



GLI Lab Seminar

LLM-based Recommendation Agents for Personalized Conversational Recommender Systems

Hae-Yoon Koo (구해윤)

Supervisor: Byungkook Oh

Graph & Language Intelligence Laboratory
Department of Computer Science and Engineering
Konkuk University

2026.08.12

CONTENTS

1. Background
2. Related Work
 - EyeCRS
 - AdaptJobRec
 - HARPO
3. Research Direction





CONTENTS

1. Background

2. Related Work

- EyeCRS
- AdaptJobRec
- HARPO

3. Research Direction

Background

Recommender System (RS)

- 추천 시스템이란?
 - ✓ 사용자의 **과거 행동 및 선호 정보**를 기반으로
 - ✓ 사용자가 관심을 가질 가능성이 높은 아이템을 예측하고 추천하는 시스템
- 일반적인 동작 방식
 - ✓ 사용자와 아이템 간의 상호작용 데이터를 활용
 - ✓ 각 아이템의 선호도를 예측한 뒤, 점수가 높은 아이템을 순위화하여 제공
 - ✓ Ex) 사용자 행동 이력: "스파이더맨 시청" → "아이언맨 시청" → "어벤져스 시청"
 - 추천 결과: "가디언즈 오브 갤럭시" 추천
- 핵심 특징
 - ✓ **One-shot recommendation**
 - 사용자의 과거 정보로 한 번에 추천 결과를 생성
 - 추천 이후 사용자의 현재 의도나 세부 조건을 추가로 확인하지 않음
 - Ex) 사용자: "영화 추천해줘." → RS: "스파이더맨: 브랜드 뉴 데이를 추천합니다."
 - ✓ **Implicit preference modeling**
 - 클릭, 구매, 시청, 평점 등 과거 행동으로 사용자의 선호를 간접적으로 추론
 - 사용자가 "지금 무엇을 원하는지" 직접 표현하지 않아도 추천 가능
 - Ex) 최근 마블 영화를 여러 편 시청 → "액션 / SF 영화를 선호한다"고 추론

Background

Conversational Recommender System (CRS)

- 대화형 추천 시스템이란?
 - ✓ 사용자와 **여러 차례 자연어로 상호작용**하면서 사용자의 선호와 제약을 파악
 - ✓ 적절한 아이템을 추천 및 설명하며, 사용자의 피드백에 따라 추천을 수정하는 시스템
- 핵심 특징
 - ✓ **Task-oriented**
 - CRS의 목적은 단순한 자유 대화가 아니라 사용자의 의사결정을 돕는 것
 - Ex) 자유 대화: "요즘 영화 뭐 봤어?" 는 대화 자체가 목적
 - Ex) CRS: "오늘 가족과 영화관에서 볼만한 영화 뭐 있어?" 는 영화를 고르는 것이 목적
 - ✓ **Multi-turn interaction**
 - 한 번의 질문과 한 번의 답변으로 끝나지 않음
 - Ex) 질문: "오늘 가족과 영화관에서 볼만한 영화 뭐 있어?"
 - Single-turn → "스파이더맨 : 브랜드 뉴 데이를 추천합니다."
 - Multi-turn → "시리즈물도 괜찮나요?" (아니오) → "러닝타임이 길어도 괜찮나요?" (네)
 - → "오디세이를 추천합니다."

Background

Why Conversational Recommendation?

- 기존 추천 시스템의 한계
 - ✓ 과거 행동이 사용자의 **현재 의도**를 항상 반영하지는 않음
 - ✓ 현재 상황이나 세부 조건은 행동 이력만으로 파악하기 어려움
- 예시
 - ✓ 과거 시청 이력 : 컨저링 → 엑소시스트 → 애나벨
 - 기존 RS의 추론 : “이 사용자는 공포 영화를 좋아한다”
 - ✓ 하지만 현재 요청은
 - “오늘은 부모님과 같이 볼 영화가 필요해. 너무 무서운 건 싫고, 2시간 이내면 좋겠어.”
- 무엇이 달라지는가
 - ✓ 과거 장르 선호만 사용하면 **현재 상황과 맞지 않는 공포 영화를 추천**
 - ✓ 현재 대화를 함께 사용하면 **공포 강도, 동행자, 러닝타임**을 반영하여 추천을 조정

