

令和6年度 秋学期 卒業研究3 (BI)
学士論文

題目 配信品質と嗜好を考慮した
コンテンツ推薦システム

指導教員 上山憲昭 教授

立命館大学 情報理工学部 セキュリティ・ネットワークコース

学籍番号 2600210092-3

落合翔大

令和7年1月31日

概要

扱うコンテンツの数が膨大なサービスが普及していくにつれ、コンテンツ推薦システムの需要が高くなっている。コンテンツ推薦システムは、ユーザ側とサービス運営側の双方に大きな利点がある。一方で、コンテンツの配信遅延や、低ビットレートはサービス離脱率の上昇につながる。そこで多くのコンテンツ事業者は、CDN(Content Delivery Network)の仕組みを利用することで、配信遅延やオリジンサーバ負荷の軽減を図っている。しかし、既存の推薦方式ではキャッシュを考慮していないため、キャッシュヒット率が低下する可能性がある。そこで本論では、動的にユーザやコンテンツが生成され、コンテンツの人気度に変化し続けるような環境において、強化学習を用いることで推薦精度とキャッシュヒット率の両方の向上を可能とする方式を提案する。また従来手法と提案手法の推薦精度とキャッシュヒット率を計算機シミュレーションで数値評価により比較した、その結果、提案手法は従来手法と比較して、推薦精度とキャッシュヒット率の両方が向上することを確認した。

目次

概要	1
第1章 序論	3
1.1 研究の背景	3
1.2 研究の目的	4
第2章 関連研究	5
2.1 動的な環境でのコンテンツ推薦システム	5
2.2 キャッシュ状態を考慮したコンテンツ推薦システム	5
2.3 コールドスタート問題	5
第3章 提案方式	6
3.1 提案方式の概要	6
3.2 提案方式の動作	6
3.3 事前学習	9
第4章 性能評価	10
4.1 評価条件	10
4.2 推薦精度	12
4.3 キャッシュヒット率	13
4.4 時間経過における学習レベル	13
4.5 報酬関数の重みを変更したときの推薦精度とキャッシュヒット率	14
第5章 まとめ	16
謝辞	17
学会発表リスト	19

第1章 序論

1.1 研究の背景

近年、動画配信サービスやオンラインショッピングなど、扱うコンテンツの数が膨大なサービスが普及しつつある。そのようなサービスでは、ユーザは自分の好みに合ったコンテンツを探し出すことは困難である。そのため、コンテンツを各自で探すのではなく、過去のデータから好みを推定して最適なコンテンツを推薦するようなコンテンツ推薦システムの需要は高くなっている。より良いコンテンツ推薦システムは、ユーザにとっては観たい動画や、欲しい商品にアクセスでき、サービス運営にとっては、売り上げや広告収入、テナント料などの収益増加につながる。このことから、コンテンツ推薦システムはユーザ側とサービス運営側の双方に大きな利点があると言える。一方で、コンテンツの配信遅延や低ビットレートはサービス離脱率上昇につながる。そのため多くのコンテンツ事業者がCDNの仕組みを利用することで配信遅延やオリジンサーバ負荷の軽減を図っている。CDNの動作を図1.1に示す。

