

# 그래프 신경망을 사용한 개인맞춤형 재활 운동 추천 시스템

김수연\*, 오정현\*, 오다건\*, 서창원\*\*, 신원용<sup>o</sup>

## Personalized Exercise Recommender Systems for Rehabilitation Using Graph Neural Networks

Sooyon Kim\*, Jeong-Heon Oh\*, Dagun Oh\*, Changwon Seo\*\*, Won-Yong Shin<sup>o</sup>

### 요약

최근 재활 치료 영역에도 딥러닝, 인공지능, 빅데이터 기술 등을 적용한 스마트 재활 치료 관련 기술 개발이 활발하게 진행되고 있다. 본 논문에서는 그래프 구조를 보다 효과적으로 반영하는 그래프 신경망을 사용하여 환자 개인별 특성에 맞는 개인맞춤형 재활 운동 추천 알고리즘 기술을 제안한다. 의료법에 의해 실제 환자 데이터 사용이 불가능한 관계로 본 연구에서는 무를 질환 환자의 속성 데이터를 생성하고, 다양한 재활 프로그램을 선정하여 데이터 교차 검증을 통해 환자-운동 간의 경험 데이터셋을 생성한다. 각 사용자에게 대한 모든 아이템 예측 선호도 중 가장 높은  $N$ 개의 아이템을 추천하는 Top- $N$  추천 시스템 시나리오에서 정밀도, 재현율, nDCG를 척도로 제안 방법의 성능을 검증한다. 생성된 데이터셋 사용시 본 논문에서 제안하는 방법이 기존의 추천 알고리즘에 비해 모든 정확도 측면에서 더욱 우수함을 보인다.

**키워드** : 재활 서비스, 운동 프로그램, 그래프 신경망, 추천 시스템, 딥러닝

**Key Words** : Rehabilitation service, Exercise program, Graph neural network, Recommender system, Deep learning

### ABSTRACT

Recently, in the field of rehabilitation treatment, applications of deep learning, artificial intelligence, and big data technology to smart rehabilitation treatment have been actively studied. In this paper, we propose a personalized exercise recommender system for rehabilitation suitable for each patient's individual characteristics using a graph neural network (GNN), which captures the graph structure more effectively. Since it is impossible to use actual patient data due to the legal issue for data collection, this paper synthetically

※ 이 성과는 문화체육관광부의 스포츠산업기술개발사업에 의거 국민체육진흥공단의 국민체육진흥기금을 지원(1375027368), 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(No. 2021R1A2C3004345), 2021년도 연세대학교 연구비의 지원(2021-22-0083)을 받아 수행된 것임.

♦ First Author : Department of Applied Statistics, Yonsei University, mulan98@yonsei.ac.kr, 학생회원

<sup>o</sup> Corresponding Author : School of Mathematics of Computing (Computational Science and Engineering), Yonsei University, wy.shin@yonsei.ac.kr, 중신회원

\* Department of Applied Statistics, Yonsei University, jeongheon\_oh98@yonsei.ac.kr, yodagunzdlwlrma@yonsei.ac.kr

\*\* School of Mathematics of Computing (Computational Science and Engineering), Yonsei University, changwoni@yonsei.ac.kr, 학생회원

논문번호 : 202201-008-B-RE, Received January 10, 2022; Revised February 11, 2022; Accepted February 14, 2022

generates attribute data of knee disease patients, selects various rehabilitation programs, and generates empirical patient-exercise connectivity data using cross-validation. The performance of proposed model is evaluated in terms of precision, recall, nDCG in the top- $N$  recommendation scenario, recommending the top- $N$  items among all the predicted preferences for each user. When the generated dataset is used, it is empirically demonstrated that the proposed method outperforms the conventional recommendation algorithm in terms of all performance metrics.

