

## 情報中立推薦システムの高速化

## The Efficiency Improvement of Information-neutral Recommender System

神嵐 敏弘 \*<sup>1</sup>  
Toshihiro Kamishima赤穂 昭太郎 \*<sup>1</sup>  
Shotaro Akaho麻生 英樹 \*<sup>1</sup>  
Hideki Asoh佐久間 淳 \*<sup>2</sup>  
Jun Sakuma<sup>\*1</sup>産業技術総合研究所  
National Institute of Advanced Industrial Science and Technology (AIST)<sup>\*2</sup>筑波大学  
University of Tsukuba

An information-neutral recommender system is designed to make recommendation that is neutral from the viewpoint specified by a user. We improve the efficiency of our INRS and show experimental results on the larger data sets.

## 1. はじめに

利用者が関心のある情報を予測し、それを提示する推薦システムは、意思決定の支援に広く利用されるようになった。しかし、その情報に偏りがあると、利用者の意思決定が適切なものとならない場合がある。この問題に対して、利用者が与えた視点に関して中立性を保証する情報中立推薦システム (information-neutral recommender system) を提案した [Kamishima 12]。このシステムでは、中立性を保証するための制約項である中立性項として相互情報量を採用していた。これは解析的に微分ができなかったため非効率的であり、非常に小規模なデータ集合しか処理できない問題があった。そこで、予測嗜好スコアの平均を一致させるという解析的に微分可能な中立性項を考案し、より大規模なデータを処理できるようにした [神嵐 13]。この効率的な中立性項を、いくつかのより大規模なデータ集合に適用し、その有効性を検証する。2. 節では推薦中立性について論じ、3. 節で実験結果を示し、4. 節でまとめを述べる。

## 2. 推薦中立性

ここでは、推薦中立性 (recommendation neutrality) の形式的定義を与え、この中立性の応用問題を示す。その後、中立性の特徴について論じ、推薦の多様性との関連を述べる。

## 2.1 形式的定義

形式的定義を与える前に、推薦中立性について、3.1 節でも扱う映画推薦を例として直感的に説明する。推薦に影響する特徴や因子である視点を利用者が指定すると、その視点に対して推薦中立性は定義される。例えば、映画の公開年は映画への嗜好に影響すると考えられる特徴で、利用者がこれを視点として指定したとしよう。実際、名作のみが長い年月を経ても鑑賞されるため、古い映画ほど評価値が高くなる傾向があることが知られている。この視点の情報が、推薦結果の生成に全く利用されないとき、推薦結果が中立であるという。この映画の例では、映画の公開年が評価値の予測に全く影響しないとき推薦は中立である。そのため、映画の公開年以外の全ての特徴が同一の映画が仮にあったとすると、それらの予測評価値は全く同じになる。

推薦中立性を強調することの効果を示すため、3.1 節の MovieLens 1M データで Year 視点を指定した場合の予測評価値の分布の変化を示す。黒色と灰色のバーはそれぞれ、1990 より古

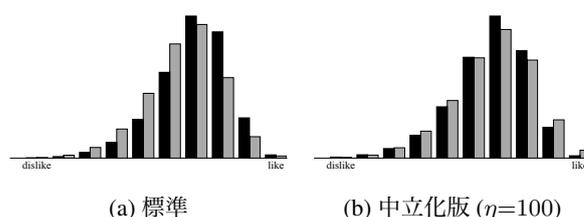


図 1: 各視点での予測評価値の分布

い映画と新しい映画に対する予測評価値の割合を示す。図 1(a) は標準の確率的行列分解法により予測したもので、予測評価値の高い右側の領域で黒いバーが灰色のバーより高く、古い映画の評価値が高くなっていることが分かる。ここで、図 1(b) のように推薦中立性を強化すると、どの領域でも黒色と灰色のバーの高さは近づき、映画の公開年の情報が評価値の予測にあまり影響しなくなっていることが分かる。

