

딥러닝 기반 논문추천 연구에 관한 체계적 문헌고찰*

A Systematic Review of Deep Learning-Based Article Recommendation Research

김 성 훈 (Seonghun Kim)**

목 차

- | | |
|---|------------------------------|
| 1. 서론 | 4. 딥러닝 기반 문헌고찰 결과 기반 연구동향 분석 |
| 2. 추천 알고리즘 및 선행연구 정리 | |
| 3. 2020~2023년에 발행된 딥러닝 기반 연구논문추천 연구의 체계적 문헌고찰 | 5. 결론 및 향후연구 제언 |

초 록

인용할 연구논문을 찾는 일은 정보과부화로 인해 더욱 힘들어지고 있는 실정이며, 이에 따라 연구논문 추천에 대한 관심이 높아지고 있다. 최근 10년 간, 논문추천의 품질을 향상시키기 위해 딥러닝 방법이 활용되고 있지만 2020년 이후 딥러닝 기반 연구논문 추천에 대한 체계적 연구는 부족한 상황이다. 본 연구는 체계적 문헌고찰법을 활용해 2020년부터 2023년까지 총 47편의 딥러닝 기반의 연구논문추천 연구를 검토하고, 데이터 요인, 데이터 표현 방법, 방법론, 사용된 추천 유형, 직면 문제, 그리고 개인화여부의 관점에서 2020년 이전의 연구와 비교해 연도별로 추천기법, 사용데이터 및 딥러닝 기법, 연구핵심내용 키워드 중심으로 정리하고 이를 기반으로 시사점을 도출하였다. 또한 분석한 연구동향을 기반으로 향후 연구방향을 제언하였다.

ABSTRACT

Finding relevant research papers for citation has become increasingly challenging due to information overload, leading to growing interest in research paper recommendation systems. Over the past decade, deep learning methods have been employed to enhance the quality of paper recommendations. However, there has been a lack of systematic research on deep learning-based paper recommendation systems since 2020. This study conducts a systematic literature review of 47 deep learning-based research paper recommendation studies published between 2020 and 2023. The analysis examines data factors, data representation methods, methodologies, recommendation types, encountered challenges, and personalization aspects. Furthermore, it compares these studies with pre-2020 research by summarizing recommendation techniques, utilized datasets, deep learning methods, and key research topics by year. Based on this comparison, key insights are derived. Additionally, future research directions are suggested based on the analyzed research trends.

키워드: 연구논문 추천, 딥러닝, 체계적문헌고찰법, 추천알고리즘, 연구논문 추천서비스

Research Paper Recommendation, Deep Learning, Systematic Literature Review, Recommendation Algorithms, Research Paper Recommendation Service

* 이 논문은 2023년 대한민국 교육부와 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2023S1A5B5A16082673).

** 성균관대학교 문헌정보학과 조빙교수, (주)텐소프트웍스 인공지능검색연구소 소장 (godwmaw@skku.edu / ISNI 0000 0005 0350 7592)

논문접수일자: 2025년 1월 28일 최초심사일자: 2025년 2월 3일 게재확정일자: 2025년 2월 13일
한국문헌정보학회지, 59(1): 461-488, 2025. <http://dx.doi.org/10.4275/KSLIS.2025.59.1.461>

© Copyright 2025 Korean Society for Library and Information Science
This is an Open Access article distributed under the terms of the Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 (<https://creativecommons.org/licenses/by-nc-nd/4.0/>) which permits use, distribution and reproduction in any medium, provided that the article is properly cited, the use is non-commercial and no modifications or adaptations are made.

1. 서론

1.1 연구의 필요성과 목적

학문분야에서도 대용량 학술정보시대(the era of big scholarly data)라는 용어가 등장한 이래(Chen et al., 2019), 빅데이터, 인공지능이 사회 전반적으로 활성화되며 지식정보사회가 심화되며 정보의 과부하가 여전한 문제로 계속되고 있다. 정보문제의 해결을 위해 추천은 자연스럽게 이용자에게 다가가고 있으며, 여러 분야에서 추천시스템의 중요성이 매우 부각되고 있다. Google의 최고 제품 책임자(CPO·Chief Product Officer)인 Neal Mohan은 뉴욕타임즈와의 인터뷰에서 유튜브 시청의 70%가 추천 알고리즘에 의해 이뤄진다고 밝혔고, 넷플릭스도 수익의 75%가 추천알고리즘을 통해 발생한다고 밝힌 것과 같이 디지털 콘텐츠 시장과 그 이외에도 다양한 온라인 커머셜 분야에서 추천 시스템은 매우 활발하게 이용되고 있다. 연구 분야에 있어서도 국가서비스인 ScienceON과 RISS는 이용자 사용이력에 따라 논문을 추천하거나 분야별 최신 연구트렌드와 최신 논문을 추천하고 있으며, 사설DB업체서비스인 DBpia, KISS 등에서도 이용자가 검색한 논문에 대해 유사도기반 추천을 하거나 다른 이용자들의 이용을 기반으로 논문을 추천하고 있다. 해외에서는 대형출판사인 Elsevier 사의 Science Direct의 경우 분야별 인기논문과 이용자가 선택한 논문과 유사한 논문을 추천하는 방식으로 논문 추천 서비스를 제공하고 있다.

연구논문 추천시스템에 대한 관심에 따라 많은 연구자들이 연구논문 추천에 관한 종합적인

연구를 수행하였고(Bai et al., 2019; Moukhtar et al., 2019; Li & Zou, 2019; Ali et al., 2020; Farber & Jatowt, 2020; Medić & Snajder, 2020; Ma et al., 2020; Kreutz & Schenkel, 2022), 현재 연구논문 추천시스템과 관련된 문제점들을 제시하였다. 대표적인 문제점으로는 신규논문 또는 새로운 이용자의 정보가 불충분하여 높은 품질의 논문 추천이 어려운 콜드스타트(cold start) 문제(Ali et al., 2020; Bai et al., 2019; Kreutz & Schenkel, 2022), 이용자 관련 데이터의 부족으로 이용자에 따라 실제적인 추천구현이 어려운 유저활동정보부족(sparsity) 문제(Bai et al., 2019), 네트워크의 불충분한 정보 구조화(network analysis) 문제, 인용관계 네트워크의 문맥정보결여(network-oriented solution), 평가기법의 차이(offline evaluations, online evaluations and user studies) 문제(Ali et al., 2020; Ali et al., 2021; Farber & Jatowt, 2020), 이용자들에게 얼마만큼 예상치 못한 결과를 쥐어줄지 어려운(serendipity) 문제 등이 보고되고 있다(Bai et al., 2019; Farber & Jatowt, 2020).

이러한 연구논문 추천의 문제와 한계에 대해 최근 10년 전부터 딥러닝 기반의 해결 방안이 활발히 연구되고 있다(Färber et al., 2018; Yang et al., 2019; Ali et al., 2020). 딥러닝을 통해 연구논문의 의미표현과 문맥적 정보를 보다 효과적으로 추출하여 연구논문에 적용할 수 있음이 논의되고 있으며(Ali et al., 2020, 13-14), Content-based filtering 기법과 Collaborative Filtering 기법을 협력적으로 사용한 연구에서도 딥러닝을 활용하여 정확도가 4% 이상 증가했음을 밝히고 있고(Yan & Jie, 2018), 딥러

닝 기반의 연구논문 추천시스템이 장차 확실한 대안 중 하나가 될 것이라 말하고 있다(Li & Zou, 2019).

실제적인 연구의 사례로서 Chen et al.(2019)은 기존의 코사인 유사도 값을 기반으로 유사한 논문을 추천하는 것을 넘어서 초록(abstract)을 저차원에서 임베딩하여 유사도를 비교하고, 논문과 저자 혹은 동종 간에 의미연결, 인용, 공저자, 저자 관계의 네트워크를 딥러닝 기법을 활용해 벡터화하여 유사도를 비교하였는데, 단순 텍스트 기반 유사도를 계산하는 BM25모델은 물론, 저자와 키워드를 각각 동시에 계산하여 논문 역전과 정보를 수정한 기법인 MMRQ (Mu et al., 2018)과 비교하여도 더 좋은 결과를 낼 수 있었다. 한편, 단순한 딥러닝 모델을 사용하기보다 다양하고 심화된 딥러닝 모델을 사용하거나 딥러닝 알고리즘을 단계적으로 사용하는 시도 또한 이루어지고 있다. Bhagavatula et al.(2018)은 논문 추천의 재현율을 높이기 위한 phase 1 딥러닝 모델과 정확률을 높이기 위한 phase 2 딥러닝 모델로 나눈 계층적 모델링을 이용해 기존 모델 대비 f1-score 기준 약 2배 수준의 상승을 이끌어냈다. Zhang과 Ma(2022)는 단순한 임베딩 기법을 적용하므로 잃어버리는 정보가 많음을 지적하고 self-attention, addictive attention 등을 섹션별로 적용하여 딥러닝 기반 추천 연구를 개선시켰다.

이상의 연구들을 고려하여 볼 때, 연구논문 추천시스템 중 딥러닝 기반의 기법을 조사, 분석하여 문제해결 방안을 종합적으로 연구할 필요가 있다. Ali et al.(2020)의 연구가 2015년부터 2019년까지의 딥러닝 기법을 사용한 연구논문 추천시스템에 관한 연구를 종합하여 1) 딥

러닝 기법들의 장점과 단점, 2) 성능평가방법론, 3) 데이터셋, 4) 도전과제 등을 중심으로 분석하였는데, 더욱 활발하게 연구된 2020년부터의 딥러닝 기반 연구논문 추천시스템에 대한 연구들의 종합은 아직 이뤄지지 않았다. 국내 상황도 주제 분류와 검색어 기반으로 개인화 검색을 시도한 김광영 외(2009), 김광영, 곽승진(2011)의 연구, 딥러닝을 활용한 하이브리드 기법을 적용해 R&D정보 추천모델 연구(조우승 외, 2024), 도서관의 인공지능 서비스 현황을 조사 분석한 연구(곽우정, 노영희, 2021), 딥러닝 기반의 추천시스템에 대한 체계적 고찰(김동만, 이태욱, 2020)이 있었으나, 딥러닝 기법을 적용하여 연구논문을 추천하거나 종합한 연구는 없었다. 딥러닝 기반 연구논문 추천시스템 관련 연구를 조사, 분석하여 연구동향을 파악하고 이용자의 필요를 잘 해결하는 효과적인 방안에 대한 조사가 필요한 시점이다.

