

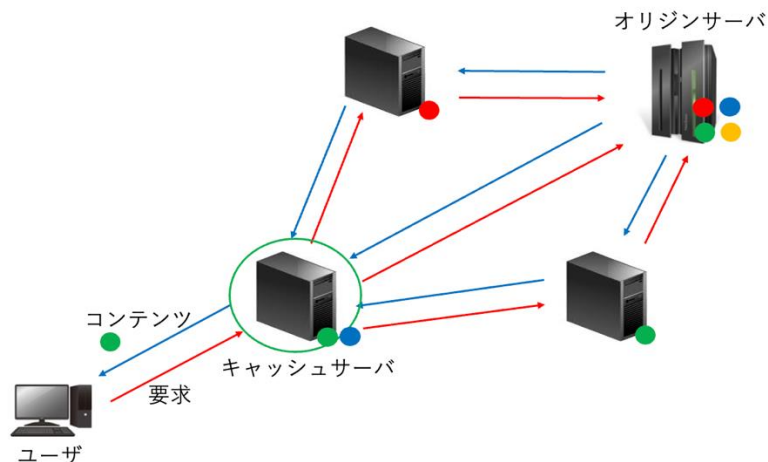
動的環境におけるGNNと強化学習を用いた 推薦精度とキャッシュヒット率の両立

立命館大学 情報理工学研究科

落合翔大 上山憲昭

研究の背景

- 扱うコンテンツ数が膨大なサービスの普及
 - 例: 動画配信サービス, オンラインショッピング
- ユーザは嗜好に合ったコンテンツを探し出すのは困難
 - 推薦システムの重要性が急速に高まっている
- コンテンツ配信遅延や低スループットはサービス離脱率上昇
 - コンテンツ配信ネットワーク(CDN)の利用
 - ユーザに近いキャッシュサーバから配信し, 負荷と遅延を軽減

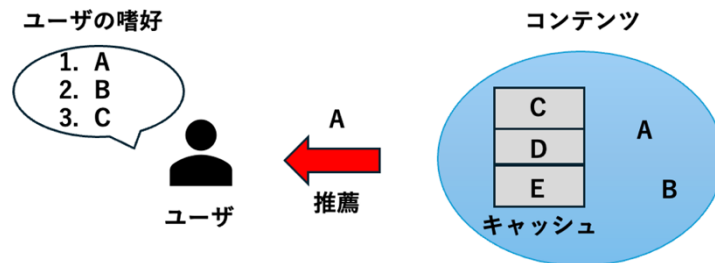


CDNを利用した推薦システムの課題

- ユーザとネットワークの観点で望ましいコンテンツが異なる


- ユーザの観点

- 個々のユーザのニッチな嗜好に合ったコンテンツ



- ネットワークの観点

- 配信コスト削減・キャッシュヒット率向上のため、高人気コンテンツ



- どちらかのみを考慮した場合、他方が性能低下する可能性

先行研究とその限界

■ 先行研究の概要

- ユーザ数, コンテンツ数, 人気度などが変化し続ける動的な環境を想定
- 強化学習を用いて推薦精度とキャッシュヒット率を同時最適化
 - 同一報酬式によって学習

■ 先行研究の限界

- 推薦精度とキャッシュヒット率という, 全く異なる指標を同時に学習することで, 干渉し合う
- ユーザの嗜好推測に協調フィルタリングを用いたことで, ユーザとコンテンツ間の複雑な関係を捉えきれていない

研究の目的とアプローチ

■ 研究の目的

- 動的環境下で、推薦精度とキャッシュヒット率の双方を考慮し、向上を目指す推薦方式の提案
- 動的環境でより顕著になるコールドスタート問題への対策

■ アプローチ


- 軽量なGNN (LightGCN) を用いてユーザの嗜好予測
- GNNの予測スコアを状態として強化学習エージェントに組み込む
- 強化学習エージェントが、自律的にキャッシュ制御

提案手法のシステム全体像

- 推薦精度とキャッシュヒット率の学習を分離
 - 推薦精度
 - GNNで嗜好予測
 - キャッシュヒット率
 - 強化学習 (Q学習) で将来利用されそうなコンテンツを配置
 - GNNの情報を利用することで, より精度の高い需要予測
 - コールドスタート問題への対策のため一定確率でランダムな行動
- 学習を分離させる利点
 - 推薦精度とキャッシュヒット率という, 異なる目的の学習の干渉を防ぐことが可能
 - 強化学習がランダムな探索を行いやすくなる