## 1. 서 론

### 1.1 사전 연구

최근 기대 수명의 증가, 돌봄 인구 감소와 더불어 사고 환자의 희생률 증가함에 따라 재활 치료가 필요한 환자가 급증하고 있다. 이에 따라 디지털 헬스케어 가 새로운 보건 의료 패러다임으로 떠오른 가운데, 그동안 의사와 환자가 대면하여 치료하는 방식으로 진행되던 재활 치료 영역에도 딥러닝, 인공지능, 빅데이터 기술 등을 적용한 스마트 재활 치료 관련 기술 개발이 활발하게 진행되고 있다. 재활 치료 시스템은 기존 단순 반복 훈련 중심의 운동 치료 방식에서 벗어나 환자의 상태와 의도를 감지하여, 피드백을 제공함으로써 환자의 개인 상태에 따른 재활 치료 효율을 높이는 방식으로 진화하고 있다. 기존의 재활 치료는 전담 치료사의 경험에 매우 의존적이어서 효율성을 보장할 수 없고 대다수의 재활 프로그램에 접근성 및 대중성이 떨어지는 문제점을 갖고 있다. 따라서 효율적인 재활 치료를 통해 환자들이 빠르게 일상으로 돌아갈 수 있게 환자 개인별 특성에 맞는 재활 운동 콘텐츠 및 시설을 제공하는 것은 중요하며, 이를 위해 재활 운동 서비스 환경에 적합한 데이터 특성 분석 기반 콘텐츠 추천 알고리즘 기술 개발이 필요하다. 개인 맞춤형 재활 치료 기술은 인공지능 기술을 접목하여 환자 상태에 따른 효과적인 재활 훈련 강도 및 치료 기간을 단축할 수 있는 재활 치료 방법을 제공하는 개인맞춤형 재활 의료기기가 국내·외에서 개발되고 있으며 향후 임상 유효성 평가 등이 진행 될 것으로 기대된다.

추천 시스템에서 가장 널리 쓰이는 방법 중 하나인 협업 필터링 (Collaborative filtering; CF)은 주어진 사용자-아이템 간의 상호작용 (예: 평점, 구매 이력 등)으로부터 사용자와 아이템의 관계를 포착하고자 한다. 가장 대표적인 알고리즘 중 하나인 Matrix Factorization (MF)<sup>[1]</sup>은 사용자-아이템 상호 작용 행렬을 사용자, 아이템의 저차원 벡터의 내적으로 분해하여 분석하는 방법이다. 최근에는 사용자와 아이템의 상호작용으로 이루어진 이분 그래프 (bipartite graph)

의 구조를 탐색하는 그래프 기반의 추천 시스템 연구가 활발히 진행되고 있다. 이를 통해 1차원적인 상호작용뿐만 아니라 보다 고차원적인 관계까지 포착할 수 있다. 초기에는 랜덤워크 (Random walk) 기반의 네트워크 임베딩 (Network embedding)을 통해 그래프 구조를 반영하였다면, 보다 최근에는 메시지 전달 기법 (비선형 활성화함수, 선형 변환 등을 활용하여 이웃 노드를 표현하는 벡터 정보를 집계하여 각 노드의 임베딩 벡터를 업데이트 하는 기법)을 사용하는 그래프 신경망 (Graph neural network; GNN) 기술이 그래프 구조를 보다 효과적으로 반영하는 기술로 발전되어왔다.

GNN 기반의 추천 시스템은 최근 좋은 성능을 보이고 있으며, top- $N$  추천을 위한 GNN 모델들은 주어진 사용자-아이템 간의 상호작용을 긍정적 반응으로 간주하는 암시적 피드백 (Implicit feedback)을 사용한다. GC-MC<sup>[2]</sup>의 경우 평점 행렬 (Rating matrix)을 완성하기 위해 그래프 합성곱 연산 (Graph convolution)을 포함한 그래프 오토인코더 (Autoencoder)를 제시하였다. 한편, Pinterest에서 개발한 PinSage<sup>[3]</sup>는 GraphSage<sup>[4]</sup>와 몇 가지 aggregation 함수들을 사용하여 확장 가능한 GNN 프레임워크를 제시하였다. Spectral CF<sup>[5]</sup>는 스펙트럼 공간 (Spectral domain)에서 사용자와 아이템 간의 연결성 정보를 풍부하게 학습하기 위해 spectral convolution 연산을 도입하였다. 사용자-아이템 간의 상호작용만을 입력값으로 사용하는 최첨단 네트워크 임베딩 기반의 추천 시스템으로는 Graph Convolutional Network (GCN)<sup>[6]</sup> 기반의 NGCF<sup>[7]</sup>, LR-GCCF<sup>[8]</sup>, LightGCN<sup>[9]</sup> 등이 있다.

### 1.2 제안 연구 소개

본 연구는 GNN에 기반하여 재활 치료가 필요한 환자의 개인별 특성에 맞는 개인맞춤형 재활 운동 콘텐츠 추천 알고리즘을 제안하고자 한다.