それでは、この推薦中立性の直感的な定義を形式的なものにする。利用者やアイテムの記述や特徴など推薦に必要な全ての情報が与えられている事象を想定し、この情報から推薦結果を予測する。この事象は、三つの確率変数  $R$ ,  $V$ , および  $F$  の具現値として表される。 $R$  は推薦結果で、本稿では予測評価値にあたり、 $V$  は視点で、本稿では特に二値である場合のみを考える。 $F$  は通常の特徴で、 $R$  と  $V$  以外の推薦に関連した全ての情報を含むとする。そして、 $V$  と  $F$  が与えられたとき、確率的推薦モデル  $\Pr[R|V, F]$  に基づいて  $R$  を予測することが推薦である。

推薦結果から視点の情報を除外するというを、形式的に  $R$  と  $V$  が統計的に独立、すなわち、 $\Pr[R] = \Pr[R|V]$  ( $R \perp V$  と表記) であることと定める。この  $R$  と  $V$  の独立性は  $\Pr[R|V, F] = \Pr[R|F]$  の条件を含意し、推薦結果が  $V$  以外の情報  $F$  のみから予測されることとなる。この独立性からは、 $R$  と  $V$  の間の相互情報量  $I(R; V)$  が 0 となることも導くことができる。これは、情報論理論的には、視点  $V$  の情報が結果  $R$  から完全に排除されていることに他ならない。このように、この推薦中立性の形式的定義は、上記の直感的な中立性と良く合致している。

## 2.2 応用問題

ここでは、推薦中立性に配慮した推薦システムが活用される潜在的な状況を挙げる。

### 2.2.1 利用者が望んだ視点に対する中立性の確保

推薦結果が偏っていると、利用者が不適切な決定をしてしまうことがある。こうした悪影響の例の一つが、Pariser が指摘したフィルタバブル (filter bubble) 問題である [Pariser]。この問題は、個人化技術によって、利用者が気づかないうちに、利用者に提示される情報の話題が狭く、偏ったものになるという懸念である。Pariser は、ソーシャルネットサービス Facebook での友人推薦での例を示している。サービスを利用し始めたころには進歩派と保守派の両方が推薦リストに現れていたが、自身が進歩派を友人として登録することが多かったため、利用しているうちに個人化の機能により保守派の友人候補が推薦リストから除外されてしまっていた。このような除外を利用者の許可なく行い、多様な意見に触れる機会が損なわれたと Pariser は主張している。推薦システムの国際会議 RecSys2011 ではこの問題についてパネル討論を行った。このパネルでは、様々な観点から推薦を受けることのできる視点制御手法が必要であるとの意見があった [Resnick 11]。

情報中立推薦システムこの視点制御に役立つものと考えている。利用者は、指定する視点を変えることで、さまざまな推薦を受けることができるようになる。Pariser の友人推薦の例では、政治的な立場を視点として指定して推薦中立性を強化すれば、政治的立場は推薦の生成過程から排除できる。そのため、たとえ進歩派の友人候補を選択し続けたとしても、保守派の候補が推薦リストから全く消えることはなくなるであろう。このことは推薦リストが個人化されないということは意味しない。推薦リストは、政治的立場以外のさまざまな情報、例えば利用者の年齢、居住地、関心のある話題などに基づいて依然として個人化される。

他に、よく閲覧・利用されるアイテムが推薦されやすいという人気バイアス (popularity bias) [Celma 08] にも推薦中立性は役立つ。アイテムの人気や市場シェアに関心がなく、それを無視したいと利用者が考えた場合に、被評価数や被消費数を視点として指定すれば、この人気バイアスは解消できる。