본 연구는 2020년 1월부터 2023년 12월 사이 발행된 딥러닝 기반 연구논문 추천 관련 연구를 종합적으로 분석하여 연구동향을 파악하고, 연도별로 추천기법, 사용데이터 및 딥러닝 기법, 연구핵심내용 키워드 중심으로 정리하고 이를 기반으로 시사점을 도출 목적으로 한다.

1.2 연구방법

본 연구의 목적을 달성하기 위해 사용할 연구방법은 다음과 같다.

첫째, 체계적 문헌고찰(systematic review) 방법을 통해 2020년부터 2023년까지 총 4년간의 연구를 총체적으로 찾아내었다. 체계적 문헌고찰은 특정 연구문제, 주제영역, 관심현상에

관련된 모든 이용 가능한 연구를 식별하여 해석하는 수단이며, 기존의 연구요약, 기존 연구 분석, 새로운 연구 활동을 위한 방향성 제시를 목적으로 한다(김봉제, 2018; 김동만, 이태욱, 2020). 본 연구에서는 Kitchenham(2004)이 제안한 체계적 문헌고찰 3단계 절차를 준용하면서도 1) 연구논문 추천시스템에 관련된 논문을 철저하게 검색하고, 2) 이들 중 연구논문 추천시스템을 종합적으로 비교 분석한 리뷰페이퍼를 엄선한 뒤, 3) 각 연구에 등장하는 연구논문 추천시스템이 가진 문제점을 추출하되 연구마다 상이하게 쓰이는 용어나 같은 용어임에도 의미가 다른 것을 철저히 분석하여 재정리하는 절차를 거칠 것이다. 2차적으로 최근 딥러닝 기반의 연구논문 추천시스템의 해결방안을 찾아내기 위해 2020~2023년도의 딥러닝 기반 연구논문 추천시스템 관련 연구를 다양한 키워드로 검색한 뒤, 딥러닝 관련 연구를 추출하되 아이디어 차원의 개념을 제시하거나 실험이 이뤄지지 않은 연구는 배제하여 문제해결방안, 알고리즘 동향 등을 도출했다.

둘째, Ali et al.(2020)는 2015년부터 2019년까지 게재된 35편의 딥러닝 기반의 연구논문을 검토하여 체계적 분석 후 정리하였는데, 상기 연구에서 제시한 딥러닝 기반의 연구 프레임워크를 활용하여 분석하였다. 각 딥러닝 기반 연구를 일반적으로 Collaborative Filtering(이하 CF), Content-based filtering(이하 CB), Graph-based(이하 GB)로 분류하여 정리하고, Ali et al.(2020) 연구에서 제시한 딥러닝 연구논문 알고리즘 체계에 분류작업을 통해 각 알고리즘별 수요와 새롭게 사용된 알고리즘 등을 도출하였다. 아래와 같이 재정리 및 추가하여 프레임워크를 생성

하여 2020년부터 2023년의 연구를 요약 정리하였다.

셋째, 연도별로 사용한 추천기법(CF, CB, GB)을 종합하여 분석하고, 사용데이터 및 딥러닝 기법 관점으로 다시 정리하였으며, 연구핵심내용을 키워드 중심으로 정리하고 이를 워드클라우드로 시각화 하였다. 마지막으로 종합한 내용을 기반으로 해당 기간 동안 딥러닝 기반 연구논문 추천연구에 있어서 시사점을 도출하였다.

2. 추천 알고리즘 및 선행연구 정리

2.1 추천 알고리즘 이론적 배경 및 분류

일반적으로 추천알고리즘은 CF, CB, GB 방식으로 분류한다(Zhang et al., 2021). 또 추천에 관한 많은 연구들이 추천을 CF, CB, GB 혹은 이들을 결합한 하이브리드 형태로 분류하고 있다(Wang et al., 2020; Chen et al., 2023).

먼저 CF 방법은 비슷한 행동을 하는 이용자들이 동일한 취향을 가질 수 있다는 원리에 기반한다. 주로 사용자-아이템 행렬에서 상관관계 또는 유사도를 계산하여 사용되며, 사용자 기반 필터링과 아이템기반 필터링의 두 가지 하위 유형으로 나뉜다.

이용자 기반 필터링(User-Based Collaborative Filtering): 특정 이용자가 선호하는 아이템과 유사한 아이템을 과거에 선호한 다른 이용자의 데이터를 통해 추천한다.

아이템 기반 필터링(Item-Based Collaborative Filtering): 특정 아이템과 유사한 속성을 가진 다른 아이템을 추천하는 방식으로, 아이템 간의

유사성을 분석한다.

CF는 사용자의 명시적(예: 만족도 평가점수) 또는 암묵적(예: 조회 및 이용시간 등) 상호작용 데이터를 활용하며, 데이터가 충분히 확보된 상황에서 강력한 성능을 발휘한다. 하지만 CF 모델은 이용자의 평점, 조회기록과 같은 상호작용 데이터에 의존적이므로 데이터 희소성(sparsity), 콜드스타트(cold-start) 문제에 취약하며, 이로 인해 성능이 저하되는 경우가 자주 보고되었다(Zhang et al., 2021; Mabude et al., 2022).

CB 방식은 아이템 자체의 속성과 이용자의 선호를 매칭하여 추천을 수행하는 접근법이다. 아이템은 고유의 특징들(features)의 벡터로 표현되며, 이용자는 과거에 선호한 아이템들의 특징들을 통해 프로파일이 생성된다. 고유의 특징들은 기존의 문서검색 시스템에서 해온 것처럼 문서 내 색인어들이 될 수도 있고, 관련 속성에 대한 메타데이터가 될 수도 있다. 새로운 아이템의 추천은 이용자가 선호했던 아이템과 유사한 아이템의 벡터 유사도를 기반으로 이뤄진다. CB는 사용자의 선호 데이터를 필요로 함에도 CF에 비해 콜드스타트 문제의 영향을 덜 받는다. 그러나 사용자의 관심이 맥락과 상황에 따라 다변화임에도 불구하고 그 영역이 좁게 정의될 경우, 유사한 추천결과만 반복되는 등, 다양성 부족의 문제가 발생할 수 있음이 보고되어 왔다. 즉, 이용자가 열람한 논문과 유사한 논문을 추천하는 CB 방식은 텍스트 의미 유사성만으로 다양한 사용자 관심사를 포착하는데 어려움이 있으며(Guesmi et al., 2023), 이용자가 과거에 읽은 논문을 참조하여 유사한 논문을 추천하기 때문에 매우 좁은 추천 범위로 사용자

의 폭넓은 이용을 제한할 수 있다.

GB 방식은 아이템 간의 관계를 그래프 구조로 모델링하여 추천을 수행하는 방법이다. 이 접근법은 노드와 엣지를 활용하여 아이템 간의 연결성을 표현하며, 다양한 네트워크 탐색 및 그래프 알고리즘을 적용한다. 사용자가 선호하거나 조회한 아이템의 주변 노드(이웃)를 탐색하여 관련 아이템을 추천하거나, 그래프 내 노드 간의 유사성 또는 연결 강도를 기반으로 추천 리스트를 생성하기도 한다. 논문추천시스템에서 GB 방식은 일반적으로 논문간 인용 네트워크, 이용자의 소셜 네트워크, 이중 정보 네트워크를 포함하여 그래프를 사용하여 특정 이용자가 열람한 논문 및 논문의 특성 대신 이용자와 논문을 그래프의 노드로 표현해왔다. 그러나 사용자 상호작용 데이터와 논문 콘텐츠 특성을 낭비하여, 신규 논문이 인용 수가 적어 발생하는 콜드스타트 문제, 과거 논문에 지나치게 높은 가중치가 배정된다는 문제가 있다.

딥러닝 기반의 연구논문 추천에 있어서도 앞서 정리한 CF, CB, GB 방식으로 추천기법이 분류되고 있으며, 각 방법에 따라 사용한 데이터 즉, 이용자와의 상호작용 데이터 학습, 텍스트 혹은 네트워크 임베딩 등 데이터를 학습하는데 다양한 딥러닝 기법이 사용되고 있다. 이때 활용한 딥러닝 기법들은 3장과 4장에서 구체적으로 다루었다.

2.2 연구논문 추천 선행연구 및 문제점 정리

현재까지 발표된 연구논문 추천시스템에 관해 종합적으로 분석한 연구는 9건 정도로 파악되며, 특히 Kreutz와 Schenkel(2022)의 연구

는 2019년부터 2021년 10월까지 발행된 논문들을 추천기법과 사용한 알고리즘, 데이터셋, 평가 기법을 중심으로 자세하게 분석했으며 연구논문 추천시스템의 문제점들을 기존의 문제점과 연구자가 새롭게 제기하는 문제점으로 구분하여 제시하였다. 또 Ali et al.(2020)은 딥러닝 기법을 이용해 연구논문을 추천한 36개의 연구를 종합하여 data factors, data representation methods, methodologies, types of recommendations used, problems addressed, personalization 등 6가지 준거를 중심으로 비교 하였다. 그 외 구체적인 연구 현황은 <표 1-1>에서 볼 수 있다.

<표 1-1>에서 제시한 9편의 논문에는 장기간에 걸쳐 연구논문 추천시스템 관련 연구들이

종합되어 있으며, 또한 여러 연구에서 추출한 연구논문 추천시스템의 문제점과 한계를 정리하고 있다. <표 1-2>에서 해당 내용을 별도로 정리하였다.