학습 데이터 생성을 위하여 운동 재활의 대표적 부위인 무릎 질환 환자의 데이터 (사용자)와 운동 콘텐츠 (아이템) 데이터를 생성하고, 데이터 교차 검증을

통해 최종적으로 환자-운동 간의 경험 데이터셋을 생성하였다.

본 논문에서는 생성된 이분 그래프 및 특성 정보를 활용하는 그래프 신경망 기반의 추천 시스템 모델을 제안한다. 제안된 모델은 추천 정확도 측면에서 기존 대표 방법인 MF (Matrix Factorization)<sup>[11]</sup>, MLP (Multi-layer Perceptron), LightGCN<sup>[9]</sup> 기술 대비 우수함을 확인하였다.

## II. 데이터셋 생성 및 처리

### 2.1 환자 특성 데이터 생성 및 처리

#### 2.1.1 데이터 생성 개요

2021년 보건의료 데이터 활용가이드라인과 의료법에 근거하여 환자의 개인정보를 활용하는 것이 현실적으로 불가능하므로 여러 통계에 근거하여 운동 재할의 대표적 부위인 무릎 질환 환자 50명의 데이터를 생성하였다.

#### 2.1.2 환자 특성 정리

##### (1) 성별, 연령대

보건 의료 빅데이터 개방시스템의 질병 소분류(3단 상병) 통계<sup>[10]</sup>를 기반으로 표 1과 같이 생성된 50명의 환자들의 성별과 연령대를 정하였다.

표 1. 생성된 환자의 성별 및 연령대 통계  
Table 1. Statistics of gender and age groups for generated patients

Gender	10's	20's	30's
Male	0	1	2
Female	0	0	1

Gender	40's	50's	60's	over 70
Male	1	2	4	3
Female	3	9	14	11

##### (2) 키, 몸무게, BMI

환자의 키, 몸무게, BMI는 Size Korea<sup>[11]</sup>의 16-69세 한국인 남녀의 실측 익명 데이터인 ‘7차 인체 지수 데이터’를 활용하여 각 성별과 연령에 해당하는 데이터를 무작위 추출하였다. 다만, 70대 이상의 데이터는 국가통계포털 (KOSIS)의 통계자료에 기반하여 생성한 가우시안 분포를 활용하여 무작위 추출하였다.<sup>[12-15]</sup>

### (3) WOMAC (주관적 무릎 장애 지수)

WOMAC (Western Ontario and Macmaster Universities Osteoarthritis Index; 주관적 무릎 장애 지수)는 무릎관절염의 상태를 주관적으로 평가하는 도구로서 무릎관절의 기능을 수치화 하는 지표 중 가장 널리 사용되는 지표이다. WOMAC 설문지는 무릎 관절 통증과 관련한 일상생활에서 무릎관절 통증과 관련한 일상생활에서 환자가 느낄 수 있는 주관적인 기능적 제한에 대한 물음으로 구성되어 있다. 최저 0점에서 최고 96점까지의 점수로 나뉘며 총합이 높을수록 신체기능 장애가 심하다. 데이터 생성을 위해 논문<sup>[16]</sup>의 WOMAC 통계에 기반하여 생성한 가우시안 분포를 활용하여 무작위 추출하였다.

### (4) Knee ROM (무릎 관절각)

ROM(Range of Motion)이란 관절 가동 범위로서, 사지를 움직일 때 측정된 관절의 운동범위를 말하고 그 최대 각도가 각 운동 방향에 따라서 표현된다. 통상적으로 타인의 도움 없이 환자 자신의 근력에 의한 운동범위인 AROM (Active ROM)과 외력 (예: 치료사)에 의해 도달한 탄력적 운동 범위인 PROM (Passive ROM)으로 구분된다. 무릎의 경우 펴기 (extension)보다 굽히기 (flexion)가 더 큰 움직임을 가져가는 사실에 근거하고, AROM과 PROM이 양의 상관관계를 가진다고 가정하여 본 논문에서는 flexion AROM 및 PROM 데이터를 참고문헌<sup>[17,18]</sup>의 통계에 기반하여 생성한 가우시안 분포를 활용하여 무작위 추출하였다.

더불어 환자의 가동범위에 따라 가능한 운동 수준을 판단하기 위해 정상범위와의 ROM 값 차이를 기준으로 환자의 Flexion AROM을 4개 수준으로 구분하였다.

