

이종 데이터 간 관계 모델링을 통한 개인화 추천 시스템의 지식 그래프 확장 기법

(Extended Knowledge Graph using Relation Modeling between Heterogeneous Data for Personalized Recommender Systems)

이승주*, 안석호*, 이의종**, 서영덕***

(SeungJoo Lee, Seokho Ahn, Euijong Lee, Young-Duk Seo)

요약

많은 추천 시스템 연구에서는 다양한 이종 데이터를 상호 호환적으로 통합하여 추천 시스템의 고질적인 데이터 부족 문제를 해결하고자 한다. 하지만, 지식 그래프를 활용하여 이종 데이터의 통합을 달성한 추천 시스템 연구는 거의 없으며, 대부분 연구에서는 기구축된 지식 그래프 상의 개체 간 연결이 명시적 관계로만 구성되어 있다는 한계가 존재한다. 본 논문에서는 이종 데이터의 통합을 위해 다중 지식 베이스로부터 추출한 데이터 간 관계 모델링을 수행하고, 이를 통해 지식 그래프를 확장하는 방법을 제안한다. 또한, 딥러닝 기반의 잠재적 관계 모델링을 통해 지식 그래프 상 개체 간 관계 정보의 신뢰성을 높이고자 한다. 본 논문에서 제안하는 확장된 지식 그래프를 사용하면 개체의 특성 벡터 품질이 개선되고, 최종적으로 예측된 사용자 선호도의 정확성을 높일 수 있다. 또한, 실험을 통해 확장된 지식 그래프 기반 추천 정확도가 기존 지식 그래프 기반 추천 정확도에 비해 향상되었음을 확인하였다.

■ 중심어 : 추천 시스템 ; 지식 그래프 ; 지식 표현 ; 이종 데이터 통합

Abstract

Many researchers have investigated ways to enhance recommender systems by integrating heterogeneous data to address the data sparsity problem. However, only a few studies have successfully integrated heterogeneous data using knowledge graph. Additionally, most of the knowledge graphs built in these studies only incorporate explicit relationships between entities and lack additional information. Therefore, we propose a method for expanding knowledge graphs by using deep learning to model latent relationships between heterogeneous data from multiple knowledge bases. Our extended knowledge graph enhances the quality of entity features and ultimately increases the accuracy of predicted user preferences. Experiments using real music data demonstrate that the expanded knowledge graph leads to an increase in recommendation accuracy when compared to the original knowledge graph.

■ keywords : Recommender systems ; Knowledge graph ; Knowledge representation ; Heterogeneous data integration

1. 서론

최근 개인화 서비스의 중요성이 매우 높아지고 있으며 다양한 분야에서 추천 시스템 연

구가 활발하게 진행되고 있다[1]. 그러나 대부분의 추천 시스템은 데이터 희소성(Data sparsity) 및 콜드 스타트(Cold start) 문제로 여전히 어려움을 겪고 있고, 이를 해결하기 위해 다양한 이종 데이터를 활용하는 방안을

* 준회원, 인하대학교 전기컴퓨터공학과 석사과정

** 정회원, 충북대학교 소프트웨어학부 조교수

*** 정회원, 인하대학교 컴퓨터공학과 조교수

본 연구는 2022년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(NRF-2022R1C1C1012408, 우수신진연구)과 정보통신기획평가원의 지원(No.2022-0-00448, 사람중심인공지능핵심원천기술개발, No.RS-2022-00155915, 인공지능융합혁신인재양성(인하대학교))을 받아 수행한 연구임.

접수일자 : 2023년 03월 09일

수정일자 : 1차 2023년 03월 16일

게재확정일 : 2023년 03월 20일

교신저자 : 서영덕 e-mail : mysid88@inha.ac.kr

제시하고 있다[2,3]. 추천 시스템에서 활용하는 이종 데이터에는 평점과 같이 사용자의 선호도를 명시적으로 확인할 수 있는 명시적 피드백(Explicit feedback)과 구매 이력, 클릭 수와 같은 사용자 로그 정보인 암묵적 피드백(Implicit feedback)이 대표적이다. 그 외에도 영화의 카테고리, 태그 정보와 같이 아이টে임을 설명하는 다양한 보조 정보들이 존재한다[2,4]. 다양한 이종 데이터를 통합하여 추천 시스템에 활용하면 사용자와 아이টে임의 잠재 특징 벡터(Latent feature vector)를 보다 풍부하게 표현할 수 있다[2,3]. 따라서, 최근 연구에서는 추천 시스템 자체의 데이터뿐만 아니라 외부의 지식 베이스 상에서 관련된 이종 데이터를 추출하고, 이를 통합하는 연구가 시도되고 있다[5].

다수의 지식 베이스에서 추출한 이종 데이터를 통합하기 위해서는 데이터 간의 관계를 미리 정의하고 표현하는 것이 필수적이며, 그래프 구조인 온톨로지[6-8]와 지식 그래프[2,9]가 주로 사용된다. 온톨로지 구축을 위해서는 개체(Entity)의 속성을 사람이 직접 분석하고 그들 간의 관계를 계층적으로 정의하는 추상화 작업이 필요하다. 하지만, 온톨로지는 “사용자 A가 상품 B를 구매했다”와 같은 개체 간의 명시적 관계(Explicit relation)만 정의할 수 있다. 추천 시스템 데이터의 특성상 명시적 관계의 수는 전체 개체 수와 비교하여 매우 적기 때문에, 온톨로지만 사용할 경우 개체 간 관계의 대부분을 표현할 수 없다. 또한, 기존의 온톨로지 구축 방법[6]은 정해진 지식 베이스를 기반으로 데이터 간 관계를 정의하기 때문에, 새로운 지식 베이스가 추가될 경우 새로운 온톨로지 구축 작업이 필수적이다. 이러한 이유로 대부분 온톨로지 기반 추천 시스템 연구는 새로운 온톨로지 구축 방법을 제시하기보단 기존의 온톨로지를 활용하여 추천 성능을 개선하는 데 집중하고 있

다[7,8]. 따라서 온톨로지 기반 추천 시스템 연구는 다중 지식 베이스를 기반으로 하는 이종 데이터 통합에 대한 궁극적인 해결책을 제공한다고 말할 수 없다[10].

온톨로지의 한계를 극복하기 위해 이종 데이터 통합을 목표로 하는 추천 시스템 연구는 주로 지식 그래프를 기반으로 한다[2,9,18]. 지식 그래프는 정점과 정점 간의 연관성을 간선으로 표현하는 단방향 그래프 형태로 삼중항으로 구성되어있다[3]. 각 삼중항은 주어 개체(Head entity), 관계(Relation), 술어 개체(Tail entity)로 이루어져 있다. 지식 그래프 기반 추천 시스템 연구에서는 사전 정의된 온톨로지를 활용하거나 노동 집약적인 지식 베이스의 개체 명 일치 작업을 통해 지식 그래프를 생성한다. 구축한 지식 그래프를 기반으로 학습을 통해 개체 간의 잠재적 관계(Latent relation) 정보를 도출해낼 수 있고, 이는 온톨로지 기반의 추천 시스템에서 발생하는 명시적 관계의 부족함을 보완할 수 있다. 하지만, 지식 그래프 상의 잠재적 관계 정보가 충분하지 않은 상태에서 개체의 특성 벡터(Feature vector)를 임베딩 하면, 사용자와 아이টে임을 표현하는 특성 벡터의 품질이 낮아지고 이로 인해 추천의 정확도가 떨어진다[11]. 따라서, 지식 그래프 상에 명시적 관계뿐만 아니라 개체 간의 잠재적 관계와 같은 다양한 관계 정보를 반영하는 것이 중요하다. 이를 위해 다양한 보조 정보를 담고 있는 다중 지식 베이스를 활용하는 것이 필요하다.

