

キャッシュ状態を考慮したコンテンツ推薦システム

村上 悠斗[†] 深川 悠馬[†] 上山 憲昭^{††}

[†] 立命館大学大学院 情報理工学研究科

〒525-8577 滋賀県草津市野路東 1-1-1

^{††} 立命館大学 情報理工学部

〒525-8577 滋賀県草津市野路東 1-1-1

E-mail: [†]{gr0579hk,gr0579ri}@ed.ritsumeai.ac.jp, ^{††}kamiaki@fc.ritsumeai.ac.jp

あらまし Netflix などのコンテンツ配信サービスにおいて、ユーザの嗜好に沿ったコンテンツ推薦がコンテンツ要求の大部分を占める重要な存在となっている。また、配信遅延や低ビットレートがユーザのサービス離脱率に影響する。そこで従来の研究では、ネットワークの負荷軽減や推薦システムの課題であるコールドスタート問題を解決するアプローチがそれぞれ提案されている。しかし従来の推薦方式ではネットワーク負荷の軽減とコールドスタート問題の両方については考慮されていない。また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。そこで本稿では、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方式と、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する。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することで、ネットワーク負荷軽減とアクセス時間の短縮を図る。また協調フィルタリングの課題であるコールドスタート問題への対応として、 ϵ -greedy 法と呼ばれる強化学習の推薦方式にキャッシュに限定した協調フィルタリングを組み合わせる。そして提案方式の有効性を計算機シミュレータにより評価する。

キーワード キャッシュ, 推薦, CDN, ICN, 協調フィルタリング, コールドスタート問題

Content Recommendation System Considering Cache State

Yuto MURAKAMI[†], Yuma FUKAGAWA[†], and Noriaki KAMIYAMA^{††}

[†] Graduate School of Information Science and Engineering, Ritsumeikan University

1-1-1, Nojihigashi, Kusatsu, Shiga 525-8577

^{††} College of Information Science and Engineering, Ritsumeikan University

1-1-1, Nojihigashi, Kusatsu, Shiga 525-8577

E-mail: [†]{gr0579hk,gr0579ri}@ed.ritsumeai.ac.jp, ^{††}kamiaki@fc.ritsumeai.ac.jp

Abstract The demand for large-scale content such as music and videos has increased, and it drives up the internet traffic. Content recommendation systems that suggest content based on user preferences have become a crucial component of content delivery services like Netflix, and it accounts for a significant portion of content requests. Additionally, factors like delivery latency and low bit rates can impact user churn rates. However, existing works have proposed methods to address network load reduction and the cold-start problem in recommendation systems separately, and traditional recommendation methods do not consider both network load reduction and the cold-start problem simultaneously. From the user perspective, recommending content tailored to individual preferences is desirable. On the other hand, from the network-providers perspective, recommending highly popular content to reduce delivery costs is preferred. Therefore, in this paper, we propose a content recommendation method aimed at improving user satisfaction and enhancing cache efficiency while addressing the cold-start problem in collaborative filtering. The proposed method limits the targets of collaborative filtering to contents cached within cache servers. It recommends content that is physically closer to users and cached in nearby cache servers to reduce the network load and shorten access times. Additionally, to address the cold-start problem, we combine cache-limited collaborative filtering with a recommendation method based on reinforcement learning called ϵ -greedy. We evaluate the effectiveness of the proposed method through computer simulations.

Key words Cache, Recommendation, CDN, ICN, Collaborative filtering, Cold start problem