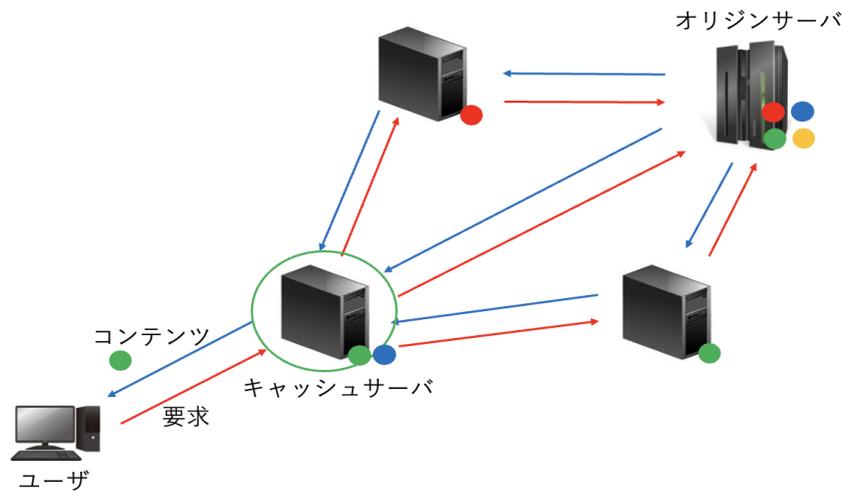


図 1.1: Content Delivery Network

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いる。ユーザからの要求に対応するコンテンツを配信するときにオリジンサーバから直接配信するのではなく、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要求ユーザとオリジンサーバの距離に関わらず安定したコンテンツ配信が可能になる。しかし、ユーザの観点ではよりユーザの好みに合ったコンテンツの推薦が望ましいのに対し、ネットワークの観点では配信コスト削減のため高人気コンテンツの推

薦が望ましい。そのため、これらの両方を考慮しないと性能が低下する可能性がある。そこで本研究の先行研究では、推薦対象をキャッシュされているコンテンツに限定し、ユーザ間やアイテム間の類似度から推薦するコンテンツを決定する協調フィルタリング (CF) により推薦する、ネットワークの配信サーバの負荷軽減と、ユーザの嗜好の両方を考慮した推薦方式を提案した [1]。しかし、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推薦対象が減少し、推薦の精度が低下する。また静的な環境を想定しているが、実際には動的にユーザやコンテンツが生成され、コンテンツの人気度が変化する。

1.2 研究の目的

ユーザやコンテンツが動的に生成され、コンテンツの人気度が常に変化し続けるような環境において、CDN の仕組みを利用した推薦システムの推薦精度とキャッシュヒット率の両方の向上を目指す。動的にコンテンツが生成され、コンテンツの要求頻度分布も変化するような環境では単一時点での最適化が難しく、最適化問題としての定式化や深層学習の適用が困難になる。

そこで本稿では、変化し続ける環境に対して試行錯誤による学習で最適な解を見つけていく強化学習を用いることで推薦システムの推薦精度とキャッシュヒット率の両方が向上するコンテンツ推薦方式を提案する。そして提案方式の有効性を確認するための計算機シミュレーションによる数値評価結果を示す。

第2章 関連研究

2.1 動的な環境でのコンテンツ推薦システム

動的な環境での推薦システムでは、コンテンツ人気度やユーザの嗜好の変化を考慮する必要がある。Thitiporn Neammanee らの研究では、時間経過によるユーザの嗜好の変化点を見つけることでユーザの嗜好を考慮したコンテンツ推薦システムが提案された [4]。対象ユーザの過去データのエントロピーを計算し、現在の好みと類似する期間のみのデータを推薦に用いる。そうすることで、より現在の好みに合ったコンテンツの推薦と、推薦にかかる計算量の減少を可能にした。

2.2 キャッシュ状態を考慮したコンテンツ推薦システム

コンテンツの配信遅延やネットワーク負荷の軽減のため多くのコンテンツ事業者は CDN の仕組みを利用したコンテンツ推薦システムを利用しているが、キャッシュを考慮しないと性能が低下する可能性がある。Yuto Murakami らの研究では推薦対象をキャッシュされているコンテンツに限定した推薦方式が提案された [1]。キャッシュされているコンテンツは一般的に配信回数が多く、人気度が高いため多くのユーザから高評価を得ることが期待できる。また、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キャッシュヒット率の低下を回避することが可能になる。

2.3 コールドスタート問題

推薦システムでコンテンツ推薦を行うときにある程度のデータがないと推薦の精度が下がるコールドスタート問題がある。動的な環境で新しいコンテンツやユーザが生成されるため、静的な環境と比較してコールドスタート問題の影響は大きくなる。Jianbo Yuan らによる研究では、新しく追加されたコンテンツを既存のアイテム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た。ディープラーニングを用いたコンテンツのペアリングによって新しいコンテンツと既存のアイテムをひとつのコンテンツとみなし、既存のコンテンツが推薦されると新しいコンテンツも推薦が行われるようにした。また、 ϵ -greedy 法を用いてランダムなコンテンツの推薦を行うことコールドスタート問題の解決も提案されている [1]。

