

RO-007

ユーザの選択履歴に依存しない指標を利用した serendipity のある推薦方式の提案と評価 Proposal and Evaluation of Serendipitous Recommendation by Introducing Metric Independent of User Profiles

秋山 高行[†] 小原 清弘[†] 谷崎 正明[†]
Takayuki Akiyama Kiyohiro Obara Masaaki Tanizaki

1. はじめに

近年、インターネットに代表される情報技術の普及とその商業利用の拡大により、ユーザがアクセスすることが可能な情報(コンテンツ)は、多様化・大量化している。こうした状況下では、ユーザは多様なコンテンツを選択できるようになる一方、自分の望むコンテンツが大量の無用なコンテンツの中に埋もれてしまい、ユーザのコンテンツ選択負荷が増大しているという課題がある。

そこで、ユーザの行動をモニタリングして嗜好情報を抽出し、嗜好に最適なコンテンツを提示する推薦技術の必要性が、コンテンツ提供サービスにおいて拡大している。将来的には、ユーザの嗜好に関わるあらゆる行動をモニタリングし、嗜好情報を抽出することが可能となり、情報の属する領域に関わらず、多様な情報を引き出し、推薦することが可能となると考えられる。そうした世界では、ユーザは思いもよらなかった自身に適した情報を得ることが可能となり、ユーザは未知なる新たな世界に足を踏み入れる機会を得ることが可能となる。また、サービス提供者は、推薦システムによって活発にサービスが利用され、継続的なサービス運用が可能となる。

推薦技術とは、ユーザの嗜好に適した情報を検索する情報検索技術である。情報検索の分野では、ユーザにとって有用な情報には、①有用であると意識している情報と、②意識していないが実際には有用な意外性・偶然性の高い情報、の2種類があると考えられている[1]。この構成は、ユーザのコンテンツに対する興味においても同様であると考え、本研究では、②に属する情報を「serendipityを感じるコンテンツ」と定義する。

従来の推薦技術には、2つの方式(コンテンツベースフィルタ、協調フィルタ)がある[2]。

コンテンツベースフィルタ方式では、コンテンツの特徴によって、ユーザのコンテンツ選択履歴から興味のある特徴ベクトルを生成し、興味のある特徴ベクトルと類似度の高いコンテンツを提示する。

協調フィルタ方式では、複数ユーザの選択履歴から、当該ユーザと選択履歴が似たユーザを抽出することにより、未選択コンテンツの興味度を計算し、興味度の高いコンテンツを提示する。

これらの従来方式では、ユーザが現在までに選択したコンテンツと類似したコンテンツを提示する。現在までに選択したコンテンツは、ユーザは興味があることを意識していると考えられるので、①に属するコンテンツが提示されることになる。例えば、出演者Aが出演するドラマをよく視聴するユーザに対しては、出演者Aが出演しているドラマを推薦する。その結果として、いつも似たようなコンテンツや、ユーザが視聴することをわかっているコンテンツ

を推薦するようになり、ユーザは推薦結果に飽きてしまう[2]。そのため、②に属する serendipity を感じるコンテンツも提示する必要がある。例えば、教育番組を視聴しないユーザにとって、好みの出演者Aが出演している教育番組なども提示する。しかし、従来方式ではそれらを優先的には提示できない。

本研究の目的は、ユーザが serendipity を感じるコンテンツを推薦する技術を実現することである。そこで本研究では、まずユーザが serendipity を感じるコンテンツの実例を収集し、人間の嗜好モデルを立てた。次に本モデルに基づく推薦方式を提案し、実例データを利用した検証実験を行った。その結果、ユーザの選択履歴に依存しない一般的な意外度を導入することによる提案方式が serendipity を感じるコンテンツ推薦を可能であることを確認した。

本論文は以下のように構成される。2章で意外性のあるコンテンツを推薦する関連研究を紹介する。3章で serendipity を感じる実例データの収集方法と解析結果、それに基づくユーザ嗜好モデルについて述べる。4章で、ユーザ嗜好モデルに基づいた提案手法とその評価結果を説明する。5章で今後の展望を、6章で結論を述べる。

2. 関連研究

初期の推薦技術の研究では、ユーザの嗜好に適した推薦結果、つまり①に属する推薦結果を提示することがユーザの満足度を向上するものと考えられていた。その後、ユーザの満足度を向上する要素として、ユーザ嗜好への適合性以外に、②に属する推薦結果として、新規性(novelty)や意外性(serendipity)の評価も重要であると指摘されている[2, 3, 4, 5]。