### 2.2.2 情報提供者の公平な扱い

推薦中立性は利用者だけでなく、推薦システムの運用者にとっても、情報提供者を公平に扱うことができるため利点がある。例えば、米連邦取引委員会 (FTC) は、競合各社のサービスよりも自社のものを検索エンジンで上位に提示しているとの懸念により Google 社を調査した [Forden 12]。これは情報検索の場合だが、推薦でも情報提供者の扱いは同様に問題となる。例えば、自社の Web サービスをより頻繁に推薦したならば、競合サービスを運営する各社から、その推薦の公平性についての問題を、推薦システムの運営者は指摘されるであろう。しかし、候補 Web サービスの運営が自社か他社であるかを視点とした推薦の中立性を考慮すれば、この点について公平性を保証した推薦が可能になる。また、この中立性の保証により、作為的な推薦をされているという利用者の懸念も取り除くことができる。

### 2.2.3 法や規定の遵守

推薦システムは、法や規定を遵守して運用されなければならない。ここで、キーワードマッチに基づく逮捕歴検索サイトの広告配信での疑念の例 [Sweeney 13] を示す。これは、ヨーロッパ系で一般的な名前より、アフリカ系で一般的な名前を検索したとき、逮捕歴を示唆するような広告文を伴った広告がより頻繁に表示されたというものである。しかし、これには調査では作為的な操作はなく、単に広告のクリック率を最大化したことによる副次的な効果によって生じた現象であった。この広告配信と同様のアルゴリズムは、ニュースなどのオンライン推

薦の Web コンテンツ最適化でも利用されているので、同様の差別的な推薦が生じることが考えられる。ここで、推薦中立性を利用すれば、性別・人種・出生地といった情報に基づかないが、犯罪の重大性や発生場所などにに基づく犯罪関連ニュースの推薦が可能になるだろう。

法や規定により制限された情報を利用しないようにすることにも推薦中立性は利用できる。例えば、プライバシー・ポリシーにより推薦には利用できない情報があるとき、これらの禁止された情報を視点として利用すれば、推薦の予測過程から、そうした情報を排除することができるようになる。

## 2.3 議論

ここでは、視点を指定することの必要性、視点の推薦結果への間接的な影響、そして推薦精度の潜在的な低下の各論点について議論する。

第一に、なぜ推薦中立性の定義で利用者が指定した視点が必要なのかについて述べる。これは、いかなる視点からも中立であるならば、推薦結果を個人化することは本質的に不可能であるからである。このことは、パターン認識分野で有名な醜いアヒルの子の定理 (ugly duckling theorem) [Watanabe 69] により示すことができる。この定理は、分類対象のある特定の特徴や側面を、他より重視することなく、その対象を分類することは不可能であることを示している。アイテムに関心があるものとは異なるものに分類することが推薦であるので、推薦をするためにはある特徴や視点を重視することが避けられず、その結果、全ての視点を同等に扱うことは不可能となる。同様のことは、RecSys2011 のパネルでも、どんな情報も中立ではなく、人々は何らかの形の偏り影響下にあるという choice architecture に基づいて指摘されていた。

第二に、視点の間接的影響について論じる。2.1 節では、視点変数  $V$  を導入した予測モデル  $\Pr[R|V, F]$  を導入した。このモデルから、単純に変数  $V$  を削除すれば推薦中立性が保証できるように思えるかもしれないが、これは誤りである。視点変数をモデルから削除して、 $\Pr[R|V, F] = \Pr[R|F]$  が成立するとする。すると、 $(R, V, F)$  の同時確率は次式となる。

$$\begin{aligned}\Pr[R, V, F] &= \Pr[R|V, F] \Pr[V|F] \Pr[F] \\ &= \Pr[R|F] \Pr[V|F] \Pr[F]\end{aligned}$$