1. はじめに

Netflix や Amazon Prime などのコンテンツ配信サービスが急速に普及している現代において、ユーザ数の増加とともに、さらなる今後の需要の拡大が予測されている。これらのサービス内では、膨大な数のコンテンツが提供されており、ユーザが自分の興味・関心に合致するコンテンツを検索などによって見つけることは一層困難となっている。そこで多くのコンテンツ配信サービスでは、要求ユーザの関心度が高いと推測されるコンテンツをユーザに提案する推薦システムが導入されている。特にコンテンツ提供事業者である CP (Content Provider) では、推薦システムがユーザのコンテンツ要求をサポートする重要な存在となっている。実際に Netflix では、推薦システムによって発生するコンテンツ要求数が全体の 8 割を占める [1]。そのため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が向上し、ユーザ数やコンテンツの視聴時間の増加が 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ことが示されている。そのためユーザから高い QoE (Quality of Experience) を求められることが予想される。そこで、多数の CP は CDN (Content Delivery Network) と呼ばれる Web コンテンツをユーザに効率的に配信するキャッシュネットワークを使用している。CloudFlare や Akamai が CDN を提供する代表的な事業者である [3]。CDN は地理的に分散配置された複数のキャッシュサーバで構成されており、キャッシュサーバにコンテンツがキャッシュされ、キャッシュサーバからコンテンツが配信される。CDN の動作を図 1 に示す。




図 1: CDN のコンテンツ配信システム

ユーザからの要求に対してコンテンツの配信を行ったとき、ユーザから物理的に近いサーバでコンテンツがキャッシュされる。ユーザからのコンテンツ要求に対して、要求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、ネットワークの状態やユーザとオリジンサーバ間の距離にかかわらず、安定したコンテンツ配信を実現する。この CDN の仕組みにより、コンテンツへのアクセスを高速化し、ユーザの体感する配信遅延とオリジンサーバの負荷を軽減することで、CP は高品質なサービスを安価に提供することが可能となる。

現在、音楽や動画などの大容量コンテンツの流通や、タブレットやスマートフォンなどの携帯端末、SNS (ソーシャルネットワークワーキングサービス) に代表されるユーザ主体の情報発信サービスが、インターネット上を流れるトラフィックの大部分を占めている。これに伴って大量のデータがネットワークに提供され、頻繁にデータが更新される環境が一般化することが予想される。そこで新しいネットワークアーキテクチャとして、情報指向ネットワーク (ICN: information-centric networking) が注目を浴びている。従来の IP アドレスを用いた場所に基づく通信を行うインターネットは、DNS (Domain Name System) によって通信相手となるホストの IP アドレスを検索し、該当の IP アドレスを持つサーバにアクセスし、コンテンツを取得する。ICN は IP アドレスに基づく通信ではなく、コンテンツ名を識別子として通信を行う。配信経路上のルータなどのノードに要求されたコンテンツをキャッシュし、配信要求が発生すると近くに存在するノードに該当のコンテンツがキャッシュされている場合、そのノードから配信される。そのため応答時間の短縮やコンテンツの配信の品質、効率の向上が期待される。ICN の動作

を 2 に示す。




図 2: 情報指向ネットワーク

推薦方式として、ユーザ間の嗜好度の類似性に基づいた推薦方式である協調フィルタリングが広く採用されている。コンテンツベースフィルタリングでは、あらかじめ、コンテンツの特徴を正確に把握するための分析技術やコンテンツの内容からユーザの嗜好が読み取れるような特徴を抽出するプロセスが必要となる。更には、ユーザが過去に好んだコンテンツと類似するコンテンツが推薦されることで、セレンディピティに欠ける可能性がある。このように個人の過去の行動履歴のみを利用すると、多様なコンテンツが推薦されない。一方、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ため、コンテンツの内容や特徴を知っておく必要はない。また、嗜好の類似するユーザを利用することで、ユーザが知らなかった意外なコンテンツを推薦できる可能性がある。しかし、これらの協調フィルタリングのアプローチでは、ユーザの行動履歴に関するデータを使用してコンテンツを推薦するため、データが少ない場合、精度が低下するコールドスタート問題と呼ばれる課題が存在する。ユーザ間で共通に評価しているコンテンツが存在しない場合に、嗜好の類似するユーザが見つけれず、推薦ができない状態である。新規コンテンツや新規ユーザの増加は、今後の配信サービスの普及していく過程で、必ず発生するものである。そのため、協調フィルタリングは優れた推薦方式である一方で、適切に機能するための多くの行動データの取得が必要となる。

