



情報中立推薦システムの高速度化

神鳶 敏弘^{*1}, 赤穂 昭太郎^{*1}, 麻生 英樹^{*1}, 佐久間 淳^{*2}

^{*1}産業技術総合研究所, ^{*2}筑波大学

2014年度人工知能学会全国大会 (第28回) @ 松山市, 2014.5.13

<http://www.kamishima.net/>

概要

推薦の中立・公平性

- ✳ 利用者の指定した点に応じて推薦中立性を確保
- ✳ システム運営者が、コンテンツ提供者を公平に扱う
- ✳ 法や契約で利用が禁止されている情報を無視した推薦プロセス



情報中立推薦システム

みにくいアヒルの子の定理などから、絶対的に中立な推薦は不可能



利用者などが指定した、特定の視点に対して、推薦結果ができるだけ中立性を保つように配慮する推薦システム

目次

推薦中立性

- ★ 視点変数, 推薦中立性, 推薦の中立化の例

推薦に的中立性が必要な例

- ★ 利用者の望んだ視点に対する中立性の確保, コンテンツ提供者の公平性, 法や規定の遵守

情報中立推薦システム

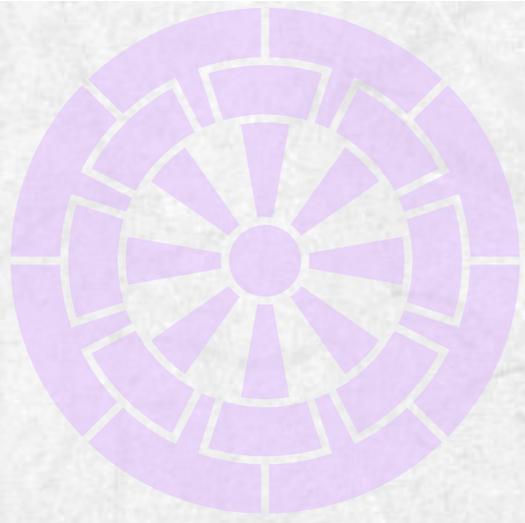
- ★ 情報中立推薦システム, 中立性項と目的関数, Calders&Verwerスコアに基づく中立性項

実験

- ★ 予測精度と情報中立性のトレードオフ

関連研究

まとめ



推薦中立性



視点変数

標準的な推薦モデルの確率変数

X : 利用者, Y : アイテム, R : 評価値



推薦中立性のために新たな変数を導入

V : 視点特徴

- * 利用者が自身の目的に応じて指定する
- * この指定された視点に対し推薦結果は中立になるようにする
- * 特徴の値は利用者やアイテム, およびこれらの特徴に依存する

例 : 視点 = 利用者の性別・映画の公開年

本研究では視点変数が二値の場合のみを対象とする

推薦中立性

推薦中立性

- ✳ 与えられた視点特徴に対し，その特徴の情報が推薦結果に全く影響しないとき，その推薦結果は中立である
- ✳ 指定した視点特徴の状態は明示的に推薦結果の推論から除外する

