

Serendipity を考慮した推薦システムの Folksonomy による実現とその評価

田上 道士¹ 山場 久昭¹ 高塚 佳代子¹ 岡崎 直宣¹ 富田 重幸¹

概要: 従来, 多くの推薦システムでは, 推薦されたアイテムがユーザの好みに合致するかどうかという視点にのみ注目して推薦を行おうとしてきた。しかし近年では, これに加えて, 推薦されたアイテムに対する未知性や意外性なども新たに要求されるようになってきている。本研究では, Serendipity にも考慮した情報推薦を実現するために, アイテムの分類を推薦者側が定義したカテゴリ (ジャンルや著者など) を用いて行うのではなく, ユーザ側が各アイテムに対して抱く印象をそのアイテムの特徴として分類に用いる。この分類を行うために Folksonomy におけるタグの情報を利用した。提案手法に基づく推薦システムを Java で実装し, 実際に推薦実験を行い, 本手法の有効性を確認した。

Development and Evaluation of Serendipitous Recommender Systems using Folksonomy

TANOUE MICHIHITO¹ YAMABA HISAAKI¹ TAKATSUKA KAYOKO¹ OKAZAKI NAONOBU¹
TOMITA SHIGEYUKI¹

Abstract: This paper proposes a recommendation method that focuses on not only predictive accuracy but also serendipity. On many of the conventional recommendation methods, each item is categorized according to its attributes (a genre, an authors, etc.) by recommender in advance; recommendation is performed using the categorization. In this study, impressions of users to items are adopted as a feature of the item, and each item is categorized according to its feature. The impressions are prepared using folksonomy. A recommender system was developed by Java language, and effectiveness of the proposed method was verified through recommender experiments.

1. 緒言

近年, インターネットの普及によって, 膨大な情報が発信されるようになったのに伴い, その中からユーザが自分の欲しい情報を見付けることが困難となっている。このため, それら大量の情報の中からユーザにとって必要な, 或いは有益・有用なものを自動的に提示する「推薦システム」が強く望まれている。

推薦システムに関してはこれまで数多くの研究がなされているが, その実現方法には, 主に「協調フィルタリング」と「内容ベースフィルタリング」の二つがある [1]。「協調フィルタリング」は「推薦を受けるユーザと類似した嗜好

を持つ他のユーザ群が, 高く評価しているアイテム」を推薦する手法である。一方, 「内容ベースフィルタリング」は「推薦を受けるユーザが好むアイテムと類似した特徴を持つアイテム」を推薦する手法である。従来, 多くの推薦システムは, どちらの手法であれ, ユーザの好みに合致するかどうかという視点にのみ注目して推薦を行おうとしてきた。しかしこれに加えて, 近年では推薦されたアイテムに対して目新しさや意外性などが新たに要求されるようになってきている [1]。

そこで本研究では, ユーザの好みに合致するかどうかだけを考慮して推薦するアイテムを選ぶのではなく, Serendipity も考慮した推薦手法について検討した。具体的には, 「コンセプト」と呼ぶ考え方をを用いた推薦手法を提案する。この「コンセプト」の導出には, Folksonomy におけるタグ

¹ 宮崎大学
University of Miyazaki

の情報を利用した。そして、提案手法に基づく推薦システムを実装し、実際に推薦実験を行い、本手法の有効性の確認を行った。

2. 提案する推薦手法

2.1 Serendipity を考慮した推薦

推薦システムの目的はユーザーにとって有用なアイテムを推薦することであるが、ユーザーの好みに合致するアイテムであっても、ユーザーが既に知っているものであれば、そのアイテムは有用ではないと考えられる。すなわち、推薦されたアイテムがユーザーの好みに合致し、かつ、未知であること (Novelty) が要求される [1]。さらに、Serendipity (意外性) も推薦に要求されるようになってきている。「Serendipity」という言葉は、「セレンディップの三人の王子たち」[2] という童話に因んで Horace Walpole が生み出した造語である。一般的には「何かを探しているとき、探しているものとは別の価値あるものを見付ける能力・才能」を指すが、推薦システムにおいては「推薦されたアイテムがユーザーにとって有用であり、未知で、かつ意外性がある」という意味で用いられる [1]。