従来の研究では、ユーザの嗜好に沿ったコンテンツ推薦を目的とした方式だけでなく、ネットワークの負荷軽減やデータのコールドスタート問題を解決するアプローチも提案されている。しかし、従来の推薦方式ではネットワーク負荷の軽減とコールドスタート問題の両方については考慮していない。また、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。そこで本稿ではユーザの満足度および CDN や ICN などのネットワークにおける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する。さらに計算機シミュレーションにより、提案方式の有効性を確認する。以下、2. 節で関連研究について述べる。そして 3. 節で提案方式の概要、5. 節で性能評価を行い、6. 節で全体をまとめる。

2. 関連研究

[4] で、Yuan らが提案したシステムは、新規コンテンツを既存の行動データを持つコンテンツとペアリングすることで、コールドスタート問題を解決している。提案されたペアリングプロセスでは、新しいコンテンツを既存のコンテンツと関連付けるための深層学習アルゴリズムにより、ユーザの新規コンテンツに関する行動データが無くても、新規コンテンツを協調フィルタリングで考慮することが可能となる。[5] では、IoT データの一般的なコールドスタート問題を提起し、新しいハイブリッドキャッシュ戦略を提案している。キャッシュをプロアクティブキャッシュとリアクティブキャッシュの 2 つに分割し、プロアクティブキャッシュでは深層学習を用いてデータの人気を予測し、リアクティブキャッシュでは改良された LRU アルゴリズムを使用している。この 2 つの組み合わせにより、パフォーマンスを確保しつつ、データのコールドスタート問題を解決している。[6] の研究では、推薦システムがユーザの需要を形成し、キャッシュの利得を高めることに着目し、基地局においてコンテンツのキャッシュと推薦を同時に最適化する手法を提案して

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。

4.2.1 コンテンツとカテゴリ間の関連度

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。例えば"Toy Story"の関連カテゴリとして、Adventure|Animation|Children|Comedy|Fantasy といったものが考えられる。あるコンテンツが m 個の異なるカテゴリに関連している場合、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。関連度は 0 から 1 の範囲の値を取り、全てのスコアの合計が 1 になるように正規化される。

例ではコンテンツ"Toy Story"を構成しているカテゴリは、Adventure から Fantasy までの 5 つなので ($m = 5$)、各カテゴリとの関連度は $f_i(j) = 1/5 = 0.2$ となる。

4.2.2 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) で与える。関心度も、0 から 1 の範囲で、全てのスコアの合計が 1 になるように正規化される。

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

ただし $C_r(u)$ はユーザ u が評価したコンテンツの集合、 M は全カテゴリの総数である。

4.2.3 ユーザの各コンテンツに対する嗜好度

各ユーザ u は、各コンテンツに対する嗜好度分布 P_u^{pref} を有する。ユーザ u のコンテンツ i に対する嗜好度 $P_u^{pref}(i)$ は、 u と i の特徴ベクトルから推定でき、これら 2 つのベクトルのコサイン類似度 $a_{u,i}$ を使用して、嗜好度を計算する。類似した嗜好を持つユーザ間の類似性の計算には、協調フィルタリングで一般的に使用されるコサイン類似度 (cosine similarity) を使用する。コサイン類似度は、2 つのベクトル間の類似性を測定し、テキスト分析やクラスタリングのグループ分けにおいて使用される。ユーザ u とコンテンツ i の類似度 $a_{u,i}$ を f_u と $f^i(j)$ から次式で与える。

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

$a_{u,i}$ を正規化することで、ユーザ u のコンテンツ i に対する嗜好度 $P_u^{pref}(i)$ は、

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

となる。

4.3 視聴行動モデル

視聴行動モデルを図 5 に示す。本システムの推薦対象とする訪問ユーザ X を決定し、推薦確率 p_r で訪問ユーザ X に対してコンテンツの推薦を行う。推薦を行う場合、 ϵ -greedy 法に移行し、確率 ϵ で訪問ユーザ X が未視聴のコンテンツ集合の中からランダムに推薦する。確率 $1 - \epsilon$ でキャッシュに限定した協調フィルタリングによる推薦を行う。推薦が受け入れられなかった場合とコールドスタートの場合は、Zipf 分布に従って未視聴のコンテンツの集合の中からランダムに視聴する。コールドスタートの状態として、訪問ユーザ X と他の Y の両方が評価値をつけているコンテンツの集合 C_{XY} が 0 の場合とキャッシュに推薦可能なコンテンツが存在しない場合を想定する。