例：

視点＝映画の公開年



映画が古いか新しいかということが
その映画を推薦するかどうかという判断に影響しない



もし公開年以外の条件が全く同じ二つの映画 A と B があった場合，
映画 B が推薦されたときは映画 A も必ず推薦され，
またこの逆も成り立つ

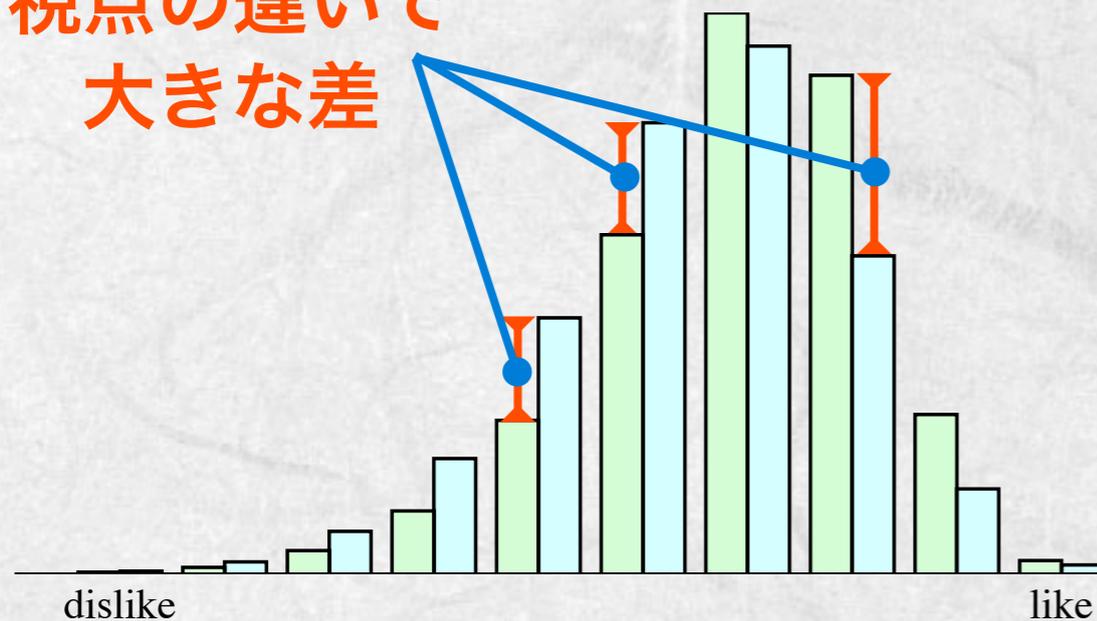
推薦の中立化の例

古い映画と新しい映画では古い映画の高く評価されやすい
そこで映画の新旧を視点として設定し中立的な推薦を行った

標準的な手法による予測

中立化した手法による予測

視点の違いで
大きな差



中立化で
差が小さく

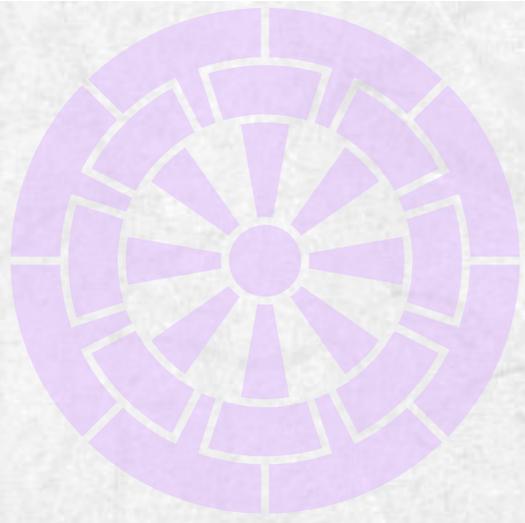


❖ 予測評価値のヒストグラムの各ビンを **古い映画** と **新しい映画** で並べた

中立化により、視点が違っても予測評価値の分布の差が小さくなった



視点の情報に推薦結果が影響されず推薦中立性が強化できている



推薦中立性が必要な例



利用者の望んだ視点に対する中立性の確保

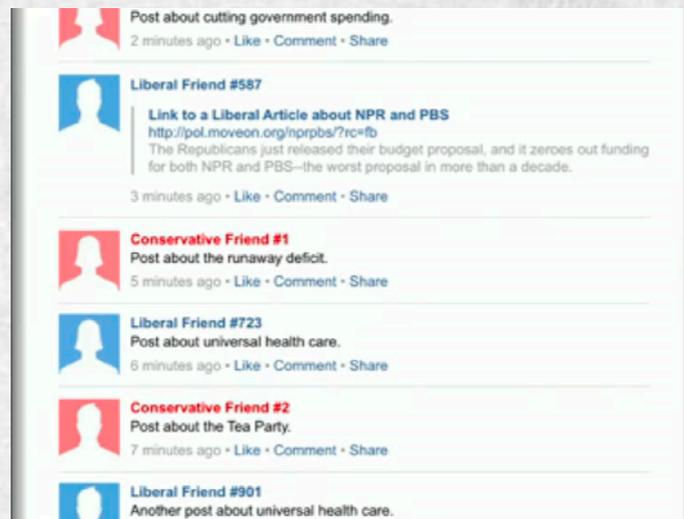
[TED Talk by Eli Pariser]

利用者の望んだ視点に対する中立性の確保

フィルターバブル問題：個人化技術によって利用者が多様な情報源や視点に接する機会が減らされているとの Eli Pariser による主張

Facebookの友人推薦リスト

進歩派の友人を増やしていると、利用者に断りなく保守派が消された



視点 = 友人候補の政治的態度



友人リストに加えるかどうかの判断で政治的態度の情報を除外

コンテンツ提供者の公平性

推薦システム運営者がコンテンツ提供者を公平に扱う必要性

検索結果の表示順位

2012年11月のBloombergの記事 (<http://bloom.bg/PPNEaS>) によれば、自身のサービスを競合企業と同種のサービスより上位に表示しているとの点についてFTCの調査を受けた

情報提供者の公平な扱い

小売店をまとめたオンラインモールや、顧客が提供する情報を掲載する不動産・求職サイトでは、コンテンツ提供者の公平性に配慮が必要



視点 = 推薦候補アイテムの情報提供者



候補の提供者の情報を推薦から無視することで提供者を公平に扱う

法や規定の遵守

[Sweeney 13]

