが特定の、一時的、暫定的のページをフィルタリング
- 何度も利用するタイプのページ

セレクトブックマ(利用データ)


- はてなブックマークのデータを利用
- 2005年2月～2008年8月のデータ
- ブクマ数5以上の全てのページ

はてなの伊藤直也様には
大変お世話になりました！

セレクトブックマ(収集データ概要)

- 以下の6種類のデータを収集
 1. URL
 2. タイトル
 3. ブクマ数
 4. 時間情報(ブックマした日付)
 5. ユーザID(ブックマしたユーザID)
 6. タグ(ブックマしたユーザに紐付くタグ名)

DBに収集



約70万URL

約2000万レコード

セレクトブックマ(ランキングロジック)

指定したタグにおいての


ポイント=ブックマ数×日数^α (α=0,1,2で実験)

※ポイントが高いものから順にランキング

※日数とは

例:2006/8/3、2006/8/6,2007/3/5にブックマされた
ら3日

目次

1. SBM研究全般について
2. 本研究背景
3. SBMデータ分析
4. セレクトブックマの開発
-  5. セレクトブックマの実験・評価
6. おまけ

Google検索との比較(「java」で検索)

順位	Google検索	セレクトブックマ($\alpha=1$)
1	Java.com:あなたとJava	Javaの道(Java入門:リファレンス)
2	無料 Java ソフトウェアをダウンロード - Sun Microsystems	Javaの学習なら、JavaDrive
3	テクノロジー - サン・マイクロシステムズ	Java技術最前線:ITpro
4	Java - WikipediaJava	浅煎り珈琲-Java アプリケーション入門
5	ノーブラシ洗車場のJAVA	頑健なJavaプログラムの書き方 (Writing Robust Java Code)
6	Javaの道(Java入門:リファレンス)	Java House ML
7	Java Solution - @IT	JavaでHello World
8	Javaとは-はてなキーワード	Java 2 Platform SE 5.0
9	Javaとは-意味・解説:IT用語辞典	Java in the Box
10	JAVA動物実験の廃止を求める会	Log4J徹底解説～目次

Google検索との比較(「ui」で検索)

順位	Google検索	セレクトブックマ($\alpha=1$)
1	ユーザインタフェース - Wikipedia	ユーザーインターフェースデザイン研究室
2	ユーザインターフェースとは【user interface】 - 意味・解説 : IT用語辞典	Technologies for UI
3	UIとは【ユーザインターフェース】 - 意味・解説 : IT用語辞典	@IT: Webアプリケーションのユーザーインターフェイス[1]-1
4	UI ゼンセン同盟	ソシオメディア UIデザインパターン
5	UI - Wikipedia	アップル ヒューマンインタフェースガイドライン
6	「使える、使いやすい、使いたい」と思えるUIとは? - @IT	Joel on Software - 環境をコントロールできれば楽しく感じるもの
7	ソシオメディアー UI デザインパターン	Yahoo! Design Pattern Library
8	UI パターンいろいろ- Design-Walker	ダメなユーザインタフェース講座
9	MOONGIFT: ≫ Prototype.js を用いたUIライブラリ「PrototypeUI」:オープンソースを毎日紹介	使える GUI デザイン
10	Google Japan Blog: Gmail モバイルのUIを刷新しました	80年代のAppleに学ぶUIの部品化とガイドライン? @IT

時間情報利用によるフィルタリング効果(「java」タグ)

順位	ブックマ数の多い順($\alpha=0$)	セレクトブックマ($\alpha=1$)
1	Java のクラスアンロード(Class Unloading)	Javaの道(Java入門:リファレンス)
2	Java の道(Java 入門・リファレンス)	Javaの学習なら、JavaDrive
3	頑健なJava プログラムの書き方 (Writing Robust Java Code)	Java技術最前線:ITpro
4	Java 技術最前線:ITpro	浅煎り珈琲-Java アプリケーション入門
5	Java の学習ならJavaDrive	頑健なJavaプログラムの書き方(Writing Robust Java Code)
6	浅煎り珈琲-Java アプリケーション入門	Java House ML
7	Java でHello World	JavaでHello World
8	Java 2 Platform SE 5.0	Java 2 Platform SE 5.0
9	【レポート】Java 初学者には最適!? 解説から 実行までブラウザでコンプリート- Javala (MYCOMジャーナル)	Java in the Box
10	Java House ML	Log4J徹底解説～目次

時間情報利用によるフィルタリング効果(「ui」タグ)

順位	ブックマ数の多い順($\alpha=0$)	セレクトブックマ($\alpha=1$)
1	Life is beautiful:直感的なUIとhande-eye-cordinationの話	ユーザーインターフェースデザイン研究室
2	直感的なインタフェースをめざして	Technologies for UI
3	ぼくはまちちゃん！(Hatena) - UIについて思うこと	@IT: Webアプリケーションのユーザーインターフェイス[1]-1
4	ユーザーインターフェースデザイン研究室	ソシオメディア UIデザインパターン
5	prima materia diary - Google のUI は OK/キャンセルを訊いてこない	アップル ヒューマンインタフェースガイドライン
6	80年代のAppleに学ぶUIの部品化とガイドライン? @ITW	Joel on Software - 環境をコントロールできれば楽しく感じるもの
7	naoyaのはてなダイアリー - インタフェースの話	Yahoo! Design Pattern Library
8	キャズムを超えろ！ - 家電メーカーよ、今すぐその時代遅れのUIから脱却せよ	ダメなユーザインタフェース講座
9	Life is beautiful: ユーザー・インターフェイスの設計に大切なのはデザイン・ポリシー	使える GUI デザイン
10	Technologies for UI	80年代のAppleに学ぶUIの部品化とガイドライン? @IT