図 5: 視聴行動モデル

5. 性能評価

5.1 性能評価条件

5.1.1 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 [10]。MovieLens は、幅広い映画に関する豊富な情報を提供する公開データベースであり、ユーザによる映画の評価や映画のメタデータを含んでいる。総コンテンツ数 $N_c = 9742$ 、全ユーザ数 $N_u = 610$ 、総ジャンル数 $N_j = 20$ である。

5.1.2 システム訪問ユーザの選択

シミュレーションでは、MovieLens のデータセット内にある各ユーザのコンテンツに対する評価回数を、そのユーザのコンテンツ配信サービスにおける利用頻度として考える。これにより、実際のコンテンツ消費パターンを模倣し、頻繁にサービスを利用して、コンテンツを視聴しているかを示す指標となる。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訪問ユーザを決定する。各ユーザは各ノードの人口比に基づいて、コンテンツ配信サービスを利用する位置をランダムに割り当てる。

5.1.3 ユーザによる評価

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が視聴される。[2] より、推薦コンテンツは全要求コンテンツの 8 割を占めている。ユーザ数が $N_u = 610$ 、コンテンツ数が $N_c = 9742$ である場合、ユーザのコンテンツに対する嗜好度は $N_{pref} = N_u \times N_c = 5942620$ 個存在する。そこで、 N_{pref} が約 8 割 ($5,942,620 \times 0.8 = 4,754,096$) の場合のコンテンツ嗜好度を閾値として設定する。ユーザがコンテンツの視聴後に付与する評価値は 5 段階評価を想定し、視聴したコンテンツの嗜好度に 5.0 を掛けたものとする。

5.1.4 コンテンツ配信

ICN の場合は、ユーザの存在するノードで要求コンテンツのキャッシュの有無を確認し、キャッシュに存在すれば直ちにユーザに配信する。もしキャッシュになければ、要求コンテンツのオリジンサーバまで要求パケットを送信し、コンテンツの配信経路上のキャッシュサーバで要求コンテンツのキャッシュを行う。コンテンツの配信経路は、ダイクストラ法で設定する。CDN では、配信要求を送信したユーザの最寄りのキャッシュサーバでのみ要求コンテンツをキャッシュする。キャッシュ置換方式は、LRU (Least Recently Used) を使用し、最も長い間要求されていないコンテンツをキャッシュから削除する。

5.2 評価指標

- H : 配信経路上のキャッシュヒット率

CDN の場合、要求パケットが発生したノードで要求コンテンツがキャッシュされていた場合に、オリジンサーバまで要求が行かず、そのノードからコンテンツが配信される。その場合のヒット率を次式で定義する。

$$H_{CDN} = \frac{n_{rCDN}}{a_r} \quad (5)$$

ただし n_{rCDN} は要求パケットが発生したノードで要求コンテンツがキャッシュされていた回数であり、 a_r はネットワーク全体の要求の発生回数である。

ICN の場合は、要求パケットがオリジンサーバまで転送される経路上の任意のノードで要求コンテンツがキャッシュされていたとき、オリジンサーバまで要求が行かず、途中のノードからコンテンツが配信される。その場合のヒット率を次式で定義する。

$$H_{ICN} = \frac{n_{rICN}}{a_r} \quad (6)$$

ただし n_{rICN} は要求パケットの転送経路上の任意のノードで要求コンテンツがキャッシュされていた回数である。

- HL : 配信ホップ長の平均

$$HL = \frac{\sum_{i=1}^A hop_i}{n} \quad (7)$$

ただし A は全要求数、 n はキャッシュヒット回数、 hop_u は要求 i に対する配信ホップ長である。

- U_v : 全視聴要求に対するユーザ満足度

$$U_v = \frac{\sum_{i \in R} P_i \times 5.0}{a_r} \quad (8)$$

ただし R は全要求の集合である。シミュレーション時間 (T_s) の開始時から、ランダムなコンテンツ推薦を行う探索時間の割合を P_{ex} とする。探索期間の終了後、時間が経過するにつれて探索の確率を減少させ、協調フィルタリングを用いた推薦（活用）の割合を増加させることが望ましい。これにより、初期段階ではランダムな探索が主となり、その後徐々にユーザの好みに基づいた推薦へと移行する。そこで、 $\epsilon = 1/t$ に設定する。ただし t はシミュレーションの経過時間である。