하지만, 지식 그래프 기반 추천 시스템 연구에서는 대부분 단일 지식 베이스만 활용하여 지식 그래프를 구축한다. 따라서, 개체 간 관계가 풍부하지 못하고 누락된 지식이 존재할 가능성이 크며, 이는 정확한 추천을 제공하기에 지식이 불완전함을 의미한다[12,13]. 이를 보완하기 위해 링크 예측 또는 삼중항 예측 작업을 수행하여 지식 그래프 상에 새로운 지

식 정보를 추가는 연구도 존재하지만[14], 지식 그래프의 불완전성을 해소하기에는 여전히 데이터가 충분하지 않다. 따라서, 다양한 이종 데이터가 담긴 다수의 외부 지식 베이스를 활용하여, 이종 데이터를 상호 호환적으로 통합할 수 있는 지식 그래프 기반 추천 시스템 연구가 필요하다.

본 논문에서는 지식 그래프의 개체 간 관계 모델링으로 새로운 관계를 추가하여 그래프를 확장하는 방법을 제안한다. 더 나아가, 해당 방법을 사용하여 다중 지식 베이스 기반 지식 그래프 상에서 이종 데이터 간의 상호 호환적 통합이 가능하도록 하였다. 제안하는 통합 방식은 딥러닝 기반의 관계 모델링을 통해 개체 간 관계를 새롭게 정의하고 추가하여, 명시적 관계뿐만 아니라 신뢰성 높은 잠재 관계 또한 지식 그래프에 반영할 수 있다. 이렇게 확장된 지식 그래프는 풍부한 관계 표현이 가능하고 기존 지식 그래프의 불완전성 문제를 해결할 수 있다. 따라서 학습을 통해 사용자 및 아이템 특성 벡터의 품질을 높이고, 최종적으로 추천 시스템 성능을 개선한다.

본 논문의 구성은 다음과 같다. 제2장에서는 추천 시스템상 이종 데이터의 통합을 위해 온톨로지와 지식 그래프 기반의 추천 시스템 연구를 분석하고 한계점을 언급한다. 제3장에서는 본 논문에서 제안하는 다중 지식 베이스 상의 이종 데이터 간 딥러닝 기반 관계 모델링으로 지식 그래프를 확장하는 방법을 소개하고, 제안 방법을 다양한 시나리오를 통해 자세히 서술한다. 제4장에서는 제안하는 기법의 성능을 평가하기 위해 수행한 실험을 설명하고, 기존의 지식 그래프와 확장된 지식 그래프 기반의 추천 성능을 비교 평가한다. 마지막으로 제5장에서는 본 논문을 마무리하고 향후 연구를 제시한다.

II. 관련 연구

1. 온톨로지 기반 추천 시스템

온톨로지는 데이터의 종류(Class) 혹은 속성(Property)을 확인하여 서로 다른 지식 베이스 간의 공유되는 개념화를 정형적으로 명세화한 집합체이다[25]. 추천 시스템에서 온톨로지를 활용하면 이종 데이터의 상호 호환을 달성할 수 있고, 다양한 데이터의 활용이 가능하여 추천의 성능이 향상된다[8]. 본 연구와 관련된 온톨로지 기반의 추천 시스템 연구는 크게 온톨로지 구축 방법[15,16]과 온톨로지 활용 방법[7,17]으로 나누어진다.

먼저, 온톨로지 구축을 위한 다양한 방법론 중, [15]에서는 서로 다른 도메인 분류법을 병합하여 참조 온톨로지를 구축하였고, 풍부한 참조 온톨로지를 통해 학자들의 배경 지식을 프로파일링하는 데 활용하였다. 또한, [16]에서는 계층 분할 클러스터링을 기반으로 여러 온톨로지를 병합하는 방법을 제안하였다. 이는 온톨로지의 유사도를 계산하여 온톨로지 쌍의 정렬을 결정하는 방식으로 기존의 온톨로지를 확장한다[16]. 그러나 대부분의 온톨로지 구축 방법은 기존의 온톨로지를 병합하거나 수정하는 방식으로만 새로운 온톨로지를 구축한다는 점에서 이종 데이터 통합 방법을 제시하지 않는다. 또한, 온톨로지는 사람이 직접 개체의 속성을 분석하여 관계의 계층화를 정의하는 작업이기 때문에, 정의된 개체 간 관계가 명시적 관계에만 치우쳐 있다는 한계가 존재한다.

둘째, 대부분의 온톨로지 기반 추천 시스템 연구는 온톨로지 구축 방법을 제시한다기보단 이미 생성된 온톨로지를 활용하여 사용자의 선호도 추론을 개선할 수 있는 학습 방식을 제안하는 데 집중한다[7,17]. [7]은 협업 필터링의 희소성과 확장성 문제를 개선하기 위해 온톨로지와 차원 축소 기술을 함께 활용한 협업 필터링 기반 추천 방안을 제시하였고, [17]에서는 관광 서비스를 위한 온톨로지를 사용하여 프로토타입 여행 추천 시스템을 개발하였다. 이처

럼 온톨로지 기반 추천 시스템 연구는 이미 존재하는 온톨로지를 단순 활용하는 기법을 소개할 뿐, 다양한 지식 베이스의 상호 호환을 위한 이중 데이터 통합 방법을 제시하지 않는다.

2. 지식 그래프 기반 추천 시스템

지식 그래프는 서로 다른 두 개체 간의 관계와 그 관계의 이유를 구조적으로 반영할 수 있으므로 이중 데이터 간의 관계를 학습하기에 적합한 구조이다. 따라서 많은 추천 시스템 연구에서도 아이템의 다양한 보조 정보를 지식 그래프에 추가하여, 아이템의 특성을 더욱 풍부하게 표현하고 학습하는 방법을 제안한다. 지식 그래프 기반 추천 알고리즘은 크게 임베딩 기반 학습 방법[2,3,18]과 경로 기반 학습 방법[9,19]으로 분류한다.

첫째, 임베딩 기반의 학습 방법은 지식 그래프의 개체 임베딩을 학습하여 사용자와 아이템의 특성 벡터를 도출해내고, 이를 통해 누락된 사용자의 선호도를 추론하는 방식이다[2,3,18]. KGCN (Knowledge Graph Convolutional Networks for Recommender Systems)은 그래프 합성곱 신경망 기법을 지식 그래프에 적용한 알고리즘으로, 각 개체의 특성 벡터를 이웃 개체에 전파하여 업데이트하는 방식이다[18]. KGAT (Knowledge Graph Attention Network for Recommendation)는 사용자와 아이템의 고차 관계를 모델링하기 위해 재귀 전파로 개체의 임베딩 품질을 점차 향상시키는 알고리즘이다[2]. 하지만, 두 모델은 단일 지식 베이스만 활용하여 지식 그래프를 구축하였다는 점에서 누락된 지식 정보로 인한 불완전한 지식 그래프를 사용한다는 한계점이 존재한다. 단일 도메인에서 더 나아가 여러 도메인의 정보를 통합하기 위해 MKGAT(Multi-modal Knowledge Graph Attention Network for Recommendation) 알고리즘을 활용하면 멀티 모달 기반의 지식 그래프 정보 전파를 통해

풍부한 개체 특성 벡터를 얻을 수 있다[3]. 그러나 이 방법은 고정된 임베딩 공간에서 임베딩 병합 수준으로 다중 도메인을 통합한다는 점에서 지식 그래프를 사용하여 이중 데이터의 통합을 실현했다고 말하기 어렵다.

