

キャッシュを考慮したコンテンツ推薦システムのキャッシュヒット率評価

Evaluation of Cache Hit Ratio of Content Recommendation System Considering Effect of Cache

村上 悠斗<sup>1</sup> 深川 悠馬<sup>1</sup> 上山 憲昭<sup>2</sup>

Yuto Murakami Yuma Fukagawa Noriaki Kamiyama

立命館大学大学院 情報理工学研究科<sup>1</sup>

Graduate School of Information Science and Engineering, Ritsumeikan University

立命館大学 情報理工学部<sup>2</sup>

College of Information Science and Engineering, Ritsumeikan University

1. はじめに

NetflixのようなCP (Content Provider) にとって、関心度が高いコンテンツをユーザに提案する推薦システムがコンテンツ要求の大部分を占める重要な技術である [1]。ユーザにとって魅力的なコンテンツを推薦することで、ユーザのサービスに対するエンゲージメントを向上し、ユーザ数や視聴時間が増加するため、CP の収益につながる [2]。特にビデオストリーミングサービスでは、低ビットレートや配信遅延はサービスの離脱率の上昇につながる。そこで多くの CP は CDN (Content Delivery Network) を Web コンテンツをユーザに効率的に配信するために使用している。CDN により、ユーザから物理的に近いキャッシュサーバからコンテンツを配信することで、コンテンツへのアクセスを高速化し、ユーザの体感する遅延とオリジンサーバの負荷を軽減することができる。

従来の推薦方式として、ユーザの嗜好度の類似性に基づいた協調フィルタリングが広く採用されている。訪問ユーザと行動や好み似た他のユーザが好むコンテンツは、訪問ユーザも好む可能性が高い。そこで協調フィルタリングは、あるユーザの行動履歴 (コンテンツの視聴や購入) をもとに、訪問ユーザが利用する可能性が高いコンテンツを推薦する。しかしユーザの行動履歴に関するデータを使用するため、データが少ない場合で精度が低下するコールドスタート問題がある。また従来の推薦方式ではネットワーク負荷の軽減については考慮していない。ユーザの観点では個々のユーザの好みに合ったコンテンツの推薦が望ましく、一方でネットワークの観点では配信コスト削減のために高人気コンテンツの推薦が望ましい。そこで筆者らは、ユーザの満足度および、キャッシュの効果向上を目的とした推薦と、協調フィルタリングのコールドスタート問題を改善するコンテンツ推薦方式を提案した [5]。本稿では本方式の有効性を確認するため計算機シミュレーションによる数値評価結果を示す。

2. 提案方式

一般的にキャッシュされているコンテンツは配信回数が多く人気度が高いため、推薦対象をキャッシュされているコンテンツに限定することで、人気度が高く、かつ訪問ユーザの嗜好に沿ったコンテンツを推薦することが可能である。また、コールドスタート問題への対応として、 $\epsilon$ -greedy 法と呼ばれる強化学習の推薦方式に協調フィルタリングを組み合わせる。

提案するキャッシュサーバ内のキャッシュされているコンテンツに限定した協調フィルタリングでは、ユーザから物理的に近いキャッシュサーバでキャッシュされているコンテンツを推薦候補とすることで、最短経路でコンテンツを配信可能である。しかし、キャッシュサーバをユーザの最寄りのキャッシュサーバに限定することで、推薦候補となるコンテンツも限定され、各ユーザの嗜好を十分に考慮できない可能性がある。そこで、最寄りのキャッシュサーバに限定せず、サーバの範囲を拡大させながら推薦の自由度向上を図る。

確率  $\epsilon$  でランダムにコンテンツの推薦 (探索) を行い、確率  $1 - \epsilon$  で現時点で収集済みの嗜好データのみを用いた協調フィルタリングによりコンテンツを推薦する (活用)。推薦コンテンツのユーザの視聴の有無をデータとして収集することで、ユーザの行動履歴などに関するデータが少ないコンテンツに対して視聴データを収集することが可能である。また類似度の高いユーザの行動履歴にないコンテンツも推薦するため、協調フィルタリングにおける推薦するコンテンツの偏りを緩和する。 $\epsilon$ -

greedy 法の動作を図 1 に示す。

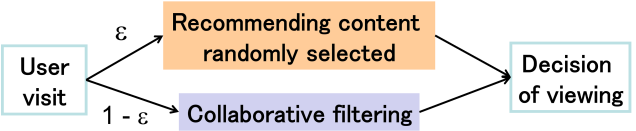


図 1:  $\epsilon$ -greedy method

提案方式の具体的な動作を図 2 を用いて説明する。評価点に基づく協調フィルタリングの動作を以下に示す。図 2 ではユーザの各コンテンツに対する 5 段階評価を嗜好データとして用いており、“-”は未評価を表す。提案方式ではキャッシュに存在するコンテンツのみを対象に評価度を比較する。