다음 <표 1-2>의 내용을 보다 심층적으로 살펴보면, 콜드스타트(cold start) 문제와 같이 신규논문 또는 새로운 이용자의 정보가 불충분하여 높은 품질의 논문 추천이 어려운 문제는 여러 연구에서 공통적으로 제기되었고(Ali et al., 2020; Bai et al., 2019; Kreutz & Schenkel, 2022), 평가기법에 관해서도 recall, MRR 등의 모델평가는 모델의 정확도를 높이는 데에 효과적이고, 이용자 평가는 실제 유저의 요구사항을 모델의 피드백으로 반영할 수 있다는 장점

<표 1-1> 연구논문 추천시스템에 관해 분석한 리뷰페이퍼 현황

	저자명	논문명	저널명	권	호
1	Bai et al., 2019	Scientific paper recommendation: A survey	IEEE Access	7	
2	Moukhtar et al., 2019	A Literature Survey on Recommendation Systems for Scientific Articles	Egyptian Computer Science Journal	43	2
3	Li & Zou, 2019	A Review on Personalized Academic Paper Recommendation	Computer and Information Science	12	1
4	Ali, 2020	Deep learning in citation recommendation models survey	Expert Systems with Applications	162	
5	Farber & Jatowt, 2020	Citation recommendation: approaches and datasets	International Journal on Digital Libraries	21	4
6	Medić & Snajder, 2020	A Survey of Citation Recommendation Tasks and Methods	Journal of Computing and Information Technology	28	3
7	Ma et al., 2020	A review of citation recommendation: from textual content to enriched context	Scientometrics	122	3
8	Ali et al., 2021	An overview and evaluation of citation recommendation models	Scientometrics	126	
9	Kreutz & Schenkel, 2022	Scientific Paper Recommendation Systems: a Literature Review of recent Publications	International Journal on Digital Libraries	23	

〈표 1-2〉 연구논문 추천시스템 리뷰페이퍼가 제시하는 문제점 요약

	논문저자	연구논문 추천시스템에 관해 제기한 문제사항
1	Bai et al., 2019	콜드스타트(cold start), 유저활동정보부족(sparsity), 방대한 데이터(scalability), 유저정보 수집과정상의 프라이버시(privacy), 연구범위확장을 가능케 하는 추천결과의 비중(serendipity)
2	Moukhtar et al., 2019	특별한 이슈사항을 제시하지 않음
3	Li & Zou, 2019	특별한 이슈사항을 제시하지 않음
4	Ali, 2020	콜드스타트(cold-start), 네트워크의 불충분한 정보 구조화(network analysis), 인용관계 네트워크의 문맥정보결여(network-oriented solution), 유저활동정보부족(data sparsity)
5	Farber & Jatowt, 2020	평가기법의 차이(offline evaluations, online evaluations and user studies), 학습데이터의 품질(citing biascite-worthiness of text), 상이한 시스템 유저층에 따라 달라지는 니즈(scenario specificity)
6	Medić & Snajder, 2020	특별한 이슈사항을 제시하지 않음
7	Ma et al., 2020	특별한 이슈사항을 제시하지 않음
8	Ali et al., 2021	평가기법차이(Offline versus online evaluations), 비교모델의 적정성(Suitability of baselines used), 학습데이터의 품질(Selection of appropriate ground truth), 데이터 및 모델공개(Data availability and results reproducibility)
9	Kreutz & Schenkel, 2022	유저정보 무시(Neglect of user modeling), 평가문제(Focus on Accuracy, User Evaluation), 실제시스템적용에 한계(Translating Research into Practice), 콜드스타트(cold start), 동음이의어(Synonymy), 연구진 자질(Persistence and Authority, Cooperation), 데이터 및 모델 공개(information Scarcity, Public Dataset), 유저활동정보부족(Sparsity or reduce coverage), 데이터의 규모(Scalability), 프라이버시(Privacy), 상이한 시스템 유저층에 따라 달라지는 니즈(Serendipity, Target audience, Recommendation Scenario, Fairness/Diversity), 데이터 전처리 알고리즘 공개(Unified Scholarly Data Standards), 유저의 불량한 피드백(gray sheep, black sheep, Shilling attack), 사용유저편의성(Complexity), 설명가능성(Explainability), 비교모델의 적정성(Comparability)

이 있으나 이용자평가에 필요한 자원 부족으로 실제로 구현된 연구가 없다는 지적이 있었다 (Ali et al., 2021; Farber & Jatowt, 2020; Kreutz & Schenkel, 2022). 이외에도 네트워크 그래프의 정보 미비(Ali et al., 2020), 문맥 정보의 토큰화 시 동음이의어 문제와 시스템의 현실적용 미비(Kreutz & Schenkel, 2022) 등의 이슈가 주요 논의사항으로 제시되었다. 〈표 1-2〉에서 연구논문 추천시스템 성능에 관한 이슈들을 재정리하면, 콜드스타트(cold start), 이용자활동정보부족(sparsity), 방대한 데이터

(scalability), 연구범위확장을 가능케 하는 추천결과의 비중(serendipity), 네트워크의 불충분한 정보 구조화(network analysis), 인용관계 네트워크의 문맥정보결여(network-oriented solution), 학습데이터의 품질(citing biascite-worthiness of text), 동음이의어(Synonymy), 설명가능성(Explainability), 비교모델의 적정성(Comparability) 등 총 10개의 이슈가 도출되었다. 그러나 모든 이슈들을 기반으로 연구들을 분석하기에는 사용한 데이터와 기법들이 상이하며 평가방법도 상이하기 때문에 다소 무리

가 있었다. 따라서 본 연구에서는 연구들이 보편적으로 해결을 추구하는 이슈(콜드스타트 및 이용자활동정보부족 문제)를 공통적으로 분석하되, 각 연구별로 이슈해결에 대한 기여점을 추출해서 트렌드 위주로 분석하였다.

3. 2020~2023년에 발행된 딥러닝 기반 연구논문추천 연구의 체계적 문헌고찰

3.1 체계적 문헌고찰에 의한 문헌 선별 절차

Ali et al.(2020)은 2019년까지 딥러닝 기반 연구논문 추천에 관한 연구를 조사 분석하였다. 본 연구에서는 상기연구 이후 즉, 2020년부터 2023년까지 출판된 연구논문 중 딥러닝 기법을 활용하여 연구논문 추천을 수행한 연구를 망라적으로 수집하여 분석하였다. Google Scholar를 활용하여 검색어는 “Scientific Article Recommendation”, “Scientific Paper Recommendation”, “Personalized Academic Paper Recommendation”, 및 “Citation Recommendation”으로 총 4개의 검색어를 사용하였다. 체계적 문헌고찰 방법론을 사용하여 검토하였는데, 1차적으로 제목과 메타데이터만을 가지고 검토하였다. Scientific Article Recommendation&로 검색한 결과, 총 171건이 검색되었으며 이중 42건의 논문을 선별하였다. Scientific Paper Recommendation&로 검색한 결과, 총 370건이 검색되었으며 이 중 79건의 논문을 선별하였다. &Personalized Academic Paper Recommendation&로 검색한 결과, 총 15건이 검색되었으며 이 중 12건의 논문을 선

별하였다. Citation Recommendation로 검색한 결과, 총 1,350건이 검색되었으며 이 중 585건의 논문을 선별하였다.

위와 같이 선별한 각각의 논문 데이터를 합쳐 2차 선별작업을 실시하였는데, 기준은 첫째, 중복 검색 문헌 등을 제거, 둘째, 저널에 게재된 논문만 선별(도서, 컨퍼런스 및 arxiv 게재 논문 제외), 셋째, 원고 작성언어를 영어와 한국어만으로 제한, 넷째, 추천분야가 영화, 물품, 저널 등을 제외시켜 논문 추천으로 제한, 다섯째, 추천기법 중 딥러닝을 사용한 논문만으로 제한하여 125건의 문헌을 선별하였다. 이를 바탕으로 목록을 만들고, 문헌 연구를 진행하며 각 논문을 세부적으로 검토한 결과 최종 47건의 연구논문을 최종 선별할 수 있었다(리스트는 3.2절 참조).

체계적 문헌고찰법에 의한 처리과정은 <그림 1>에서 제시하였다.

3.2 선별된 문헌 분류기준 및 결과

선별한 논문을 체계적으로 정리하고 분석하기 위해 적절한 분류 기준이 필요하다. Ali et al.(2020)은 Kefalas et al.(2015)의 연구에서 제시한 기준을 확장하여 사용하였는데, 본 연구는 Ali et al.(2020)에 제시한 기준을 기반으로 확장하여 최근 딥러닝 기법까지 반영하고자 한다. 먼저 Ali et al.(2020)가 제시하는 대분류 기준은 다음과 같다.

- 데이터 요소(Data factors/features)
- 데이터 표현 방식
(Data representation methods)

검색	1차 키워드='Scientific Article Recommendation', 'Scientific Paper Recommendation', 'Personalized Academic Paper Recommendation', 'Citation Recommendation'로 확인한 문헌 수: N=1867	←	(학위논문 제외, 기간 2020~2023년 외 제외 등)
	↓		
	2차 키워드='논문 추천 시스템'으로 확인된 문헌 수: N=718	←	제외된 문헌 수: N=1149 ('논문 추천 시스템'을 주제에 포함 여부 등)
	↓		
선별	연구자 교차 검토로 내용 선별 대상 문헌 수: N=125	←	제외된 문헌 수: N=593 (컨퍼런스 및 arxiv 제외 등)
	↓		
선정	최종 선정 문헌 수: N= 47		

〈그림 1〉 체계적 문헌고찰법에 의한 연구 문헌 선정 절차

- 텍스트 임베딩 기법 (Text Embedding Method)
- 채택된 방법론 (Methodologies and models)
- 제공되는 추천 유형 (Recommendation types)
- 해결하려는 문제(Problems faced)
- 개인화 여부 (Personalization/Non-Personalization)

본 연구에서는 대부분의 연구가 논문 내 텍스트 데이터를 활용하므로 텍스트 임베딩에 사용한 기법을 대분류로 추가하였고, Ali et al. (2020)가 제시한 대분류내에 최신 트렌드에 맞

는 항목들을 추가하였다.