둘째, 경로 기반의 방법은 지식 그래프에서 전파되는 다중 홉 경로를 추출하여 사용자의 선호도를 표현한다[9,19]. 지식 그래프 상에 존재하는 개체 간 연결 패턴을 활용하는 경로 기반 방법 중 대표적으로 KPRN(Knowledge-aware Path Recurrent Network)은 개체, 개체 유형 그리고 관계의 정보를 포함하는 다중 홉 경로를 추출한다[9]. 추출한 경로를 활용하여 사용자가 아이템을 선호하는 이유에 관해 설명을 부여한다. 설명 가능한 규칙 기반의 신경망 추천 알고리즘인 RuleRec은 규칙 학습 모듈과 추천 모듈로 구성된 공동 학습 프레임 워크이다[19]. 이 알고리즘은 아이템의 다양한 연관성을 추론하기 위해 지식 그래프에서 추출한 귀납적 규칙을 활용하여 다중 홉 관계 패턴을 요약하고 사용자 선호도를 예측한다. 하지만, 두 방법 모두 이중 데이터의 상호 호환을 해결하지 않고, 단일 지식 베이스에서 추출한 데이터의 경로 학습 방법만 제시하고 있다. 또한, 대부분의 경로 기반 지식 그래프 연구에서는 추출하는 경로에 대한 신뢰성을 검증하기보다 경로 학습으로 사용자 선호도를 추론하는 방식만 제시하고 있다. 따라서 지식 그래프가 구성하고 있는 개체 간의 관계가 명시적 관계뿐만 아니라 잠재적인 관계 특성을 반영할 수 있도록 관계 정보의 품질을 개선하는 방법이 필요하다.

이처럼 대부분의 지식 그래프 기반 추천 시스템 연구는 지식 그래프를 생성하기 위해 주로 기구축된 온톨로지를 활용하거나, 데이터 간의 개체 명 일치 작업을 통해 명시적 관계만 고려한다. 또한, 주로 단일 지식 베이스만 활용하여 지식 그래프를 구축하기 때문에, 지식 그

래프를 구성하는 지식 데이터의 양이 부족하다. 따라서, 본 논문에서는 다중 지식 베이스를 활용하여 많은 양의 이중 데이터를 확보한 상태에서 지식 그래프를 구축하는 방법을 제안한다. 그리고 딥러닝 기반의 개체 간 관계 모델링을 통해 지식 그래프가 명시적 관계뿐만 아니라 신뢰 있는 잠재 관계 정보 또한 포함하도록 하였다. 이렇게 확장된 지식 그래프의 학습으로 사용자 및 아이템 특성 벡터의 품질을 개선하고 최종적으로 추천 시스템의 성능을 높일 수 있다.

III. 관계 모델링을 통한 지식 그래프 확장 기법

본 논문에서 제안하는 방법은 크게 두 가지 과정으로 구성된다. 첫 번째는 지식 그래프 상의 개체 간 관계를 모델링하는 과정이며, 두 번째는 확장된 지식 그래프를 학습하여 사용자의 선호도를 추론하는 과정이다. 개체 간의 관계 모델링을 기반으로 새로운 관계 정보와 신규 개체를 지식 그래프에 추가하면, 학습을 통해 풍부한 양의 사용자 및 아이템 특성 벡터를 임베딩 할 수 있다. 이렇게 얻은 특성 벡터를 통해 사용자의 선호도를 추론한다.

1. 추천 시스템에서의 지식 그래프

지식 그래프는 정점 사이에 연결된 간선이 의미론적으로 잘 정의된 단방향 그래프이다. 일반적으로, $\varepsilon = \{e_1, e_2, \dots, e_k\}$ 은 지식 그래프 상의 정점 즉, 개체의 집합을 표현한다. $R = \{r_1, r_2, \dots, r_l\}$ 은 지식 그래프 상의 간선, 즉 관계의 집합을 나타내며, k, l 은 개체와 관계 각각의 개수를 의미한다. 따라서 지식 그래프 KG 은 카테시안 곱인 $\varepsilon \times R \times \varepsilon$ 의 부분집합이며 다음과 같이 정의된다.

$$KG = \{(h, r, t) | h, t \in \varepsilon, r \in R\} \quad (1)$$

여기서 h, r, t 은 각각 주어, 관계 그리고 술어 개체를 나타낸다. (h, r, t) 은 개체 h 에서 개체 t




그림 1. 개체 유형에 기반한 관계 모델링
Fig. 1 Relation modeling based on entity type.

로 이어지는 관계 r 를 의미한다.

추천 시스템에서 개체는 일반적으로 지식 베이스의 개체(예: 영화 지식 베이스의 감독, 주연 및 카테고리 등)이지만, 사용자 U 및 아이템 I 도 개체가 될 수 있다. 예를 들어, 사용자 $u \in U$ 와 아이템 $i \in I$ 에 해당하는 피드백이 있는 경우, 삼중항 $(u, r_{Interact}, i) \in KG$ 를 생성할 수 있으며, $r_{Interact}$ 는 [12]에서 정의된 관계를 활용한다. $r_{Interact}$ 과 같은 추가 정보로 확장된 지식 그래프인 $\overline{KG} = \{(h, r, t) | h, t \in \overline{\varepsilon}, r \in \overline{R}\}$ 은 아이템에 대한 사용자의 선호도를 더 잘 예측할 수 있다. 본 논문에서 $\overline{\varepsilon}$ 와 \overline{R} 은 각각 $\overline{\varepsilon} := \varepsilon \cup U$ 와 $\overline{R} := R \cup \{r_{Interact}\}$ 로 정의한다.

또한, 지식 그래프 상의 각 개체는 개체의 유형을 가지고 있다. 예를 들어, 음악 지식 베이스의 두 개체인 Pop과 Zazz는 카테고리라는 개체 유형으로 분류될 수 있다. 개체 유형과 같은 유용한 정보를 지식 그래프 학습에 활용하면 개체의 특성 벡터 품질을 더욱 높일 수 있다[20,21]. 본 논문에서는 개체 유형 집합 A 와 개체 유형 매핑 함수인 $\varnothing : \varepsilon \rightarrow A$ 를 정의하고, 이를 활용하여 개체 간의 새로운 관계를 정의한다.

2. 지식 그래프 상에서의 관계 모델링

본 논문에서는 지식 그래프 상의 개체 간 관계 모델링을 통해 새로운 관계 지식을 추가하기 위해 개체 유형 정보를 활용한다. 관계를 정의하고자 하는 두 개체 유형의 동일 여부에 따라 두 가지 방법으로 관계 모델링을 수행하며, 그림 1에서 보는 것과 같이 이중 개체 관

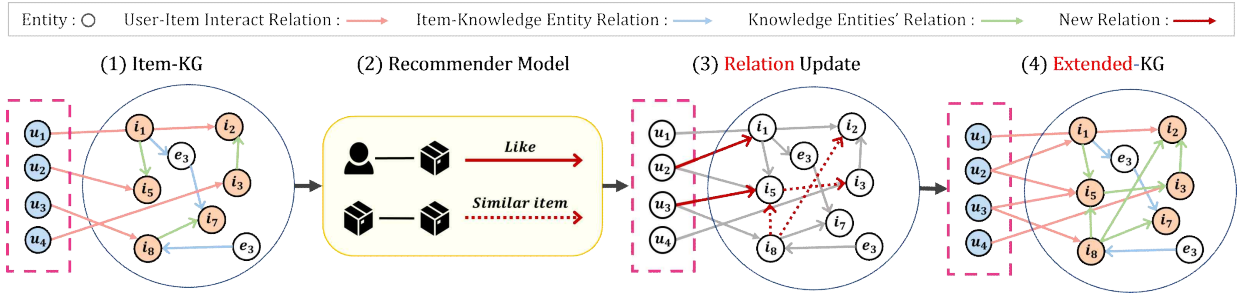


그림 2 협업 필터링에 기반한 관계 모델링 (시나리오 1)
Fig. 2 Relation modeling using collaborative filtering (Scenario 1)

계 모델링(Inter-entity relation)과 동종 개체 관계 모델링(Intra-entity relation)으로 나뉜다. 적절한 관계를 정의하기 위해 개체 유형이 $a \in A$ 인 모든 개체 집합을 고려하고 각 개체는 $\epsilon_a = \{e | e \in \epsilon, \emptyset(e) = a\}$ 로 표현한다. 본 논문에서는 딥러닝 기반의 잠재 관계 모델링을 통해 지식 그래프를 확장하여 개체 간의 관계성을 강화하고, 다중 지식 베이스의 이종 데이터 통합을 달성한다. 두 종류의 관계 모델링에 대한 자세한 설명은 다음 장에서 소개한다.