$\alpha=1$ と2の場合の比較(「java」タグ)

順位	セレクトブックマ($\alpha=1$)	セレクトブックマ($\alpha=2$)
1	Javaの道(Java入門:リファレンス)	Javaの道(Java入門:リファレンス)
2	Javaの学習なら、JavaDrive	Javaの学習なら、JavaDrive
3	Java技術最前線:ITpro	Java技術最前線:ITpro
4	浅煎り珈琲-Java アプリケーション入門	浅煎り珈琲-Java アプリケーション入門
5	頑健なJavaプログラムの書き方(Writing Robust Java Code)	Java House ML
6	Java House ML	JavaでHello World
7	JavaでHello World	Java 2 Platform SE 5.0
8	Java 2 Platform SE 5.0	頑健なJavaプログラムの書き方(Writing Robust Java Code)
9	Java in the Box	Java in the Box
10	Log4J徹底解説～目次	Log4J徹底解説～目次

$\alpha=1$ と2の場合の比較(「ui」タグ)

順位	セレクトブックマ($\alpha=1$)	セレクトブックマ($\alpha=2$)
1	ユーザーインターフェースデザイン研究室	ソシオメディア UIデザインパターン 最新のUIデザインパターン
2	Technologies for UI	UI-patterns.com
3	@IT: Webアプリケーションのユーザーインターフェイス[1]-1	ユーザーインターフェースデザイン研究室
4	ソシオメディア UIデザインパターン	@IT: Webアプリケーションのユーザーインターフェイス[1]-1
5	アップル ヒューマンインタフェースガイドライン	Technologies for UI
6	Joel on Software - 環境をコントロールできれば楽しく感じるもの	ソシオメディア UIデザインパターン
7	Yahoo! Design Pattern Library	Joel on Software - 環境をコントロールできれば楽しく感じるもの
8	ダメなユーザインタフェイス講座	Yahoo! Design Pattern Library
9	使える GUI デザイン	ダメなユーザインタフェイス講座
10	80年代のAppleに学ぶUIの部品化とガイドライン? @IT	アップル ヒューマンインタフェースガイドライン

セレクトブックマ β 版公開中

- セレクトブックマで検索
- URLは以下

<http://plazman.chi.mag.keio.ac.jp/sbm/summary.jsp>

- 明日(12/7(日))は、サーバ停止のため利用不可

セレクトブックマ(アンケート結果)

- アンケート調査を実施
- 合計14人が回答
- 有用なページ発見: 10人／14人
- 面白いページ発見: 10人／14人

セレクトブックマ(考察)

- ブクマ数の多いタグによる1単語検索で有用
- 利用シーンが特定の、一時的、暫定的なWebページをフィルタリング
- Googleなどの検索では見つけにくいですが、有用なWebページの発見も可能
- 検索リテラシーを不要とした検索
- Googleなどと比較して、その単語に強い興味がある場合に有用

セレクトブックマ(今後の課題)

- ロジックの改良

- 時間の閾値は一日で良いのか？

- 最適な日付係数 α の発見

- 現時点だと古いページが有利

➡ ブクマされた時期などによる重み付け

- タグをつける行為の意味(フィールドワーク)

➡ タグ率の利用

- データ数、データの偏りの問題

➡ はてブ以外のSBMデータも調査、利用

- 被験者を利用した評価

セレクトブックマ(今後の課題:評価)


- 以下の4つを比較

1. Google検索
2. タグによるブックマ数順のランキング
3. セレクトブックマ(現時点でのもの)
4. セレクトブックマ(改良版)

- 被験者に上記4つでの上位10件のページを比較してもらう
- 20~30人ぐらい
- タグは5~10種類程度


目次

1. SBM研究全般について
2. 本研究背景
3. SBMデータ分析
4. セレクトブックマの開発
5. セレクトブックマの実験・評価


 6. おまけ

ブックマストリーム概要

- Webページを年間、月間、日間ごとにブックマ数順にランキング化して表示
- タグごとにもランキング可能



- ブクマ数の多いページをまとめてチェック
- 過去のブックマ数の多いページを発見

 近日公開予定

関連サービス

- MixClips

➡ 複数のSBMの人気ブックマを横断的に表示するサービス
※「はてなブックマーク」「del.icio.us」「@nifty クリップ」
「livedoor clip」「buzzurl」「newsing」「あとで新聞」等

- はてなブックマークじわじわ来てるエントリー

➡ 集中的にブックマされていないため、「人気エントリー」に
上がってきていないWeb ページを検出

※総ブックマ数40 以上、同日連続ブックマ数15以下のWeb
ページを検出