먼저 데이터 요소는 딥러닝 기법을 사용할 때 어떤 데이터를 입력데이터로 활용하는지에 관한 것으로 연구의 특징의 기초가 된다. 세부 요소로는 초록, 제목과 같은 메타데이터에 해당하는 논문 내용(Papers content), 태그/키워드 (Tags/keywords), 이용자 이력과 같이 선호도 및 성향을 분석할 수 있는 이용자 프로필(User profile), 학회정보(Venue information), 논문 간 인용 및 저자간 연대를 포함하는 인용 네트워크(Citation network), 연구자 간 유대를 나타내는 소셜 네트워크(Social network), 연구자가 논문에 관한 만족도를 밝히는 평점(Ratings) 정보 등이 있다.

데이터 표현 방식은 입력받은 데이터를 어떤 형태로 구성하여 활용하였는지를 의미한다. 세부 항목으로는 행렬 기반(Matrix-based), 그래프 기반(Graph-based), 하이브리드(Hybrid)가 있다. 행렬 기반은 이용자-아이템(user-item) 행렬과 같이 이용자가 자신이 사용한 아이템을 표기하거나 혹은 평점을 매기는 방식을 의미한다. 그래프 기반은 그래프를 사용해 노드 간 유용한 관계를 탐색하는 방식으로 저자, 논문, 학회, 주제(키워드) 등이 노드가 되고 엮지로 연결을 나타낸다. 이때 그래프 형태를 기초로 저차원 임베딩을 수행하는데, 그래프의 모양이 비슷한 논문을 추천하겠다는 논리이다. 하이브리드(Hybrid)는 그래프와 행렬 또는 그 외의 방식을 혼합하여 사용하는 접근이다.

텍스트 임베딩 기법은 Ali et al.(2020)가 딥러닝 기법 내에서만 분류수행을 하고 있는데 대부분의 연구가 어떤 모양이든 텍스트를 다루고 있고 꼭 딥러닝만을 사용하지는 않기 때문에 본 연구에서 추가적으로 분류 수행한 항목이다. 전통적으로 검색을 위해 사용해 온 키워드 카운트 기반의 TF-IDF 기법은 그 단순성과 효과성으로 여전히 딥러닝 기법이 적용되는 시점에도 활용되고 있다. 그러나 키워드 카운트 기반은 의미를 담지 못하기 때문에 동음이의어나 맥락과약 등에서 한계를 지니고 있다. 이를 극복하는 기법들이 계속 발전되었는데, 단어 간의 동시출현 빈도를 기준으로 유사한 단어가 유사한 벡터를 갖도록 학습한 Word2Vec, 전체 단어 공존 행렬을 이용해 단어 벡터를 학습한 GloVe(Global Vectors for Word Representation), 단어를 n-gram으로 분해해 학습한 FastText, Word2Vec의 확장으로 문장부터 문헌까지 벡

터화 시킨 Sentence2Vec과 Doc2Vec, BERT, RoBERTa, GPT 등 사전학습된 모델(Pretrained Language Model)에서 도출되는 임베딩을 사용한 방식까지를 본 연구에서 다루었다.

방법론 및 모델은 연구논문 추천에 있어 사용된 딥러닝 기법들을 의미한다. Restricted Boltzmann Machine(RBM)(Roux & Bengio, 2008), 임베딩(embedding) 기법(Grover & Leskovec, 2016; Mikolov et al., 2013), 합성곱 신경망(CNN)(Liu et al., 2017), 순환 신경망(RNN)(Goodfellow et al., 2016) 등 텍스트와 네트워크의 임베딩 및 복잡한 맵핑을 학습하는 데 널리 쓰인다. 입·출력층(visible/hidden layer) 간 양방향(대칭적) 연결이 있는 2계층(two-layer) 확률적 그래프 모델인 RBM은 동일 계층 내 연결이 없도록 제한해 효율을 높인 초기 딥러닝 모델이다. 서로 자주 같이 인용되는 논문들을 은닉층에서 학습해 새 논문(또는 사용자가 과거에 인용했던 목록)을 입력받아 인용될 가능성이 높은 논문을 추천해 주는 방식으로 사용된다. 다층 퍼셉트론(Multi Layer Perceptron, MLP) 가장 단순한 형태의 신경망으로 알려져 있으며, 피드포워드(feed-forward) 방식이라고도 한다(Azad et al., 2021). 합성곱 신경망(Convolutional Neural Network, CNN)은 MLP와 유사하지만, 이미지나 텍스트를 특정 윈도우에 넣고 그 특성을 종합하여 추출하는 합성곱(convolution)과 풀링(pooling) 계층을 통해 연산수를 크게 줄이므로 대규모 데이터에서도 빠른 학습과 적은 메모리 사용량을 보이는 기법이다. 이미지 분류에 적용되어 유명해진 모델이지만, 텍스트와 그래프 분석에도 사용될 수 있다.

또 다른 방법론으로 순환 신경망(Recurrent Neural Network, RNN)은 입력 데이터가 시계열(sequential) 구조일 때, 과거 정보를 메모리 형태로 유지해 추론에 반영하는 방법론이다. 연구논문추천에도 인용도 시계열적인 의미가 있고, 텍스트 자체도 시계열로 이해할 수 있기 때문에 활용이 가능하다. 전통적 RNN은 시퀀스가 길 경우 장기 의존(long-term dependency) 문제를 일으키고, 역전파 과정에서 기울기 소실(vanishing gradient)이 발생하기 쉽다. 이를 해결하기 위해 셀(cell) 구조를 도입하여 어떤 정보를 선택할지 게이트(gate)로 제어한 LSTM(Long Short-Term Memory)모델이 소개되었고(Goodfellow et al., 2016), 별도의 셀 상태 대신 은닉 상태 하나로만 정보를 주고받으며, 리셋(reset) 게이트와 업데이트(update) 게이트를 사용하는 GRU모델도 소개되었다. 생성적 적대 신경망(Generative Adversarial Network, GAN)은 생성자(Generator)와 판별자(Discriminator)라는 두 개의 신경망이 서로 속이려 하고 판별하려 하는 경쟁적인 학습을 반복하는 구조를 갖는다.

딥 강화학습(Deep Reinforcement Learning, DRL)은 강화학습에 딥러닝을 접목한 방식으로, 에이전트가 매 시점(action step)에서 어떤 행동을 취하면, 환경(environment)이 보상(reward)과 다음 상태(state)를 반환하는 식으로 진행된다. 인용 추천에서는 시간에 따라 변화하는 사용자 선호도를 고려해, 추천 순위(score)를 동적으로 학습하는 방식으로 활용될 수 있다(Fu et al., 2021). 하이브리드(Hybrid)는 인용 추천 성능을 추가로 향상하고자 두 개 이상의 딥러닝 네트워크를 결합한 형태이다.

Ali et al.(2020)의 연구 외에 최근 연구논문 추천에 적용된 추가 방법론들은 다음과 같다. Attention은 입력 데이터의 각 부분에서 중요한 부분에 집중하도록 하는 메커니즘으로, 문장처럼 순서가 있는 데이터에서 자주 사용된다(Bahdanau et al., 2015). 예를 들어, 번역 시 현재 단어를 예측할 때 문장 내에서 어떤 단어가 더 중요한지 판단한다. Transformer는 Attention과 Self-Attention을 활용해 문장처럼 순서가 있는 데이터를 처리하는 강력한 딥러닝 모델로 최근 널리 알려진 GPT 모델의 근간이 되는 메커니즘이다. Self-Attention은 입력 데이터의 각 요소가 다른 요소와 얼마나 연관 있는지 스스로 비교하며 중요도를 계산하는 특징을 가지며, 문장에서 단어 간 관계를 파악해 문맥을 더 잘 이해하게 도와준다(Vaswani et al., 2017). 전통적인 순차 모델과 달리 병렬 처리가 가능해 학습 속도가 빠르며, 번역, 요약, 텍스트 생성 같은 다양한 작업에 사용되며, 입력 데이터의 중요도를 효율적으로 계산해 문맥을 더 잘 이해하는 데 장점이 있다.

추천 유형(Recommendation types)은 크게 세 가지로 구분된다. (1) 로컬 인용 추천(local citation recommendation), (2) 글로벌 인용 추천(global citation recommendations), (3) 태그/라벨 추천(tag/label recommendations)이다. 로컬 인용 추천은 논문의 특정 문맥(인용이 필요한 위치)에 대해 인용을 추천을 제공하는 방식이며, 글로벌 인용 추천은 특정 쿼리(원고) 전체에 대해 관련 논문을 추천한다.

직면하는 문제(Problems faced)는 인용 추천 모델에서 흔히 겪는 두 가지 주요 문제인 (1) 콜드스타트(cold-start), (2) 희소성(sparsity)을

의미한다. 본 연구에서는 꼭 해결이 아니더라도 이 두 문제를 관심을 가지고 해결을 노력한 것이 있다면 관련된 것으로 표기하였다.

마지막으로 개인화 유형(Personalization)은 추천 결과가 특정 사용자에게 최적화되는지 여부에 따라 모델을 구분하였다. 사용자 프로필과 과거 행동 등을 적극적으로 활용해, 각 사용자 별로 다른 추천 결과를 내는 것을 개인화 추천으로, 이외는 달리 개인적 특성을 반영하지 않은 추천기법을 비개인화 추천으로 분류하였다.

이상의 기법에 대한 기준으로 본 연구에서 다룬 딥러닝 기반 연구논문 추천 연구와 분류 결과는 다음 <표 2-1>, <표 2-2>에서 제시하였다.

4. 딥러닝 기반 문헌고찰 결과 기반 연구동향 분석

본 장에서는 3장에서 수행한 체계적 문헌고찰 결과를 토대로 딥러닝 기반 연구논문 추천의 동향을 분석하였다. 분석순서는 먼저 CF, CB, GB 등 추천기법을 중심으로 연도별 분석을 수행하고, 사용데이터와 딥러닝 기법을 중심으로 연도별 분석, 연구핵심내용을 중심으로 워드클라우드 분석, 마지막으로 모든 내용을 종합 분석하였다.