推薦サービスを法や規定に従って運用する必要性

キーワードマッチ広告の配信

人名で検索したとき，ヨーロッパ系由来の名前より，アフリカ系由来の名前に対して，より頻繁に逮捕歴を示唆するテキストと共に，逮捕歴検索サイトの広告が表示された

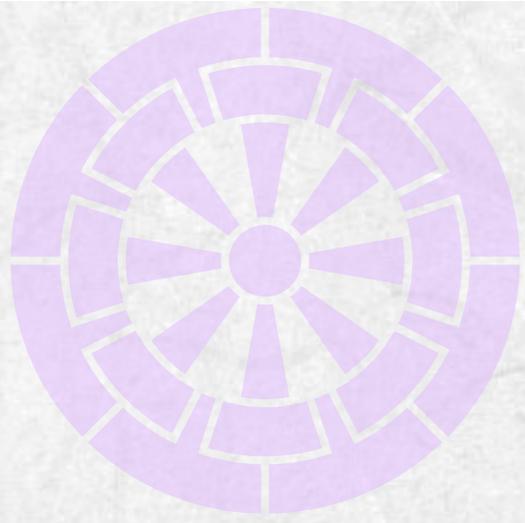


社会的に差別的な扱いは回避されるべき

視点 = 対象者のセンシティブな個人属性情報



法的・社会的にセンシティブな情報を排除して推薦することが可能



情報中立推薦システム



情報中立推薦システム

情報中立推薦システム

指定した視点特徴からの中立性

推薦中立性を保つための制約項を導入

+

高い予測精度

経験誤差の最小化によって高い予測精度を達成



確率的行列分解モデルを情報中立化したアルゴリズムを考案

中立性項と目的関数

中立性項 $\text{neutral}(R, V)$: 推薦中立性を評価する項

- * 予測評価と視点特徴の両方に依存
- * 推薦中立性が高いほど、すなわち視点特徴の予測評価値への影響が小さいほど大きな値を出力する

標準的な推薦モデルを拡張した情報中立推薦モデルの目的関数

中立性パラメータ
中立性と予測精度のバランスを調整

正則化
パラメータ

$$\sum_{r \in \mathcal{D}} \text{loss}(r, \hat{r}) + \eta \text{neutral}(R, V) + \lambda \|\Theta\|_2^2$$

損失関数

中立性関数

L₂正則化項

この目的関数を最小化するようにパラメータを学習

推薦中立性の形式的定義

推薦中立性：視点特徴の値に推薦結果が影響されないこと



$\Pr[R | V] = \Pr[R]$ ：推薦結果 R と視点特徴 V が統計的に独立



中立性関数 = R と V の統計的独立性の評価指標



相互情報量

$$I(R; V) = \sum_{R, V} \Pr[R, V] \log \frac{\Pr[R|V]}{\Pr[R]}$$

従来法：解析的微分不能・非効率



Caldars&Verwerスコア

$$\| \Pr[R|V = 0] - \Pr[R|V = 1] \|$$

提案法：解析的微分可能・効率的

Calders&Verwerのスコア(CVスコア)

視点特徴の値が異なる場合の R の分布を近づける

$$- \| \Pr[R|V = 0] - \Pr[R|V = 1] \|$$

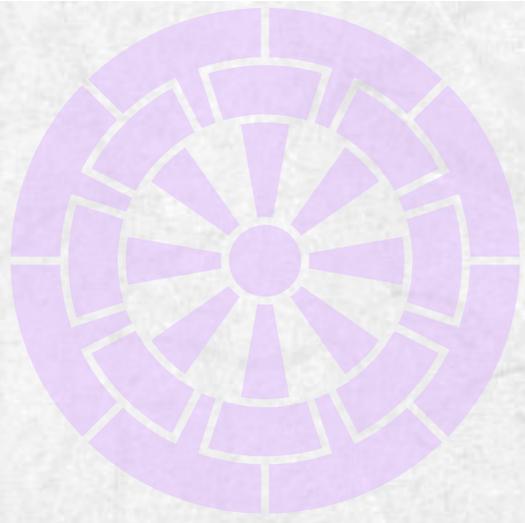


m-match法

$$- (\text{Mean}_{\mathcal{D}(0)}[\hat{r}] - \text{Mean}_{\mathcal{D}(1)}[\hat{r}])^2$$