Background

Personalized Conversational Recommender System

- Personalized CRS는 왜 등장했는가?
 - ✓ 기존 CRS는 주로 **현재 대화 세션**에서 드러난 선호를 파악
 - ✓ 현재 대화만으로는 사용자의 장기 취향과 개인적 특성을 충분히 반영하기 어려움
- 대표적인 연구 방향
 - ✓ **Long-term Preference 활용**
 - 과거 평점, 구매, 클릭, 시청 행동에서 장기 선호를 학습
 - 현재 세션의 일시적인 요청과 함께 사용
 - ✓ **Historical Dialogue 활용**
 - 현재 대화 이전에 사용자가 나눈 과거 대화 세션을 활용
 - 사용자가 과거에 직접 표현한 선호와 피드백을 반영
 - ✓ **Multi-aspect User Modeling**
 - 현재 대화, 과거 대화, 유사 사용자 등 여러 관점에서 사용자 선호를 모델링
- 예시
 - ✓ 과거 행동 : 컨저링 → 엑소시스트 → 애나벨 (장기적으로 공포 영화를 선호)
 - ✓ 현재 대화 : “오늘은 부모님과 볼 거라 너무 무서운 건 싫어요.”
 - ✓ 개인화된 CRS : 현재 대화의 낮은 공포 강도를 우선하되, 평소 선호한 긴장감도 함께 고려

Background

Challenge

- 장기 선호는 항상 현재 추천에 도움이 될까?
 - ✓ 사용자의 과거 행동과 이전 대화는 중요한 개인화 정보
 - ✓ 하지만 현재 상황과 관련이 없거나 충돌하면 **추천을 방해**할 수 있음
- **잘못된 개인화**
 - ✓ 과거 공포 영화 선호를 지나치게 반영
 - ✓ 현재의 동행자와 공포 강도 제약을 충분히 고려하지 않음
 - ✓ 현재 상황과 맞지 않는 공포 영화를 추천
- **적절한 개인화**
 - ✓ 현재 요청과 관련된 장기 선호만 선택적으로 활용
 - ✓ 현재 제약을 우선하면서 평소 취향을 보조적으로 반영
 - ✓ 공포 강도는 낮지만 긴장감 있는 미스터리 / 스릴러 후보를 추천
- **핵심 질문**
 - ✓ **어떤 과거 정보를 현재 추천에 사용할 것인가?**
 - ✓ 현재 의도와 장기 선호가 충돌하면 무엇을 우선할 것인가?
 - ✓ 오래되거나 무관한 선호는 어떻게 수정하거나 잊을 것인가?

Background

대화형 추천 시스템의 발전

- **초기 Interactive CRS**
 - ✓ 시스템이 정해진 속성이나 조건을 질문
 - ✓ 사용자의 답변을 통해 후보 아이템을 줄이는 방식
 - ✓ Ex) 장르, 가격대, 브랜드, 러닝타임 질문
- **Neural / Open-ended CRS**
 - ✓ 자유로운 자연어 추천 대화를 neural model로 처리
- **Personalized / User-Centric CRS**
 - ✓ 현재 세션뿐 아니라 장기 선호, 과거 대화 및 유사 사용자 활용
 - ✓ 사용자별 추천 및 응답 생성 강화
- **LLM-based CRS**
 - ✓ 복합적인 자연어 요구 이해
 - ✓ zero-shot / few-shot 추천 및 자연스러운 설명 생성
- **Agentic CRS**
 - ✓ LLM이 대화만 생성하는 것을 넘어
 - ✓ **memory, planning, tool use, feedback**을 이용해 추천 과정을 조율

Background

LLM 기반 추천 에이전트란?

- LLM 기반 CRS
 - ✓ 대화를 LLM에 넣으면 추천과 응답을 한 번에 생성
 - ✓ User Dialogue → LLM → Recommendation / Response
 - ✓ LLM이 하는 일은 **입력을 읽고 출력을 만드는 것** 하나
- LLM 기반 추천 에이전트
 - ✓ LLM이 **현재 상태를 파악하고 다음 행동을 스스로 결정**
 - ✓ 필요하면 외부 도구를 호출하고, 결과를 보고 행동을 수정
 - ✓ User Dialogue → (Memory 읽기 → Planning → Tool 호출 → 결과 확인) → Response
- 구성 요소
 - ✓ Memory : 과거 대화와 행동 기록을 저장하고 필요한 것만 꺼내 씀
 - ✓ Planning : 무엇을 먼저 할지, 언제 물어보고 언제 추천할지 결정
 - ✓ Tool : 추천 모델, 지식 그래프, 검색, DB 조회를 도구로 호출
 - ✓ Feedback : 사용자의 반응을 받아 다음 행동과 기억을 갱신
- 핵심 차이
 - ✓ 추천 모델이 LLM을 돕는 것이 아니라, **LLM이 추천 모델을 도구로 호출**

Background

왜 LLM 기반 추천 에이전트인가?