4.1 추천기법 중심 연도별 분석

본 절은 CF, CB, GB 등 추천기법을 중심으로 연도별 추이를 시각화 한 결과를 보고한다. CF 기법은 2020년도에 0건에서 2023년 4건으로 사용빈도가 대체적으로 낮으나 점차 확대되

는 상황이며, 전체적으로 CB기법이 딥러닝 기반의 방법 중에서 가장 많고, 그 뒤를 GB가 있고 있다. 이는 방법론 자체의 특징이라기보다는 가용한 데이터의 한계로 인해 나타나는 특징으로 파악된다.

4.2 사용데이터 및 딥러닝 기법 중심 연도별 분석

본 절에서는 사용한 데이터와 딥러닝 기법을 중심으로 연도별 횟수 및 추이 시각화를 수행했다. 각 연도별로 횟수를 반영하였으며, 연도별 전체연구 수 대비 기법의 비율을 그래프로 시각화 했다. 1에 가까울수록 전체 연구 대비 해당 데이터와 기법의 사용 비율이 높음을 나타낸다.

데이터 부문에서는 제목, 초록같은 텍스트가 거의 모든 연구에서 활용되고 있으며, 연구자의 검색기록, 이전 연구기록 등의 프로파일 정보의 활용빈도가 높아지고 있다. CF 기법을 활용하기 어려운 이유가 연구자의 프로파일 확보의 문제 때문인데, 데이터 확보가 보다 용이해지고 있는 상황으로 파악된다.

딥러닝 기법에 있어서는 텍스트 및 네트워크 임베딩은 모든 연구에 걸쳐 일반적으로 수행되는 것으로 파악되고, 사용되는 메커니즘은 attention과 transformer기반 사전학습된 모델의 활용이 두드러지는 것으로 관찰된다.

4.3 연구핵심내용 중심 연도별 워드클라우드 분석

본 연구에서는 연구논문의 제목과 기여사항을 정리한 텍스트를 가지고 텍스트 카운트 기

〈표 3〉 추천기법 중심 연도별 분석표

추천기법	2020년	2021년	2022년	2023년	합계	추이그래프
CF	0	1	2	4	7	
CB	7	6	15	8	36	
GB	4	6	7	10	27	

〈표 4〉 사용데이터 및 딤러닝 기법 중심 연도별 분석표

대분류	중분류	2020	2021	2022	2023	추이
Data factors/ Information used	Paper contents	7	9	16	14	
	Tags/keywords	2	5	2	8	
	User/author profile	1	4	4	5	
	Venue information	1	1	2	5	
	Citation network	3	6	8	9	
	Social network	0	0	1	3	
	Ratings	0	0	2	1	
	External Resources	0	1	0	3	
Methodologies adopted	Embeddings	4	7	10	9	
	AutoEncoder	2	3	1	3	
	RBM	0	0	0	0	
	MLP	2	2	8	10	
	GAN	0	1	0	0	
	CNN	2	1	6	3	
	RNN Family	1	1	4	5	
	DRL	0	0	0	0	
	attention	1	1	5	8	
	Transformer-based model	2	3	4	6	
	GNN	1	3	2	4	
	non-DL approach	1	3	6	1	

과약하기 위해 인용네트워크에 장단기기억모델 (BiLSTM)을 최초로 적용한 연구(Wang et al., 2020)가 시도되었고, GB 방식과 CB 방식이 하이브리드로 연결되는 모델인 Hybrid-Node2Vec (Kazemi & Abhari, 2020)이 등장하였다. 논문에 관한 네트워크에 이종의 데이터가 함께 등장하는 것을 넘어(Alkhatib & Rensing, 2020), 타이틀, 초록, 키워드, 본문, 인용 등 텍스트와 네트워크 임베딩을 결합하여 논문의 모든 정보를 활용하는 최초의 연구(Alfarhood & Cheng, 2020)가 등장하여 추천에 사용하는 특징들이 크게 확대되는 것이 2020년 연구의 특징이다.

워드클라우드를 시각화 한 결과 <그림 2-1>에서 보는 것처럼 “Memory”, “Network”, “Context”와 같은 키워드가 2020년도의 주요 트렌드로 나타났다. 이는 맥락을 이해하는 문맥인식모델과 네트워크모델 중에서도 장단기기억중심의 특징적이었음을 보여준다.

이상 정리한 바와 같이 2020년 연구의 특징은 사전학습 모델의 활용과 네트워크 분석의 다양화(장단기기억 활용, 텍스트 임베딩과 융합)라고 볼 수 있겠다.

4.4.2 2021년도 연구

2021년도에는 총 9편의 딥러닝 기반 연구논문 추천에 관한 연구가 발표되었다. GB기반의 연구가 연도 중 6편(66%)로, 총 4편(57%)이었던 2020년도와 비교해서 근소하게 확장되었다. 2020년에는 BERT와 GCN 등 사전학습 모델 및 기본 그래프 네트워크 구조의 도입이 두드러졌다면, 2021년에는 그래프 신경망(GNN)과 Transformer 기반 아키텍처의 결합이 연구의 중심이 되어 논문 네트워크 그래프를 구성하

는 방식에 대한 심도있는 연구가 두드러진다. 토픽모델과 고차인용정보를 활용한 Graph Neural Collaborative Topic Model(Xie et al., 2021), 논문 원문의 단어들을 가지고 네트워크를 구성하고 연결중심성(Degree-Centric) 설정 및 위치정보를 기억하는 방법을 제시한 GTNT 모델(Mei et al., 2021), 논문 네트워크와 LOD 지식그래프를 활용하여 정보를 풍성하게 만든 CGPRec 모델(Tang et al., 2021) 등이 특징적이었다.

또 2020년에는 기본적인 네트워크-텍스트 융합 모델이 주를 이루었다면, 2021년에는 시간적 요소와 개인화된 선호를 반영하는 모델이 강화되었다. Ma et al.(2021)은 저자의 시간 기반 선호를 반영한 Chronological Citation Recommendation 모델을 제안했고, Zhu et al.(2021)은 저자의 이전 관심사와 이력을 이중 네트워크에 반영하여 보다 정교한 추천을 수행하였다.

이 외에도 sentenceBERT를 사용한 NeuSub (Kieu et al., 2021), CF 기법은 좀처럼 등장하지 않음에도 연구자의 검색 및 조회기록을 활용하여 선호도를 분석한 CF기반의 모델 DeepCCF (Zhang et al., 2021) 등이 2021년도의 특징적인 연구였다.

워드 클라우드 분석 결과도 <그림 2-2>에서 보는 것처럼 “Network”, “Graph”, “Knowledge”, “Preference”, “Time”과 같은 키워드가 강조되므로 네트워크 및 시간 기반 연구자의 선호도가 비중있게 다뤄졌음을 시사한다.

2020년에는 논문의 기본 정보(제목, 초록 등)가 주로 사용되었다면, 2021년에는 논문 네트워크, 지식 그래프, 시간 기반 데이터가 포함된 모델이 등장한 것이 주요 특징으로 정리된다.

4.4.3 2022년도 연구

2022년도에는 총 17편의 딥러닝 기반 연구 논문 추천에 관한 연구가 발표되었고, 가장 특징적인 면은 순차적인 데이터의 흐름이 아니라 특별히 집중할 부분을 강조하는 메커니즘인 Attention이 텍스트 임베딩과 네트워크 분석에 활발하게 사용된 점이다.

CATA⁺⁺(Alfarhood & Cheng, 2020) 모델에서 Attention 메커니즘이 적용되어 논문의 유관 부분을 효과적으로 파악하고 추천하였고, CGPRec(Tang, Liu, & Qian, 2021) 모델에서도 문장 내 중요한 단어를 추출해내는데 사용되었다. 2022년에는 보다 더 활발하게 attention이 사용되었는데, 이는 다양한 데이터를 활용하는 맥락에서 보다 중요한 것에 집중하고자 하는 의도가 반영된 것으로 파악된다. DACR(Zhang & Ma, 2022) 모델은 단어 단위의 관련성(relatedness), 중요도(importance), 논문의 섹션별 목적맥락을 포착하는데 attention을 활용하였고, Yang et al.(2022) 도 attention을 이용하여 추천근거가 되는 키워드를 제공함으로써 추천의 설명력을 향상시켰다. SPR-SMN(Ali, Qi, Kefalas et al., 2022) 모델은 sciBERT를 이용해 임베딩을 수행하는 SPECTER 기법과 함께 종단 간 메모리 네트워크를 사용하는 새로운 논문 추천 모델을 제시하며, attention을 활용하여 풍부한 의미 체계와 장거리 종속성을 유지하고자 하였다.

그래프와 attention이 결합되는 연구도 있었는데, MRNE(Mei et al., 2022) 모델은 강화학습과 그래프 attention이 활용되었는데, 논문 내 텍스트와 공저자 관계, 인용관계를 심층적으로 결합하였다. 그래프 분석에 attention을, 텍스

트분석에 CNN을 사용하여 상호 강화학습을 수행한 뒤, 저자 유사성과 텍스트 유사성을 고려해서 임베딩을 한 것이 특색이다.

이 외에도 문맥을 보다 잘 이해하고 다양한 데이터를 활용해 맥락정보를 확장하고 연구자의 선호도를 분석하고자 했던 2020~2021년의 연구 위에 2022년에는 문장 혹은 섹션 단위로 임베딩하여 추천을 정밀하게 수행하고자 했다. Wang et al.(2022)은 SentCite 모델에서 문장 단위의 임베딩을 수행하여 이용자의 질의에 대해 문장 수준의 추천을 수행하였으며, Zhang과 Ma(2022)는 Dual Attention Model을 활용하여 문맥과 인용을 정교하게 연결하기 위해 논문의 섹션별로 단어를 임베딩하여 문맥 이해를 세분화했다.