意外性のあるコンテンツを推薦しようとする試みはいくつか報告されている。Ziegler 等は、推薦リスト内のコンテンツは類似するコンテンツよりも多様な分野のコンテンツで構成される方が、ユーザにとって意外性がある可能性が高いと仮定した。この仮説に基づいて、推薦リスト内の多様性を高める方式を提案している[6, 7]。これらの方式では、2つのコンテンツの類似性を定量的に求め、それらを用いて推薦リスト内の全コンテンツの類似性を Intra-List Similarity として定義した。さらに、類似性の低いコンテンツを追加していくことによって多様性を高めている。

意外性のあるコンテンツを直接的に推薦しようとする試みも報告されている。Hijikata らは、ユーザから明示的に与えられる既知・未知という情報を用いてコンテンツが既知である確率を計算することによって、新規性や意外性を向上させる手法を提案している[8]。また、ユーザが選択したコンテンツに対しての評価(興味があるかないか)を用いて、コンテンツがユーザにとって興味がある確率と興味がない確率を計算し、どちらの確率も同程度であるようなコンテンツを意外性のあるコンテンツとして仮定し、推

[†](株)日立製作所中央研究所, Hitachi, Ltd., Central Research Laboratory

薦する方式も提案されている[9]。

また、ユーザが習慣的に利用するものとは異なるコンテンツを意外性のあるコンテンツとして仮定し、推薦する方式も提案されている[10]。この方式では、ユーザが好むコンテンツを予測する嗜好モデルと、ユーザが習慣的に選択するコンテンツを予測する習慣モデルを導入する。そして、嗜好モデルによる予測結果と習慣モデルによる予測結果との差異に基づいてコンテンツの意外性を推定し、意外性が高いコンテンツを多く含む推薦リストを推薦する。

以上のように、意外性のある推薦方式に関しては、論理ベースで提案されている推薦方式であり、実際のユーザの嗜好に関する知見を元に推薦方式を組み立てているものはない。また、多くの研究は、serendipityを感じるコンテンツは、意外性のあるコンテンツであると仮定しており、意外性があるが嗜好に合致しないコンテンツの存在を取り扱っていない。

本研究では、まず、「ユーザはどのようなコンテンツに実際に serendipity を感じるか」を明確にし、そこで得られた知見をもとに仮説を立てる。そして、実例データに即した仮説に基づいた推薦方式を提案する。

3. Serendipity の実例収集と解析結果に基づく仮説

3.1 ユーザの嗜好に関する仮説

本研究では、まず、人間の嗜好に関する仮説を立て、仮説に基づいてユーザの実例データを解析し、「ユーザはどのようなコンテンツに実際に serendipity を感じるか」を検証した。本節では、はじめに立てた仮説について説明する。図1は仮説を表現する概念図である。本仮説では、各コンテンツはコンテンツを特徴づける特徴空間内での特定の位置に配置される。この特徴空間は高次元空間であるが、簡単のため図中では2次元の距離空間を用いた。ユーザがこれまでに選択したコンテンツは、ユーザが現在認識・知覚している興味を表す特徴ベクトルから近い領域に存在する(推薦されて納得できるコンテンツなので、以下、納得感のあるコンテンツと呼ぶ)。そこから離れた領域には serendipity を感じる、つまり、意外性があり興味を持てるコンテンツが存在すると考えられる。その領域からさらに遠い領域には、興味のないコンテンツが存在することになる。ユーザが認識・知覚している領域(納得感を感じる領

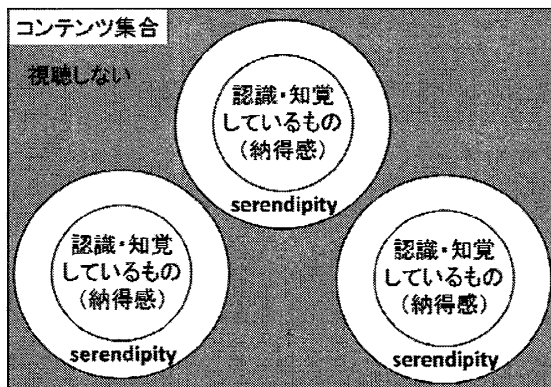


図1 概念図 (ユーザによって分布は異なる)

域)は、特徴空間内で複数存在すると推測される。なぜなら、コンテンツを選択した理由は単一ではなく、例えば、ドラマの選択理由とドキュメンタリ番組の選択理由は異なると考えられるからである。