- 개인화에 쓸 정보가 많아짐
 - ✓ 현재 대화, 장기 선호, 과거 대화 세션, 유사 사용자
 - ✓ 정보가 늘수록 **무엇을 쓸지 고르는 일** 자체가 문제가 됨
- 한 번의 프롬프트로는 처리하기 어려움
 - ✓ 개인화 정보를 전부 프롬프트에 넣으면 길이 한계에 걸림
 - ✓ 현재 요청과 무관한 과거 정보까지 들어가 의도 파악을 흐림
 - ✓ 무엇을 넣을지 고르려면 **현재 요청과 비교하는 판단 단계**가 필요
- 추천에 필요한 자원은 대화 밖에 있음
 - ✓ 실제 후보 아이템, 사용자 프로필, 지식 그래프는 LLM 안에 없음
 - ✓ 필요한 시점에 **외부 도구를 호출**하고 결과를 다시 읽어야 함
- 대화는 한 번에 끝나지 않음
 - ✓ 물어볼지 추천할지, 다시 계획할지를 턴마다 결정해야 함
 - ✓ 사용자 피드백을 받아 기억과 계획을 갱신해야 함
- 그래서 **Memory, Planning, Tool, Feedback**을 갖춘 에이전트 형태로 발전

CONTENTS

1. Background

2. Related Work

- EyeCRS
- AdaptJobRec
- HARPO

3. Research Direction



Related Work

Recent Works

- 개인화된 LLM 추천 에이전트의 핵심 설계 문제 세 가지
 - ✓ 어떤 과거 정보를 기억하고 사용할 것인가
 - 과거 대화가 쌓일수록 현재 요청과 무관한 정보가 섞임
 - 전부 사용하면 개인화가 오히려 추천을 방해함
 - ✓ 언제, 어떻게 계획하고 도구를 사용할 것인가
 - 계획과 도구 호출을 늘리면 정확해지지만 응답이 느려짐
 - 단순한 질문까지 무거운 과정을 거치면 사용자가 이탈
 - ✓ 어떤 행동 경로를 좋은 추천으로 평가할 것인가
 - 여러 추론 경로를 만들 수 있지만 무엇이 좋은 경로인지 기준이 없음
 - Recall이나 BLEU가 높아도 사용자가 만족하지 않는 경우가 많음
- 오늘 살펴볼 세 논문
 - ✓ EyeCRS (WWW 2026) : 과거 대화 중 쓸 것만 골라내는 방법
 - ✓ AdaptJobRec (AAAI 2026) : 질의 복잡도에 따라 처리 경로를 나누는 방법
 - ✓ HARPO (ACL 2026) : 추론 경로를 만들고 추천 품질로 평가하는 방법

CONTENTS

1. Background
2. Related Work
 - EyeCRS
 - AdaptJobRec
 - HARPO
3. Research Direction



[2026][WWW][EyeCRS]

Not All Information Brings Benefits: Personalization-Driven Agent Debate for Conversational Recommendation

Pengfei Zhang*

202421080437@std.uestc.edu.cn

University of Electronic Science and
Technology of China
Chengdu, China

Guojia An*

an_guojia@163.com

University of Electronic Science and
Technology of China
Chengdu, China

Jin Huang

jh2642@cam.ac.uk

University of Cambridge
Cambridge, United Kingdom

Yuhan Yang

y.yuhan2000@gmail.com

University of Electronic Science and
Technology of China
Chengdu, China

Yang Yang

yang.yang@uestc.edu.cn

University of Electronic Science and
Technology of China
Chengdu, China

Jie Zou[†]

jie.zou@uestc.edu.cn

University of Electronic Science and
Technology of China
Chengdu, China

Background

- Personalized CRS는 과거 대화를 개인화 정보로 사용
 - ✓ historical dialogue session : 현재 대화 이전에 나눈 완결된 과거 대화
 - ✓ dialogue history : 현재 대화 안의 이전 발화
 - ✓ EyeCRS가 다루는 것은 **과거 대화 세션**
- 기존 방식
 - ✓ 사용자의 과거 대화 세션을 **전부 모아서** 현재 추천에 입력
 - ✓ 정보가 많을수록 개인화가 잘 된다고 가정
- Cognitive Negative Transfer
 - ✓ 이전에 배운 지식을 새로운 상황에 잘못 적용해 오히려 수행이 나빠지는 현상
 - ✓ CRS에서는 오래되거나 무관한 과거 선호가 현재 의도 파악을 방해
 - ✓ Ex) 과거 대화에서 “공포 영화를 좋아한다”고 말한 사용자
 - 현재 요청은 “부모님과 같이 볼 영화”
 - 과거 선호를 그대로 쓰면 공포 영화를 추천하게 됨

Introduction

- 과거 정보는 정말 도움이 되는가
 - ✓ 과거 대화를 넣었을 때와 넣지 않았을 때 정답 아이템과의 유사도 변화를 측정
 - ✓ TGRReDial : 증가 35.9%, 변화 없음 36.1%, 감소 27.9%
 - ✓ ReDial : 증가 33.2%, 변화 없음 38.5%, 감소 28.3%
 - ✓ 도움이 되는 경우는 약 3분의 1, 나머지는 무의미하거나 오히려 해로움
- 문제 정의
 - ✓ 과거 대화를 쓸지 말지를 시스템이 스스로 판단해야 함
 - ✓ 판단 기준을 학습할 정답 라벨이 없음
- 핵심 아이디어
 - ✓ 과거 세션마다 찬성 에이전트와 반대 에이전트가 토론
 - ✓ 토론 내용을 보고 판정 모델이 유용한 세션만 선택
 - ✓ 선택된 세션을 프롬프트가 아니라 모델 파라미터에 주입




Figure 2: Distribution of cognitive negative transfer phenomena on TGRReDial and ReDial datasets.