〈그림 2-3〉에서 역시 attention이 매우 핵심되는 용어로 드러나고 있는 것처럼, 2022년의 연구에는 attention을 통해 다양한 데이터 중에서도 더욱 집중할 의미를 찾아내고자 했고, 섹션별, 문장단위의 추천을 하고자 하는 시도가 등장한 특징이 있다.

4.4.4 2023년도 연구

2023년도에는 총 14편의 딥러닝 기반 연구 논문 추천에 관한 연구가 발표되었다. Dinh et al.(2023)는 Ebesu와 Fang(2017), Färber et al.(2020)이 연구했던 NCN 모델을 활용하되 NCN 모델이 인용문맥과 attention 만으로 추천하던 단점을 보완하여 추가적인 텍스트 정보(논문 제목, 초록 등)를 통합하고, BERT와 self-attention 메커니즘을 활용하여 추천 품질을 향상시켰다. Chen et al.(2023)은 저자의 최근 연구관심사를 해당 연구분야 특성과 접목하

여 추천하기 위해 저자의 이전 연구이력 정보를 이용해 연구 관심사를 추출하고 지식그래프를 활용, 해당 도메인의 특성과 결합하여 추천하는 연구를 수행하였다. Ali et al.(2023)은 그래프 기반 추천에 있어 이기종 노드를 넘어 근접성(Proximity) 개념을 추가하여 연구논문 추천의 성능을 개선하였다. Xiao, Huang et al.(2023)는 기존 이종 정보 네트워크(Heterogeneous Information Network, HIN) 방식이 논문, 주제, 저자 등 서로 다른 타입의 노드가 연결된 것처럼 보이지만, 실제로는 유사성 측정을 위해 제한된 관계만 학습(closed-metapath)하던 한계를 지적하고 그 한계를 넘기 위해 open-metapath를 적용한 최초의 연구를 수행하였다. Thierry, Bao & Ali(2023)는 CB가 선호도를 반영하지 못하는 단점 개선을 위해 저자들의 이전 연구정보를 입력데이터에 추가하여 선호도를 반영한 연구논문을 추천하였다. Jiang et al.(2023)는 CB 기반의 추천모델이 연구자 관심을 제대로 파악 못하는 것에 착안하여 연구경력에 따라 선임급과 신규연구자로 구분하고 연구자 분류에 따라 장기적 연구 관심사와 단기적 연구관심사를

attention 메커니즘과 TCN(Hierarchical Temporal Convolution Networks)을 통해 측정하여 추천에 활용하였다.

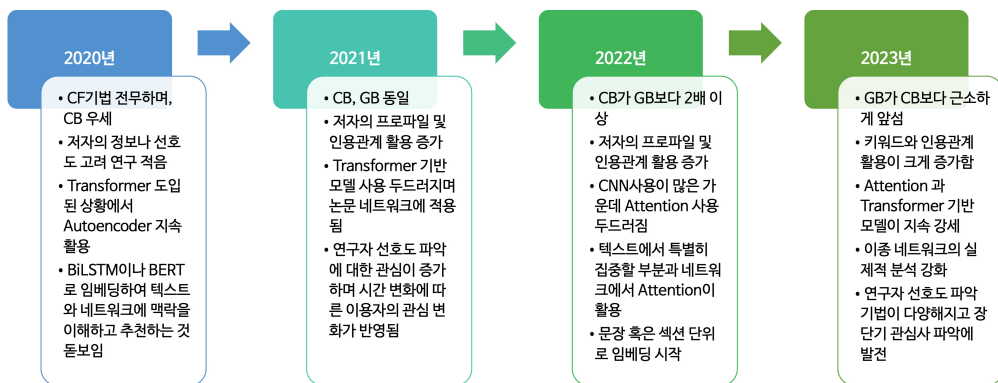
4년간의 연구논문 추천 관련 연구동향을 종합하여 도식화 하면 <그림 3>과 같다.

5. 결론 및 향후연구 제언

본 연구는 딥러닝 기반 연구논문 추천 관련 연구를 종합적으로 분석하여 연구동향을 파악하고 향후 연구방향을 제언하기 위해 체계적 문헌고찰법에 의해 2020년 1월부터 2023년 12월 사이 발행된 딥러닝 기반 연구논문 연구에 검색과 식별과정을 거쳐 정확하게 관련된 문헌을 추출하였다.

체계적 문헌고찰 결과, 2020년부터 23년까지 4개년도에서 딥러닝 기반 연구논문 추천연구는 총 47건이었으며, 연도별로는 2020년도 7건, 2021년도 9건, 2022년도 17건, 2023년도 14건으로 파악되었다.

각 문헌을 선행연구에서 보인 분류기준으로



<그림 3> 2020~2023 딥러닝 기반 연구논문 추천 연구 동향 정리

분류하고, 각각의 문헌을 심도있게 분석한 결과, 딥러닝 기법을 적용한 연구논문 추천에는 CB방식이 가장 많았고(47건 중 36건으로 77%), GB가 27건(57%), CF가 7건(15%)였다. 이는 딥러닝 기법이 발전하면서 텍스트를 처리할 수 있는 기법과 네트워크 임베딩 및 분석에 용이한 점과 동시에, 이용자 즉 연구자들과의 상호작용 데이터 확보가 쉽지않은 현실에 기인한 결과로 판단된다.

2020년 이후, 사전학습된 언어모델을 통해 임베딩하는 기법의 적용이 크게 확산되었고, 장단기기억모델을 활용해 인용의 맥락을 파악하는 등 단순한 연관성보다는 맥락적 관련성을 보다 세밀하게 접목하여 추천하도록 발전되었다. 특히 2021년에는 저자의 관심사가 시간에 따라 달라지는 점에 착안하여 변화하는 선호를 반영하고 저자의 이전 관심사와 이력을 반영한 보다 정교한 추천 연구가 수행되었다. 점차 플랫폼 텍스트와 고차인용관계 등 접용할 수 있는 모든 데이터가 적용되는 맥락에서 모든 특징들이 같은 비중을 갖는 것이 부적절할 수 있기에 2022년도에는 텍스트 및 네트워크 맥락에서 주목할 부분을 특정하여 추천하고, 문맥과 인용을 정교하게 연결하기 위해 논문의 섹션별로 단어를 임베딩하여 문맥 이해를 세분화하여 추천하고 문장단위로 추천하는 등의 세밀화 되는 과정이 관찰되었다. 2023년도에는 보다 더 세밀한 추천으로 발전되었는데, 기존의 이중 네트워크 분석이 갖는 문제를 해결하고 보다 복잡한 관계를 잘 이해하면서도 집중할 부분을 집중하는 방향과 연구자들의 연구관심사를 파악하되 선입급과 신진연구자를 구분하는 등으로 세분화 되었다.

2020년부터 2023년의 연구동향을 종합해 보

면, 딥러닝 기법을 다양하게 조합하여 맥락에 대한 이해와 임베딩의 세분화가 이뤄지고 있고, 특히 이용자의 장단기적인 선호도를 파악하기 위한 노력이 주목할 만 하였고, 이는 연구논문 추천의 세밀함의 관점에서 자연스러운 방향이라고 할 수 있다. 다만, 데이터와 분석기법이 많이 발전되고 있음에도 이용자의 상호작용 데이터는 대형출판사 데이터베이스 위주로 진행되는 현 논문서비스 상황에서는 태생적으로 수집이 어렵고, 인용-피인용 네트워크에서 피인용 네트워크는 논문 출판 후 다소 시간이 필요한 영역이라 또한 태생적인 데이터 문제가 있다. 따라서 CF, GB 방식보다는 논문의 텍스트가 비교적 쉽게 확보가 되므로 CB 기법이 더 많은 추천기법이 될 것으로 예상된다.

어떤 기법이 연구논문 추천에 가장 적합할지 가늠하기는 매우 어렵다. 본 연구에서 분석한 47편의 연구들 모두 상이한 데이터셋을 사용하여 실험하였으며, 평가방식도 상이하기에 각 연구에서 제시한 수치들로 성능을 가늠하는 것은 적절하지 못하다. 이용자 중심의 평가가 도움이 될 수 있으나, 실험 환경에서 이용자 평가한 사례가 있기는 하나 피험자가 22인 정도였고 (Guesmi et al., 2023), 실제 사용 환경에서 이용자 평가연구는 전무하였다. 이러한 선행연구들의 특성으로 인해, 본 연구에서 평가 지표에 따른 추천 메커니즘의 성능 평가나 혹은 추천 시스템의 실제 성능에 대한 비교가 미흡하여 연구 결과의 신뢰도를 높이고 실제 상황에서 활용하는 근거를 제시하기에 제한이 되는 것은 본 연구의 한계라고 판단된다. 따라서 본 연구는 연구논문 추천분야의 연구가 어떤 최신 알고리즘이 적용되어 진행되고 있는지, 최신 메

커니즘의 적용이 항상 답이라고 할 수는 없으나 알고리즘이 적용되는 지점을 관찰함으로써 추천문제에서의 이슈가 무엇인지, 추천의 미세한 조정이 어느 정도까지 이루어지고 있는지에 관한 관점에서 이해하고 활용하는 것이 적절할 것이다.

후속 연구를 통하여 추천 모델들의 실제 응용 사례가 더욱 제시되고, 실제 데이터를 기반으로 다양한 추천 기법과 딥러닝 기법을 적용하여 평가하여 사용자의 피드백 기반 성능 평가를 할 필요가 있다. 또한 이용자 중심의 평가

를 통해 연구논문 추천에 대한 이용자의 근본적인 필요점과 요구사항이 도출되며 추천 시스템을 통한 정보과부하 문제를 효과적으로 해결하는 방법에 대한 심층적 논의가 필요하다고 본다. 본 연구가 실제 연구자들에게 연구논문이 추천되는 서비스 기획에 있어 동향과 이슈를 제공하는데 활용되길 기대하며, 문헌정보학과 실제 서비스 환경에서 다양한 추천 기법이 연구되고 시스템화 되어 다양한 적용이 이뤄지며 연구자들과 이용자들의 구체적인 참여와 실험이 수행되기를 기대해 본다.