ユーザーが自分の好みに合致するアイテムを探すときは、そのようなアイテムが存在すると期待されるような領域を中心に探すものと考えられ、その領域には含まれていないが実際はユーザーにとって有用なアイテムがあったとしても、自力では見付けられない可能性が高い。逆にそのようなアイテムに出会えたとき、それはユーザーにとって思いがけない有用な出会いとなる可能性が高いと言える。本研究では、「ユーザー自身が有用なアイテムがあると期待している領域に含まれていないが実際はユーザーの好みに合致し、かつ未知である」アイテムが推薦されたとき、ユーザーは Serendipity を感じるものと考え、このようなアイテムのことを「Serendipity のあるアイテム」と呼ぶことにする。

ここで、従来の推薦手法に注目すると、その多くは推薦者側があらかじめ定義したカテゴリ (「著者」や「ジャンル」など) を利用してアイテム进行分类し、それに基づいて推薦を行っていた。例えば、ミステリー小説が好きなユーザーには、推薦者側の視点で「ミステリー」のカテゴリに分類されている本の中から推薦される本が選ばれ、その「ミステリー」のカテゴリには分類されていない (例えば「恋愛」のカテゴリのみに分類されている) 本の中にミステリーの特徴を持つ本 (ユーザーが有用と感じる本) があっても、それは推薦されにくかった (図 1)。しかし、このような本はこのユーザーにとって Serendipity のある本である可能性が高い。

そこで本研究では、このような Serendipity のあるアイテムも推薦に含まれる (図 2) ようにするために、アイテムの分類を推薦者側の視点で行うのではなく、ユーザー側が各アイテムに対して抱く印象をそのアイテムの持つ特徴と

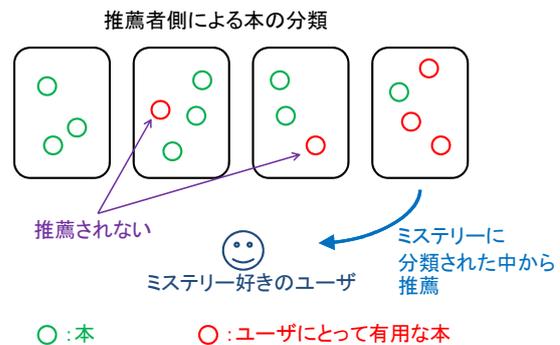


図 1 従来の推薦

Fig. 1 Conventional recommendation.

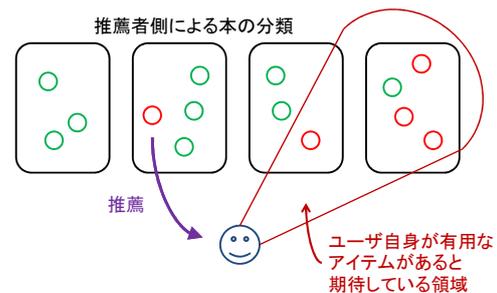


図 2 Serendipity のある推薦

Fig. 2 Serendipity on recommendation.

して分類に利用する。例えば、推薦者側の視点では「ミステリー」のカテゴリには分類されないような (「恋愛」のカテゴリに分類されるような) 本であっても、その本に対して「ミステリー」という印象を抱いたユーザーがいた場合、その本に「ミステリー」という特徴付けが行われるものとする。このようなアイテムの特徴付けを行うにあたり、Folksonomy におけるタグの情報を用いる。

2.2 Folksonomy

Folksonomy とは、従来のトップダウンな分類手法とは対照的な、ボトムアップ方式の分類法である。従来、ユーザーに提供される情報は、サービス提供者側があらかじめ定義したカテゴリに基づいて分類されていた。これに対して Folksonomy では、ユーザー各々が各情報に対して「タグ」を付与することで分類が行われる。「タグ」とは、その情報の特徴などをもとに、ユーザーが自由に作成したキーワードである。使用できるキーワードに制限はない。また、一つの情報に複数のタグを付与することも許されている。従来の分類法と比較して、Folksonomy は以下のような特徴を持つ。

- ユーザーの感覚や認識構造が分類に反映されやすい。
- タグ付けを行うにあたり、ユーザーは任意のキーワードを入力するだけであり、そこに特別な知識は必要としないため、気軽に行うことができる。

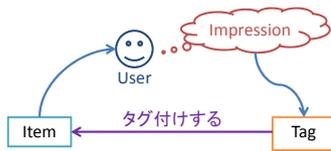


図3 アイテムに対して抱いた印象によるタグ付け

Fig. 3 Tagging according to impressions which the user feels on the item.