가. 이종 개체 관계 모델링

서로 다른 두 개체 유형 집합 ϵ_a 및 ϵ_b 가 관계 r_{ab} 를 기반으로 모델링 될 수 있는 경우, 일부 개체인 $e \in \epsilon_a$ 및 $f \in \epsilon_b$ 에 대해 (e, r_{ab}, f) 의 삼중항을 생성할 수 있다. 예를 들어, $\epsilon_a = Movie$ 및 $\epsilon_b = Genre$ 로 설정하면 두 개체 집합 간의 관계는 일부 영화 개체 $m \in Movie$ 와 일부 장르 개체 $j \in Genre$ 의 관련성을 기반으로 관계를 정의할 수 있고 다음과 같은 2개의 삼중항인 $(j, r_{IsGenreToMovie}, m)$ 와 $(m, r_{GenreOfMovies}, j)$ 를 생성할 수 있다. 만약 개체 간 관련성 여부가 기존에 존재하지 않는 경우, 협업 필터링을 활용하여 두 개체 간의 새로운 유사 관계를 정의할 수 있다. 따라서 이와 같은 방식으로 지식 그래프에 더 많은 관계 정보를 추가할 수 있다.

나. 동종 개체 관계 모델링

두 개체가 속한 하나의 개체 유형 집합 ϵ_a 가 관계 r_a 에 기반을 두어 모델링 될 수 있다면, 일부 개체 $e, f \in \epsilon_a$ 에 대해 (e, r_a, f) 형식의 삼중항을 생성할 수 있다. 예를 들어 $\epsilon_a = Item$ 로 설정하면, 두 아이템 $i_1, i_2 \in Item$ 간의 관계는 i_1, i_2 의 아이템 유사도를 기반으로 정의할 수 있고, 다음과 같은 2개의 삼중항인 $(i_1, r_{IsSimilarItem}, i_2)$ 와 $(i_2, r_{IsSimilarItem}, i_1)$ 를 생성할 수 있다. 또한, 지식 기반 개체 간의 새로운 관계도 정의할 수도 있다. 예를 들어, 모든 아이템의 카테고리 집합(예: 영화 지식 베이스의 로맨스, 판타지, 공포)은 아이템 목록을 기반으로 카테고리의 유사도를 계산할 수 있으므로 카테고리 개체 간의 유사 관계를 추가할 수 있다. 또한, 다중 지식 베이스의 이종 데이터 통합 과정 중 동일한 개체 유형 집합에 속하는 두 개체가 연결되는 과정에서 기존 지식 그래프에 존재하지 않았던 새로운 관계와 신규 개체를 추가할 수 있다.

3. 사례 연구

이번 장에서는 앞서 소개한 개체 간 관계 모델링으로 지식 그래프를 확장하는 세 가지 시나리오를 소개한다. 먼저 단일 지식 베이스 상에서 지식 그래프를 확장하는 사례를 소개한다. 그런 다음, 기존 지식 그래프의 개체와 신규 개체 간의 새로운 관계를 추가하는 사례를 소개한다. 마지막으로 다중 지식 베이스를 활용하여 이종 데이터 간의 신규 관계 추가에

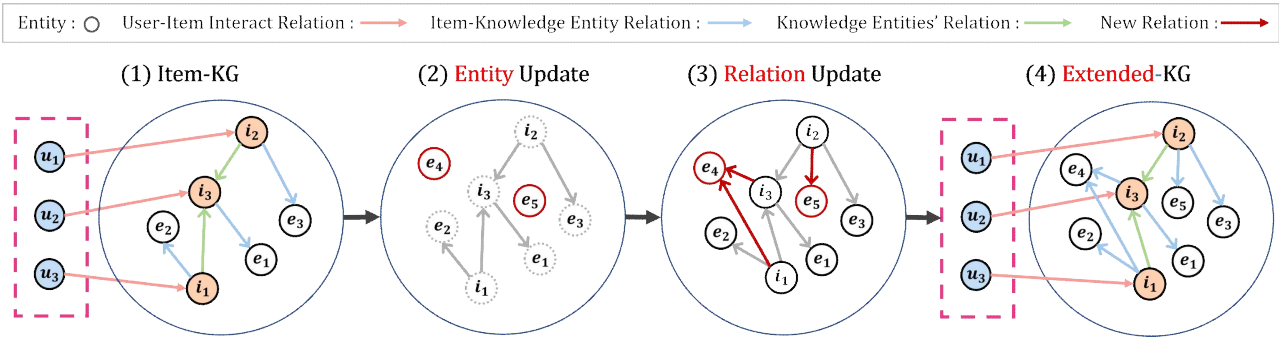


그림 3 신규 개체의 관계 모델링을 통한 지식 그래프 확장 (시나리오 2)
Fig. 3 Updated entity and relation in Knowledge Graph (Scenario 2)

따라 지식 그래프를 확장하는 사례를 제시한다.

가. 시나리오 1: 협업 필터링 기반 관계 모델링

지식 그래프에 사용자와 아이템의 피드백 정보를 추가한 기존 사례가 존재하지만[22], 이는 추가된 피드백 정보의 양이 데이터 희소성 문제를 해결하기에 충분하지 않다. 첫 번째 시나리오는 이러한 부족함을 보충하기 위해 추천 시스템 알고리즘을 기반으로 예측 평점과 아이템 간의 유사도 정보를 지식 그래프에 추가 관계로 반영한다. 그림 2와 같이 (1) 기존의 아이템 지식 그래프를 기반으로, (2) 협업 필터링을 통해 사용자와 아이템 간의 선호도와 아이템 간의 유사 관계를 유추한다. 예를 들어, 사용자 u_2 개체와 아이템 i_1 개체 사이의 예측 평점이 특정한 임계치 이상으로 유추되면 두 개체 간의 선호 관계를 추가할 수 있다. 또한, 아이템 i_3 개체와 아이템 i_5 개체 사이의 유사도가 특정한 임계치 이상으로 유추되면 두 아이템 개체 간의 유사 관계를 추가할 수 있다. (3) 이렇게 신규 관계를 추가함으로써, (4) 내부 지식 베이스의 지식 그래프를 확장할 수 있다. 시나리오 1상에서 고려할 수 있는 신규 관계와 구체적인 예시는 표 1과 같다.