次節以降にて、CDN と ICN のそれぞれにおいて、キャッシュサイズと、シミュレーション時間 (T_s) の中でランダムなコンテンツ推薦を行う探索時間の割合 P_{ex} を与えたときの、キャッシュヒット率と平均ホップ長、ユーザ満足度の数値結果を示す。

5.3 キャッシュヒット率

キャッシュサイズと P_{ex} の 3 つの場合の各々について、提案方式でコンテンツを推薦した場合 (Cache-based CF) と、従来の協調フィルタリングで推薦した場合 (Normal CF) のキャッシュヒット率を図 6 に示す。ただし図 6(a)(c)(e) には CDN における結果を、図 6(b)(d)(f) には ICN における結果を各々示す。また ICN の場合は、推薦対象として考慮するキャッシュの範囲を 0, 3, 10 ホップとした場合の各々について示している。CDN の場合も ICN の場合も、全ての探索時間 P_{ex} とキャッシュサイズにおいて、キャッシュを考慮した協調フィルタリングが従来の協調フィルタリングと比較して、キャッシュヒット率が高い。

5.4 平均ホップ長

同様に平均ホップ長の結果を図 7 に示す。全てのキャッシュサイズと P_{ex} において、従来の方式より、提案方式の平均ホップ長が短く、キャッシュサイズがより小さい場合に高い性能を示すことがわかる。ICN の場合、要求パケットの配信経路上のルータにコンテンツがキャッシュされルータから配信されるため、CDN の場合と比較して、平均ホップ長が短くなっている。ICN におけるキャッシュ方式として、配信経路上の全てのサーバに要求コンテンツをキャッシュすることを想定しているため、複数サーバに共通のコンテンツが重複してキャッシュされている可能性が高い。そのため推薦に利用するキャッシュサーバ数の拡大より、キャッシュサイズの増加が性能向上に効果的となった。また、推薦自由度を拡大することで、推薦コンテンツの視聴確率とともに平均ホップ長も増加している。

ランダム推薦の割合である P_{ex} については、 P_{ex} が小さい程、ホップ長が短くなる。 P_{ex} を大きくすると、ランダムにコンテンツを推薦する頻度が高くなり、視聴コンテンツは人気度やキャッシュに基づかないためキャッシュされている可能性が低く、再び要求される可能性は低い。そしてランダム推薦の度に、要求パケットはオリジンサーバまで送信され、配信経路上の全てのサーバでキャッシュされる。そのため、ランダムに推薦する頻度が少なく、協調フィルタリングによる推薦頻度が多くなるにつれて、ホップ長が短くなったと考えられる。また、ユーザから近いサーバに要求コンテンツがキャッシュされており、配信要求時の経由ノード数が少なかったと考えられる。




図 6: キャッシュヒット率




図 7: 平均ホップ長

5.5 ユーザ満足度

視聴した全コンテンツに対するユーザ満足度を図 8 に示す。推薦候補がキャッシュに限定されるため、キャッシュサーバ内

のコンテンツ数が少ないと、ユーザの嗜好を十分に考慮できない。そのため、ユーザから最寄りのサーバに限定され、キャッシュサイズが10のとき、CDNの場合と同様にユーザ満足度が最も低い結果となっている。キャッシュに限定しない従来の協調フィルタリングと比較して、図??、図??では提案方式の方がユーザ満足度が低い。しかし、図??では、キャッシュサイズが100,1000の場合に従来のユーザ満足度を上回っている。 $P_{ex} = 0$ の場合、ランダム推薦により、視聴されるコンテンツ数は0である。そのためZipf分布に従った人気度コンテンツの視聴、または協調フィルタリングによる視聴のどちらかとなる。データが十分に溜まっていない初期の段階では協調フィルタリングは機能しないため、Zipf分布に基づくコンテンツの視聴によりデータが蓄積され、サーバにコンテンツがキャッシュされる。キャッシュされたコンテンツは人気度が高いため、キャッシュを活用した提案方式によるユーザの満足度が従来の方式と比較して高くなったと考えられる。キャッシュヒット率とユーザ満足度の評価結果から、キャッシュに推薦するコンテンツが限定されることから、キャッシュサイズが小さい場合にキャッシュに限定しない従来の協調フィルタリングと比較して、ユーザの満足度は低下するが、キャッシュ効果が向上した。