第3章 提案方式

3.1 提案方式の概要

ユーザやコンテンツが動的に生成され、コンテンツ人気度が変化し続けるような環境では、試行錯誤による学習で最適な解を見つける強化学習が有効的と考えられる。そのため、ユーザに対してコンテンツとなる映画を推薦するような推薦システムを想定して、強化学習を用いることで推薦精度とキャッシュヒット率の両方を旨とする方式である。

3.2 提案方式の動作

1. 推薦システムはよりユーザの好みに合ったコンテンツを推薦するためにユーザの嗜好を推測する必要がある。そのため、ユーザの嗜好を協調フィルタリングを用いて推測する。協調フィルタリングは過去のデータから類似した嗜好をもつユーザ間の類似性をピアソン相関係数で評価を行う。ピアソン相関係数は $-1 \sim 1$ の値をとり、相関係数が 1 に近いほどユーザ間の嗜好の類似度が高く、 -1 に近いほどそれぞれのユーザは別の嗜好をもつことを表す。協調フィルタリングの動作を図 3.1 に示す。訪問ユーザ x に対して推薦を A, B, C, D, E の 5 人のユーザの過去データを用いて協調フィルタリングを行う。“-”は未評価を表し、各コンテンツに対する評価値は 0 から 5 で表す。

	商品1	商品2	商品3	商品4	商品5	商品6	商品7	商品8	商品9	商品10	Xとの相関係数
訪問ユーザ 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
推薦度	2.00	4.00	1.00	1.50	4.50	3.33	2.00	1.66	2.33	3.66	

図 3.1: 協調フィルタリング

1. 訪問ユーザ x と各ユーザの類似度を表す相関係数 P_{xy} を計算

$$P_{xy} = \frac{\sum_{m \in C_{xy}} (r_{xm} - R_x)(r_{ym} - R_y)}{\sqrt{\sum_{m \in C_{xy}} (r_{xm} - R_x)^2} \sqrt{\sum_{m \in C_{xy}} (r_{ym} - R_y)^2}} \quad (3.1)$$

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

2. 相関係数が高い上位 $k(k = 3)$ 人のコンテンツに対する評価値の平均を計算
3. 評価値の平均値が最も高いコンテンツを推薦

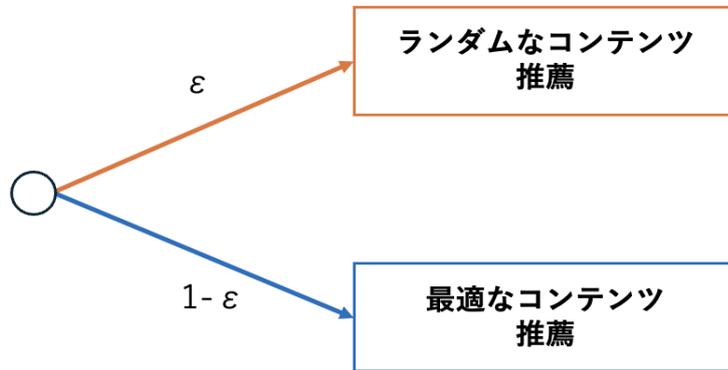
協調フィルタリングで得られたユーザ間の類似度を表す相関係数 P_{xy} を用いて、訪問ユーザ x と類似ユーザ y との類似度を S_{xy} とする。協調フィルタリングで得られた訪問ユーザ x と正の相関をもつユーザを類似ユーザとして利用する。類似ユーザ y がコンテンツ i に対する評価値を E_{yi} とすると、加重平均を用いることでユーザ x がコンテンツ i に対する評価値の予測値が導出できる。しかし、コンテンツ人気度が変化し続けるような環境においては、現在の人気度を考慮する必要がある。そのため現在コンテンツ i の人気度 P_i とコンテンツ i の人気度の変化量を表す T_i を用いて拡張を行う。 T_i の導出式を、現在コンテンツ i の人気度 P_i 、1つ前のコンテンツ i の人気度 $P_{i,pre1}$ 、2つ前のコンテンツ i の人気度 $P_{i,pre2}$ を用いて以下の式 3.2 で示す。コンテンツに対するそれぞれの人気度は 0 から 1、 T_i は -1 から 1 の値をとる。