$V=0$ と 1 のときの予測スコアの平均を合わせる
分布の1次モーメントだけ的一致だが実用的にはよい性能を示す

解析的に微分できるので目的関数の数値最適化は効率的



実験結果

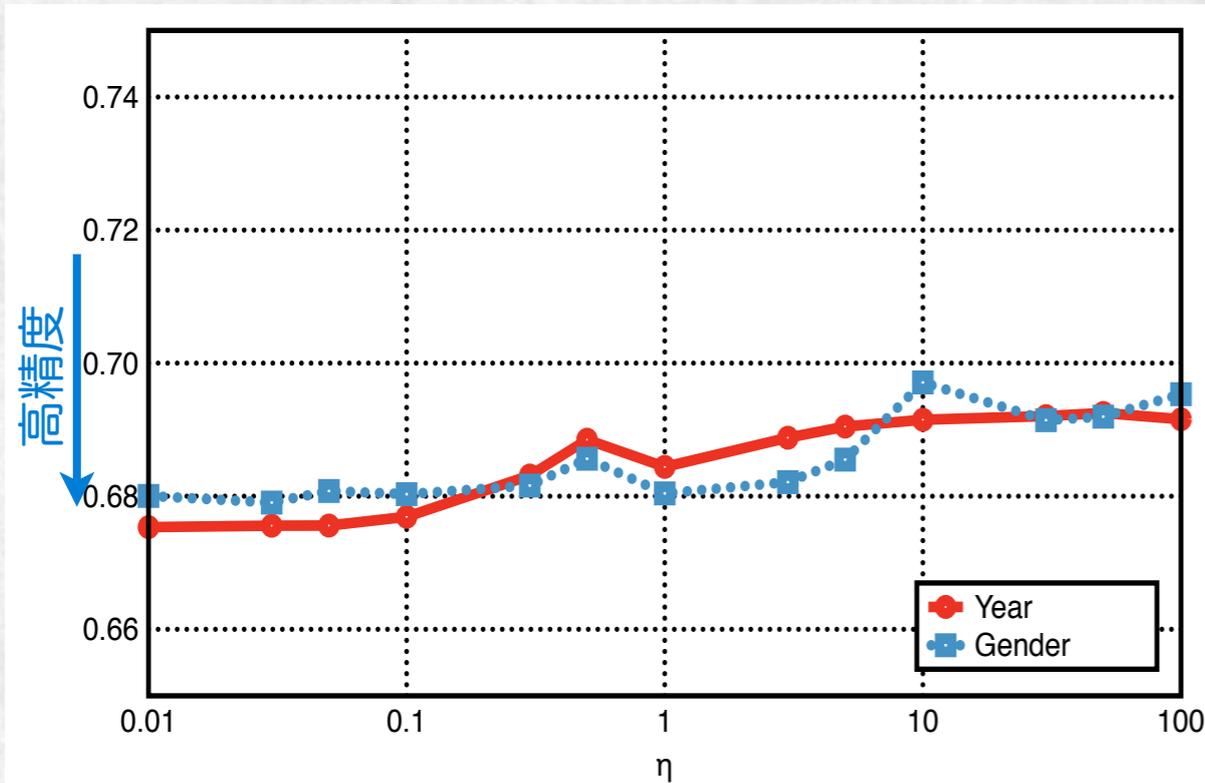


Movielens 1M (実験条件)

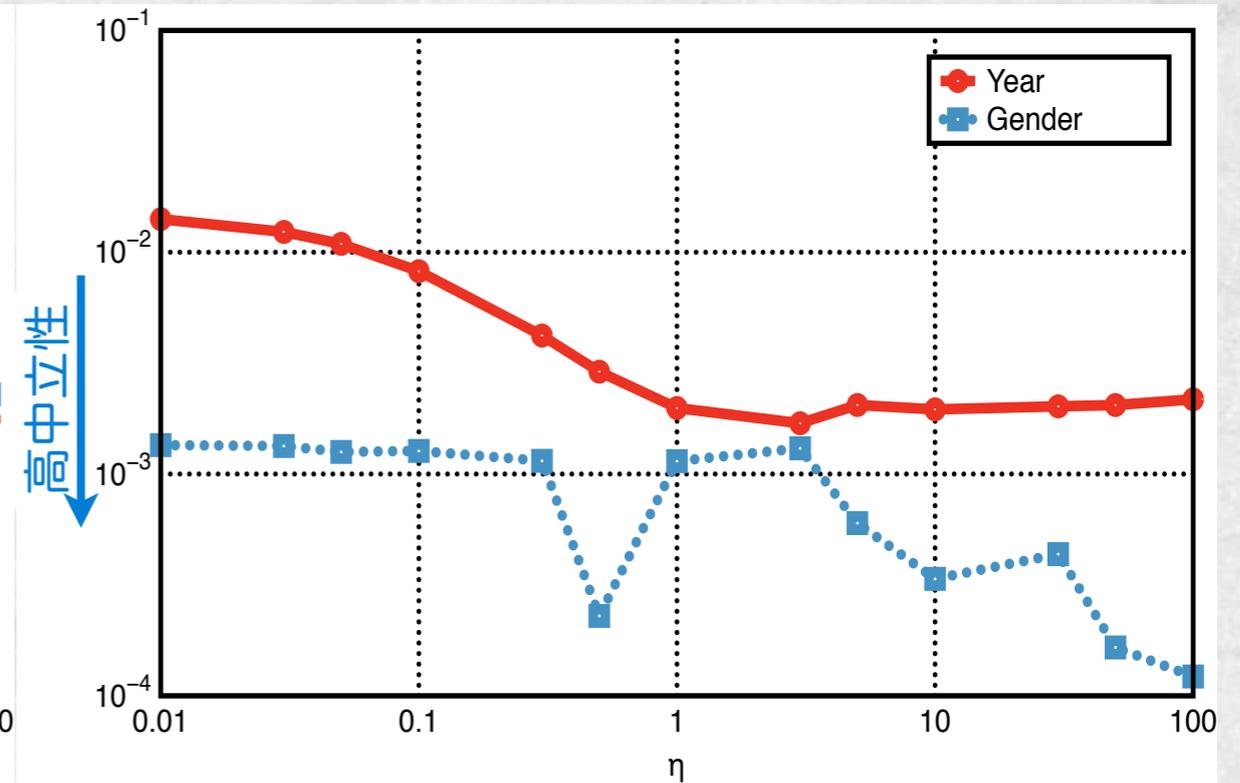
- * Movielens 1m データ：映画の評価データ，評価値数 1,000,209，利用者数 6040，アイテム数 3,706
 - * 以前の相互情報量による正則化項ではこの 1/100 までしか処理できなかった
- * 潜在因子数 $K=7$ ，正則化パラメータ $\lambda = 1$
- * 5分割交差確認
- * 実験に使った視点特徴：**Genderの方が元から中立性が高い**
 - * **Year**：映画の公開年が1990年以降かどうか
 - * **Gender**：評価者の性別
- * 評価尺度
 - * 予測精度：**MAE**（平均絶対誤差）
 - * 中立性：**NMI**（予測評価値と視点特徴の正規化相互情報量）