Introduction : 예시

- 상황
 - ✓ 현재 대화: "Hi, can you recommend a comedy movie?"
 - ✓ 이 사용자에게는 과거 대화 세션 네 개가 남아 있음
 - ✓ 정답 아이템: Four Weddings and a Funeral
- 기존 방식 (그림 위쪽)
 - ✓ 과거 세션 네 개를 **구분 없이 전부** 추천기에 입력 (Blind Usage)
 - ✓ 현재 의도와 무관한 세션까지 반영되어 **정답과 다른 영화를 추천**
- 제안 방식 (그림 아래쪽)
 - ✓ Agent Debate가 세션 하나하나를 검토
 - ✓ **세션 2와 세션 4만 유용하다고 판정**하고 나머지는 제외
 - ✓ 선별된 세션만 사용해 정답과 일치하는 추천 결과를 얻음
- 읽는 포인트
 - ✓ 과거 정보를 버리는 것이 아니라 **현재 대화와 맞는 것만 고르는 것**

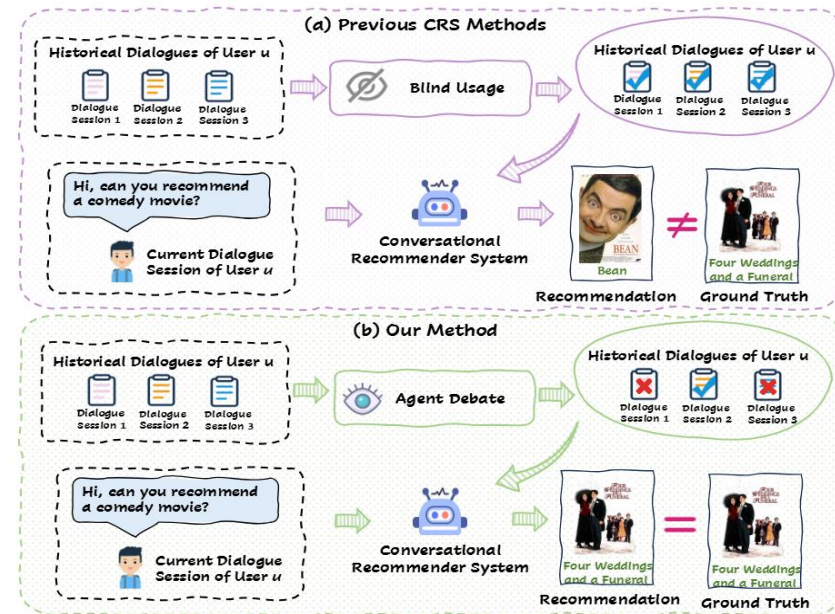


Figure 1: Previous CRS methods vs. our method.

Proposed Method

- 두 개의 모듈로 구성
 - ✓ Multi-Agent Debate Module: 과거 세션 중 쓸 것만 선별
 - ✓ Parametric Injection Module: 선별된 세션을 LoRA 파라미터로 주입
- 현재 대화 세션은 그대로 사용하고, **과거 세션만 걸러냄**