$$T_i = (P_{i,pre1} - P_{i,pre2}) + (P_i - P_{i,pre1}) \quad (3.2)$$

これらの変数を用いて、コンテンツ人気度の変化を考慮した、訪問ユーザ x に対してコンテンツ i を推薦したときの、ユーザ x のコンテンツ i に対する評価値の予測値 $V(x, i)$ を以下の式 3.3 で示す。

$$V(x, i) = \frac{\sum_k S_{ki} \cdot E_{ki}}{\sum_k S_{ki}} + P_i + T_i \quad (3.3)$$

2. ユーザからのコンテンツ要求に対して、推薦するコンテンツを選択する。しかし、常に最適なコンテンツを選択し続けると学習に偏りが出る可能性がある。そのため ϵ -greedy 法を用いる。 ϵ -greedy 法は確率 ϵ でランダムなコンテンツの推薦を行い、確率 $1 - \epsilon$ で予想される報酬が最大となるコンテンツの推薦を行う。そのため、強化学習による学習の偏りを減少させることが可能になる。また、生成されたばかりのコンテンツを推薦する確率が高くなることでコールドスタート問題への対策が可能になる。しかし、確率 ϵ のランダムなコンテンツの推薦の回数が増加しすぎると、推薦システムの性能低下につながる。そのため、 ϵ の値は適宜変更する必要がある。 ϵ -greedy 法の動作を図 3.2 に示す。

図 3.2: ϵ -greedy 法

3. 最適なコンテンツを強化学習アルゴリズムのひとつである Q 学習を用いて選択する。Q 学習では予想される将来の価値を表す価値関数を Q 値とする。Q 値は Q テーブルを用いて管理される。ユーザ x のコンテンツ y に対して予想される評価値を Q 値 Q_{xy} とする。 Q_{xy} は式 3.3 で示した評価値の予測値を用いる。最適なコンテンツを推薦するときは、Q 値が最大となるものを選択する。
4. 推薦したコンテンツを視聴したかどうか、キャッシュの中にあったかどうか、得られたレビューの値によって強化学習の報酬を付与する。報酬 R は、推薦したコンテンツの視聴の有無を表す 2 値変数 D 、コンテンツに対する評価値として得られたレビューの値 E 、キャッシュの有無を表す 2 値変数 C 、各々の重み w_i を用いて次式 3.4 で示す。

$$R = w_1 D + w_2 E + w_3 C \quad (3.4)$$

Q テーブルの更新式を報酬 R 、予想される Q 値の最大値 Q_{max} と 2 つのパラメータ学習率 α と割引率 γ を用いて以下の式 3.5 で示す。学習率 α は新しい情報をどの程度反映するかを決定するパラメータで、割引率 γ は将来の報酬を現在の報酬と比較する際に、どの程度重視するかを決定するパラメータである。2 つのパラメータは 0 から 1 の値をとり、学習率が 1 に近ければ近いほど新しい情報を反映し、割引率が 1 に近ければ近いほど長期的な利益を重視する。

$$Q_{xy} = Q_{xy} + \alpha(R + \gamma Q_{max} - Q_{xy}) \quad (3.5)$$

以上の動作を繰り返し、価値関数である Q 値を最大化させる行動を選択することで学習レベルを高め、推薦精度とキャッシュヒット率の両方の向上を目指す。また、常に最適な行動をとるのではなく、 ϵ -greedy 法で確率的にランダムな行動をとることで強化学習の学習の偏りやコールドスタート問題への対策を行う。しかし、推薦するユーザが過去に視聴したコンテンツの数が少ない場合は、嗜好の推測ができない。そのため、視聴したコンテンツ数が 1 以上の任意の数 n を超えるまでは ϵ の値に関わらずランダムなコンテンツの推薦を行う。その後、ある程度視聴したコンテンツ数が増え、協調フィルタリングでユーザの好み推測できるようになれば、最も類似度が高いユーザの Q 値を引き継いで学習を行う。