환자를 44세 이하 여성, 45세 이상 여성, 44세 이하

표 2. 연령, 성별에 따른 능동가동범위 수준 구분  
Table 2. AROM level with respect to the age and gender

	Female		Male	
	≤44	≥45	≤44	≥45
Normal AROM	140.9	136.5	136.5	131.6
ROM difference = (Patients AROM - Normal AROM)				
AROM level	0(normal)	ROM difference ≥ -3		
	1(mild)	-12 ≤ ROM difference < -3		
	2(hard)	-24 ≤ ROM difference < -12		
	3(severe)	ROM difference < -24		

남성, 45세 이상 남성의 4개 군으로 나누어 Flexion AROM의 정상범위를 CDC (Centers for disease control and prevention) 기준<sup>[19]</sup>을 참고하여 정한 뒤, 수준 0을 ‘정상’, 수준 3을 ‘심각’으로 하여 Flexion AROM의 수준을 표 2와 같이 구분하였다.

(5) MMT (도수 근력 검사)

MMT (Manual muscle test)는 정형 물리치료, 신경계 물리치료에서 사용하는 도수 근력 검사이다. 세부 분류 기준에 따른 다양한 MMT 검사들 중 MRC Scale<sup>[20]</sup>을 활용하여 환자들을 분류하였다.

또한 성별, 연령, ROM 이 근력에 영향을 주기 때문에<sup>[17,18]</sup>, 이를 반영하는 Flexion AROM 수준을 활용하여 표 3의 기준에 따라 MMT 데이터를 생성하였다.

표 3. 연령, 성별, Flexion AROM level에 따른 MMT 기준 Table 3. MMT Scale with respect to the age, gender, and flexion AROM level

Age	Flexion AROM level	MMT	
		Male	Female
30-50	0	4	4
	1	4	3
	2	3	2
	3	2	1
50-70	0	4	3
	1	3	3
	2	3	2
	3	1	1

2.1.3 처리

각 특성별로 스케일이 모두 다르기 때문에 각 특성마다 평균이 0, 분산이 1이 되도록 표준화 작업을 수행하였다.

2.2 운동 프로그램 데이터 생성 및 처리

2.2.1 운동 프로그램 생성 개요

참고문헌<sup>[21-32]</sup>에 기술된 무릎 재활 운동을 참고하여, 재활 초기 단계에서 진행되는 운동부터 재활의 마무리 단계에서 이뤄지는 운동까지 총 30개 운동을 생성된 프로그램 아이টে็ม으로 선정하였다.

2.2.2 운동 프로그램 특성 정리

(1) 자세

운동 프로그램을 크게 누운 자세, 앉은 자세, 서있는 자세, 3가지로 분류하였다. 이때 엎드린 자세는 누

운 자세에 포함된다.

(2) 목적

무릎 재활 운동의 목적으로 관절 가동 범위의 회복, 무릎 주변의 근력 강화, 무릎의 수행 능력 유지의 3가지로 분류하였다.

(3) 강도

운동 강도는 다른 특성들과 달리 프로그램에 따라 명백하게 결정되는 특성은 아니기 때문에 무릎에 가해지는 부하를 기준으로 프로그램의 강도를 설정하였다. 강도는 총 7단계로 나뉘어져 있으며 ‘1’은 가장 낮은 강도를 의미하고 반대로 ‘7’은 가장 높은 강도를 의미한다. 누운 자세의 운동은 무릎에 가해지는 부하가 상대적으로 적어 낮은 강도로 설정하였다. 체중만큼의 부하가 가해지는 맨몸운동의 경우 체중보다 적은 무게로 진행하는 기구 운동보다 더 높은 강도를 가지도록 설정하였다.

(4) 도구/기구 사용

도구/기구 사용 유무를 운동프로그램의 특성 값으로 설정하였다. 도구/기구에는 밴드, 계단, 박스, 벽 등 운동 시 부수적으로 필요한 모든 물품이 포함된다.

(5) 유형

생성된 운동은 크게 무산소, 유산소 운동으로 분류될 수 있고, 무산소 운동은 운동에 대한 부하를 기준으로 등척성, 등장성, 등속성의 세부항목으로 분류될 수 있다. 이에 따라 총 4가지(등척성, 등장성, 등속성, 유산소 운동) 유형으로 분류하였다.