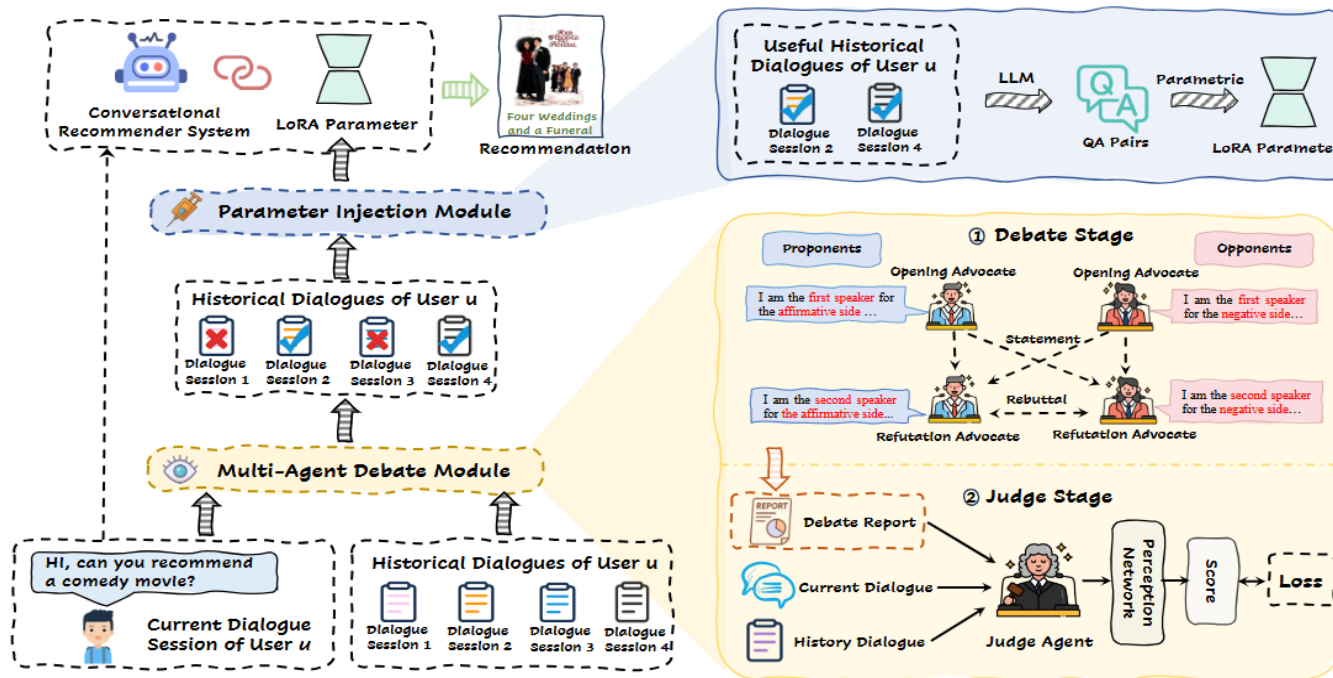



Figure 3: Overview of EyeCRS and its two components: (i) Multi-Agent Debate Module, which filters out unhelpful historical dialogue sessions to mitigate cognitive negative transfer; and (ii) Parametric Injection Module, which injects beneficial historical knowledge into the intrinsic parameter space of the LLM for personalized reasoning.

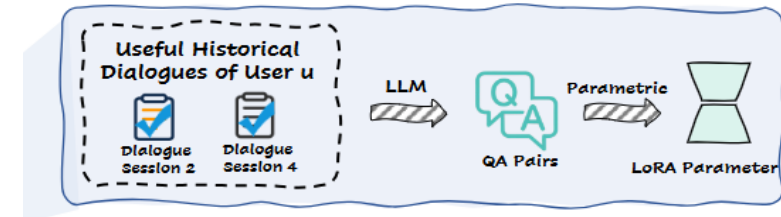

Proposed Method : Multi-Agent Debate

- 과거 세션 하나마다 두 팀을 붙임
 - ✓ Proponent : 이 세션은 현재 의도를 이해하는 데 도움이 된다
 - ✓ Opponent : 이 세션은 현재 판단을 방해한다
- 토론은 두 단계
 - ✓ Statement : 각자 현재 대화와 과거 세션을 보고 처음 주장을 생성
 - ✓ Rebuttal : 상대 주장을 읽고 반박을 생성
 - ✓ 두 단계 기록을 합쳐 **토론 기록**으로 저장하고 다음 단계로 전달
- 왜 토론인가
 - ✓ LLM에게 한 번만 물어보면 근거 없이 판단하기 쉬움
 - ✓ **양쪽 근거를 모두 만들게 해서** 판단 신뢰도를 높임



Proposed Method : Judge & Injection

- Judge
 - ✓ 토론 기록과 현재 대화를 하나의 입력으로 만들어 점수를 계산
 - ✓ 임계값을 넘는 세션만 사용
 - ✓ 인코더는 고정하고 **점수 계산 부분만 학습**
- 정답 라벨이 없는 문제를 푸는 방법
 - ✓ 과거 세션을 넣었을 때 정답 아이템과의 유사도가
 - **올라가면 positive, 내려가면 negative**
 - ✓ 이 신호로 판정 모델을 학습 (weak supervision)
- Parametric Injection
 - ✓ 선별된 세션을 질문 답변 쌍으로 바꿔 LoRA로 학습
 - ✓ 프롬프트에 넣지 않으므로 컨텍스트 길이를 소모하지 않음
 - ✓ 개인 정보가 참고 자료가 아니라 **모델 안의 기억**이 됨



CONTENTS

1. Background
2. Related Work
 - EyeCRS
 - AdaptJobRec
 - HARPO
3. Research Direction



[2026][AAAI][AdaptJobRec]

AdaptJobRec: Enhancing Conversational Career Recommendation through an LLM-Powered Agentic System

**Qixin Wang^{1,2}, Dawei Wang¹, Kun Chen¹, Yaowei Hu¹
Puneet Girdhar¹, Ruoteng Wang¹, Aadesh Gupta¹, Chaitanya Devella¹
Wenlai Guo¹, Shangwen Huang¹, Bachir Aoun¹, Greg Hayworth¹
Han Li^{1*}, Xintao Wu^{2*}**