3.3 事前学習

シミュレーション前に事前学習を行うときは、任意数のユーザで推薦システムが初期状態として持っている N 個のコンテンツに対する学習を行う。選択されたひとりのユーザにひとつのコンテンツを推薦することを 1 エピソードとして任意数学習を行う。推薦するコンテンツの選択方法は ϵ -greedy 法により、ランダムなコンテンツと最適なコンテンツから選択される。事前学習により得た学習データをシミュレーションに引き継ぐ。

第4章 性能評価

4.1 評価条件

提案方式の有効性を検証するために、計算機シミュレーションを用いた数値評価を行う。性能評価に用いるパラメータを表 4.1 に示す。単一のキャッシュサーバのみを考慮する。また、キャッシュの置換方式としては、キャッシュされているコンテンツの中で、最後に要求されてからの経過時間が最も長いものから置換していく LRU(Least Recently Used) を想定する。データセットとしては Movielens の映画のタイトル、ジャンル、各映画に対する評価をデータセットとして使用する [2]。データセットは、映画推薦システムの研究や開発に広く用いられており、リアルなユーザの分析に適している。シミュレーション中に要求発生イベントは要求発生間隔ごとに、ユーザ生成イベント、コンテンツ生成イベントはランダムに発生する。コンテンツ人気度は生成されるレビューによって変化する。

提案手法は強化学習を用いて学習を行うが事前学習は行わない RL0 と、強化学習を用いた学習と 10,000 エピソードの事前学習を行う RL1 の 2 つのパターンで数値評価を行う。従来手法として推薦精度とキャッシュヒット率を強化学習を用いた学習を行わず、協調フィルタリングのみを用いた推薦システム CF との比較を行う。

表 4.1: 評価に用いたパラメータ

記号	定義	値
C	キャッシュ容量	50
$N_{content}$	総コンテンツ数	9742
N_{user}	総ユーザ数	610
$n_{content}$	シミュレーション開始時のコンテンツ数	300
n_{user}	シミュレーション開始時のユーザ数	100
T	シミュレーション時間	1,000(s)
$I_{request}$	要求発生間隔	10.7(ms)

ユーザは推薦されたコンテンツを視聴するかどうかをユーザの嗜好とコンテンツの人気度、人気度の変化量から判断する。ユーザの嗜好は [1] で提案されたユーザのコンテンツに対する嗜好度のモデル化をコンテンツ人気度と人気度の変化量を用いてコンテンツの人気度が変化する環境に対応するように拡張を行う。ユーザ x とコンテンツ i の類似度を a_{xi} としたとき、ユーザ x のコンテンツ i に対する嗜好度 $P_x^{pref}(i)$ はコンテンツ i の現在の人気度 P_i 、コンテンツ i の人気度の変化量 T_i を用いて以下の式 4.1 で示す。

$$P_x^{pref}(i) = \frac{a_{xi}}{\sqrt{\sum_{i \in I} a_{xi}}} + P_i + T_i \quad (4.1)$$

ユーザは推薦されたコンテンツに対する嗜好度が閾値を超えていた場合、コンテンツを視聴する。また、ユーザは推薦されたコンテンツに対する嗜好度をレビューとして生成する。生成されたレビューの値によってコンテンツ人気度を変化させる。コンテンツ人気度はコンテンツに対して生成されたレビューの平均値とする。コンテンツ i の現在の人気度 P_i の計算式はコンテンツ x に対して生成された n 個のレビュー R_x を用いて以下の式 4.2 で示す。