LightGCNによるユーザの嗜好予測

- GNN (Graph Neural Network)
 - ユーザとコンテンツの繋がりをグラフとして表現



- グラフ構造の強み

- 直接的な視聴履歴だけでなく、他ユーザを介した間接的・潜在的な好みまで推測可能

- LightGCNの特徴

- 従来のGNNから非線形活性化関数などを排除した軽量なアーキテクチャ
- 計算資源が制限されるエッジサーバ上でも、高精度かつ高速な推論が可能

予測スコアを利用した状態空間の構築

- GNNの予測スコア
 - ユーザとコンテンツの埋め込みベクトルの内積で算出
 - 生成される値: 上限・下限のない連続値
- 予測スコアを強化学習の状態空間に利用する際の課題
 - 連続値のまま使用すると, 状態数が無限大になり, 学習が困難
- 状態定義を離散化
 - シグモイド関数を用いて予測スコアを $[0, 1]$ の範囲に正規化
 - k 個 ($k = 5$) のビンに分割して離散値に変換
- 最終的な状態空間
 - コンテンツIDとビン数の積

Q学習によるキャッシュ制御

- Q学習によるキャッシュの自立制御
 - 行動: GNNが推薦候補としたコンテンツをキャッシュするかどうかの2値判定
 - 判断の仕組み: 現在の状態からQテーブルを参照し, 将来の期待報酬 (Q値) が最大となる行動を選択
 - 確率 ϵ でランダムな行動
 - コールドスタート問題への対策
- 行動に対する報酬
 - 登録ペナルティ: 無駄なストレージの占有を防ぐため小さな値
 - ヒット報酬: 実際に再利用された際の大きな値

→ むやみに登録せず, 利用される確率が高いもののみを選択

性能評価条件とパラメータ

- データセット
 - Movielens 1M
 - ユーザ数: 6,040
 - コンテンツ数: 3,883
 - 評価数: 1,000,209
- CDN (エッジサーバ) 環境
 - 単一のキャッシュサーバを想定
 - キャッシュ容量: 200
- ユーザからのリクエストに対して10個のコンテンツを提案
- リクエストの発生メカニズム
 - 推薦要求はデータセットのタイムスタンプを基準とし、実データの時系列順に発生

比較手法

■ Baseline

- 推薦精度: 協調フィルタリング
- キャッシュヒット制御: LRU

■ 先行研究 (Joint Q-Learning)

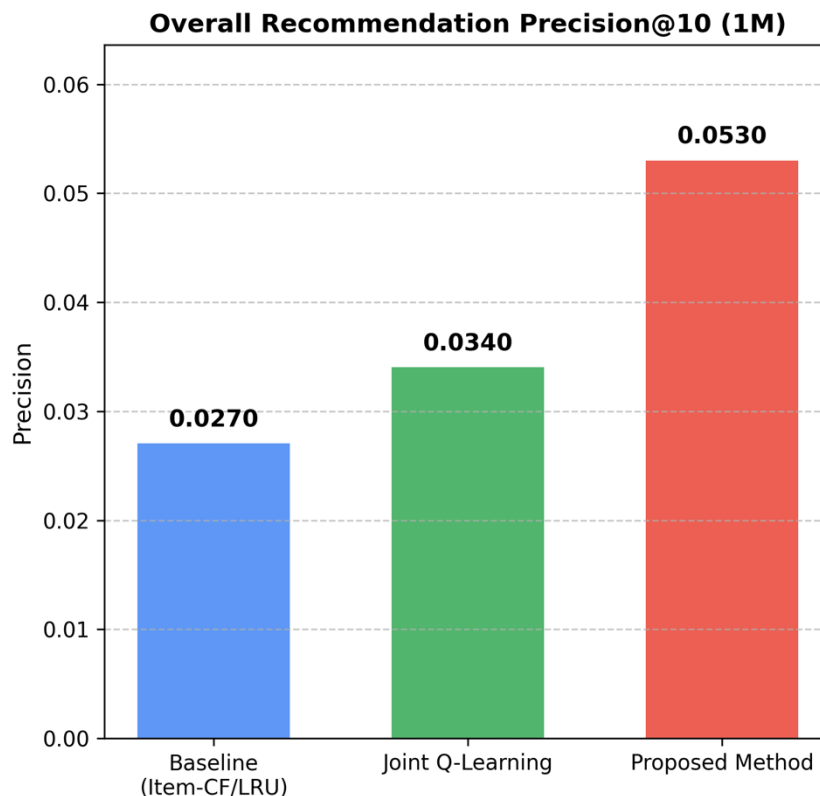
- 推薦精度: 協調フィルタリングで予測し, 強化学習で向上
- キャッシュヒット率: 強化学習