3.2 実例収集方法

本研究では、ユーザの実例データを収集するために、30人の被験者を対象にアンケート調査を行った。被験者に3か月分のテレビ番組(31433件)の中からランダムにテレビ番組情報を提示し、提示された番組が推薦結果として「納得感を感じるか(①に属するか)」、「意外に良いと感じるか(②に属するか)」、「興味が無いか」の3評価値を付与してもらう方法をとった。なお、提示する番組情報は、電子番組表(Electric Program Guide: EPG)に記載されているタイトルや出演者、内容説明のテキスト情報を用いた。

被験者は、20代から40代までの男女であり、各被験者は約100~9000件の番組に評価値を付与した。

3.3 解析方法

アンケートによって収集したコンテンツを、EPGに含まれるテキスト情報を形態素解析して生成された単語ベクトルによって表現する。このとき、各ベクトル成分は、当該単語が入っているか否かの2値で表現する。そして、ユーザの興味領域を推定するために、「納得感がある」コンテンツをクラスタリングした。その際、コンテンツ P_i とコンテンツ P_j 間の距離を以下のように定義した。

$$\text{distance}(P_i, P_j) = \sum_{n=1}^N w_n |P_i(n) - P_j(n)| \quad (1)$$

ここで、 $P_i(n)$ は、コンテンツ P_i の単語番号 n の単語のベクトル成分、 w_n は単語番号 n の単語へのユーザの重み(興味度の指標)である。重み成分 w_n によって、ユーザによって異なるコンテンツ間距離を実現することが可能である。

単語番号 n の単語 v の重み成分 w_n は、tfidf (term frequency と inverse document frequency の積) により計算する[11]。tfidf は、注目している集合中での単語出現頻度と全体集合中での単語出現頻度によって、注目している集合に特徴的に出現している語に重みづけする指標である。

$$\text{tfidf}(v | D(w)) = \text{tf}(v | D(w)) \times \log\left(\frac{N_{\text{all}}}{N(v)}\right) \quad (2)$$

ここで、 $D(w)$ は注目しているコンテンツ集合を指し、本研究では、納得感のあるコンテンツ集合である。 $\text{tf}(v|D(w))$ は、注目している集合 $D(w)$ の中で単語 v が出現する頻度、 N_{all} は全コンテンツの個数、 $N(v)$ は全コンテンツの中で単語 v が出現する回数である。

こうして生成された納得感を感じる興味領域(以下、納得感領域と呼ぶ)の中心ベクトルからの「意外に良い」コンテンツ(serendipityを感じるコンテンツ)と「興味のない」コンテンツまでの距離を計算することによって、仮説を検証する。

3.4 解析結果

収集したアンケートを集計し、各被験者の評価番組数が図2であり、各被験者における納得感のあるコンテンツと




図2 各被験者の評価コンテンツ数
縦軸：評価コンテンツ数、横軸：被験者番号




図3 各被験者における納得感のあるコンテンツと serendipity を感じるコンテンツの割合
縦軸：全評価コンテンツ数における割合、横軸：被験者番号

serendipity を感じるコンテンツの全コンテンツ中での割合を算出した結果が図3である。被験者によって、それらの割合は様々であるものの、全コンテンツ中での興味のあるコンテンツの割合が低いことがわかり、ユーザにとって不慣れたコンテンツの多さが確認できた。各コンテンツの割合の多様性については、日頃、テレビ番組を頻りに視聴する被験者にとっては、多くの番組が納得感を感じるものとなり、serendipity を感じるものが少なくなる。一方、日頃、テレビ番組を視聴しない被験者にとっては、多くの番組に serendipity を感じる傾向がある。

個別に口頭で感想を聞いたところ、serendipity を感じるコンテンツとは、今までは知らなかったが興味のある発見性の高いもの（普段見ない放送大学で放送される興味のある番組など）や、興味の要素の意外で思わぬ組合せが含まれているもの（コメディアンである爆笑問題が出演する教育番組など）、という側面があることがわかった。しかし、意外に感じるコンテンツは必ずしも serendipity を感じるコンテンツではないということもわかった。また、serendipity を感じるコンテンツが無かった、もしくは、どう判断してよいかわからなかった、という被験者もあり、主観的な感想を定量的に定義することに困難さがあることがわかった。

まず、ある被験者（以下、ユーザと呼ぶ）の納得感のあるコンテンツのクラスタリング結果を図4に示す。クラスタリングは、ユーザの興味領域数に関する事前知識が無い場合、階層的クラスタリングを用いた。クラスタ数を決定する枝の高さを決定することにより、ユーザの興味領域数が決定される。