¹Walmart Global Tech
han.li@walmart.com

²University of Arkansas
xintaowu@uark.edu

Background

- Agentic CRS의 일반적인 동작
 - ✓ 질의를 받으면 계획을 세우고, 도구를 호출하고, 결과를 확인해 다시 계획
 - ✓ ReAct, Plan-and-Execute, RecMind, InteRecAgent가 모두 이 형태
- 얻는 것
 - ✓ 복잡한 요청을 여러 단계로 나눠서 처리 가능
 - ✓ 필요한 정보를 도구로 가져와 정확도 상승
- 잃는 것
 - ✓ 단계가 늘어난 만큼 **응답 시간이 길어짐**
 - ✓ LLM 호출 횟수가 늘어 비용도 함께 증가
- 실제 서비스에서의 문제
 - ✓ Walmart 채용 서비스는 연간 수백만 명이 사용
 - ✓ 질의의 상당수는 “내 지원 상태 알려줘” 같은 **단순 조회**
 - ✓ 단순 질의까지 계획과 메모리 단계를 거치면 **느려서 쓸 수 없음**

Introduction


- 문제
 - ✓ 모든 질의를 같은 파이프라인으로 처리하는 것이 자연의 원인
 - ✓ 첫 토큰을 빨리 내보내는 것만으로는 해결되지 않음
 - ✓ 사용자가 원하는 것은 **정보에 도달하는 시간**을 줄이는 것
- 핵심 아이디어
 - ✓ 질의를 **simple**과 **complex**로 먼저 분류
 - ✓ simple은 추천 API와 지식 그래프로 바로 응답
 - ✓ complex만 메모리 처리와 계획 단계를 거치게 함
- 함께 해결한 것
 - ✓ 대화 기록 중 현재 질의와 관련된 부분만 뽑아 계획 품질을 높임
 - ✓ 동시에 실행 가능한 작업을 묶어 병렬로 처리
- 결과
 - ✓ 평균 응답 시간 최대 **53.3% 감소**, 추천 정확도는 오히려 상승

Introduction : 예시

- **Simple query** : “Check my Job Application Status”
 - ✓ 대화 기록과 질의를 합쳐 지원 상태 API로 바로 조회
 - ✓ 메모리 처리와 계획 단계를 **거치지 않음**
 - ✓ 사용자는 몇 초 안에 원하는 정보를 받음
- **Complex query** : “Help me make a career development plan”
 - ✓ Memory Process가 대화 기록에서 관련 부분만 추출
 - Ex) “딥러닝 자격증을 땀다”는 이전 발화는 사용, 사무실 위치 질문은 제외
 - ✓ Planner가 다섯 개의 서브태스크로 분해
 - ① 커리어 패스 추천 ② 스킬 갭 식별 ③ 학습 자료 추천
 - ④ 멘토 추천 ⑤ 지원 가능한 공고 추천
 - ✓ 각 태스크를 도구로 실행한 뒤 하나의 응답으로 종합
- **읽는 포인트**
 - ✓ 같은 시스템 안에서 **두 개의 처리 경로**가 갈린다는 것

Proposed Method

- 구성
 - ✓ Agent: 질의 복잡도 판단, 도구 연결, 응답 생성
 - ✓ Memory Process, Planner, 개인화 추천 도구, People.AI 지식 그래프
- Complexity Identification
 - ✓ simple: 대화 기록과 질의를 합쳐 추천 API로 바로 처리
 - ✓ complex: Memory Process → Planner → Tools 순서로 처리



Proposed Method : Memory & Planner

• Memory Processing Module

- ✓ 기존 방식은 대화 기록을 잘라내거나 요약해서 사용
- ✓ 필요한 내용이 빠지거나 무관한 내용이 남아 계획이 흔들림
- ✓ few shot 예시로 **현재 질의와 관련된 부분만 추출**해 질의와 합침
- ✓ 되묻는 횟수와 후속 질의 수가 줄어드는 효과

• Planner

- ✓ 기존 플래너는 작업을 **순서대로 하나씩** 나열
- ✓ 동시에 해도 되는 작업을 묶어 **중첩 리스트**로 출력
- ✓ Ex) 시애틀 공고 수 조회와 서니베일 공고 수 조회는 동시에 실행한 뒤 비교

• 개인화 추천 도구

- ✓ People.AI 지식 그래프 사용 (노드 160만, 엣지 8300만)
- ✓ 프로필의 스킬, 학력, 지역을 공고와 매칭해 점수를 계산
- ✓ 클릭, 저장, 좋아요 같은 실시간 반응으로 점수를 조정

• 도구 결과가 부족하면 Planner로 되돌려 다시 계획

You need to re-write the user request on the last part of the text under [TEXT] while considering the chat history if additional information is needed. For example:

```
[TEXT]
User: Where is the Bentonville Walmart Fitness Center located?
Assistant: 1400 SE 5th St, Bentonville, AR 72716
User: How many people applied for the 3D Designer job last week?
Assistant: 512 candidates applied for the 3D Designer job last week.
User: how about the Graphic Designer role?
[OUTPUT]
How many people applied for the Graphic Designer job in last week?
```

Few-shot example 1:
Chat history contains relevant information

```
[TEXT]
User: How many people apply 3D Designer job in last week?
Assistant: 512 candidates apply 3D designer job in last week.
User: How's the weather today?
[OUTPUT]
How's the weather today?
```

Few-shot example 2:
No relevant information in chat history

```
[TEXT]
(chat_history)
(user_query)
[OUTPUT]
```

Figure 3: System Prompt of Few-shot Learning Memory Processing Module.