Movielens 1M (結果)

予測精度 (MAE)



中立性 (NMI)



中立性パラメータ η : 推薦中立性重視

❖ 標準的な確率的行列分解モデルによるMAEは 0.685

- ✳ 中立性パラメータ η を大きくして推薦中立性を重視すると、全般的に推薦中立性が向上 (NMIは減少) する。
- ✳ 予測精度は低下する (MAEが増加) が、その度合いは小さい。

提案手法で予測精度を損なうことなく推薦中立性を向上できた

Movielens 1M (推薦傾向の調査)

推薦中立性を強化することによる推薦のパターンの変化

Gender視点特徴で、映画のジャンルごとに評価値の変化を調査

計算手順

- * 18種類の映画ジャンルごとにデータを分割
- * さらに各ジャンルごとに、評価者の性別によってデータを二つに分割
- * 各データごとに評価値の平均値を計算し、男性の評価値から女性の評価値を引く

評価値

平均値を計算した評価値は次の2種類

- * **元データ**：訓練データの利用者が与えた評価値
- * **予測値**：推薦中立性を強化する確率的行列分解モデルにより予測した評価値 ($\eta = 100$ の場合)

Movielens 1M (ジャンルごとの平均評価)

男性の平均評価 - 女性の平均評価

この差が正值のジャンルは男性の評価に対して女性の評価が低い

	元データ	中立化後の予測値
Children's	-0.214	-0.158
Musical	-0.213	-0.151
Romance	-0.100	-0.046
Crime	0.024	0.074
Film-Noir	0.074	0.130
Western	0.103	0.162

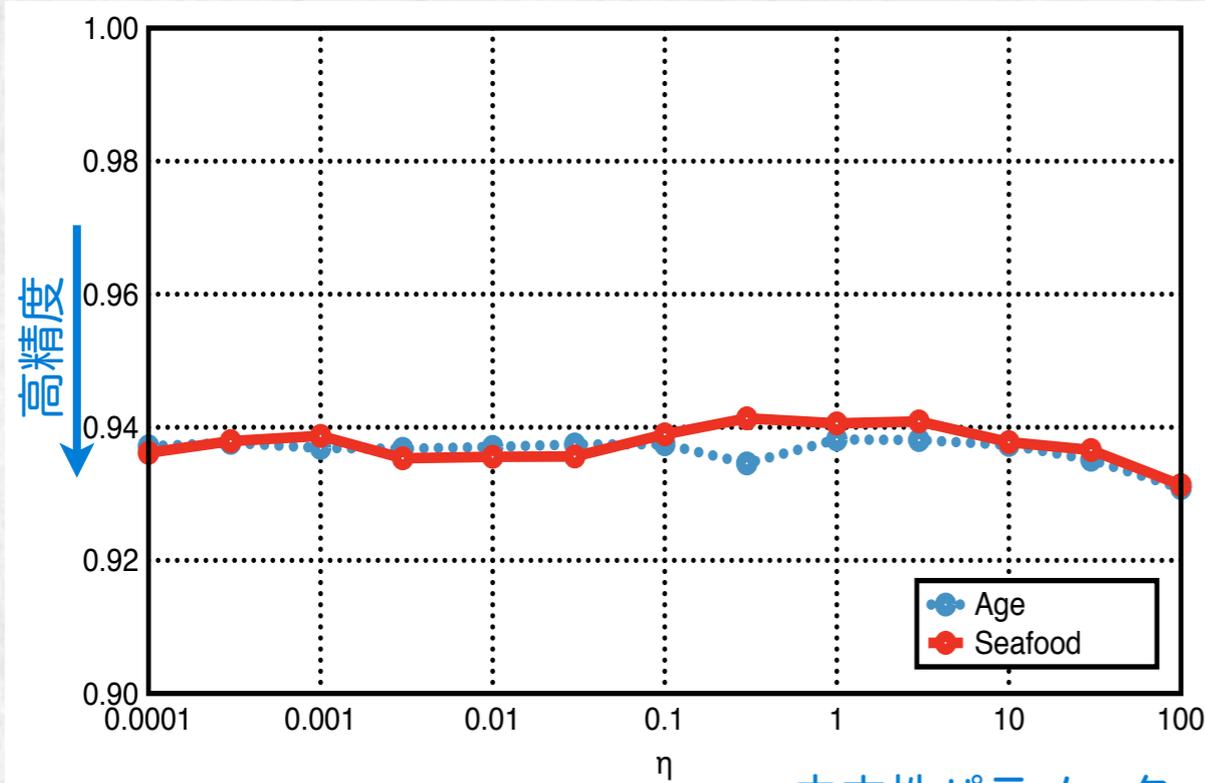
- ✳️ 男女の評価の差が大きいジャンルは、中立化によって差が小さくなる
- ✳️ 情報中立推薦は単純に予測評価値を並行移動しているのではなく、予測評価値への影響を考慮して予測評価値を変化させている