図4において、全ての枝の高さに応じてクラスタを生成

し、クラスタ中心からの納得感のあるコンテンツまでの距離の平均値（納得感領域の半径）とそのクラスタに属する興味のないコンテンツまでの距離の平均値（興味のない領域の半径）の比を枝の高さに対してプロットした（図5）。クラスタ数が多ければ、興味のないコンテンツは、納得感領域の外側に分布する。一方、クラスタ数が少なければ、複数の納得感領域を単一の領域とするため、納得感領域の内側に興味のないコンテンツが分布する。しかし、妥当なクラスタ数は、ユーザによって異なる。

納得感領域の半径とそのクラスタに属する serendipity を感じるコンテンツまでの距離の平均値（serendipity を感じる領域の半径）の比を枝の高さに対してプロットした結果が図6である。クラスタ数が多ければ、serendipity を感じるコンテンツは、納得感領域のより外側に分布するようになる。




図4 納得感のあるコンテンツのクラスタリング結果




図5 枝の高さによる納得感領域の半径と興味の無い領域の半径のプロット
(分母：興味の無い領域の半径)




図6 枝の高さによる納得感領域の半径と serendipity を感じる領域の半径の比のプロット
(分母：納得感のある領域の半径)

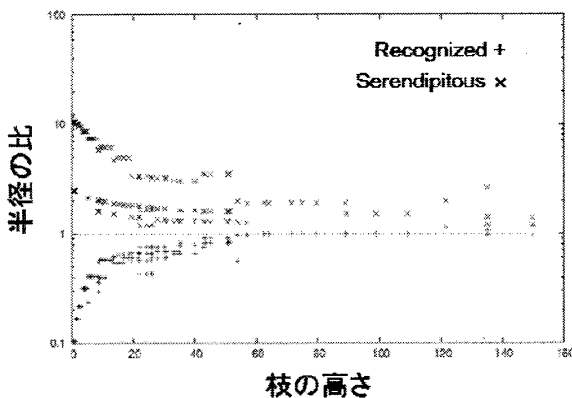


図7 クラスタの高さによる興味の無い領域の半径と、納得感領域の半径、serendipity を感じる領域の半径、それぞれの比のプロット
(いずれも分母は興味の無い領域の半径)

以上の二つの結果をまとめてプロットした結果が図7である。納得感のあるコンテンツの外側に興味の無いコンテンツが分布し、さらに外側に serendipity を感じるコンテンツが分布することが示された。

3.5 解析結果に基づく嗜好モデル

これまでの結果をまとめると、EPGの内容に含まれる単語によって表現している特徴空間内では、納得感領域近傍では、納得感領域のすぐ外側に興味の無い領域が分布し、そのさらに外側に serendipity を感じる領域が分布していることになる。この結果は、図1の仮説と異なるものである。そこで、人間の嗜好は図1のような構造ではなく、図8のような構造となっていると考えられる。

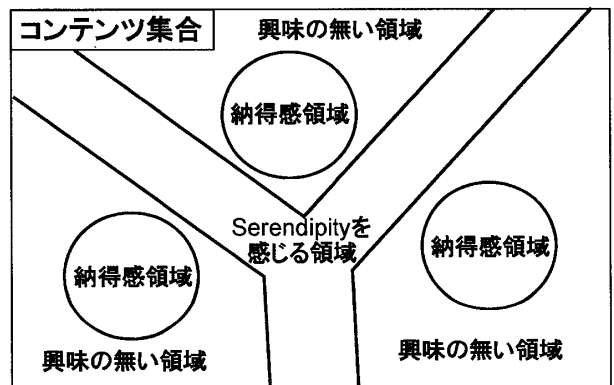


図8 実験結果に基づく嗜好モデル
(ユーザによって分布は異なる)

本研究では、コンテンツベクトルは各単語が含まれるか否かの2値で表現されているため、納得感領域中心からの距離とは、納得感領域中心ベクトルに含まれていないが当該コンテンツベクトルには含まれている単語の数である。さらに、tfidfによるユーザの興味度の重みづけがなされていることから、重みの小さい興味の無い(ほとんど視聴していない)単語を含んでいても、納得感領域から距離がそれほど離れず、他の納得感領域に含まれている重みが大きい単語を含んでいると、納得感領域から距離が離れることになる。そのため、各納得感領域内のコンテンツとは類似していないが、重みの大きい興味度の高い単語が含まれるコンテンツが、各納得感領域の境界付近に分布していると考えられ、それらのコンテンツをユーザは「serendipity を感じるコンテンツ」と認識すると考えられる。このことは、ユーザアンケート調査の際に任意に収集したユーザの感想において、「Serendipity を感じるコンテンツとは、番組内容の予想外な組み合わせが含まれているもの」という側面を表していると考えられる。