표 1 시나리오 1 기반 신규 관계 정보
Table 1 New Relations in Scenario 1

Relation Type	Relation Name	Triples
Inter - entity relation	r_{Like}	(u, r_{Like}, i)
	$r_{PositivelyRatedBy}$	$(i, r_{PositivelyRatedBy}, u)$
Intra - entity relation	$r_{IsSimilarUser}$	$(u, r_{IsSimilarUser}, v)$
	$r_{IsSimilarItem}$	$(i, r_{IsSimilarItem}, j)$

- **예측 평점 기반 관계 모델링:** 사용자와 아이템 개체 사이의 관계를 추가하기 위해 사전에 정의한 이종 개체 관계인 r_{Like} 와 $r_{PositivelyRatedBy}$ 를 고려한다. 먼저, 이미 매겨진 평점에 따라 특정 사용자 u 가 아이템 i 에 특정 임계치 이상의 평점을 주었다면, 해당 관계를 지식 그래프에 추가한다. 따라서, 지식 그래프에 2개의 삼중항 (u, r_{Like}, i) 및 $(i, r_{PositivelyRatedBy}, u)$ 를 추가할 수 있다. 만약 결측 평점이라면, 협업 필터링을 통해 예측한 평점이 특정한 임계치 이상일 경우, 해당 관계 역시 지식 그래프에 추가한다. 예측 평점은 실제 평점과 비교하면 정확도가 다소 떨어지므로 예측 평점에 대한 임계치는 기존 평점에 대한 임계치보다 높게 설정해야 한다.

- **유사도 기반 관계 모델링:** 사용자와 사용자, 그리고 아이템과 아이템 사이의 관계를 추가하기 위해 사전에 정의한 동종 개체 관계인 $r_{IsSimilarUser}$ 와 $r_{IsSimilarItem}$ 을 고려한다. 만약 협업 필터링에 의해 특정한 두 사용자

u, v 의 유사도가 특정 임계치 이상으로 예상되면, $r_{IsSimilar User}$ 관계를 지식 그래프에 추가한다. 마찬가지로, 특정한 두 아이템 i, j 의 유사도가 특정 임계치 이상으로 예상되면, $r_{IsSimilar Item}$ 관계를 지식 그래프에 추가한다. 따라서, 지식 그래프에 2개의 삼중항 $(u, r_{IsSimilar User}, v)$ 및 $(i, r_{IsSimilar Item}, j)$ 를 추가할 수 있다.

나. 시나리오 2: 신규 개체의 관계 모델링

본 논문에서 제안하는 관계 모델링은 사용자 또는 아이템의 개체뿐만 아니라 지식 기반의 개체도 다룬다. 따라서, 온라인 데이터베이스(예: IMDB, DBpedia, Wikipedia)를 기반으로 지식 기반의 신규 개체와 새로운 관계를 정의할 수 있다. 시나리오 2는 그림 3과 같이 (1) 기존 지식 그래프에 (2) 신규 개체 e_4 와 e_5 가 추가된 경우에도, (3) 신규 관계 모델링으로 e_4 와 i_3 간의 관계 또는 e_5 와 i_2 간의 관계를 추가하여, (4) 지식 그래프를 확장하는 방법이다. 새로운 개체 유형이 추가되는 경우와 이미 존재하는 개체 유형 집합 내에 새로운 개체가 추가되는 경우로 나누어 시나리오를 구성할 수 있으며, 시나리오 2상에서 고려하는 신규 관계는 표 2와 같다.

표 2 시나리오 2 기반 신규 관계 정보
Table 2 New Relations in Scenario 2

Relation Type	Relation Name	Triples
Inter - entity relation	$r_{Belongs To}$	$(i, r_{Belongs To}, c)$
	$r_{IsRelated To}$	$(c, r_{IsRelated To}, i)$
Intra - entity relation	$r_{IsSimilar Category}$	$(c_1, r_{IsSimilar Category}, c_2)$

- 새로운 개체 유형의 관계 모델링: 영화 지식 베이스에 새로운 개체 유형인 카테고리 개체가 추가되었고, 이 신규 개체들과 기존 지식 그래프 상의 개체 간 관계 모델링을 한

다고 가정한다. 이 경우, 신규 개체 유형인 카테고리에 대해 다음과 같은 두 개의 관계(즉, 동종 개체 관계, 이종 개체 관계)를 생각해볼 수 있다. 먼저, 이종 개체 간 관계의 관점에서, $\epsilon_{Category}$ 와 I 사이의 두 가지 관계, 즉 $r_{Belongs To}$ 와 $r_{IsRelated To}$ 를 정의할 수 있다. 아이템의 특성 벡터를 기반으로 클러스터링하여 가장 유사한 아이템이 속한 카테고리에 따라 해당 아이템 개체와 카테고리 개체의 신규 관계를 정의한다. 다시 말해, 아이템 i 가 카테고리 $c \in \epsilon_{Category}$ 에 해당하는 경우, 지식 그래프에 2개의 삼중항 $(i, r_{Belongs To}, c)$ 와 $(c, r_{IsRelated To}, i)$ 를 추가할 수 있는 뜻이다. 두 번째, 동종 개체 간 관계의 관점에서 유사 카테고리 개체 간 관계인 $r_{IsSimilar Category}$ 를 생각해볼 수 있다. 아이템 특성 벡터의 클러스터링 결과, 두 아이템에 해당하는 두 카테고리가 서로 유사한지 아닌지를 판단할 수 있고 만약 두 카테고리 사이의 유사도가 특정한 임계치를 넘는다면, 두 카테고리 개체 사이에 관계 $r_{IsSimilar Category}$ 를 추가한다. 따라서 지식 그래프에 2개의 삼중항인 $(c_1, r_{IsSimilar Category}, c_2)$ 와 $(c_2, r_{IsSimilar Category}, c_1)$ 를 추가할 수 있다. 이러한 관계는 IMDB나 Wikipedia와 같은 온라인 데이터베이스에 정의되어 있지 않으므로 결과적으로 지식 그래프 상에 더 다양한 관계를 제공할 수 있다는 장점이 있다.

- 기존 개체 집합 내의 새로운 개체에 대한 관계 모델링: 새로운 개체 유형뿐만 아니라, 기존에 이미 존재하는 개체 유형을 가지는 신규 개체가 추가되었을 때에도 관계 모델링을 수행할 수 있다. 시간 $T-1$ 까지 존재하지 않았던 신규 개체 e_T 가 시간 T 에 추가되었다고 가정한다. 개체 e_T 의 개체 유형이 $a \in A$ 인 경우, 집합 ϵ_a 에서 $\overline{\epsilon_a} := \epsilon_a \cup \{e_T\}$ 로 업데이트할 수 있다. 그런 다음, 집합 $\overline{\epsilon_a}$ 과 함께 정의된 두 관계(즉, 동종 개체 관계, 이종

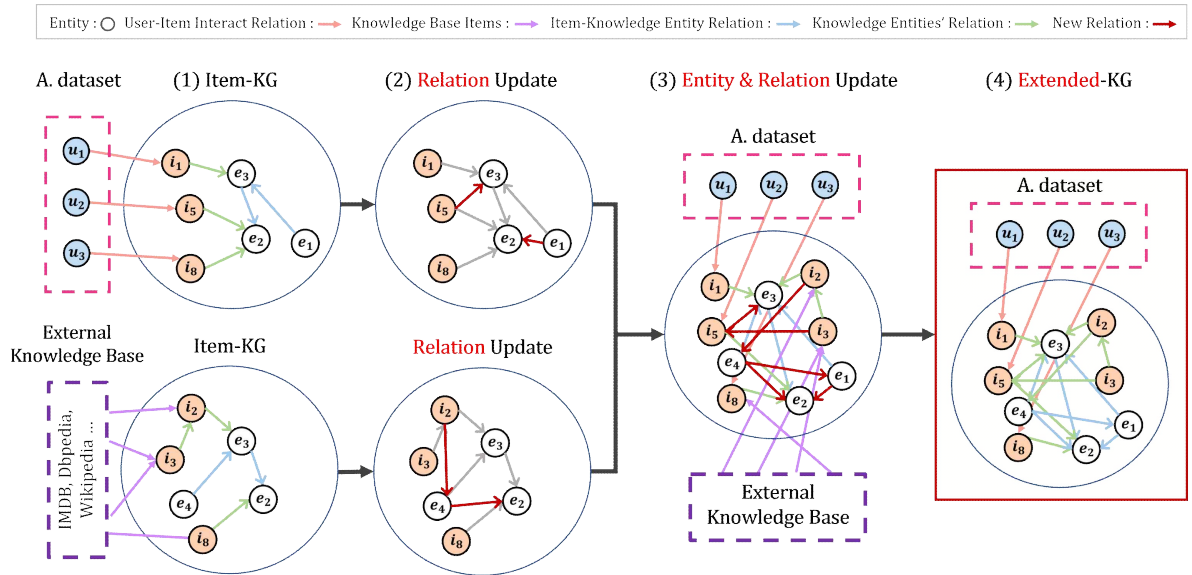


그림 4 다중 지식 베이스 기반 이종 데이터의 통합을 위한 지식 그래프 확장 (시나리오 3)