$$P_i = \frac{\sum_{k=1}^n R_k}{5n} \quad (4.2)$$

生成されるレビューは 0 から 5 の値で評価を行うのに対して、コンテンツ人気度は 0 から 1 の値をとるため分母に 5 を掛けて数値の調整を行う。

4.2 推薦精度

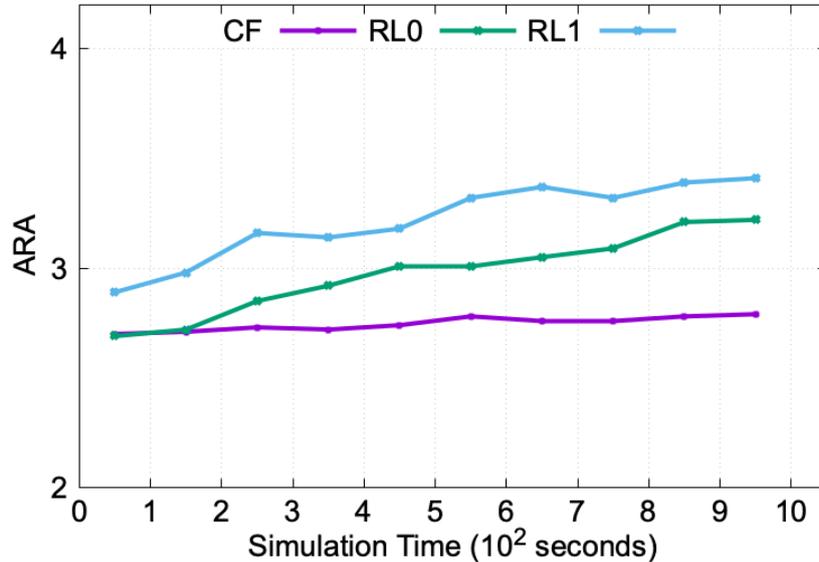


図 4.1: 時間経過による推薦精度の推移

推薦精度は、推薦システムから推薦されたコンテンツをユーザが視聴した後にコンテンツに対する評価値として生成されるレビューの値とする。図 4.1 は時間経過による推薦精度の推移を示す。横軸はシミュレーション時間、縦軸 ARA (Average Recommendation Accuracy) はシミュレーション時間を 10 等分したときの各期間で得られた推薦精度の平均値を表す。

比較対象である協調フィルタリングのみの推薦システム CF は時間経過とともに僅かに推薦精度が向上するが、変化量は少ないことがわかる。これは、協調フィルタリングは過去のデータから推薦するコンテンツを決定するため、コンテンツ人気度が動的に変化するような環境での現在の人気度が反映できていないからだと考える。それに対して、提案手法である RL0 と RL1 は時間経過とともに推薦精度が向上していくことが確認できる。事前学習を行う RL1 は事前学習を行わない RL0 に比べてシミュレーション開始時から推薦精度の値が高くなっている。これは事前学習によりシミュレーション開始時のコールドスタート問題が解消し、ユーザの好みの推測ができていていることを示す。しかし、1000 秒のシミュレーション期間で RL0 は、RL1 よりもシミュレーション開始時からの向上の変化量が大きいことが確認できる。そのため、シミュレーション時間を長くしたときにどのような値となるのか検証を今後行う予定である。

4.3 キャッシュヒット率

協調フィルタリングのみを用いた CF，提案手法である RL0 と RL1 でシミュレーションを行ったときのキャッシュヒット率を以下の表に示す．キャッシュヒット率は推薦システムが推薦したコンテンツが，キャッシュの中にあった割合とする．

表 4.2: キャッシュヒット率

CF	RL0	RL1
0.0325	0.1153	0.1545

表 4.2 から比較対象の協調フィルタリングのみを用いた推薦システム CF に比べ，提案手法の RL0, RL1 はどちらもキャッシュヒット率が高くなっていることが確認できる．

4.4 時間経過における学習レベル

強化学習を用いる提案手法では，報酬の最大化のために価値関数を更新する必要がある．そのため，価値関数の更新にかかる時間によってコンテンツ推薦に遅延が発生する可能性も考えられる．そこで提案手法において価値関数が更新される回数の時間経過による推移を図 4.2 で示す．横軸をシミュレーションの経過時間とし，縦軸はシミュレーション時間を 10 等分したときのそれぞれの期間で，価値関数が更新された回数を表す．