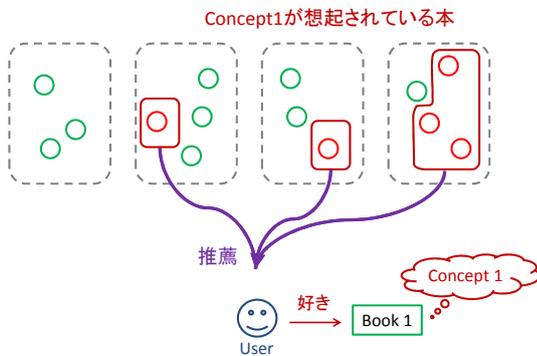


図4 提案手法による推薦

Fig. 4 Basic idea of the proposed method.

- 階層構造を持たないフラットな分類である。

2.3 「コンセプト」の考え方の導入

アイテムに付けられているタグを直接用いて分類を行おうとすると、タグの「同義性」や「多義性」による問題が生じてしまう。例えば、ある二つのアイテムの一方にはタグ「blog」が、他方にはタグ「weblog」が付いているとき、それらアイテムは同じ意味のタグが付けられているにも関わらず、共通の特徴を持っているものとして扱われない。

そこで本研究では「コンセプト」と呼ぶ考え方を導入する。すなわち、ユーザは各アイテムに対して抱いた印象をもとに、使用するタグを選ぶものと仮定し(図3)、その印象によって分類を行う。ただし実際にユーザがどのような印象を抱いたかはわからないのでそれをタグの情報をもとに逆に導出し、これを「コンセプト」と呼ぶ。この「コンセプト」をアイテムの特徴として用い、ユーザの好きなアイテムに関連強いコンセプトに対して、それと「同じ、或いは、似ているコンセプト」と関連性が強いアイテムを推薦する(図4)。

2.4 提案手法

以下、提案手法の概要について述べる。後述の実験では推薦の対象(アイテム)として本を用いているため、以下でも「本」を前提に説明するが、本手法の適用対象を本に限定しているわけではない。

初めに、各コンセプトは全てのタグそれぞれとの関連度

タグ	関連度
Tag ₁	[Bar chart]
Tag ₂	[Bar chart]
⋮	⋮
Tag _n	[Bar chart]

図5 コンセプトの表現

Fig. 5 Represent of the concept.

のベクトルで表現するものとし(図5)、以下の手順でコンセプトを導出する。まず、ある二つのタグが同じ本に付けられている頻度が高いとき、それらタグは同じコンセプトをもとに使用されている可能性が高いと仮定する。この仮定のもと、タグ間の類似性の度合いを定義し、この類似度が高いタグ同士が集まるようにクラスタを作り、そのクラスタそれぞれを一つのコンセプトと対応付けることにする。

そして、「各本が持つ特徴」と「ユーザの好みの特徴」を、導出された全てのコンセプトそれぞれとの関連度のベクトルで表現する。基本的には、ユーザの好みと似た特徴を持つ本を推薦するわけだが、本研究ではさらに、「コンセプト間の類似度」と呼ぶ考えも導入し、推薦の候補となる本の幅を広げる工夫も行っている。

2.4.1 タグ間の類似度

ある二つのタグ a, b について、 a が付けられている本にほぼ常に b も付けられていれば、 a, b は同じコンセプトをもとに使用されている可能性が高いと仮定し、このようなとき「 a と b は類似している」と考える。すなわち、タグ a, b と任意の本について、

- (ア) a と b がともに付けられている
- (イ) どちらも付けられていない
- (ウ) a は付けられているが、 b は付けられていない
- (エ) a は付けられていないが、 b は付けられている

の四つの組み合わせのうち、(ア)と(イ)の頻度が高い場合は a, b の類似性が高く、(ウ)と(エ)の頻度が高い場合は類似性が低くなる。本研究では二つのタグがどのくらい類似しているかの尺度を「タグ間の類似度」と呼び、これを AEMI (Augmented Expected Mutual Information) [3] で表すことにする。任意の本について「タグ a が付けられている」という事象を α 、「タグ b が付けられている」という事象を β とすると、タグ a, b 間の類似度は、

$$AEMI(\alpha, \beta) = \sum_{(A=\alpha, B=\beta), (A=\bar{\alpha}, B=\bar{\beta})} MI(A, B) - \sum_{(A=\bar{\alpha}, B=\beta), (A=\alpha, B=\bar{\beta})} MI(A, B)$$