■ 提案手法

- 推薦精度: GNN (LightGCN) で予測
- キャッシュヒット率: GNNの予測スコアを利用し, 強化学習で向上

推薦精度の比較

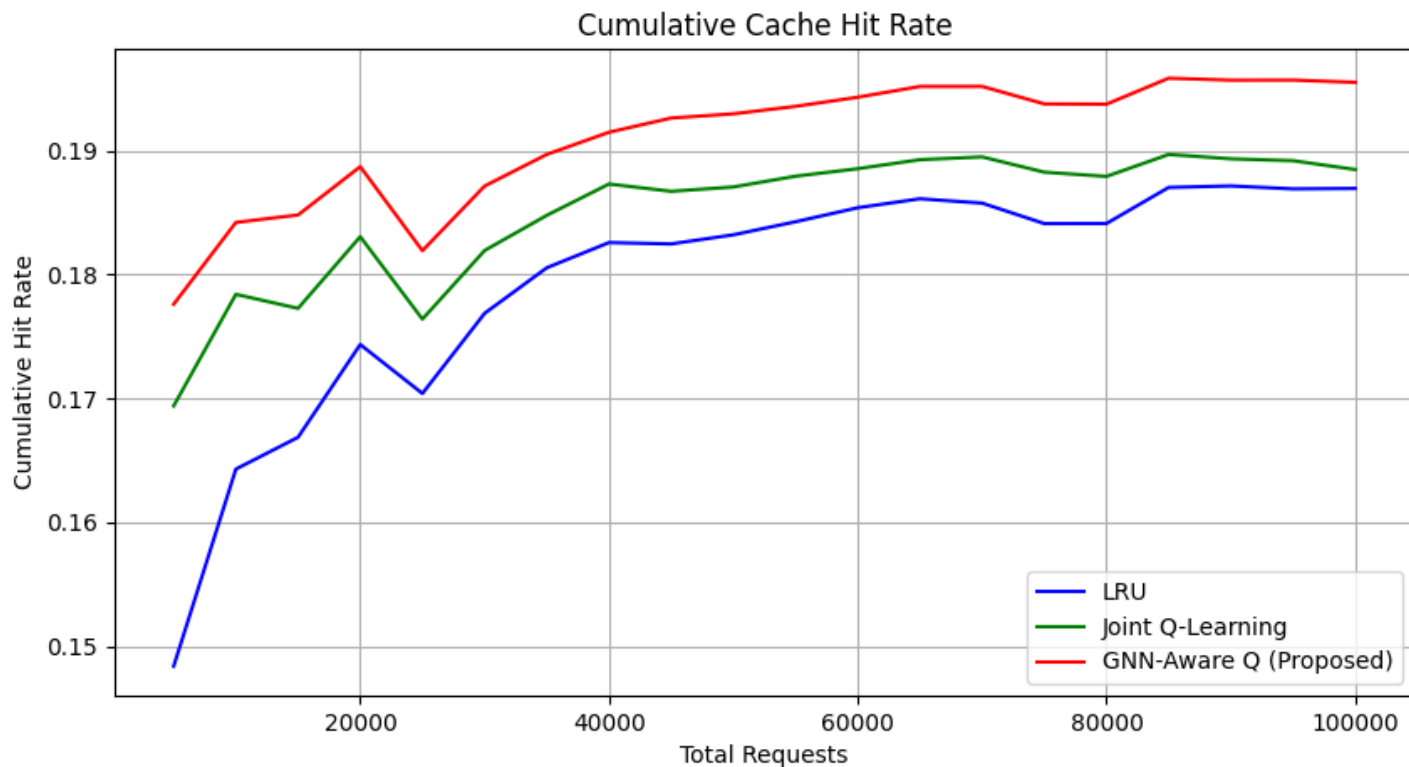
- 評価指標: Precision@10
 - 提案した10個のコンテンツ内に正解が含まれていた割合