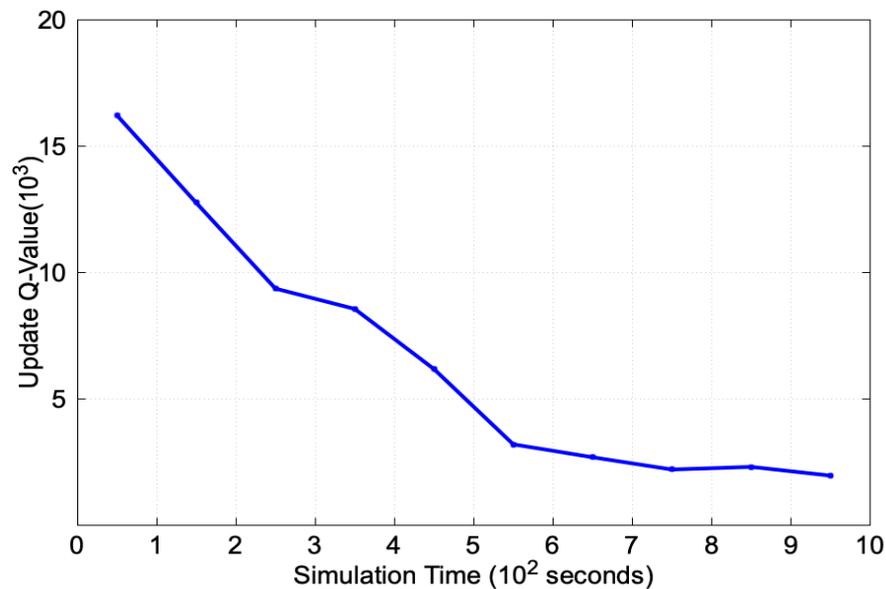


図 4.2: 時間経過による強化学習の学習レベル

シミュレーション開始時は試行錯誤しながら学習を行うために価値関数の更新回数が多いことが確認できる．しかし，時間経過とともに強化学習の学習レベルが高くなり，価値

関数が更新される回数が減少することが確認できる。そのため価値関数の更新による遅延の影響は時間経過とともに少なくなることが考えられる。一方で、コンテンツ人気度が変化し続ける環境においては価値関数の更新回数は一定数残り続けると考えられる。

4.5 報酬関数の重みを変更したときの推薦精度とキャッシュヒット率

強化学習の報酬関数 3.4 の重みを変更することによって、学習の比重を調節できる。報酬関数の重みを変更したときの時間経過による推薦精度の推移を比較する。推薦精度をキャッシュヒット率の 2 倍程度学習を行う A2C1 と、1 対 1 程度の割合で行う A1C1 と、キャッシュヒット率を推薦精度の 2 倍程度学習を行う A1C2 の 3 つの比重で学習を行った提案手法での比較を行う。それぞれの重みの設定値を表 4.3 で示す。