寿司データ (実験条件)

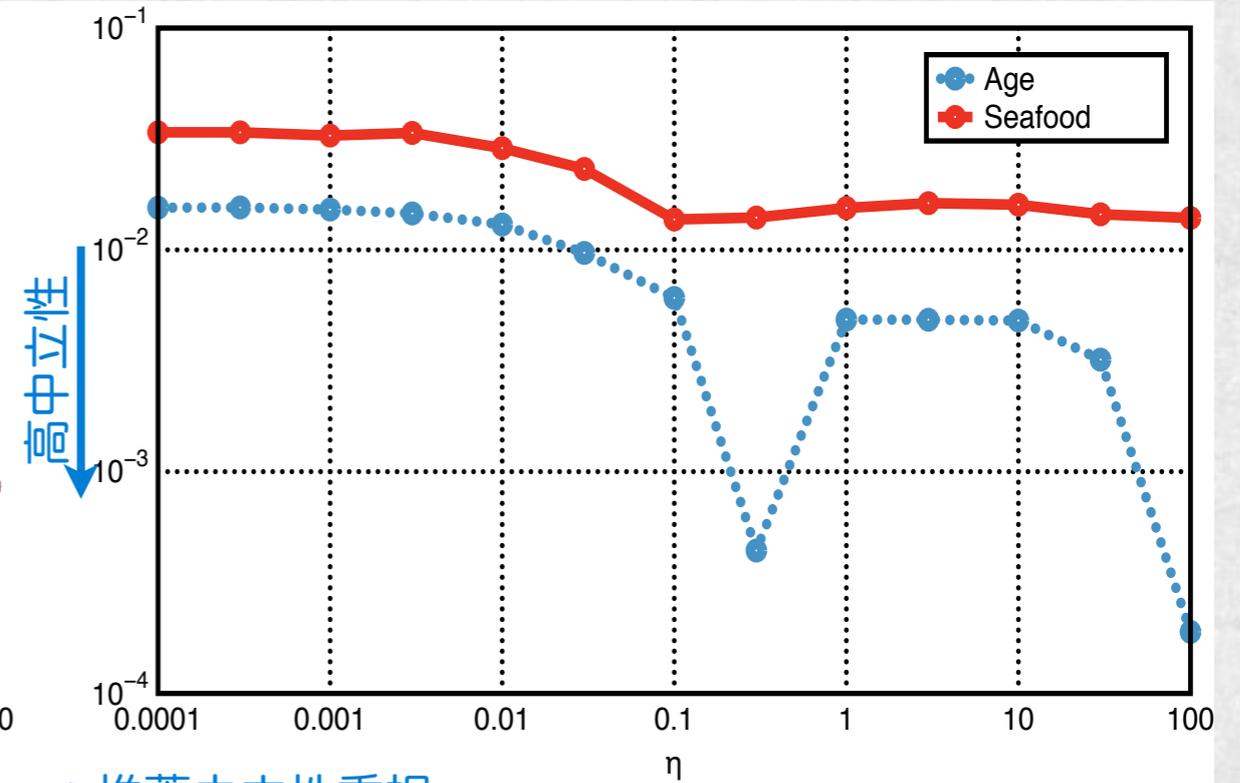
- * 寿司データ：寿司の嗜好データ，評価値数 50,000，利用者数 5000，アイテム数 100
- * 潜在因子数 $K=5$ ，正則化パラメータ $\lambda = 10$
- * 5分割交差確認
- * 実験に使った視点特徴：
 - * **Age**：被験者の年齢が10代か，もしくは20代以上か
 - * **Seafood**：魚介類の寿司かどうか
- * 評価尺度
 - * 予測精度：**MAE** (平均絶対誤差)
 - * 中立性：**NMI** (予測評価値と視点特徴の正規化相互情報量)

寿司データ (結果)

予測精度 (MAE)



中立性 (NMI)