一つの納得感領域中心ベクトルからの距離によって、各領域の分布をプロットした結果が図9である。実線が興味の無いコンテンツの分布、点線が serendipity を感じるコンテンツの分布、破線が納得感を感じるコンテンツの分布である。納得感を感じるコンテンツの分布は、原点近傍のピークが、当該納得感領域を示しており、その次の大きなピークは、隣の納得感領域が複数集合して生成されるものと考えられる。図から、興味の無いコンテンツは納得感領域と、serendipity を感じる領域の双方に広く分布して




図9 納得感領域中心からの各領域のコンテンツの頻度分布
(縦軸：コンテンツの頻度、横軸：納得感領域中心からの距離、実線：興味のないコンテンツ、
点線：serendipityを感じるコンテンツ、破線：納得感を感じるコンテンツ)

おり、本研究で定義したコンテンツ間距離では、serendipityを感じるコンテンツのみを精度良く判別することはできないように思われる。

次章では、本研究で得られた嗜好モデルを用いたserendipityを感じるコンテンツの推薦方式を提案する。

4. 推薦方式の提案と評価

4.1 推薦方式

4.1.1 コンテンツ間距離による推薦方式

本方式で用いた距離は、(式1)で定義されるユーザ嗜好を反映した距離である。この距離を計算するには、まずユーザの視聴履歴を元にユーザが興味を持つコンテンツの特徴を学習する。前章と同様に、コンテンツの特徴として番組情報に含まれる単語を用い、単語が含まれているかを2値で表わした単語ベクトルを特徴ベクトルとする。次に、視聴したコンテンツ(納得感を感じたコンテンツ)を階層的クラスタリング法によってグループ分けし、納得感を感じる領域の中心ベクトルを求める。ここで、前章のユーザ毎の納得感領域半径を考慮し、納得感領域数は経験的に7~10とした。そして、各未視聴コンテンツと最も近い納得感領域の中心ベクトルからの距離を求め、距離の大きさが上位となったコンテンツを推薦する。つまり、次式で定義されるスコアの上位10件を推薦する。

$$\text{Score}(P_i) = \text{distance}(P_i, C_{\text{nearest}}) \quad (3)$$

ここで、 C_{nearest} とは、コンテンツ P_i との距離が最も近い納得感領域中心ベクトルである。

本方式では、前章でも述べたように、興味のないコンテンツが広く分布しているために、距離の大きい領域であっても、serendipityを感じるコンテンツを精度良く推薦しない可能性がある。以下、本方式を方式1と呼ぶ。

4.1.2 一般的な意外度を導入した推薦方式

本方式(方式2と呼ぶ)は、方式1のコンテンツ間距離にコンテンツ自身の意外さを導入したものである。アンケート調査の結果、serendipityを感じるコンテンツとは、ユーザにとって「予想外(意外)」である側面を持っていることがわかった。また、発見性のあるものは、ユーザにとって、普段視聴する放送局と興味のある要素の意外な組み合わせが含まれているものと解釈した。図8のモデルはそのような側面が強く反映されていることを示している。コンテンツの意外さとは予想のしにくさであり、番組推薦ではコンテンツに含まれる特徴の組合せの起こりにくさに関係すると仮定した。そこで、方式2では、予想しにくく興味度が高いコンテンツを、「serendipityを感じる」コンテンツとする。どのユーザに対してもコンテンツの予想のしやすさを表す同一の指標とコンテンツ中での当該コンテンツに含まれる単語の組合せの起りやすさの和で定義する。

Expectedness(P_i)

$$\begin{aligned} &= \frac{1}{|P_i|} \sum_{v,w \in P_i} \text{Tendency of co-occurrence}(v, w) \quad (4) \\ &= \frac{1}{|P_i|} \sum_{v,w \in P_i} \frac{N_{vw}}{N_v + N_w - N_{vw}} \end{aligned}$$

Tendency of co-occurrence(v, w)とは、単語 v と w が同じコンテンツに含まれる度合いを表し、単語 v と w の共起がどの程度ユーザにとって意外かどうかを定量的に評価する。 N_v は単語 v を含むコンテンツ数、 N_{vw} とは、単語 v と w を含むコンテンツ数である。 $|P_i|$ はコンテンツ P_i に含まれる単語数であり、正規化係数である。単語の組合せが起こりにくければ、Expectednessは低く、全ユーザにとって意外性が高いコンテンツと考える。この指標の逆数を意外度(Unexpectedness)とし、方式1のtfidfで重みづけされた