表 4.3: 重みの設定値

シナリオ	w_1	w_2	w_3
A1C2	10	1	5
A1C1	10	1	2.5
A2C2	10	2	2.5

推薦精度の時間経過による推移を図 4.3 で示す。

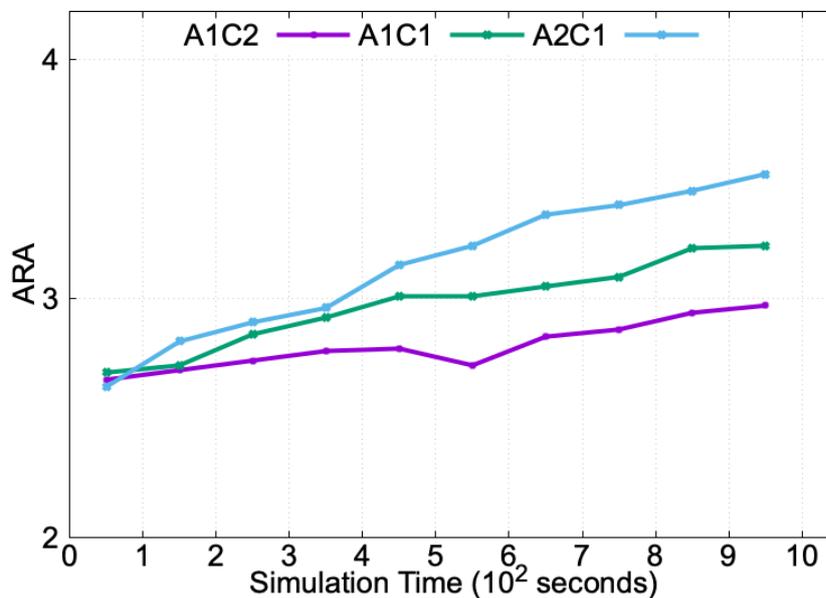


図 4.3: 重みを変更したときの推薦精度の推移

報酬関数の重みを変更したときのキャッシュヒット率を比較する。それぞれのキャッシュヒット率を表 4.4 に示す。図 4.3 と表 4.4 より、重みを変更することで向上させる割合を調節できることが確認できる。また、学習比率が低いときでも従来手法の協調フィルタリン

表 4.4: キャッシュヒット率

A1C2	A1C1	A2C1
0.1723	0.1153	0.0576

グのみを用いた推薦システムと比較して、推薦精度とキャッシュヒット率の両方が向上していることが確認できる。これは、動的に変化している環境のなかで推薦を行う時点での各ユーザの評価とコンテンツ人気度変化の予測が可能になっているからと考えられる。

第5章 まとめ

コンテンツ数が膨大なサービスの普及とネットワーク負荷の軽減のために CDN の仕組みを利用したコンテンツ推薦システムの需要が拡大しているが、キャッシュ状態を考慮しないことで、キャッシュヒット率が低下する可能性があるということが課題である。また、既存研究の多くは静的な環境が想定されている。そこで本稿では、動的な環境で強化学習を用いることで、推薦精度とキャッシュヒット率の両方の向上を目指す方式を提案した。そして計算機シミュレーションの数値評価により協調フィルタリングのみの推薦システムと比較して、推薦精度とキャッシュヒット率の両方が向上することを確認した。また、強化学習の学習レベルの向上により、強化学習で発生する遅延の影響は時間経過とともに小さくなると考えられる。

今後は、複数のキャッシュサーバを自律的に推薦コンテンツを決定するエージェントとみなしたマルチエージェント強化学習を用いた推薦方式において、複数のキャッシュサーバを考慮して動的にコンテンツの需要が変化する場合の推薦精度とキャッシュヒット率の数値評価を行う予定である。また、強化学習の性能向上のため、Q 学習からニューラルネットワークを用いる DQN(Deep Q-Network) への拡張を行う予定である。

謝辞

本研究を行うに当たり, ご指導を頂いた上山教授に感謝します. また日常, 有益な議論をして頂いた研究室の皆様に感謝します.

参考文献

- [1] Yuto Murakami, Yuma Fukagawa, and Noriaki Kamiyama, Content Recommendation Considering Cache State, IEEE HPSR 2024, July 2024
- [2] Movielens, <https://movielens.org/>
- [3] Jianbo Yuan, Walid Shalaby, Mohammed Korayem, David Lin, Khalifeh Aljadda, and Jiebo Luo, Solving Cold-Start Problem in Large-scale Recommendation Engines: A Deep Learning Approach, 2016 IEEE International Conference on Big Data (Big Data)
- [4] Thitiporn Neammanee, and Saranya Maneroj, Time-Aware Recommendation Based on User Preference Driven, 2018 42nd IEEE International Conference on Computer Software & Applications

学会発表リスト

- 落合翔大, 上山憲昭, “配信品質と嗜好を考慮したコンテンツ推薦システム“, 電子情報通信学会 2025 年総合大会, 東京, 2025 年 3 月
- 落合翔大, 上山憲昭, “キャッシュ状態と嗜好を考慮したコンテンツ推薦システム“, 電子情報通信学会 NS 研究会, 沖縄, 2025 年 3 月