- 1. 訪問ユーザ X と各ユーザ間で類似度 (相関係数)  $P_{xy}$  を計算 (1)
- 2. 相関係数が高い上位  $k$  人 ( $k = 3, C, D, E$ ) の、キャッシュ中の各コンテンツに対する評価度の平均を計算
- 3. 平均値が最大のコンテンツ (= 5) をユーザ X に推薦

Cached content											Correlation coefficient
Content	1	2	3	4	5	6	7	8	9	10	
User X	-	4	2	-	-	-	-	1	1	5	1.000
A	5	3	4	-	-	-	-	1	2	1	0.063
B	-	-	-	1	1	2	4	5	4	0	-0.982
C	2	3	2	1	-	4	3	2	1	4	0.941
D	2	-	-	2	4	5	1	2	5	5	0.500
E	-	5	0	-	5	1	-	1	1	2	0.615
Degree of recommend	2.00				4.50	3.33	2.00				

図 2: Collaborative filtering for only cached contents

$$P_{xy} = \frac{\sum_{m \in C_{xy}} (r_{xm} - R_x)(r_{ym} - R_y)}{\sqrt{\sum_{m \in C_{xy}} (r_{xm} - R_x)^2} \sqrt{\sum_{m \in C_{xy}} (r_{ym} - R_y)^2}} \tag{1}$$

$C_{xy}$  : ユーザ x と y の両方が評価値をつけているコンテンツの集合

$r_{nm}$  : ユーザ n のコンテンツ m に対する評価値

$R_n$  : ユーザ n の  $C_{xy}$  に対する評価値の平均値

3. ユーザ視聴行動モデル

3.1 ユーザの視聴

ユーザは検索等による独自の探索行動と推薦システムによって、コンテンツを視聴する。探索行動では、ユーザは zipf 分布に従って視聴するコンテンツを選択する。各コンテンツの人気度順位は、全ユーザからの評価数から決定する。推薦によるコンテンツの視聴では、ユーザに推薦されたコンテンツへの嗜好度がある閾値を超えている場合に、その推薦コンテンツを視聴する。閾値は、推薦を受け入れるための厳しさを基準を表し、閾値が高いほど、ユーザはより限られた数の推薦を受け入れる。一方で閾値が低い場合は、推薦されるコンテンツを受け入れる基

準が緩和され、多くの推薦を受け入れる。ユーザのコンテンツに対する嗜好度の推測には、コンテンツとカテゴリの関連度およびユーザのカテゴリに対する関心度を考慮した [3]。

### 3.2 ユーザのコンテンツに対する嗜好度のモデル化

訪問ユーザの嗜好に近いコンテンツを推薦することで、ユーザはそのコンテンツを要求する確率が高くなる。[3]より、ユーザの各コンテンツに対する嗜好度を、コンテンツとカテゴリ間の関連度とユーザのカテゴリに対する関心度から推測する。

#### 3.2.1 カテゴリとコンテンツ間の関連度

各コンテンツは、1 つまたは複数のカテゴリに関連している。(例 "Toy Story", Adventure|Animation|Children|Comedy|Fantasy)

あるコンテンツが  $m$  個の異なるカテゴリで記述されている場合、カテゴリとコンテンツ間の関連度  $f^i(j)$  を  $1/m$  に設定し、コンテンツ  $i$  がカテゴリ  $j$  にどれだけ関連しているかを示す。

例ではコンテンツ "Toy Story" を構成している各カテゴリとの関連度は  $f^i(j)=1/5=0.2$  となる。

#### 3.2.2 ユーザのカテゴリに対する関心度

ユーザ  $u$  のカテゴリ  $j$  に対する関心度  $f_u(j)$  を (2) で導出する。

$$f_u(j) = \frac{\sum_{i \in C_r(u)} f^i(j)}{\sum_{j=1}^M \sum_{i \in C_r(u)} f^i(j)} \quad (2)$$

$C_r(u)$  : ユーザ  $u$  が評価したコンテンツの集合

$M$  : 全カテゴリの総数

#### 3.2.3 ユーザのコンテンツに対する嗜好度の予測

ユーザ  $u$  のコンテンツ  $i$  に対する嗜好度  $P_u^{pref}(i)$  を導出する。 $f_u$  と  $f^i(j)$  から推測するためコサイン類似度を用いる。すなわちユーザ  $u$  とコンテンツ  $i$  の類似度  $a_{ui}$  を次式で得る。

$$a_{ui} = \frac{\sum_{j=1}^M f_u(j) f^i(j)}{\sqrt{\sum_{j=1}^M f_u(j)} \sqrt{\sum_{j=1}^M f^i(j)}} \quad (3)$$