特徴の興味度によるコンテンツ間距離との2乗和で定義される以下のスコアの上位リストを、ユーザが serendipity を感じるコンテンツとして推薦する。

$$\text{Score}(P_i) = \alpha \times \text{distance}(P_i, C_{\text{nearest}})^2 + (1 - \alpha) \times \text{Unexpectedness}(P_i)^2 \quad (5)$$

ここで、 α はユーザ嗜好を反映する距離とコンテンツ自身が持っている意外さの組み合わせ度合いを制御するパラメータである。

4.2 評価方法

提案した2方式の有効性を調べるため、以下のデータセットと手順で評価を行った。

4.2.1 データセット

3章で行ったアンケート調査の結果を用いた。30人の被験者の内、納得感のある番組数と serendipity を感じる番組数がそれぞれ100番組以上と十分に多かった被験者14人の評価済みデータを用いた。ここで、ユーザが納得感のある番組を推薦されることに飽きるまでの時間を推薦システム導入から1カ月間程度と仮定し、1カ月間で視聴する番組数を50番組とした。それぞれの被験者が評価したデータ数は1000~5000件であり、「意外に良い」コンテンツは、全コンテンツ中に7~8%程度の割合で含まれていた。

4.2.2 評価手順

各被験者に対して、提案方式を適用する。

従来の推薦に飽きてくるまでの時間を1カ月程度(50番組程度)と想定し、それまでに納得感領域を学習するものとする。そのため、学習データセットとして、50個の納得感を感じる番組をランダムに選んで生成する。各データセットで学習した納得感領域を用いて、残りの評価済みデータにおいて、各方式に基づくスコアの上位10件を推薦結果とする試行を行う。本報告では、各被験者に対して、学習データセットをランダムに10セット生成したので、10回の試行を行った。

4.2.3 評価指標

推薦結果の精度評価指標として、検出率と適合率を用いる。検出率は、推薦結果に正解が含まれている割合を示し、適合率は推薦結果における正解数の割合を示す。

具体的には、検出率は、各試行での推薦結果10件のリストの中に、被験者が「serendipityを感じる」と評価したコンテンツが1件以上含まれていた試行の割合として算出した。適合率は、10回の試行で、各試行での推薦結果10件のリストの中で、被験者が「serendipityを感じる」と評価したコンテンツ数の割合の平均値として算出した。

4.3 評価結果と考察

検出率と適合率の評価結果について述べる。

表1は、提案2方式と、ランダムにコンテンツを提示する方式、方式2で導入した意外度のみをスコアとして推薦する方式の精度を評価した表である。各精度は、ユーザ毎に算出された精度のユーザ平均値である。方式2の精度は、パラメータ α を変化させてもっとも精度が高かった値に設定しており、本報告では0.05である。

ランダムにコンテンツを提示するものの検出率と適合率は低くなっており、serendipityを感じるコンテンツを予測

することの困難さが分かる。しかし、提案方式2は他方式よりも高い検出率と適合率が得られており、ユーザが serendipity を感じるコンテンツを含む推薦リストを提示できることが示された。

評価結果から、方式1はランダム方式と有意な差は見られないが、方式2は有意な差が見られた。導入した意外度のみで推薦した方式では、ランダム方式よりも精度が下がったことから、ユーザ嗜好を反映する距離とコンテンツ自体が持つ意外度を組み合わせることによって、serendipityを感じるコンテンツを推薦することが可能であるという見通しを得た。

表1. 精度評価結果

方式	ランダム	方式1	方式2	意外度のみ
検出率[%]	51.9	49.8	78.2	32.8
適合率[%]	7.98	7.51	21.6	5.21

方式1と方式2の精度の違いを考察する。方式1では、納得感中心と類似度の低いものを提示するので、興味の無いものも含まれる。一方、方式2では、類似度が低いものの中から、意外に良いものと意外だが興味の無いものを意外度に基づき判別する。そのため、精度が向上していると考えられる。このことから推察した距離と意外度による人間の嗜好領域の概念を図10に示す。納得感領域中心から距離の離れた領域に、興味の無いコンテンツと serendipity を感じるコンテンツが存在する。serendipity を感じるコンテンツには、単語の共起度合いが低い組み合わせを含む傾向があるので、意外度によって、二つのコンテンツが分かれる構造になっていると考えられる。