中立性パラメータ η : 推薦中立性重視

❖ 標準的な確率的行列分解モデルによるMAEは 0.907

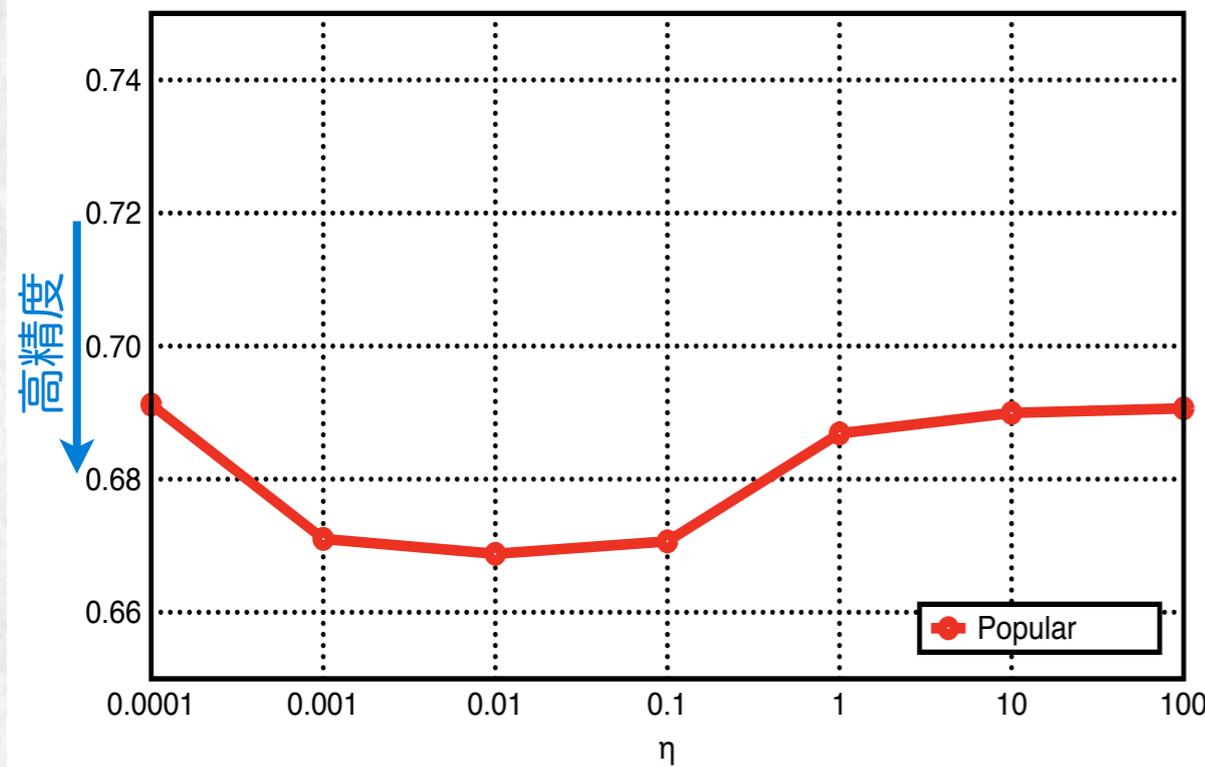
- ❖ 中立性パラメータ η を大きくすると, Movielensほどではないが中立性が向上した
- ❖ 予測精度についてはMovielensよりさらに予測精度の低下が小さかった

Flixster (実験条件)

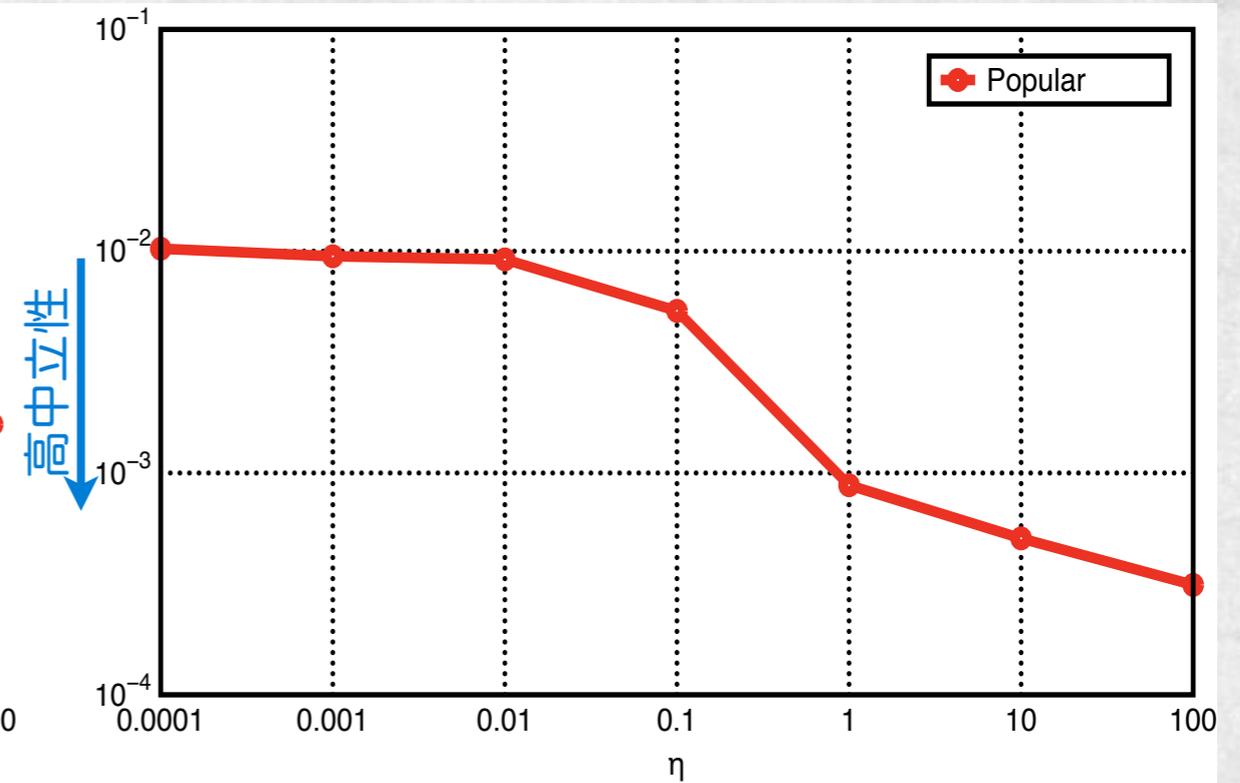
- * Movielens 1m データ：映画の評価データ，評価値数 8,196,077，利用者数 147,612，映画数 48,794
- * 潜在因子数 $K=10$ ，正則化パラメータ $\lambda=10$
- * 5分割交差確認
- * 実験に使った視点特徴：
 - * **Popular**：被評価アイテムが人気アイテムかどうか
人気アイテムとは被評価値数が全体の1%以上のもの，全評価値数の47.2%がこれらのアイテムのに対するもの
(推薦システムは被評価値数が多いアイテムが推薦されやすい人気バイアスがある)
- * 評価尺度
 - * 予測精度：**MAE** (平均絶対誤差)
 - * 中立性：**NMI** (予測評価値と視点特徴の正規化相互情報量)