참 고 문 헌

- 곽우정, 노영희 (2021). 도서관의 인공지능(AI) 서비스 현황 및 서비스 제공 방안에 관한 연구. *한국도서관·정보학회지*, 52(1), 155-178.
- 김광영, 박승진 (2011). 주제분류 기반의 개인화 검색시스템에 관한 연구. *한국문헌정보학회지*, 45(4), 77-102.
- 김광영, 심강섭, 박승진 (2009). 분류와 사용자 질의어 정보에 기반한 개인화 검색 시스템. *한국문헌정보학회지*, 43(3), 163-180.
- 김동만, 이태욱 (2020). 딥러닝 기반 추천 시스템에 대한 체계적 문헌고찰: 국내 문헌을 중심으로. *한국컴퓨터교육학회 학술발표대회논문집*, 24(2(A)), 255-258.
- 김봉제 (2018). 체계적 문헌고찰을 통한 인성교육 연구 동향 분석: 네트워크 텍스트 분석과 다차원적도 분석 방법을 중심으로. *도덕윤리과교육*, 59(-), 185-213.
- 조우승, 이종원, 김태현, 신동구, 정희경 (2024). 비선호 패턴 분석 기법을 활용한 R&D정보 추천 모델 개선. *한국정보통신학회논문지*, 28(2), 123-129.
- Abbas, M., Ajayi, S., Bilal, M., Oyegoke, A., Pasha, M., & Ali, H. (2022). A deep learning approach for context-aware citation recommendation using rhetorical zone classification and similarity to overcome cold-start problem. *Journal of Ambient Intelligence and Humanized Computing*. <https://doi.org/10.1007/s12652-022-03899-6>
- Alfarhood, M. & Cheng, J. (2020). CATA⁺⁺: a collaborative dual attentive autoencoder method

- for recommending scientific articles. *IEEE Access*, 8, 183633-183648.
<https://doi.org/10.1109/ACCESS.2020.3029722>
- Ali, Z., Kefalas, P., Muhammad, K., Ali, B., & Imran, M. (2020). Deep learning in citation recommendation models survey. *Expert Systems with Applications*, 162, 113790.
- Ali, Z., Qi, G., Kefalas, P., Khusro, S., Khan, I., & Muhammad, K. (2022). SPR-SMN: scientific paper recommendation employing SPECTER with memory network. *Scientometrics*, 127(11), 6763-6785. <https://doi.org/10.1007/s11192-022-04425-3>
- Ali, Z., Qi, G., Muhammad, K., Bhattacharyya, S., Ullah, I., & Abro, W. (2022). Citation recommendation employing heterogeneous bibliographic network embedding. *Neural Computing and Applications*, 34(13), 10229-10242. <https://doi.org/10.1007/s00521-021-06135-y>
- Ali, Z., Ullah, I., Kefalas, P., Thierry, N., Haq, K., & Sarkar, A. (2023). Citation recommendation employing proximity-based heterogeneous network embeddings. *Intelligent Systems Conference*, 477-495. https://doi.org/10.1007/978-3-031-47721-8_32
- Ali, Z., Ullah, I., Khan, A., Ullah Jan, A., & Muhammad, K. (2021). An overview and evaluation of citation recommendation models. *Scientometrics*, 126, 4083-4119.
- Alkhatib, W. & Rensing, C. (2020). Personalized citation recommendation using an ensemble model of DSSM and bibliographic information. *Artificial Intelligence Supported Educational Technologies*, 175-192. https://doi.org/10.1007/978-3-030-41099-5_10
- Azad, S. T., Ahmadi, G., & Rezaeiapanah, A. (2021). An intelligent ensemble classification method based on multi-layer perceptron neural network and evolutionary algorithms for breast cancer diagnosis. *Journal of Experimental & Theoretical Artificial Intelligence*, 34, 949-969.
- Bahdanau, D., Cho, K., & Bengio, Y. (2015). Neural machine translation by jointly learning to align and translate. *International Conference on Learning Representations (ICLR)*.
- Bai, X., Wang, M., Lee, I., Yang, Z., Kong, X., & Xia, F. (2019). Scientific paper recommendation: a survey. *IEEE Access*, 7, 9324-9339.
- Bhagavatula, C., Feldman, S., Power, R., & Ammar, W. (2018). Content-based citation recommendation. *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, 1, 238-251.
<https://doi.org/10.18653/v1/N18-1022>
- Cai, X., Wang, N., Yang, L., & Mei, X. (2022). Global-local neighborhood based network representation for citation recommendation. *Applied Intelligence*, 52, 10098-10115.
<https://doi.org/10.1007/s10489-021-02964-5>
- Chaudhuri, A., Sarma, M., & Samanta, D. (2022). SHARE: designing multiple criteria-based

- personalized research paper recommendation system. *Information Sciences*, 617, 41-64.
<https://doi.org/10.1016/j.ins.2022.09.064>
- Chen, J., Liu, Y., Zhao, S., & Zhang, Y. (2019). Citation recommendation based on weighted heterogeneous information network containing semantic linking. *IEEE International Conference on Multimedia and Expo (ICME)*, 31-36. <https://doi.org/10.1109/ICME.2019.00014>
- Chen, W., Zhang, Y., Xian, Y., & Wen, Y. (2023). Hotspot information network and domain knowledge graph aggregation in heterogeneous network for literature recommendation. *Applied Sciences*, 13(2), 1093. <https://doi.org/10.3390/app13021093>
- Dai, T., Yan, W., Zhang, K., Qiu, C., Zhao, X., & Pan, S. (2021). Gated relational stacked denoising autoencoder with localized author embedding for global citation recommendation. *Expert Systems with Applications*, 184, 115359. <https://doi.org/10.1016/j.eswa.2021.115359>
- Dinh, T., Pham, P., Nguyen, G., & Vo, B. (2023). Enhanced context-aware citation recommendation with auxiliary textual information based on an auto-encoding mechanism. *Applied Intelligence*. <https://doi.org/10.1007/s10489-022-04423-1>
- Ebesu, T. & Fang, Y. (2017). Neural citation network for context-aware citation recommendation. *Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR'2017)*.
- Farber, M. & Jatowt, A. (2020). Citation recommendation: approaches and datasets. *International Journal on Digital Libraries*, 21(4), 375-405.
- Färber, M., Klein, T., & Sigloch, J. (2020). Neural citation recommendation: a reproducibility study. *Proceedings of the 10th International Workshop on Bibliometric-enhanced Information Retrieval (BIR 2020)*.
- Färber, M., Thiemann, A., & Jatowt, A. (2018). CITEWERTs: a system combining cite-worthiness with citation recommendation. *European Conference on Information Retrieval*, 815-819.
- Fu, M., Agrawal, A., Irissappane, A. A., Zhang, J., Huang, L., & Qu, H. (2021). Deep Reinforcement Learning Framework for Category-Based Item Recommendation. *IEEE Transactions on Cybernetics*, 52, 12028-12041.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. Cambridge: MIT Press.
- Grover, A. & Leskovec, J. (2016). Node2vec: scalable feature learning for networks. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 855-864. <https://doi.org/10.1145/2939672.2939754>
- Guesmi, M., Chatti, M., Kadhim, L., Joarder, S., & Ain, Q. (2023). Semantic interest modeling and content-based scientific publication recommendation using word embeddings and sentence

- encoders. *Multimodal Technologies and Interaction*, 7(9), 91.
<https://doi.org/10.3390/mti7090091>
- Gündoğan, E. & Kaya, M. (2022). A novel hybrid paper recommendation system using deep learning. *Scientometrics*, 127(7), 3837-3855. <https://doi.org/10.1007/s11192-022-04420-8>
- Guo, L., Cai, X., Qin, H., Hao, F., & Guo, S. (2022). A content-sensitive citation representation approach for citation recommendation. *Journal of Ambient Intelligence and Humanized Computing*. <https://doi.org/10.1007/s12652-021-03153-5>
- Jeong, C., Jang, S., Park, E., & Choi, S. (2020). A context-aware citation recommendation model with BERT and graph convolutional networks. *Scientometrics*, 124, 1907-1922.
<https://doi.org/10.48550/arXiv.1903.06464>
- Jiang, C., Ma, X., Zeng, J., Zhang, Y., Yang, T., & Deng, Q. (2023). TAPRec: time-aware paper recommendation via the modeling of researchers' dynamic preferences. *Scientometrics*.
<https://doi.org/10.1007/s11192-023-04731-4>
- Kazemi, B. & Abhari, A. (2020). Content-based Node2Vec for representation of papers in the scientific literature. *Data & Knowledge Engineering*, 127, 101794.
<https://doi.org/10.1016/j.datak.2020.101794>
- Kefalas, P., Symeonidis, P., & Manolopoulos, Y. (2015). A graph-based taxonomy of recommendation algorithms and systems in LBSNs. *Transactions on Knowledge and Data Engineering (TKDE)*, 28(3), 604-622. <https://doi.org/10.1109/TKDE.2015.2496344>
- Kieu, B. T., Unanue, I. J., Pham, S. B., Phan, H. X., & Piccardi, M. (2021). NeuSub: a neural submodular approach for citation recommendation. *IEEE Access*, 9, 148459-148468.
- Kitchenham, B. (2004). Procedure for performing systematic review. Keele University.
- Kreutz, C. K. & Schenkel, R. (2022). Scientific paper recommendation systems: a literature review of recent publications. *International Journal on Digital Libraries*, 23.
- Li, Z. & Zou, X. (2019). A review on personalized academic paper recommendation. *Comput. Inf. Sci*, 12(1), 33-43. <https://doi.org/10.5539/cis.v12n1p33>
- Lin, J., Yu, Y., Song, J., & Shi, X. (2022). Detecting and analyzing missing citations to published scientific entities. *Scientometrics*, 2395-2412. <https://doi.org/10.1007/s11192-022-04334-5>
- Liu, J., Osadchy, M., Ashton, L., Foster, M., Solomon, C. J., & Gibson, S. J. (2017). Deep convolutional neural networks for Raman spectrum recognition: a unified solution. *The Analyst*, 142(21), 4067-4074. <https://doi.org/10.1039/c7an01371j>
- Lu, Y., Yuan, M., Liu, J., & Chen, M. (2023). Research on semantic representation and citation recommendation of scientific papers with multiple semantics fusion. *Scientometrics*.