この式は、 $F$  が与えられたときの  $R$  と  $V$  の条件付き独立性、すなわち  $R \perp\!\!\!\perp V | F$  を示している。これは、 $R$  と  $V$  の独立性条件  $R \perp\!\!\!\perp V$  よりも弱い条件であり、この条件の下では、 $V$  とは独立でない  $F$  中の特徴や情報が、その独立でない特徴を通じて  $V$  の情報が推薦結果に影響する。この現象は、2.2.3 節のオンライン広告の例でも見られたもので、人種の情報を全く用いなかったにもかかわらず、人種の情報を間接的に含んだ他の情報の影響が広告の選択に影響していた。なお、推薦中立性は公正配慮型データマイニング [Pedreschi 08] と関連するが、この分野ではこうした間接的な影響は red-lining 効果と呼ばれている。

最後に、予測精度と推薦中立性の関係について述べる。推薦の中立性を強化すると、推薦結果の予測に利用できる情報が減少するため、推薦の予測精度は基本的には低下する。 $V$  の情報が排除されていないとき、予測に利用できる情報は  $R$  と  $(V, F)$  の間の相互情報量  $I(R; V, F)$  であるが、排除後には  $I(R; F)$  となる。両者の差を求めると、

$$I(R; V, F) - I(R; F) = I(X; V|F) \geq 0$$

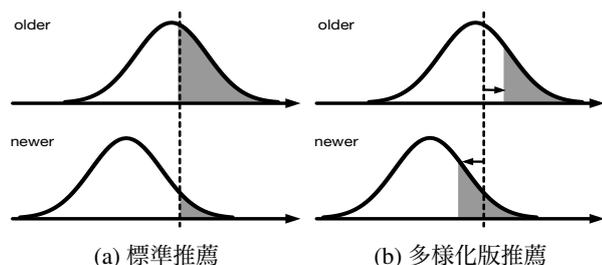


図2: 推薦多様性の強化

であるため、 $V$  の情報を排除することにより利用可能な情報は非増加となる。よって、推薦中立性強化には、予測精度を悪化させるトレードオフが一般には存在する。

## 2.4 推薦多様性との関連

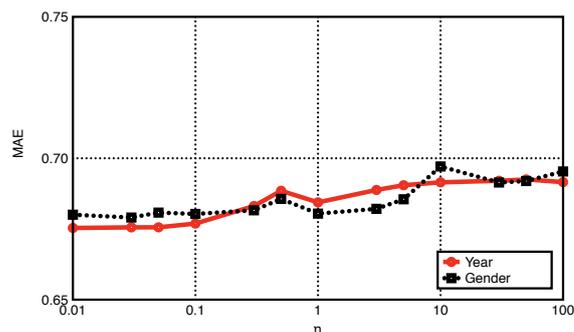
ここで、推薦中立性は推薦多様性 [Ziegler 05] とは異なる概念であることを示しておきたい。推薦されるアイテムが互いに類似していないというこの推薦多様性と、推薦中立性とは大きく二つの点で異なっている。

第一に、多様性は推薦されたアイテムの集合についての性質であるのに対し、中立性は指定した視点と各推薦結果との間の関係である。様々な推薦多様性の概念が今までに提案されてきたが、同時に推薦されたアイテム集合、特定の利用者に連続的に推薦されたアイテム集合、全利用者に推薦されたアイテム集合など、どれもアイテム集合を対象としている。そのため、単一の推薦を多様にすることは不可能である。一方で、推薦するかどうかの判定や、予測評価値が、指定した視点に対して統計的に独立であれば、単一の推薦でも中立にすることは可能である。