You need to split the sentences under [TEXT] into several sub-tasks, following the format shown in the examples. Group the subtasks that can be executed asynchronously into a single list. If the sentence contains only one intent, do not split it.

For example,

```
[TEXT]
Which city has more machine learning engineer job openings, Seattle or Sunnyvale?
[OUTPUT]
- [Get machine learning engineer job opening number from Seattle; Get machine learning engineer job opening number from Sunnyvale]
- [Compare job opening numbers of Sunnyvale and Seattle]
```

Few-shot example 1:
Contain asynchronously executable sub-tasks

```
[TEXT]
How many machine learning engineer job openings at Sunnyvale?
[OUTPUT]
- [Get machine learning engineer job opening number from Sunnyvale]
```

Few-shot example 2:
Do not contain asynchronously executable sub-tasks

```
[TEXT]
(integrated_user_query)
[OUTPUT]
```

Figure 4: System Prompt of AdaptJobRec Planner.

CONTENTS

1. Background

2. Related Work

- EyeCRS
- AdaptJobRec
- HARPO

3. Research Direction



Related Work

[2026][ACL][HARPO]

HARPO: Hierarchical Agentic Reasoning for User-Aligned Conversational Recommendation

Subham Raj¹ Aman Vaibhav Jha¹ Mayank Anand² Sriparna Saha¹


¹Department of Computer Science and Engineering, Indian Institute of Technology Patna, India

²Indian Institute of Information Technology Allahabad, India

{subham_2221cs25, 2201ai54_aman, sriparna}@iitp.ac.in
anandmayank698@gmail.com

Background

- 지금까지의 CRS는 무엇으로 평가되었는가
 - ✓ Recall@K, BLEU 같은 **대리 지표(proxy metric)**로 성능을 측정
 - ✓ 대리 지표가 높아도 사용자가 만족하지 않는 경우가 많음
- 예시
 - ✓ 요청: "여름 결혼식에 입을 캐주얼한 옷"
 - ✓ 시스템이 이를 **평상복**으로 이해해도 지표 점수는 잘 나옴
 - ✓ 하지만 실제 상황에는 맞지 않는 추천 → **지표와 만족도가 어긋남**
- 원인
 - ✓ 학습 목표가 **검색 정확도나 문장 유창성**에 맞춰져 있음
 - ✓ 추천 품질 자체를 직접 학습하지 않음
- 그래서 필요한 것
 - ✓ 여러 후보 경로를 만들어 보고
 - ✓ **어떤 경로가 좋은 추천인지 판단하는 기준**을 함께 학습해야 함



Introduction

- 핵심 아이디어
 - ✓ 추론 경로를 **여러 개 만들어 보고**, 품질로 평가하고, 여러 에이전트가 다듬음
- 네 개의 구성 요소
 - ✓ STAR: Tree of Thought로 여러 추론 경로를 탐색하고 최적 경로를 선택
 - ✓ CHARM: 추천 품질을 네 가지로 분해해 보상으로 학습
 - ✓ BRIDGE: 다른 도메인으로 옮겨도 동작하도록 표현을 적응
 - ✓ MAVEN: 추천, 비판, 설명 에이전트가 합의하여 최종 응답 생성
- 예시
 - ✓ Query: "I loved The Dark Knight but want something with less violence for family movie night."
 - ✓ 후보 생성과 평가를 거쳐 **The Incredibles**를 최종 추천
 - ✓ 응답: 다크나이트의 영웅적 요소는 유지하면서 가족이 함께 볼 수 있는 작품이라고 설명
- 결과
 - ✓ ReDial: Recall@10 **+18.7%**, 사용자 만족도 +21.4%
 - ✓ INSPIRED: Recall@10 **+34.3%**, 만족도 +26.9% / MUSE: Recall@10 +12.9%, 만족도 +18.0%

Proposed Method

- 하나의 LLM backbone 위에 네 개의 모듈이 연결됨
 - ✓ Query → BRIDGE (도메인 적응) → STAR (경로 탐색) → MAVEN (합의) → 최종 응답
 - ✓ CHARM이 만든 품질 보상이 STAR의 경로 선택 기준으로 사용됨




Figure 2: Overall architecture of the HARPO framework. The model integrates four components: STAR for structured agentic reasoning, CHARM for hierarchical preference optimization, BRIDGE for cross-domain transfer, and MAVEN for multi-agent refinement, all built on a shared language model backbone.