Flixster (結果)

予測精度 (MAE)



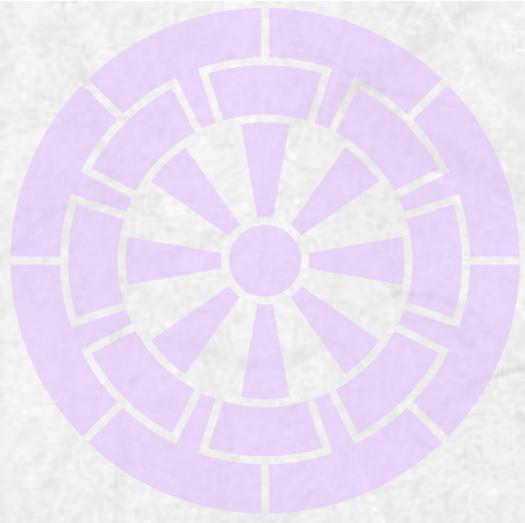
中立性 (NMI)



中立性パラメータ η : 推薦中立性重視

❖ 標準的な確率的行列分解モデルによるMAEは 0.665

- ❖ 中立性パラメータ η を大きくするに伴って, 単調に中立性が改善されている
- ❖ 予測精度の悪化はわずかに抑えられている



関連研究



推薦の多様性

[Ziegler+ 05]

話題の分散化 (Topic Diversification)

利用者と嗜好が一致するアイテムを選びつつ，推薦リストから類似したアイテムは排除することで，推薦アイテムの多様性を確保

類似度関数 c : アイテムの内容に基づいてアイテム間の類似度を測る
アイテムの階層的な分類があるとき，その構造木中でのホップ数の逆数などで測る

多様性

アイテムが推薦リスト中や推薦時系列上にのアイテムが互いに類似していない

推薦結果間の関係

中立性

視点特徴の情報を排除するだけで，推薦アイテム間の類似性は関係ない

推薦結果と視点の関係

プライバシー保護データマイニング

評価値変数 R と視点特徴 V の独立性

評価値変数 R と視点特徴 V の相互情報量が 0



プライバシー保護データマイニングの観点からの解釈

評価値 R の予測値を知られても、視点特徴 V の情報が漏洩しない

✿ t -近接性と概念的には強い関連がある

まとめ

本発表の寄与

- ✳️ 推薦における中立性を定式化
- ✳️ 推薦中立性を強化する情報中立推薦システムを開発
- ✳️ 提案アルゴリズムが予測精度をそれほど低下させることなく、中立性を強化できることを実験的に示した
- ✳️ 効率的に計算可能な中立化項を提案し、実際にいろいろな大規模ベンチマークデータで検証した

今後の予定

- ✳️ 他の独立性指標の採用で、効率性と中立化性能の両立
- ✳️ 評価値予測ではなく、適合アイテムの推薦での中立化手法の開発

実験コードを公開しています

まだ前のバージョンですが、更新予定です

<http://www.kamishima.net/inrs>

謝辞

- * Grouplens research lab と Dr. Mohsen Jamali による実験データの提供に感謝する
- * 本研究は JSPS 科研費 16700157, 21500154, 23240043, 24500194, および 2550094 の助成を受けたものである