(6) 움직임

무릎 부위의 근육을 이용하는 재활운동의 주 움직임은 굴곡 (Extension)과 신전 (Flexion)이다. 이에 따라 움직임을 굴곡, 신전, 굴곡과 신전 그리고 그 외 총 4가지로 분류하였다.

(7) 보조적 역할 수행 여부

같은 자세의 운동일지라도 운동을 함에 있어 자세와 기구에 따른 신체의 보조적 역할 수행에 차이가 있다. 예를 들어 월시트 (wall sit)에서는 벽이 부하를 줄여주는 보조적 역할을 수행하는 반면, 중량 스쿼트 (squat)에서 중량은 더 많은 부하를 주는 역할을 수행한다. 위와 같은 경우를 구분하기 위해, 보조적 역할의 유무를 특성 값으로 분류하였다.

2.2.3 데이터 처리

운동 자세, 운동 목적 등의 범주형 변수들은 모두 숫자형 변수로 변환하였고, 환자 데이터와 같이 각 특성별로 스케일이 다르기 때문에 각 특성마다 평균이 0, 분산이 1이 되도록 표준화 작업을 수행하였다.

2.3 환자-프로그램 간 경험데이터 생성 및 처리

재활 시 시기와 환자의 상태에 따라 요구되는 치료와 강도가 다르기 때문에 실제 환자 데이터의 특성을 반영한 추천 시스템 구축을 위하여 경험 데이터 생성 기준을 세우는 것이 중요하다. 또한, 이를 통한 연구 재현 및 후속 연구가 용이해질 것으로 기대된다. 재활 프로그램이 하나의 속성이 아닌 복합적인 요소에 의해 결정되므로 아래 4개 기준들에 따라 환자-운동 경험 데이터를 생성하였다.

분당서울대학교병원 재활의학과<sup>25)</sup>에 따르면, 재활 시 시기별로 적절한 치료가 요구되며, 초기 단계(수술 이후 3주)에는 능동적 관절운동(AROM exercise)을, 그 이후에는 닫힌 사슬 운동(Close kinetic chain exercise; CKC)과 기능 훈련이 요구된다. 이는 앞선 II장 2절 내 (1)항에서 기술된 목적에 따른 세 종류의 무릎 운동 재활 운동으로 구분 가능하다. 초기 단계에는 관절 가동 범위 회복을 위한 ‘회복’ 목적의 운동을, 그 이후에는 근력 강화를 위한 ‘증진’ 운동, 최종적으로 런지(lunge) 등에 해당하는 기능적 운동인 ‘유지’ 목적의 운동으로 구분하였다. 최종적으로 표 2의 환자 Flexion AROM level과 운동의 목적에 기반하여 표 4와 같이 관절 가동범위에 따른 경험데이터 생성 기준을 설정하였다.

대한비만학회<sup>133)</sup>에 따르면 체질량 지수가 25이상은 비만으로 판단한다. 비만 환자들에는 유산소 위주의 운동 프로그램을 수행할 것을 권장한다. 반면, 체질량 지수가 18.5보다 낮은 저체중 환자들에는 근육량을 증가시키는 무산소 위주의 운동프로그램을 수행할 것을 권장한다. 이에 기반하여 표 5와 같이 체질량 지수에 따른 경험 데이터 생성 기준을 설정하였다.

MMT 등급이 1인 환자는 근수축만 느껴지는 상태,

표 4. 관절 가동 범위에 따른 경험데이터 생성 기준  
Table 4. Edge creation criteria with respect to the ROM

Flexion AROM level	Purpose
0 (normal)	improve / maintain
1 (mild)	recover / improve / maintain
2 (hard)	recover / improve
3 (severe)	recover

표 5. 체질량 지수에 따른 경험데이터 생성 기준  
Table 5. Edge creation criteria with respect to the BMI

BMI	Type
BMI < 18.5	Mainly Non-aerobic exercise
18.5 ≤ BMI < 25	Every type of exercise
BMI ≥ 25	Mainly Aerobic exercise

즉 가장 낮은 수준의 근력을 가진 상태이고, 등급이 2인 환자는 중력을 제거한 채로만 운동이 가능한 상태이다. 또한 등급이 3 이상인 환자는 중력에 저항하여 운동이 가능한 상태이다<sup>20)</sup>. 이에 따라 표 6과 같이 MMT 등급에 따라 보조적 역할 수행 여부, 운동 자세, 그리고 강도에 따른 기준을 설정하였다.