となる。ここで $\bar{\alpha}$ は「タグ a が付けられていない」という事象を示す。また、 $MI(A, B)$ は、事象 A と B が相互にど

のくらい依存しているかという情報量であり，以下の式で表される．

$$MI(A, B) = P(A, B) \log \frac{P(A, B)}{P(A)P(B)}$$

ここで， $P(A)$ は「事象 A の発生頻度」を，また， $P(A, B)$ は「事象 A と B の同時発生頻度」を示す．

2.4.2 タグのクラスタリング

次に，類似度が高いタグ同士が集まったクラスタ群を生成する手法について説明する．まず，全てのクラスタの集合 $Cset$ を用意しておく（初期状態では空集合）．次に，全てのタグの組 (Tag_i, Tag_j) ($i \neq j$) を生成し，それをタグ間の類似度が高い順に並べる．その中から，類似度があらかじめ決めておいた閾値 V_t を超えるタグの組を選出する．そして，そこからタグ間の類似度が高い順にタグの組を取り出して，その二つのタグ Tag_i と Tag_j について以下の処理を行う．

1. $Cset$ に含まれるクラスタのうち， Tag_i と Tag_j の双方をともに含むクラスタを除いた，残りのクラスタそれぞれについて以下を行う．

今注目しているクラスタ Cl_k に含まれていないタグ (Tag_i と Tag_j の一方，或いはその両方) と， Cl_k 内に含まれる各タグとの類似度の平均値を求め，それが V_t を超えていればそのタグを Cl_k に追加する．ただし，タグを追加した結果の Cl_k と同一のタグ集合からなるクラスタが既に $Cset$ に存在する場合は， Cl_k を $Cset$ から削除する．

2. 1. の処理によって更新された $Cset$ の中に， Tag_i と Tag_j の双方をともに含むクラスタが一つも存在しなかった場合は， Tag_i と Tag_j からなる新たなクラスタを生成し， $Cset$ に加える．

2.4.3 コンセプトの導出

クラスタリングの結果から得られた各クラスタに対応するコンセプトを，全てのタグそれぞれとそのクラスタとの関連度のベクトルとして表現する．

まず，全てのタグとクラスタの組み合わせ (Tag_i, Cl_k) それぞれについて， Tag_i と「 Cl_k に含まれる各タグ」との類似度の平均値を求め，これを t_{ik} とする．すると，図6に示すような行列が得られるので，各行ベクトルを正規化する（図7）．ただし， s_i は各行ベクトルの要素の和である．そして，図7における各クラスタ Cl_k に対応する列ベクトルを，コンセプト Co_k とする．

$$\overrightarrow{Co_k} = \langle rel(Tag_i, Cl_k) | i = 1, 2, \dots, n \rangle$$

$$rel(Tag_i, Cl_k) = \frac{t_{ik}}{s_i}$$

2.4.4 本の特徴ベクトルの算出

各本の特徴は，導出された全てのコンセプトそれぞれと

	Cluster ₁	Cluster ₂	Cluster ₃	...	Cluster _m	計
Tag ₁	t ₁₁	t ₁₂	t ₁₃	...	t _{1m}	s ₁
Tag ₂	t ₂₁	t ₂₂	t ₂₃	...	t _{2m}	s ₂
Tag ₃	t ₃₁	t ₃₂	t ₃₃	...	t _{3m}	s ₃
⋮	⋮	⋮	⋮	⋮	⋮	⋮
Tag _n	t _{n1}	t _{n2}	t _{n3}	...	t _{nm}	s _n

図6 タグと「クラスタに含まれる各タグ」との類似度の平均値の行列

Fig. 6 Matrix of averages of similarity between a tag and "tags in a cluster".

	Cluster ₁	Cluster ₂	Cluster ₃	...	Cluster _m
Tag ₁	t ₁₁ /s ₁	t ₁₂ /s ₁	t ₁₃ /s ₁	...	t _{1m} /s ₁
Tag ₂	t ₂₁ /s ₂	t ₂₂ /s ₂	t ₂₃ /s ₂	...	t _{2m} /s ₂
Tag ₃	t ₃₁ /s ₃	t ₃₂ /s ₃	t ₃₃ /s ₃	...	t _{3m} /s ₃
⋮	⋮	⋮	⋮	⋮	⋮
Tag _n	t _{n1} /s _n	t _{n2} /s _n	t _{n3} /s _n	...	t _{nm} /s _n
	Concept ₁	Concept ₂	Concept ₃	...	Concept _m

図7 タグとクラスタの関連度の行列

Fig. 7 Matrix of strength of relations of a tag and a cluster.