Fig. 4 Expanded Knowledge graph for Integrating Heterogeneous Data based on Multiple Knowledge bases (Scenario 3)

개체 관계)를 고려하여 개체 간의 새로운 관계를 연결한다. 다시 말해, 해당 개체는 유형이 이미 정해져 있고, 개체 유형이 해당하는 이종 개체 관계와 동종 개체 관계가 사전에 정의되어 있으므로, 구성된 관계를 기준으로 신규 개체와 다른 개체 사이의 관계를 모델링할 수 있다. 이는 본 논문이 제안하는 방식이 실시간으로 유입되는 동적 데이터를 고려하여 지식 그래프를 확장하는 것 또한 가능성을 보여준다.

다. 시나리오 3: 다중 지식 베이스 기반 지식 그래프 확장

마지막으로 여러 개의 외부 지식 베이스를 통합하여 이종 데이터 간의 상호 호환이 가능한 지식 그래프 확장 사례를 소개한다. 해당 시나리오는 그림 4에 표현되어있다. (1) A 데이터 셋과 IMDB, DBpedia, Wikipedia와 같은 외부 지식 베이스를 기반으로 구축한 두 개의 지식 그래프가 존재한다고 가정한다. 이때, (2) 두 지식 그래프를 모두 활용한 개체 간 관계 모델링을 통해 e_3 와 i_5 간의 관계 또는 e_1 와 e_2 간의 관계와 같은 신규 관계를 추가하

고 지식 그래프를 확장할 수 있다. (3) 두 지식 그래프는 앞서 소개한 두 시나리오상의 관계 모델링을 활용하여 통합된 지식 그래프를 생성한다. (4) 이를 통해 A 데이터 셋은 기존의 지식 그래프에 존재하지 않았던 새로운 개체와 신규 관계 정보를 갖는 확장된 지식 그래프를 얻을 수 있다.

이종 데이터의 통합을 위해 일반적으로 두 개 이상의 외부 데이터 집합을 고려해야 하지만 본 시나리오에서는 간단하게 하나의 데이터 셋과 해당 데이터 셋과 관련된 하나의 외부 지식 베이스만 있는 상황을 고려한다. A 데이터 셋과 외부 지식 베이스는 시나리오 1과 2의 방법을 통해 각각의 지식 그래프에 신규 관계를 추가한다. 이렇게 확장된 두 지식 그래프를 시나리오 2의 방법으로 합치면 단독 데이터 셋에서는 유도할 수 없는 새로운 개체와 신규 관계를 추가할 수 있다. 최종적으로 A 데이터 셋은 외부 지식 베이스의 이종 데이터 통합으로 다양한 보조 정보를 반영한 지식 그래프를 얻을 수 있으므로 이로 인해 아이템 특성 벡터의 품질이 개선되고 추천 정확도가 향상된다. 이처럼 개체 간 관계 모델링을 통

표 4 정량적 비교평가 결과

Table 4 Comparative experimental results

Model		Precision@2	Precision@5	Recall@2	Recall@5	NDCG@2	NDCG@5
KGCN	KGbase	0.5505	0.5746	0.6945	0.9301	0.6702	0.8855
	KGextend	0.5655	0.5736	0.7111	0.9303	0.6906	0.8840
RippleNet	KGbase	0.4090	0.4971	0.6233	0.8211	0.6406	0.8116
	KGextend	0.4135	0.4973	0.6250	0.8221	0.6450	0.8125

한 지식 그래프 확장 방식은 다중 지식 베이스 상의 이중 데이터 통합을 달성한다.

4. 선호도 추론

확장된 지식 그래프를 활용한 임베딩 기반 학습 방법은 사용자와 아이템의 특성 벡터를 더욱 풍부하게 추출할 수 있으며, 이를 통해 추천 시스템의 선호도 예측 성능을 향상시킬 수 있다. 또한, 관계 모델링을 통해 추가된 정점(개체)과 간선(관계)도 고정된 임베딩 공간에서 임베딩을 진행하므로, 확장된 지식 그래프는 KGCN, KGAT, MKGAT 등 기존 임베딩 기반 학습 방법에 모두 적용할 수 있다.

IV. 실험

본 논문에서의 실험은 Last.fm[23] 데이터를 이용하여 지식 그래프의 개체 간 신규 관계 추가가 실제 추천 정확도 향상에 얼마나 기여하는지 실험을 통해 검증하였다. 제안 방법에 따라 확장된 지식 그래프의 성능을 증명하기 위해 시나리오 1을 기반으로 실험을 수행하였고, 이를 통해 시나리오 2와 3의 실현 가능성을 확인했다.

지식 그래프의 임베딩 기반 학습 모델인 KGCN[18]과 Ripplenet[24]을 사용하여 기존 지식 그래프(KGbase)와 확장된 지식 그래프(KGextend) 사이의 성능을 비교하였다.

비교 실험을 위해 활용한 지식 그래프 기반 추천 시스템 모델에 대한 간단한 설명은 다음과 같다.

- **KGCN[18]**: 지식 그래프 상에서 관련 아이템 속성을 임베딩하고 그래프 합성곱 네트워크 기법을 활용하여 사용자의 선호도를 예측하는 방식이다.

- **Ripplenet[24]**: 추천을 위해 지식 그래프 상에서 사용자의 선호도를 전파하는 메모리 네트워크 방식이다.

실험을 위해 Pytorch3을 기반으로 위 두 알고리즘을 구현하였으며, 학습 데이터와 테스트 데이터의 비율은 80%와 20%로 설정했다. 두 알고리즘 모두 BCE(Binary cross-entropy)를 손실 함수로 사용하였으며, Adam을 옵티마이저(Optimizer)로 사용했다. KGCN의 학습률, 배치 크기, 에포크 수 및 개체 차원 크기는 각각 0.005, 32, 50 및 16으로 설정했고, Ripplenet는 각각 0.001, 32, 50 및 16으로 설정했다.

표 3 지식 그래프의 상세 정보

Table 3. Statistics of Knowledge Graph

Knowledge graph	KGbase	KGextend
#User	1,872	1,872
#Item	3,846	3,846
#Entities on Knowledge base	5,520	5,520
#Total entities	5,547	5,873
#Relation types	60	61
#User-item interactions	92,835	94,835
#Item-item similarities	0	3,000
#Item knowledge triplets	15,518	18,518

1. 데이터 집합과 지식 그래프 구성

Last.fm은 음악 청취 정보를 포함하는 온라인 음악시스템으로, 음악가는 상품으로 취급

한다. 이러한 Last.fm 데이터 셋에 대한 지식 그래프를 구성하기 위해 Microsoft Satori[18]를 활용하였다. 먼저, 전체 지식 그래프에서 신뢰 수준이 0.9보다 큰 삼중항의 하위 집합을 선택하였다. 이를 통해 신뢰성이 높은 정보에 한정하여 지식 그래프를 구성할 수 있다. 그리고 하위 지식 그래프가 주어졌을 때, 유효한 음악가의 Satori ID의 이름과 삼중항(head, type.object.name, tail) 중 술어 개체명을 일치시켜 Satori ID를 수집한다. 일치하지 않는 아이템이 있는 삼중항은 단순화를 위해 제외하였다. 마지막으로, 추출한 아이템 ID를 모든 삼중항의 주어 개체와 일치시키고, 하위 지식 그래프와 일치하는 모든 삼중항을 선택하여 최종적으로 지식 그래프를 생성하였다.