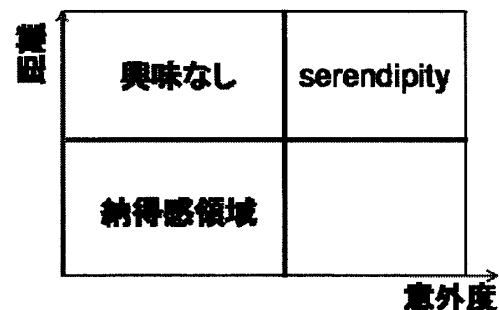


図10 距離と意外度による人間の嗜好の概念図

本研究で導入したコンテンツの意外度は、全コンテンツ集合の中での当該コンテンツに含まれる単語の組合せの起こりやすさである。例えば、ユーザは新聞のテレビ欄やweb上の電子番組表を閲覧し、目に触れた番組から存在する番組内容を予想する。よって、番組表において登場頻度が低い番組内容は意外性を感じると考えられる。テレビ欄や番組表はユーザが提供するものではなく、ユーザを取り巻く環境が提供するものなので、今回導入した意外度はユーザの個性に依存しないものとして単純化した。表1の結果から、「意外」とは、ユーザの個性よりも生活環境に強く依存しており、他方の「興味」は、ユーザの個性に依存していることが示された。本研究の被験者は、類似した生活環境に属すと考えられ、居住国が異なる場合などの大き

く生活環境が異なるユーザに対しての意外度の影響は異なるものと考えられる。そのため、意外度は、ユーザが現在までに顕在的・潜在的に接触したコンテンツ集合の中での、当該コンテンツの内容に類似したコンテンツの登場頻度とすべきと考えられる。

最後に、提案方式と前述の関連方式を比較する。意外性や serendipity といった概念はユーザの主観に依存するので、精度の比較評価は困難である。そこで、前提とするコンテンツや、処理方式を比較した結果を表2にまとめる。

提案方式は、学習に必要なユーザの評価値が少なく、対象とするコンテンツもユーザの利用状況に依存しない。一方、コンテンツに関する情報を必要とするものの、近年、インターネットにおけるフリーの辞書 Wikipedia の発展や、テレビ番組に関するメタデータを作成するベンダとの協業の可能性もあることから、提案方式は、他の方式よりも汎用性が高く、端末でもサーバでも稼働可能であるため、様々なシステムに搭載可能である。

表2. 意外性のあるコンテンツ推薦方式の比較

要求するデータ	提案方式	習慣性利用	興味の差分利用	協調フィルタ
ユーザの感想	不要	不要	必要	不要
他ユーザの履歴	不要	不要	必要	必要
ユーザの習慣性	不要	必要	不要	不要
コンテンツ情報	必要	必要	必要	不要

しかし、実際にどの方式がユーザ満足度を向上するかは、ユーザ評価により検証すべきであり、今後さらなる検証を進める。また、実運用段階では、それぞれの特徴をユーザ状況に応じて切り替えることも考えられる。

5. 今後の課題

本研究で提案した推薦方式により、serendipity を感じるコンテンツ推薦の実現可能性を確認できた。今後の課題として、下記のようなものが考えられる。

- (1) 推薦精度向上
- (2) ユーザの主観評価によるユーザ満足度評価
- (3) 実装システム性能に合わせた最適設計

(1)の精度向上においては、現状の方式では、複数の納得感領域を生成したときに serendipity を感じるコンテンツが含まれない領域が生成されることがあり、適切な納得感領域を選択する必要がある。生成された納得感領域内のコンテンツ数や半径を考慮して、適切な納得感領域選択アルゴリズムを考案することで、精度を向上する。また、メタデータやインターネット上のコンテンツ情報などを利用して、コンテンツに関する情報を充実することで、精度を向上することも考えられる。

さらには、朝は視聴したくないが、夜には視聴したい、といったユーザ嗜好の状況依存性を、位置情報や時間帯情報を利用して、とらえる方向性も必要である。以前はよく利用していた今ではあまり利用しなくなったものを提示さ

れると意外に良いと感じる、かつて興味があったが今では興味がない、などのユーザ嗜好の時間依存性や流動性をとらえていく。本方式では、特徴空間をユーザ個人の選択履歴によって生成しているため、以前利用していたものと現在利用しているものの空間上での分布は異なるものと考えられる。このような空間の時間的な再構成を捉えることによって、ユーザの継続的な興味の持続を可能とすると考えられる。