図 8: ユーザ満足度

6. まとめ

Netflixなどのコンテンツ配信サービスにおいて、ユーザの嗜好に沿ったコンテンツを推薦するシステムがコンテンツ要求の大部分を占める重要な存在となっている。また、配信遅延や低ビットレートがユーザのサービス離脱率に影響する。しかし従来の推薦方式ではネットワーク負荷の軽減とコールドスタート問題の両方については考慮していない。そこで本論では、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。

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し、その推薦されたコンテンツを視聴することで、ネットワーク負荷軽減とアクセス時間の短縮を図った。また協調フィルタリングの課題であるコールドスタート問題への対応として、 ϵ -greedy法と呼ばれる強化学習の推薦方式にキャッシュに限定した協調フィルタリングを組み合わせた。

提案方式の有効性を計算機シミュレータにより評価した結果、キャッシュに限定しない協調フィルタリングと比較して、推薦候補のコンテンツをキャッシュに限定したことによって、

キャッシュサイズが小さく、最寄りのサーバに限定した場合にユーザの満足度が低下した一方で、キャッシュヒット率が向上した。提案方式により、キャッシュに限定することで平均ホップ長も従来の方式と比較して短くなった。ICNでは要求パケットの配信経路上のルータにコンテンツがキャッシュされていると、そのルータから配信されるため、CDNと比較して平均ホップ長が短くなる。人気度が高いコンテンツがキャッシュされている状況下では、ユーザの視聴した全てのコンテンツに対する満足度は僅かに低下しているが、提案方式によって推薦されたコンテンツに対するユーザの満足度は向上し、推薦するコンテンツの質も高いことがわかった。

今後の展望として、本稿でランダムにコンテンツを推薦した探索において、ユーザからの人気度が高いコンテンツを予測し、そのようなコンテンツを推薦することで、キャッシュに限定することによる提案方式の性能向上が期待できる。また、ICNにおけるキャッシュ方式として、キャッシュするサーバを限定することで推薦自由度を拡大した場合の性能向上が図れると考えられる。

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] E. Gourdin, P. Maille, G. Simon, and B. Tuffin, "The Economics of CDNs and Their Impact on Service Fairness", *IEEE Transactions on Network and Service Management*, IEEE, 14 (1), pp.22-33, 2017.
- [4] Y. Jianbo, "Solving Cold-Start Problem in Large-scale Recommendation Engines: A Deep Learning Approach", *IEEE International Conference on Big Data (Big Data)* 2016.
- [5] X. Yang, H. Zhang, H. Ji, and X. Li, "Hybrid Cooperative Caching Based IoT Network Considering the Data Cold Start", *IEEE Wireless Communications and Networking Conference (WCNC)* 2021.
- [6] D. Liu, and C. Yang, "A Learning-based Approach to Joint Content Caching and Recommendation at Base Stations", *IEEE Global Communications Conference (GLOBECOM)* 2018.
- [7] D. K. Krishnappa, M. Zink, C. Griwodz, and P. Halvorsen, "Cachecentric video recommendation: An approach to improve the efficiency of youtube caches," *ACM Trans. Multimedia Comput. Commun. Appl.*, vol. 11, no. 4, pp. 48:1-48:20, Jun. 2015.
- [8] H. Zhang, C. Li, Y. Zhao, and C. Zhang, "Caching Videos with Category Diversity based Recommendation: Model and Algorithm", *IEEE 6th International Conference on Computer and Communications* 2020.
- [9] L. E. Chatzileftheriou, M. Karaliopoulos and I. Koutsopoulos, "Caching-aware Recommendations: Nudging User Preferences towards better Caching Performance", *IEEE. INFOCOM* 2017.
- [10] MovieLens, <https://movielens.org/>.