확장된 지식 그래프(KGextend)를 생성하기 위해 개체 간의 관계 모델링은 딥러닝 기반의 협업 필터링 알고리즘인 NCF(Neural Collaborative Filtering)[4]를 활용했다. 이 알고리즘은 0에서 1의 범위로 정규화한 사용자의 아이템에 대한 평점을 기반으로, 새로운 예측 평점과 아이템 간의 유사도를 예측한다. 새로운 삼중항을 생성하기 위해 예측 평점과 아이템 간 유사도에 대한 임계치를 각각 1, 0.7로 설정하였다. KGextend로부터 추출한 삼중항 데이터에는 KGbase의 삼중항 데이터 대부분이 포함된다. 이를 통해 KGbase의 정보를 보완하고 새로운 지식을 확장할 수 있다. 지식 그래프와 확장된 지식 그래프의 세부 사항은 표 3에 요약되어 있다.

2. 평가지표

추천 시스템에서 평가 지표로 널리 사용되는 Precision과 Recall 그리고 NDCG(Normalized Discounted Cumulative Gain)을 기반으로 서로 다른 지식 그래프의 모델 성능을 평가하였다[4,18,26]. Precision@K는 상위

K개의 아이템 추천 결과 중 올바른 추천 아이템의 비율을 의미하며, Recall@K는 사용자의 선호 아이템 목록에 대한 올바른 추천 아이템의 비율을 의미한다. 또한, NDCG@K는 이상적인 추천 조합 대비 실제 추천한 아이템 조합이 얼마나 좋은지를 나타내는 지표이다. 실험에서는 해당 데이터셋의 특성과 사용자 경험을 고려하여, 추천 시스템이 사용자에게 보다 적은 수의 아이템 중에서 최선의 선택을 하도록 돕기 위해 K 값을 상대적으로 작은 값인 2와 5로 설정하였다. 이를 기반으로 모든 테스트 사용자와 아이템에 대한 Precision@K, Recall@K, 그리고 NDCG@K의 평균으로 성능을 계산하였다.

3. 실험 결과

표 4는 두 개의 지식 그래프 기반 추천 알고리즘(KGCN, RippleNet)을 활용하여 기존의 KGbase와 KGextend 간의 성능 비교를 보여준다. 실험 결과, 관계 모델링에 의해 확장된 지식 그래프가 기존 지식 그래프보다 추천 시스템의 성능이 향상된 것을 확인할 수 있다. 표 4에서 볼 수 있듯이 KGCN의 경우, KGextend가 KGbase보다 Precision과 Recall, 그리고 NDCG가 각각 평균 1.27%와 1.21% 그리고 1.44%의 향상된 성능을 보여준다. RippleNet에서는 각각 0.57%, 1.21%, 0.4%의 개선을 보여준다. 이는 확장된 지식 그래프에 추가된 신뢰도 높은 보조 정보가 많아졌기 때문에 학습된 개체의 특성 벡터 품질이 향상되었고, 따라서 사용자 선호도 추론의 정확도가 향상된 것을 의미한다.

해당 실험은 시나리오 1을 기반으로 수행되었으며, 표 3에서 확인할 수 있듯이 기존의 지식 그래프에 아이템 간의 유사 관계를 표현하는 3,000개의 신규 관계를 추가하여 시나리오 1 기반의 지식 그래프(KGbase)를 확장하였다. 또한, 사용자의 아이템에 대한 평점을 예

측하여 2,000개의 선호 관계를 추가하였고 이를 학습에 활용하였다. 이처럼 간단한 지식 그래프 확장만으로도 표 4와 같은 추천 시스템 성능 향상을 이룬 것을 확인할 수 있다. 시나리오 2와 3을 기반으로 더 많은 양의 신규 개체와 관계 정보를 추가한다면 더 큰 성능 향상을 기대할 수 있다. 즉, 단일 지식 베이스 뿐만 아니라 다중 지식 베이스를 추천 시스템에 활용한다면 다양한 이종 데이터를 지식 그래프 상에 표현하고 확장할 수 있으므로 기존의 지식 그래프보다 풍부한 사용자와 아이템의 특성 벡터를 얻을 수 있고 이로 인해 추천 시스템의 정확도가 향상될 것으로 예상된다.

V. 결론 및 향후 연구

본 논문은 이종 데이터의 통합을 위해 개체 간 잠재 관계 모델링을 활용한 지식 그래프 확장 방법을 제안한다. 이 방법은 개체 유형 정보를 활용하여 지식 그래프에 개체 간의 잠재 관계를 점진적으로 추가함으로써 확장된다. 이를 통해 단일 지식 베이스 뿐만 아니라 다양한 외부 지식 베이스를 활용하여 이종 데이터의 신규 개체와 잠재 관계를 지식 그래프 상에 추가하여 부족한 지식 데이터를 보완하고 이종 데이터 통합을 달성한다. 본 논문에서는 이 방법을 구체적으로 설명하기 위해 3가지 실제 시나리오를 제시하였고, 간단한 방식의 지식 그래프 확장이 기존 지식 그래프보다 향상된 추천 성능을 제공하는 것을 확인하였다.

본 논문에서 수행한 실험은 시나리오 1을 기반으로 한 확장된 지식 그래프에 대한 추천 시스템 성능을 검증한 것이다. 따라서, 향후 시나리오 2와 3에 대한 추가적인 실험을 통해 외부 지식 베이스로부터 확장된 지식 그래프의 추천 시스템 성능을 보다 정량적으로 검증할 계획이다. 또한, 본 실험에서는 음악 데이터만 사용하였지만, 추후 영화나 여행과 같은

다양한 도메인 데이터와 관련된 실험을 진행할 예정이다. 마지막으로, 임베딩 학습 방식 뿐만 아니라 경로 기반 학습 방식의 지식 그래프 기반 추천 시스템 연구에도 적용할 수 있도록, 확장된 지식 그래프 상에서 효율적인 경로 추출 알고리즘을 추가적으로 제안할 계획이다.