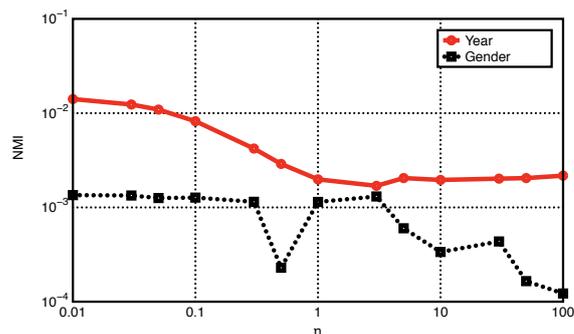
第二に、多様性は幅広い話題の情報を提供するためのものであるのに対し、中立性は偏っていない情報を提供するためのものである。古い映画が新しいものより良く評価されている図1のような状況を考える。図2(a)のように、標準的な推薦アルゴリズムでは、塗りつぶした部分の最上位の評価がされた映画が選ばれて推薦される。この場合、新しい映画の評価は低いため、古い映画よりあまり推薦されていない。図2(b)のように多様性を強化するため、古い映画の代わりに新しい映画を推薦リストに追加する。すると、新旧どちらの映画も推薦されるようになり、幅広い分野の映画が利用者に推薦できるようになる。しかし、予測評価値は依然として映画の新しさに影響されている。言い換えれば、映画の公開年の情報に影響されているという意味で、多様化された推薦にも依然として偏っている。これは、図1(b)で示した推薦中立性の場合とは大きく異なっている。逆に、推薦中立性を強化しても、指定した視点とは無関係な話題については非常に狭い範囲の話題が選択される可能性がある。以上のように、推薦の多様性と中立性の目的は明確に異なっている。

## 3. 実験

ここでは、文献 [Kamishima 12] の方法を効率化した、文献 [神島 13] の  $m$ -match 中立性項を用いた方法を、Movielens 1M データ、寿司嗜好データ、および Flixster データに適用した結果を示す。ここでは実験結果のみを示し、手法の詳細や、細かい実験条件については文献 [神島 13] を参照されたい。この手法は確率的行列分解 (probabilistic matrix factorization; PMF) を用いた手法に推薦中立性を強化するための制約項である中立性項を加えたものである。確率的行列分解には、分解した空間



(a) Year と Gender 視点での MAE の変化



(b) Year と Gender 視点での NMI の変化

図3: 予測精度と中立性尺度の変化

の潜在因子の次元数  $K$  と過学習を防ぐための正則化の影響度を制御する  $\lambda$  のパラメータがある。中立化した PMF アルゴリズムでは、さらに中立性項の影響を制御するためのパラメータ  $\eta$  があり、大きいほど中立性項の影響が大きくなる。すなわち、 $\eta$  が大きいと、予測精度よりも、より推薦中立性を重視した推薦を行うようになる。評価指標は二つあり、一つは予測精度を測るための MAE (mean absolute error) で、大きいほど推薦の予測精度が高い。もう一つは、NMI (normalized mutual information) で、推薦結果  $R$  と視点  $V$  の間の正規化した相互情報量である。小さい方が  $R$  と  $V$  はより統計的に独立であるため、小さな値の方が推薦中立性が高いといえる。

### 3.1 Movielens 1M データ

最初のデータは、Movielens 1M データ [Gro] である。文献 [神島 13] の実験で用いた Movielens 100k データの 10 倍の大きさであり、同じ Year と Gender の二つの視点で実験した。Year 視点は、映画の公開年が 1990 年より古いかどうかを表し、Gender 視点は利用者の性別という視点である。平均評価値を予測評価値として示すことは訓練データの評価値の分布に従ってランダムな評価値を示すランダム推薦と等価とみなせ、その誤差は上界の目安となる。一方で、標準の PMF アルゴリズムによる基本推薦は、中立性を無視し、予測精度のみを考慮しているためその誤差は下界の目安となる。ランダム推薦と基本推薦の MAE はそれぞれ 0.934 と 0.685 であった。

アルゴリズムのパラメータ  $\lambda = 1$  と  $K = 7$  として、中立性パラメータ  $\eta$  を変化させたときの MAE と NMI の変化を図1に示す。全体の傾向としては、文献 [神島 13] の小規模データと同様であった。すなわち、 $\eta$  を大きくして中立性を向上させるに伴って、予測誤差は悪化するが、その度合いは急激ではない (NMI の縦軸が対数であることに留意されたい。) Year 視点の方が、Gender より、元の状態での評価の差が大きいため、