- <https://doi.org/10.1007/s11192-022-04566-5>
- Ma, S., Zhang, C., & Liu, X. (2020). A review of citation recommendation: from textual content to enriched context. *Scientometrics*, 122(3), 1445-1472.
- Ma, S., Zhang, H., Zhang, C., & Liu, X. (2021). Chronological citation recommendation with time preference. *Scientometrics*, 126, 2991-3010.
<https://doi.org/10.1007/s11192-021-03878-2>
- Mabude, C., Awoyelu, I., Akinyemi, B., & Aderounmu, G. (2022). An integrated approach to research paper and expertise recommendation in academic research. *International Journal of Advanced Computer Science and Applications*.
<https://doi.org/10.14569/ijacsa.2022.0130456>
- Medić, Z. & Šnajder, J. (2020). A survey of citation recommendation tasks and methods. *Journal of Computing and Information Technology*, 28(3), 183-205.
- Mei, X., Cai, X., Xu, S., Li, W., Pan, S., & Yang, L. (2022). Mutually reinforced network embedding: an integrated approach to research paper recommendation. *Expert Systems with Applications*, 204, 117616. <https://doi.org/10.1016/j.eswa.2022.117616>
- Mei, X., Cai, X., Yang, L., & Wang, N. (2021). Graph transformer networks based text representation. *Neurocomputing*, 463, 91-100. <https://doi.org/10.1016/j.neucom.2021.08.032>
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient estimation of word representations in vector space. *International Conference on Learning Representations*.
<https://doi.org/10.48550/arXiv.1301.3781>
- Moukhtar, B., Salah, A., & Ahmed, C. (2019). A literature survey on recommendation systems for scientific articles. *Egyptian Computer Science Journal*, 43(2).
- Mu, D., Guo, L., Cai, X., & Hao, F. (2018). Query-focused personalized citation recommendation with mutually reinforced ranking. *IEEE Access*, 6, 3107-3119.
- Nogueira, R., Jiang, Z., Cho, K. H., & Lin, J. (2020). Navigation-based candidate expansion and pretrained language models for citation recommendation. *Scientometrics*, 125, 3001-3016.
<https://doi.org/10.1007/s11192-020-03718-9>
- Pornprasit, C., Liu, X., Kiattipadungkul, P., Kertkeidkachorn, N., Kim, K., Noraset, T., Hassan, S., & Tuarob, S. (2022). Enhancing citation recommendation using citation network embedding. *Scientometrics*, 1-32. <https://doi.org/10.1007/s11192-021-04196-3>
- Qin, H., Han, X., Ma, X., & Yan, W. (2023). Personalized literature recommendation based on heterogeneous entity academic network. *Journal of King Saud University-Computer and Information Sciences*, 35(8), 101649. <https://doi.org/10.1016/j.jksuci.2023.101649>

- Roostae, M. (2022). Citation worthiness identification for fine-grained citation recommendation systems. *Iranian Journal of Science and Technology, Transactions of Electrical Engineering*, 46(2), 353-365. <https://doi.org/10.1007/s40998-021-00472-3>
- Roux, N. L. & Bengio, Y. (2008). Representational power of restricted boltzmann machines and deep belief networks. *Neural Computation*, 20, 1631-1649.
- Tang, H., Liu, B., & Qian, J. (2021). Content-based and knowledge graph-based paper recommendation: exploring user preferences with the knowledge graphs for scientific paper recommendation. *Concurrency and Computation: Practice and Experience*, 33(13), e6227. <https://doi.org/10.1002/cpe.6227>
- Tao, S., Shen, C., Zhu, L., & Dai, T. (2020). SVD-CNN: a convolutional neural network model with orthogonal constraints based on SVD for context-aware citation recommendation. *Computational Intelligence and Neuroscience*, 2020(1), 5343214. <https://doi.org/10.1155/2020/5343214>
- Thierry, N., Bao, B., & Ali, Z. (2023). RAR-SB: research article recommendation using SciBERT with BiGRU. *Scientometrics*. <https://doi.org/10.1007/s11192-023-04840-0>
- Thierry, N., Bao, B., Ali, Z., Tan, Z., Christ Chatelain, I., & Kefalas, P. (2023). PRM-KGED: paper recommender model using knowledge graph embedding and deep neural network. *Applied Intelligence*. <https://doi.org/10.1007/s10489-023-05162-7>
- Vagliano, I., Galke, L., & Scherp, A. (2022). Recommendations for item set completion: on the semantics of item co-occurrence with data sparsity, input size, and input modalities. *Information Retrieval Journal*, 25(3), 269-305. <https://doi.org/10.1007/s10791-022-09408-9>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems (NeurIPS)*, 30, 5998-6008.
- Wang, H., Cheng, J., & Yang, C. (2022). SentCite: a sentence-level citation recommender based on the salient similarity among multiple segments. *Scientometrics*, 127(5), 2521-2546. <https://doi.org/10.1007/s11192-022-04339-0>
- Wang, J., Zhou, J., Wu, Zhen., & Sun, X. (2023). MARec: a multi-attention aware paper recommendation method. *Expert Systems with Applications*, 232, 120847. <https://doi.org/10.1016/j.eswa.2023.120847>
- Wang, J., Zhu, L., Dai, T., & Wang, Y. (2020). Deep memory network with bi-lstm for personalized context-aware citation recommendation. *Neurocomputing*, 410, 103-113. <https://doi.org/10.1016/j.neucom.2020.05.047>

- Xi, L., Hu, Q., & Liu, H. (2023). Graph-embedding-inspired article recommendation model. *Expert Systems with Applications*, 214, 119100. <https://doi.org/10.1016/j.eswa.2022.119100>
- Xiao, X., Huang, J., Wang, H., Zhang, C., & Chen, X. (2023). OpenMetaRec: open-metapath heterogeneous dual attention network for paper recommendation. *Expert Systems with Applications*, 231, 120806. <https://doi.org/10.1016/j.eswa.2023.120806>
- Xiao, X., Xu, J., Huang, J., Zhang, C., & Chen, X. (2023). TCRec: a novel paper recommendation method based on ternary coauthor interaction. *Knowledge-Based Systems*, 111065. <https://doi.org/10.1016/j.knosys.2023.111065>
- Xie, Q., Zhu, Y., Huang, J., Du, P., & Nie, J. Y. (2021). Graph neural collaborative topic model for citation recommendation. *ACM Transactions on Information Systems*, 40(3), 1-30. <https://doi.org/10.1145/3473973>
- Yan, W. & Jie, T. (2018). Deep learning-based personalized paper recommendation. *Journal of Chinese Information Processing*, 32(4), 114-119.
- Yang, L., Zhang, Z., Cai, X., & Guo, L. (2019). Citation recommendation as edge prediction in heterogeneous bibliographic network: a network representation approach. *IEEE Access*, 7, 23232-23239.
- Yang, N., Jo, J., Jeon, M., Kim, W., & Kang, J. (2022). Semantic and explainable research-related recommendation system based on semi-supervised methodology using BERT and LDA models. *Expert Systems with Applications*, 190, 116209. <https://doi.org/10.1016/j.eswa.2021.116209>
- Ye, X., Liu, D., & Li, T. (2023). Multi-granularity sequential three-way recommendation based on collaborative deep learning. *International Journal of Approximate Reasoning*, 152, 434-455. <https://doi.org/10.1016/j.ijar.2022.11.011>
- Zhang, J. & Zhu, L. (2022). Citation recommendation using semantic representation of cited papers' relations and content. *Expert Systems with Applications*, 187, 115826. <https://doi.org/10.1016/j.eswa.2021.115826>
- Zhang, J., Gu, F., Ji, Y., & Guo, J. (2021). Personalized scientific and technological literature resources recommendation based on deep learning. *Journal of Intelligent & Fuzzy Systems*, 41(2), 2981-2996. <https://doi.org/10.3233/JIFS-210043>
- Zhang, Y. & Ma, Q. (2022). Dual attention model for citation recommendation with analyses on explainability of attention mechanisms and qualitative experiments. *Computational Linguistics*, 48(2), 403-470. https://doi.org/10.1162/coli_a_00438
- Zhu, Y., Lin, Q., Lu, H., Shi, K., Qiu, P., & Niu, Z. (2021). Recommending scientific paper via

heterogeneous knowledge embedding based attentive recurrent neural networks. Knowledge-Based Systems, 215, 106744. <https://doi.org/10.1016/j.knosys.2021.106744>

• 국문 참고자료의 영어 표기

(English translation / romanization of references originally written in Korean)

- Jo, Wooseung, Lee, Jongwon, Kim, Tae-Hyun, Shin, Donggu, & Jung, Hoekyung (2024). Improvement of R&D information recommendation model using non-preferred pattern analysis techniques. *Journal of the Korea Institute of Information and Communication Engineering*, 28(2), 123-129.
- Kim, Bongje (2018). Analysis of trends in character education research through a systematic review of the literature: focussing on network text analysis and multidimensional scaling. *Journal of Moral & Ethics Education*, 59(-), 185-213.
- Kim, Dong-Man & Lee, Tae-Wuk (2020). A study on systematic review of korean literatures about recommendation system based on deep-learning. *Proceedings of the The Korean Association Of Computer Education*, 24(2(A)), 255-258.
- Kim, Kwang-Young & Kwak, Seung-Jin (2011). A study on personalized search system based on subject classification. *Journal of the Korean Society for Library and Information Science*, 45(4), 77-102.
- Kim, Kwang-Young, Shim, Kang-Seop, & Kwak, Seung-Jin (2009). A personalized retrieval system based on classification and user query. *Journal of the Korean Society for Library and Information Science*, 43(3), 163-180.
- Kwak, Woojung & Noh, Younghee (2021). A study on the current state of the library's AI service and the service provision plan. *Journal of Korean Library and Information Science Society*, 52(1), 155-178.