その本との関連度のベクトルで表現する．本 $Book$ とコンセプト Co_k との関連性の強さは， $Book$ に付けられたタグ Tag_i と， Co_k に対応するクラスタ Cl_k との関連度の総和と定義する．

$$\overrightarrow{featur(Book)} = \langle rel(Book, Co_k) | k = 1, 2, \dots, m \rangle$$

$$rel(Book, Co_k) = \sum_i rel(Tag_i, Cl_k)$$

すなわち， $Book$ の特徴ベクトルは，図7における， $Book$ に付けられた Tag_i に対応する行ベクトルのみを取り出し，その和をとったベクトルとなる．

2.4.5 ユーザの好みの特徴ベクトルの算出

ユーザの好みの特徴は，まずユーザとコンセプトの間の関心度（好みの度合い）を導入した上で，導出された全てのコンセプトそれぞれへのそのユーザの関心度のベクトルで表現する．ユーザ $User$ のコンセプト Co_k への関心度は， $User$ の好きな本 $Book_i$ と Co_k との関連度の総和と定義する．すなわち， $User$ の好みの特徴ベクトルは， $Book_i$ の特徴ベクトルの和からなるベクトルとなる．

$$\overrightarrow{featur(User)} = \langle pre(User, Co_k) | k = 1, 2, \dots, m \rangle$$

$$pre(User, Co_k) = \sum_i rel(Book_i, Co_k)$$

ここで，「ユーザの好きな本」という情報を獲得するには

様々な方法が考えられる。一般的な手法として、アンケートや数段階評価などユーザに直接入力してもらう明示的な方法や、Web上の履歴やブックマークなどユーザの挙動から暗黙的に取得する方法がある。後述の実験では、ユーザに自分の好きな本を直接教えてもらう方法を取っている。

2.4.6 推薦する本の選出

推薦する本を選ぶにあたり、基本的には「ユーザが好むコンセプトと関連性が強い本」を推薦する。具体的には、「ユーザが好むコンセプトとの関連性の強さ」(*point1*と呼ぶ)をユーザの好みの特徴ベクトルと本の特徴ベクトルの内積として、これが高い本を選ぶ。

$$point1(User, Book) = \sum_i \{pre(User, Co_i) \times rel(Book, Co_i)\}$$

しかし、ここではさらに、Serendipityのある本が推薦されやすくなることを期待して、推薦の候補となる本の幅を広げる拡張を行っている。

ユーザはそのユーザが好むコンセプトと関連性が強い本だけでなく、「ユーザが好むコンセプトに類似したコンセプトと関連性が強い本」にも関心を持つ可能性が高く、そのどちらのコンセプトとも（ユーザが好むコンセプトとそれに類似したコンセプトとの双方と）関連性が強い本にはより高い関心を持つと考えられる。そこで、「コンセプト間の類似度」という考えも導入して、「ユーザが好むコンセプトに類似したコンセプトとの関連性の強さ」(*point2*)を以下式で表し、これを *point1* に足し合わせた値が高い本を推薦する。

$$point2(User, Book) = \sum_i \{pre(User, Co_i) \times \frac{sim(Co_i, Co_{max}(Co_i))}{sim(Co_i, Co_i)} \times rel(Book, Co_{max}(Co_i))\}$$

ここで $Co_{max}(Co_i)$ は、 Co_i にとって最も類似しているコンセプトを表す。本研究では二つのコンセプトが類似しているのは、両コンセプトがともに強い関連性を持つようなタグの割合が大きいこととする。よって、コンセプト Co_a と Co_b の類似度を、それらのベクトルの内積と定義する。

$$sim(Co_a, Co_b) = \sum_i \{rel(Tag_i, Co_a) \times rel(Tag_i, Co_b)\}$$

3. 実験

提案手法に基づく推薦システムをJavaで実装し、本手法の有効性を確認するための実験を行った。

3.1 実験用データ

実験に用いるデータは「ブックログ (Booklog)」[4]から収集した。ブックログは仮想本棚を作成できるWebサービスであり、2012年1月現在50万人以上のユーザが利用しており、本やCDなど3300万以上のアイテムが登録されている。それぞれの本についてその情報を掲載したページが用意され、各本のページからその本と関連した本のページへのリンクも張られている。また、ブックログはFolksonomyを採用しており、参加ユーザは、それぞれの仮想本棚に登録した本にタグを付けることができる。このWebサイト上の2011年の年間ランキングに載っていた本、及び、それらの本のページから関連した本としてリンクが張られていた本、合わせて6,717冊を選び、付けられていたタグの情報を取得した。収集されたタグの数は18,922個であった。