(2)では、Serendipity という概念は、ユーザの主観に強く依存すると考えられるので、ユーザの主観評価による満足度評価は、実サービス適用段階においては、重要である。このことに関しても、評価方式も合わせて検討していく。

そして、(3)において、実サービスを見据え、システム性能に合わせたデータ構造や高速化手法を検討し、最適な設計を検討する必要がある。

また、今回の人間嗜好に関する知見を足掛かりにして、今後、脳科学分野や心理学分野の知見を収集し、人間に関する理解を深め、よりユーザに使い勝手のよい推薦技術を検討していく。本研究では、テレビ番組を対象にして検証を行ったが、書籍やCD、さらには論文・特許など、人間が利用するあらゆるコンテンツを対象にするとともに、ユーザの様々な行動履歴を抽出する方法を検討し、解析することによって、人間嗜好に対する理解を深めていく。

6. 結論

serendipity のある推薦 (意外性のある興味深い情報を推薦する)の実現を目的とし、ユーザの嗜好情報抽出による推薦方式を提案し、評価した。

人間の嗜好に関するモデルの仮説を立て、30人の被験者の評価履歴を用いた検証実験を行った結果、ユーザ嗜好を反映するコンテンツ間距離 (非類似度)を用いて、人間の嗜好の構造に対する実データに基づいた知見を得た。得られた知見に基づき、ユーザの嗜好を反映するコンテンツ間距離とコンテンツの意外度を組み合わせてコンテンツを推薦する方式を提案し、従来では困難であった serendipity を感じるコンテンツ推薦を 78%の検出率で実現し、有効性を確認した。

また、本研究によって、人間にとって「意外」とは、個性よりも生活環境に強く依存しており、他方の「興味」は、ユーザの個性に依存していることが示された。この結果は、人間はどのようなものを好み、どのようなものを嫌うのか、といった人間嗜好の原理的理解へアプローチする重要な足掛かりとなると考えられる。

参考文献

- [1]E. Toms :Serendipitous Information Retrieval, Proc. of DELOS Workshop,2000
- [2]Herlocker, J., et al. : Evaluating Collaborative Filtering Recommender Systems, ACM Transactions on Information Systems, Vol.22, No.1,pp5-53(2004)
- [3]K. Swearingen and R. Sinha: Beyond Algorithms: An HCI Perspective on Recommender Systems, ACM SIGIR Workshop on Recommender Systems, (2001)
- [4]S. M. McNee, J. Riedl, and J. A. Konstan: Making Recommendations Better: An Analysis Model for Human-Recommender Interaction, In proc. of ACM Special Interest Group on Computer-Human Interaction (ACM SIGCHI), pp.997-1101,(2006)
- [5]S. M. McNee, J. Riedl, and J. A. Konstan: Being accurate is not enough: How accuracy metrics have hurt recommender systems, In

- proc. of ACM Special Interest Group on Computer-Human Interaction (ACM SIGCHI), pp.997-1101,(2006)
- [6] C. N. Ziegler, G. Lausen and L. S. Thieme: Taxonomy-driven Computation of Product Recommendations, In proc. of the 2004 ACM CIKM Conference on Information and Knowledge Management, pp406-415, (2004)
 - [7] Cai-Nicolas Ziegler, Sean M. McNee, Joseph A. Konstan, George Lausen: Improving Recommendation Lists Through Topic Diversification, In proc. of World Wide Web Conference, pp22-32, (2005)
 - [8] Y. Hijikata, T. Shimizu, S. Nishida: Discovery-oriented Collaborative Filtering for Improving User Satisfaction, In proc. of the 14th ACM International Conference on Intelligent User Interfaces (ACM IUI 2009), pp67-76, (2009)
 - [9] Leo Iaquinta, Marco de Gemmis, Pasquale Lops, Giovanni Semeraro, Michele Filannino, Piero Molino: Introducing Serendipity in a Content-based Recommender System, Hybrid Intelligent Systems, 2008. HIS '08. Eighth International Conference on 10-12 Sept. 2008 Page(s):168 – 173
 - [10] T. Murakami, et al. : A Method to Enhance Serendipity in Recommendation and its Evaluation, Transactions of the Japanese Society for Artificial Intelligence, Vol. 24, Issue 5, pp. 428-436 (2009).
 - [11] Li-Ping Jing, et al. : Improved Feature Selection Approach TFIDF In Text Mining, Proceedings of the First International Conference on Machine Learning and Cybernetics (2002)