表 1: ジャンルごとの平均の差の評価

(a) Year: old - new			(b) Gender: male - female		
ジャンル	元データ	予測値	ジャンル	元データ	予測値
Animation	-0.040	-0.300	Children's	-0.214	-0.158
Documentary	0.113	-0.121	Musical	-0.213	-0.151
Film-Noir	0.238	-0.036	Romance	-0.100	-0.046
Western	0.524	0.263	Crime	0.024	0.074
Mystery	0.563	0.296	Film-Noir	0.074	0.130
Fantasy	0.593	0.327	Western	0.103	0.162

表 2: 寿司嗜好データでの実験結果

	Age		Seafood	
	MAE	NMI	MAE	NMI
標準	0.907	$3.95 \times 10^{-3}$	0.907	$3.03 \times 10^{-2}$
$\eta=10^{-2}$	0.937	$1.30 \times 10^{-2}$	0.936	$2.87 \times 10^{-2}$
$\eta=10^0$	0.938	$4.85 \times 10^{-3}$	0.941	$1.54 \times 10^{-2}$
$\eta=10^2$	0.931	$1.89 \times 10^{-4}$	0.931	$1.39 \times 10^{-2}$

推薦の中立化による影響がより明確に現れている。だが、文献[神島 13]の Gender ではほぼ中立化の影響は見られなかったが、ここでは若干ではあるが中立化の効果がみられる。以上のことから、提案手法により、予測精度を大きく損なうことなく、中立性が強化できることが確認できた。

推薦のパターンがどのように変化してきたかを示すため、ジャンルごとの平均の差の変化を表 1 に示す。Year と Gender 視点のそれぞれのデータをまず 18 種の映画ジャンルに分け、それぞれについて視点ごとの平均評価値を求めてその差を示した。平均評価値の差は、元データの値と、 $\eta = 100$  での中立化推薦の予測値それぞれを示してある。元データで評価の差が最も大きい両端の 6 種類のジャンルを選択した。表 1(a) では、新しい映画が高評価なものが上 3 行、古いものが高評価なものが下 3 行である。表 1(b) では、女性に高評価なものが上 3 行、男性に高評価なものが下 3 行である。元データの評価の差が大きなジャンルでは、予測評価の差の絶対値は全般的に小さくなっている。例えば、Year 視点の Fantasy の差は 0.593 から 0.327 へと大きく減少している。このことから、中立化した推薦は単純に評価値を並行移動する操作をしているわけではないことが分かる。また、Gender 視点では、全体の平均にあまり大きな変化はなかったが、ジャンルごとの差を見ると違いが見取れる。例えば、Children's, Musical, および Romance といったジャンルでは平均の差が縮小されている。

### 3.2 寿司嗜好データ

寿司嗜好データ (<http://www.kamishima.net/sushi/>) [Kamishima 03] は、5000 人の被験者にそれぞれ 100 種のうち 10 種の寿司について嗜好を尋ねたものである。被験者が 10 代かどうかの Age と寿司が魚介類かどうかの Seafood の 2 種類の視点で実験した。パラメータ  $\lambda = 10$  と  $K = 5$  で、中立性パラメータ  $\eta$  を変化させた結果を表 2 に示す。『標準』の行は標準 PMF による結果、 $\eta = X$  の行はその  $\eta$  での中立化した推薦の結果である。ここでも、 $\eta$  の増加にともなって、予測精度を大きくは損なうことなく、中立性が強化できている。

### 3.3 Flixster データ

最後の Flixster データ (<http://www.sfu.ca/~sja25/datasets/>) [Jamali 10] は、利用者数 147,612、映画数 48,794、