REFERENCES

- [1] 김형숙, 이종혁, 이현동, "인공지능 기반 개인 맞춤형 의류 추천 서비스 개발," 스마트미디어저널 제10권, 제1호, 116-123쪽, 2021년 03월
- [2] Xiang Wang, Xiangnan He, Yixin Cao, Meng Liu and Tat-Seng Chua, "Kgat: Knowledge graph attention network for recommendation," *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining(KDD '19)*, pp. 950 - 958, New York, NY, US, 2019.
- [3] Rui Sun, Xuezhi Cao, Yan Zhao, Junchen Wan, Kun Zhou, Fuzheng Zhang, Zhongyuan Wang and Kai Zheng, "Multi-modal knowledge graphs for recommender systems," *Proceedings of the 29th ACM international conference on information & knowledge management(CIKM '20)*, pp. 1405 - 1414, New York, NY, US, 2020.
- [4] Xiangnan He, Lizi Liao, Hanwang Zhang, Liqiang Nie, Xia Hu and Tat-Seng Chua, "Neural collaborative filtering," *Proceedings of the 26th international conference on world wide web*, pp. 173 - 182, Republic and Canton of Geneva, Switzerland, 2017.
- [5] Xiting Wang, Kumpeng Liu, Dongjie Wang, Le Wu, Yanjie Fu and Xing Xie, "Multi-level recommendation reasoning over knowledge graphs with reinforcement learning," *Proceedings of the ACM Web Conference 2022*, pp. 2098 - 2108, New York, NY, US, 2022.
- [6] Sabino Metta, Paolo Casagrande, Alberto Messina, Maurizio Montagnuolo and Francesco Russo, "Leveraging MPEG-21 user description for interoperable recommender systems," *Proceedings of the 31st Annual ACM Symposium on Applied Computing*, pp. 1072 - 1074, New York, NY, US, 2016.
- [7] Mehrbakhsh Nilashi, Othman Ibrahim and Karamollah Bagherifard, "A recommender system based on collaborative filtering using ontology and dimensionality reduction

- techniques," *Expert Systems with Applications*, Vol. 92, pp. 507 - 520, Feb. 2018.
- [8] Stuart E Middleton, David C De Roure and Nigel R Shadbolt, "Capturing knowledge of user preferences: ontologies in recommender systems," *Proceedings of the 1st international conference on Knowledge capture*, pp. 100 - 107, New York, NY, US, 2001.
- [9] Xiang Wang, Dingxian Wang, Canran Xu, Xiangnan He, Yixin Cao and Tat-Seng Chua, "Explainable reasoning over knowledge graphs for recommendation," *Proceedings of the AAAI conference on artificial intelligence*, Vol. 33, pp. 5329 - 5336, Honolulu, Hawaii, USA, 2019.
- [10] A. Kim, S. Lee and K. Lee, "Ontology Construction for Interoperability and Scalability of Human-Object Interaction Datasets," *Journal of KIISE*, Vol.48, No.8, pp. 947-958, Aug. 2021.
- [11] C. Chung and J. J. Whang, "Knowledge Graph Embedding via Metagraph Learning," *Proc. of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp. 2212-2216, New York, NY, US, Jul. 2021.
- [12] S. Choi and S. Park, "A Knowledge Graph Embedding-based Ensemble Model for Link Prediction," *Journal of KIISE*, Vol.47, No.5, pp. 473-478, May 2020.
- [13] J. Roh, W. Shin, H.-K. Park and Y.-T. Park, "A Knowledge Completion Approach using Rule Generation based on Neuro-Symbolic Method," *Journal of KIISE*, Vol.48, No.4, pp. 425-433, Apr. 2021.
- [14] S. Kong, C. Chung, S. Ju and J. Whang, "Knowledge Graph Embedding with Entity Type Constraints," *Journal of KIISE*, Vol.49, No.9, pp. 773-779, Sep. 2022.
- [15] Bahram Amini, Roliana Ibrahim, Mohd Shahizan Othman and Mohammad Ali Nematbakhsh, "A reference ontology for profiling scholar's background knowledge in recommender systems," *Expert Systems with Applications*, Vol. 42, Issue 2, pp. 913 - 928, 2015.
- [16] Fabiana Freire de Araujo, Fernanda Lígia R Lopes and Bernadette Farias Lóscio, "MeMO: A clustering-based approach for merging multiple ontologies," *2010 Workshops on database and expert systems applications*, pp. 176 - 180, Bilbao, Spain, 2010.
- [17] Olawande Daramola, Mathew Adigun and Charles Ayo, "Building an ontology-based framework for tourism recommendation services," *Information and Communication Technologies in Tourism*, pp. 135 - 147, Amsterdam, Netherlands, 2009.
- [18] Hongwei Wang, Miao Zhao, Xing Xie, Wenjie Li and Minyi Guo, "Knowledge graph convolutional networks for recommender systems," *The world wide web conference*, pp. 3307 - 3313, New York, NY, US, 2019.
- [19] Weizhi Ma, Min Zhang, Yue Cao, Woojeong Jin, Chenyang Wang, Yiqun Liu, Shaoping Ma and Xiang Ren, "Jointly learning explainable rules for recommendation with knowledge graph," *The world wide web conference*, pp. 1210 - 1221, New York, NY, US, 2019.
- [20] Xiou Ge, Yun-Cheng Wang, Bin Wang and C.C. Jay Kuo, "CORE: A knowledge graph entity type prediction method via complex space regression and embedding," *Pattern Recognition Letters*, Vol. 157, pp. 97 - 103, May 2022.
- [21] R. Xie, Z. Liu and M. Sun, "Representation Learning of Knowledge Graphs with Hierarchical Types," *Proc. of the 25th International Joint Conference on Artificial Intelligence*, pp. 2965-2971, New York, NY, US, Jul. 2016.
- [22] Zhu Sun, Jie Yang, Jie Zhang, Alessandro Bozzon, Long-Kai Huang and Chi Xu, "Recurrent Knowledge Graph Embedding for Effective Recommendation," *Proceedings of the 12th ACM Conference on Recommender Systems (RecSys '18)*, pp. 297 - 305, New York, NY, USA, 2018.
- [23] Thierry Bertin-Mahieux, Daniel PW Ellis, Brian Whitman and Paul Lamere, "The million song dataset," *Proceedings of the 12th International Society for Music Information Retrieval Conference (ISMIR 2011)*, pp. 591 - 596, Miami, Florida, USA, 2011.
- [24] Wang, H., Zhang, F., Wang, J., Zhao, M., Li, W., Xie, X. and Guo, M, "Ripplet: Propagating user preferences on the knowledge graph for recommender systems," *Proceedings of the 27th ACM international conference on information and knowledge management*, pp. 417-426, New York, NY, USA, Oct. 2018.
- [25] 홍택은, 유경호, 김판구, "전력 비즈니스 플랫폼 기반의 전력 도메인 온톨로지 구축 및 추론 방법," *스마트미디어저널*, 제9권, 제2호, 51-62쪽, 2020년 06월
- [26] 이희준, 이원석, 최인혁, 이충권, "딥러닝을 이용한 시퀀스 기반의 여행경로 추천시스템-제주도 사례-," *스마트미디어저널*, 제9권, 제1호, 45-50쪽, 2020년 03월

저자 소개



이승주

2021년 인하대학교 수학과 (이학사) 졸업.
2021년~현재 인하대학교 전기컴퓨터공학과 인공지능전공 석사 과정.

<주관심분야 : 추천 시스템, 지식 그래프>



안석호

2021년 인하대학교 수학교육과 (이학사) 졸업.
2021년~현재 인하대학교 전기컴퓨터공학과 인공지능전공 석사 과정.

<주관심분야 : 시계열 분석, 사물 인터넷, 추천 시스템, 자연어 처리>



이의종

2012년 고려대학교 컴퓨터정보학과 (이학사) 졸업.
2018년 고려대학교 컴퓨터학과 (공학박사) 졸업.
2018년~2020년 세종대학교 정보보호학과 박사후연구원.

2020년~현재 충북대학교 전자정보대학 소프트웨어학부 조교수.

<주관심분야 : 소프트웨어공학, 자가-적응 소프트웨어, 데이터-기반 소프트웨어, 사물 인터넷, 소프트웨어 모델링>



서영덕

2012년 고려대학교 컴퓨터통신공학부 (공학사) 졸업.
2018년 고려대학교 컴퓨터학과 (공학박사) 졸업.
2018년 고려대학교 컴퓨터정보통신연구소 연구교수.

2018년 세종대학교 정보보호학과 박사후연구원.
2019년~2020년 세종대학교 데이터사이언스학과 조교수.
2020년~현재 인하대학교 컴퓨터공학과 조교수.

<주관심분야 : 데이터 마이닝, 추천 시스템, 사물 인터넷>