これらの値を正規化すると、ユーザ  $u$  のコンテンツ  $i$  に対する嗜好度は、

$$P_u^{pref}(i) = \frac{a_{ui}}{\sqrt{\sum_{i \in I} a_{ui}}} \quad (4)$$

となる。

## 4. 性能評価条件

### 4.1 データセット

シミュレーションで使用する各映画の評価やタイトル、ジャンルのデータを MovieLens のデータセットから用いる [4]。データセット内の各ユーザのコンテンツに対する評価数をコンテンツ配信サービスの利用頻度として考え、システム利用ユーザを決定する。

データセット内の各ユーザが付与したコンテンツに対する評価数を、コンテンツ配信サービスの利用頻度の指標として捉える。評価数から得られた累積分布より、各シミュレーションにおける、システムの利用ユーザとして決定する。

### 4.2 想定するネットワーク

ユーザと各コンテンツのオリジンサーバは、各ノードの人口比率に従って配置される。また、提案する協調フィルタリングでは、訪問ユーザの該当ノードから  $N$  ホップ以内に位置するキャッシュサーバでキャッシュされているコンテンツを協調フィルタリングの推薦候補とする。ユーザが要求したコンテンツがキャッシュサーバにキャッシュされていればキャッシュサーバから送信するが、キャッシュされていなければオリジンサーバから配信する。キャッシュ置換方式は、キャッシュの中で過去に要求されてから最も時間が経過したコンテンツが置換される LRU (Least Recently Used) を想定する。

## 5. 性能評価結果

推薦によるコンテンツの視聴では、ユーザに推薦されたコンテンツへの嗜好度がある閾値を超えている場合に推薦コンテンツを視聴する。閾値は推薦を受け入れるための厳しさや基準を表し、閾値が高いほどユーザはより限られた数の推薦を受け入れる。0 から 1.0 の嗜好度の値を基にデータから抽出し実験的に閾値を設定した。閾値が小さい場合 (0.0001) と大きい場合 (0.001) における提案方式と、推薦をしないコンテンツ視聴方式のキャッシュヒット率を表 1 に示す。探索確率  $\varepsilon$  は  $1/t$  に設定し、シミュレーション時間の経過とともに協調フィルタリングによる推薦の割合を増加させ、ユーザから 3 ホップ以内のサーバでキャッシュされているコンテンツを協調フィルタリングの推薦候補とする。

結果より、閾値が低い場合、キャッシュされている推薦コンテンツがユーザに視聴される確率が高いため、推薦がない場合と比較してキャッシュヒット率は増加している。一方で閾値が高い場合、キャッシュヒット率が他の方式と比較して低下している。これは、閾値が高いために視聴される推薦コンテンツが減少し、キャッシュされるコンテンツ数も減少するためだと考える。協調フィルタリングを用いたコンテンツ推薦によりユーザの満足度の向上が期待される反面、必ずしも高人気コンテンツが推薦されるとは限らないため、キャッシュヒット率の低下が懸念される。しかし提案方式を用いることで、キャッシュヒット率の低減が抑えられることが確認できる。

表 1: Cache hit ratio in each cache size

Cache size	Cache hit rate (%)		
	No recommendation	Low threshold	High threshold
10	1.25	3.31	1.18
100	5.29	5.91	5.29
1000	18.40	16.73	14.60

## 6. まとめ

本稿では、著者らが以前、提案したキャッシュを考慮した協調フィルタリングによる推薦方式の有効性を確認するため、数値評価結果を示した。今後の研究方針として、キャッシュを考慮しない一般的な協調フィルタリングとの比較や訪問ユーザから推薦候補がキャッシュされている各キャッシュサーバまでの距離 (ホップ数) を増加させながらキャッシュヒット率や配信ホップ長の評価を行う予定である。さらに、本稿では推薦度が最も高いコンテンツ 1 つのみを推薦したが、推薦コンテンツ数の増加が推薦コンテンツの視聴確率の向上への影響度についても評価する。

**謝辞** 本研究成果は JSPS 科研費 21H03436 と 21H03437 の助成を受けたものである。ここに記して謝意を表す。

### 参考文献

- [1] C. A. Gomez-Urbe and N. Hunt, "The Netflix recommender system: Algorithms, business value, and innovation," ACM Transactions on Management Information Systems (TMIS), vol. 6, no. 4, pp. 1-19, Dec. 2015.
- [2] Z. Tufekci, "Youtube, the great radicalizer," The New York Times, 2018.
- [3] L. E. Chatzieftheriou, M. Karaliopoulos and I. Koutsopoulos, "Caching-aware Recommendations: Nudging User Preferences towards better Caching Performance", IEEE INFOCOM 2017.
- [4] MovieLens, <https://movielens.org/>
- [5] 村上 悠斗, 上山 憲昭, "キャッシュを考慮したコンテンツ推薦システム", 信学会 2023 年ソ大会, B-6-7