そして評価値数 8,196,077 のデータである。被評価値数が上位 1% 以上の人気アイテム (評価値全体の 47.2% に相当) かどうかを視点として、人気バイアスの補正を試みた。パラメータは  $\lambda = 10$  と  $K = 10$  とした。標準 PMF では  $MAE=0.665$ ,  $NMI=1.24 \times 10^{-2}$  だった。中立性を強化すると  $\eta=0.01$  では、 $MAE=0.669$ ,  $NMI=9.18 \times 10^{-3}$  であり、さらに  $\eta=100$  では、 $MAE=0.691$ ,  $NMI=3.13 \times 10^{-4}$  であった。やはり、中立化項の影響を大きくすることで被評価値数に対する情報を削除でき、人気バイアスの補正ができています。

## 4. まとめ

本論文では、利用者が指定した視点に対する中立性を向上させる情報中立推薦システムの効率を向上するため、新たな中立性項を導入した。この手法を従来よりも大きなデータに適用し、その有効性を示した。

謝辞: 本研究は JSPS 科研費 16700157, 21500154, 23240043, 24500194, および 25540094 の助成を受けた。GroupLens research lab. と Dr. Mohsen Jamali による実験データの提供に感謝する。

## 参考文献

- [Celma 08] Celma, Ò. and Cano, P.: From Hits to Niches?: or How Popular Artists Can Bias Music Recommendation and Discovery, in *Proc. of the 2nd KDD Workshop on Large-Scale Recommender Systems and the Netflix Prize Competition* (2008)
- [Forden 12] Forden, S.: Google Said to Face Ultimatum From FTC in Antitrust Talks, Bloomberg (2012), (<http://bloom.bg/PPNEaS>)
- [Gro] GroupLens research lab, University of Minnesota (<http://www.groupLens.org/>)
- [Jamali 10] Jamali, M. and Ester, M.: A Matrix Factorization Technique with Trust Propagation for Recommendation in Social Networks, in *Proc. of the 4th ACM Conf. on Recommender Systems*, pp. 135–142 (2010)
- [Kamishima 03] Kamishima, T.: Nantonac Collaborative Filtering: Recommendation Based on Order Responses, in *Proc. of The 9th Int'l Conf. on Knowledge Discovery and Data Mining*, pp. 583–588 (2003)
- [Kamishima 12] Kamishima, T., Akaho, S., Asoh, H., and Sakuma, J.: Enhancement of the Neutrality in Recommendation, in *Proc. of the 2nd Workshop on Human Decision Making in Recommender Systems*, pp. 8–14 (2012)
- [神島 13] 神島 敏弘, 赤穂 昭太郎, 麻生 英樹, 佐久間 淳: 情報中立推薦での中立性項の改良, 電子情報通信学会技術研究報告, IBISML 2013–7 (2013)
- [Pariser] Pariser, E.: The Filter Bubble: (<http://www.thefilterbubble.com/>)
- [Pedreschi 08] Pedreschi, D., Ruggieri, S., and Turini, F.: Discrimination-aware Data Mining, in *Proc. of the 14th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining*, pp. 560–568 (2008)
- [Resnick 11] Resnick, P., Konstan, J., and Jameson, A.: Panel on The Filter Bubble, The 5th ACM Conf. on Recommender Systems (2011), (<http://acmrecsys.wordpress.com/2011/10/25/panel-on-the-filter-bubble/>)
- [Sweeney 13] Sweeney, L.: Discrimination in Online Ad Delivery, *Communications of the ACM*, Vol. 56, No. 5, pp. 44–54 (2013)
- [Watanabe 69] Watanabe, S.: *Knowing and Guessing – Quantitative Study of Inference and Information*, John Wiley & Sons (1969)
- [Ziegler 05] Ziegler, C.-N., McNee, S. M., Konstan, J. A., and Lausen, G.: Improving Recommendation Lists Through Topic Diversification, in *Proc. of the 14th Int'l Conf. on World Wide Web*, pp. 22–32 (2005)