- 従来手法と比較して約1.5倍から2倍の性能向上

キャッシュヒット率の比較

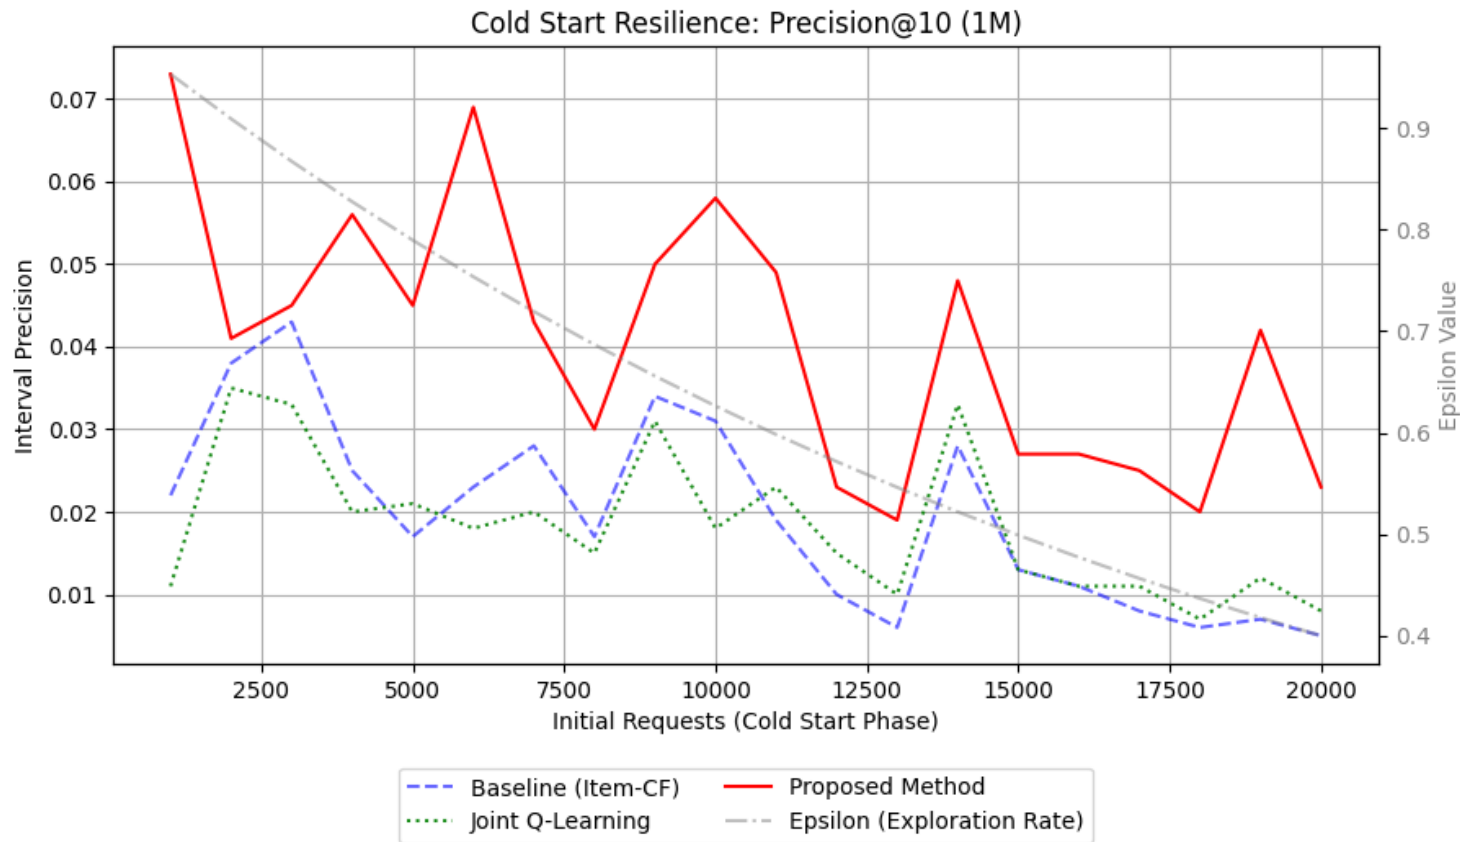
- キャッシュヒット率: ユーザが要求したコンテンツがキャッシュされていた割合



- 提案手法が最も高い数値

コールドスタート問題への適応性

■ 一定区間ごとの推薦精度の推移



- シミュレーション全体を通して最も高い推薦精度
 - コールドスタート問題を改善

考察

- 性能評価結果
 - 推薦精度: 従来手法と比較し, 約1.5倍から2倍の性能
 - キャッシュヒット率: シミュレーション全体を通して最も高い値
- 結果からの考察
 - 推薦精度とキャッシュヒット率の学習の分離
 - キャッシュ状況やランダムな行動に左右されない推薦
 - 予測スコアを利用した精度の高い需要予測
 - 高次特徴量の抽出
 - LightGCNによる潜在的な関係性のリアルタイムな予測
 - 動的環境への適応力
 - ϵ -greedy法による学習の偏りの解消

まとめと今後の展望

■ まとめ

- CDNを利用した推薦システムでは望ましいコンテンツが異なる
- GNNで推薦精度, 強化学習でキャッシュヒット率を分担して学習することで, 干渉を防ぐ

■ 今後の展望

- 異なるデータセットでの性能評価
- 複数のキャッシュサーバが連携し, キャッシュを最適化する協調キャッシュ制御への拡張
- 計算負荷の測定