3.2 実験の内容と評価方法

取得した情報から、提案手法に基づいて、コンセプトの導出と各本の特徴ベクトルの算出を行い、推薦システムに組み込んだ。この推薦システムで被験者(50名)に本を推薦した。

被験者には各自「好きな本」を列挙してもらい、それらの本の特徴ベクトルから各ユーザの好みの特徴ベクトルを求め、前述の *point1* と *point2* の和が高い本10冊を推薦した。被験者が挙げた好きな本のうち、その本の情報(付けられているタグの情報)を構築した推薦システムが持っていなかった本については、その情報をブックログから新たに取得した。そして被験者には、推薦された本それぞれについて、以下三つの質問に答えてもらった。

Q1 推薦された本に対する興味関心の有無

1. とても興味関心を持てる
2. 少し興味関心を持てる
3. あまり興味関心を持ってない
4. 全く興味関心を持ってない

Q2 推薦された本に対する認知度

1. 読んだことがある
2. 読んだことはないが、どういう本であるか知っている
3. 読んだことはないが、そういう本があるということくらいは知っている
4. 読んだこともないし、全く知らない

Q3 その本が推薦されたことの妥当性

1. 妥当である
2. どちらともいえない
3. 意外である

3.3 実験結果

得られた500件(50名×10冊分)の評価の、三つの質

表 1 推薦実験の評価結果

Table 1 The results of the recommendation experiment.

	1.	2.	3.	4.	計
Q1	156	153	149	42	500
Q2	65	55	77	303	500
Q3	228	147	125	N/A	500



図 8 Serendipity のある本と評価された割合

Fig. 8 The rate of recommended books that were serendipitous.

問それぞれに対する各評価の回答数を表 1 に示す。推薦された本に対して興味関心があると評価した回答数は 309 件 (61.8 %) であった。これは他の研究と同等の精度である (例えば [5])。また、興味関心があると評価された本のうち、その認知度が低かった (よく知らない本であった) と評価した回答の数は 200 件であり、さらにその中で意外と評価した回答の数は 38 件であった (図 8)。つまり、ユーザーが興味関心を持った本の中で、約 12 % が Serendipity のある本であった。意外な本ばかりが推薦されるのではなく、おおよそは順当な本が推薦され、そこに意外な本が数冊推薦されることが推薦システムの有様として適切であると考えられる。このことから、この結果は Serendipity のある本が推薦された割合として適当なものであると考えられる。ただし、意外性があると評価された本が、本当に従来手法のもとでは推薦されなかったような本であったのかなど、より詳細な調査を行う必要がある。

3.4 追跡調査とその結果

推薦実験のおよそ 6 ヶ月後に、推薦された本を実際に読んでみてどのように感じたか、追跡調査を行った。具体的には、各被験者に、本実験によって推薦されたことで実際に読んでみた本について、おもしろかったかどうかを 4 段階で評価してもらった。

得られた評価結果 (41 件) を表 2 に示す。評価値が若いほど、「おもしろかった」という評価になる。本推薦によって実際に読まれた本のうち約 83 % がおもしろかったと評価されており、この結果からも本手法の有効性が確認できる。

表 2 追跡調査の評価結果

Table 2 The results of the follow-up survey.

1.	2.	3.	4.	計
17	17	7	0	41

4. 結言

本研究では、Serendipity を考慮した推薦手法について検討した。具体的には、Folksonomy におけるタグの情報をもとにユーザーが本に対して想起する印象を「コンセプト」として導出し、推薦する本の選出にあたってこのコンセプトを利用する推薦手法を提案した。提案手法に基づいて推薦システムを実装し、実際にユーザーに対して推薦の実験を行った。この実験結果から、提案手法によるシステムは十分な推薦精度を持っており、また、その推薦の中にユーザーにとって Serendipity のある本も含ませることができていることを確認した。

参考文献

- [1] 神島 敏弘：推薦システムのアルゴリズム，人工知能学会誌,vol.22,no.6～vol.23,no.2(2007-2008)
- [2] 竹内 慶夫 (編集, 翻訳)：セレンディップの三人の王子たち—ペルシアのおとぎ話，偕成社 (2006)，ISBN 978-4036526307
- [3] Philip L. Cahn：A non-invasive learning approach to building web user profiles，KDD.99 Workshop on Web Usage Analysis and User Profiling(1999)
- [4] ブクログ：http://booklog.jp/
- [5] 丹波智史, 土井拓生, 本位田真一：Folksonomy マイニングに基づく Web ページ推薦システム，情報処理学会論文誌,47(5),1382-1392(2006)