Proposed Method : STAR & CHARM

- STAR (Structured Tree-of-Thought Agentic Reasoning)
 - ✓ Thought Generator가 여러 추론 경로를 생성 (Path A, Path B)
 - ✓ Value Network가 각 경로의 **추천 품질**을 예측
 - ✓ 작업을 끝냈는지가 아니라 **품질 기준으로 최적 경로를 선택**
- CHARM (Contrastive Hierarchical Alignment with Reward Marginalization)
 - ✓ 추천 품질을 네 가지로 분해
 - **Relevance** 요청과 맞는가 / **Diversity** 비슷한 것만 주지 않는가
 - **Satisfaction** 사용자가 만족하는가 / **Engagement** 대화를 이어가고 싶은가
 - ✓ 항목마다 별도의 reward head를 두고 점수를 계산
 - ✓ Meta Learner가 **대화 맥락에 따라 항목별 가중치를 조정**
- 두 모듈의 연결
 - ✓ CHARM이 만든 품질 신호로 **STAR의 Value Network를 학습**
 - ✓ 즉 무엇이 좋은 추천인지를 배운 뒤, 그 기준으로 경로를 고름

Proposed Method : BRIDGE & MAVEN

- BRIDGE (Cross-Domain Transfer)
 - ✓ Adversarial Discriminator로 도메인을 구분하는 정보를 지움
 - ✓ Domain Gate가 적응된 표현과 원래 표현을 섞는 비율을 학습
 - ✓ 영화 도메인에서 배운 것을 패션 도메인으로 옮겨도 동작
- MAVEN (Multi-Agent Refinement)
 - ✓ 세 개의 에이전트가 각자 역할을 맡음
 - 후보 생성 / 후보 평가 및 비판 / 추천 이유 설명
 - ✓ Orchestrator가 결과를 모아 합의된 추천을 만들
 - ✓ 서로 어긋나지 않도록 agreement loss로 함께 학습
- 세 논문 정리
 - ✓ EyeCRS : 무엇을 기억할 것인가
 - ✓ AdaptJobRec : 언제 도구를 부를 것인가
 - ✓ HARPO : 어떤 경로를 좋은 추천으로 볼 것인가



CONTENTS

1. Background
2. Related Work
 - EyeCRS
 - AdaptJobRec
 - HARPO
3. Research Direction

Research Direction

연구 방향 A : 개인화된 대화형 추천

- 다루는 문제

- ✓ 개인화 정보 = 현재 세션 정보에 장기 사용자 정보를 보완적으로 결합한 것
- ✓ Current-session Signals : 현재 대화에서 직접 드러난 목적, 선호, 제약
 - Ex) “부모님과 같이 볼 영화”, “너무 무서운 건 싫음”, “2시간 이내”
- ✓ Long-term Preference / Profile : 과거 행동이나 rating에서 추정한 장기 선호
 - Ex) 컨저링 → 엑소시스트 → 애나벨 (공포 영화 선호)
- ✓ Historical Dialogue Sessions : 현재 대화 이전에 나눈 과거 대화 세션
- ✓ Similar / Look-alike Users : 비슷한 취향을 가진 다른 사용자들의 정보

- 오늘 본 논문과의 연결

- ✓ EyeCRS가 다룬 것은 네 가지 중 Historical Dialogue Sessions 하나
- ✓ 네 종류를 함께 쓸 때 무엇을 우선할지는 아직 정해진 답이 없음

- 해볼 만한 것

- ✓ 턴이 진행될 때마다 쓸 개인화 정보를 다시 고르는 방법
- ✓ “이건 싫어” 같은 부정 피드백을 선호에 반영하는 방법

Research Direction

연구 방향 B : Knowledge Graph + LLM 추천

- 다루는 문제
 - ✓ LLM 추천기가 가진 한계
 - **Hallucination** : 존재하지 않는 아이템이나 근거를 만들어 냄
 - **최신 지식과 도메인 지식 부족** : 학습 이후에 나온 아이템 정보를 모름
 - 일반적인 RAG는 **노이즈가 섞이고 지식의 구조 관계를 놓침**
 - ✓ 해결 방향: 지식 그래프에서 **구조 정보를 검색해** 추천 생성에 결합
- 대표 연구
 - ✓ K-RagRec : Knowledge Graph Retrieval-Augmented Generation for LLM-based Recommendation
 - ✓ Wang et al., ACL 2025. KG의 구조 정보를 검색해 LLM 추천에 주입하는 프레임워크
- 남아 있는 문제
 - ✓ 어떤 부분 그래프를 얼마나 가져올 것인가
 - ✓ 검색한 지식과 사용자 선호를 어떻게 결합할 것인가
 - ✓ 그래프가 커질수록 **검색 비용과 노이즈**가 함께 증가
- 오늘 본 논문과의 연결
 - ✓ AdaptJobRec도 People.AI 지식 그래프를 **도구로 호출**
 - ✓ 즉 KG는 이미 에이전트의 도구 자리에 들어와 있음



Thank you for listening

Hae-Yoon Koo (hykoo@konkuk.ac.kr)

Graph & Language Intelligence Laboratory
Konkuk University

2026.08.12