II장 2절 내 (3)항에서 앞서 언급한 바와 같이, WOMAC 통계(평균:40.86, 표준편차:3.6)에 기반하여 WOMAC 값을 표 7과 같이 세 범위로 나누어 범위로 가능한 운동 강도를 설정하였다.

의료 데이터 확보의 어려움으로 인해, 본 논문에서는 세 명의 실험자가 앞서 기술한 기준들을 바탕으로

표 6. MMT 등급에 따른 경험데이터 생성 기준  
Table 6. Edge creation criteria with respect to the MMT

MMT Grade	Supplementary role Perform	Posture	Intensity
1	Yes	Lying	1-2
2	Yes	Lying or Sitting	1-4
3 or more	Yes or No	Every Posture	1-7

표 7. WOMAC에 따른 경험데이터 생성 기준  
Table 7. Edge creation criteria with respect to the WOMAC

WOMAC	Intensity
WOMAC < 40	1 - 7
40 ≤ WOMAC ≤ 50	1 - 5
WOMAC > 50	1 - 3

표 8. 최종 데이터  
Table 8. Summary of the generated dataset

number of patients	50
number of items (exercise)	30
number of patients' attribute	9
number of items' attribute	7
number of edges	207

50명의 환자와 30개의 운동 프로그램, 환자 간 경험 데이터를 평균적으로 각 환자가 5-6개의 경험을 갖도록 생성하였다. 일관성을 위해 세 명의 실험자가 생성한 데이터에 대해 최소 두 명이상이 공통적으로 연결한 환자-운동 데이터를 최종 데이터로 활용하였다. 최종적으로 생성된 데이터는 표 8과 같다.

### III. 개인맞춤형 운동 추천 시스템 설계

#### 3.1 시스템 및 설계 모델 개요

본 논문에서는  $d_u$ 개의 속성 값을 가지는  $M$ 명의 사용자 집합  $U$ ,  $d_v$ 개의 속성 값을 가지는  $N$ 개의 아이템 집합  $V$ , 그리고 사용자-아이템 엣지 (edge)들의 집합  $E$ 로 이루어진 이분 그래프  $G = (U, V, E)$  를 활용하여 개인맞춤형 운동 추천 시스템을 설계하고자 한다.

본 논문에서는 GNN 기술을 활용하여 주어진 환자, 운동 속성 값 데이터와 환자-운동 프로그램 간 엣지 정보를 충분히 반영한 임베딩 벡터를 획득하고, 이를 활용하여 각 환자에게 적절한 운동 프로그램을 추천하는 모델을 구축한다.

#### 3.2 제안 알고리즘

환자, 운동 프로그램 속성 데이터를 활용하여 초기 임베딩 벡터를 생성하고, 그래프 구조를 반영하기 위해 GNN 기술을 활용한다. 최종적으로, 그림 1에서와

같이 환자-운동 프로그램 경험 정보를 활용하여 최적화를 수행하고, 이를 통해 얻은 임베딩 벡터로부터 top-N 추천을 통해 각 환자에게 적절한 운동 프로그램 추천을 실시한다.

$M$ 명의 사용자와 그에 상응하는 속성 값,  $N$ 개의 아이템과 그에 상응하는 속성 값으로 이루어진 행렬을 각각  $X_u, X_v$ 라고 할 때 이를 활용하여 임베딩 벡터를 생성한다. 사용자, 아이템의 임베딩 벡터를 같은 실수 공간  $\mathbb{R}^d$ 에서 생성하기 위해, 훈련 가능한 선형 변환 행렬 (trainable weight transformation matrix)  $W_u \in \mathbb{R}^{d_u \times d}, W_v \in \mathbb{R}^{d_v \times d}$  을 생성하여, 사용자, 아이템의 임베딩 벡터  $E^{0_u} = X_u W_u, E^{0_v} = X_v W_v$ 를 얻고, 이를 초기 임베딩 벡터  $E^0 = \begin{bmatrix} E^{0_u} \\ E^{0_v} \end{bmatrix} \in \mathbb{R}^{(M+N) \times d}$  로 활용한다. 기존의 LightGCN<sup>[9]</sup> 방법은 초기 임베딩 벡터를 무작위 생성한 반면, 본 논문에서는 사용자, 아이템 속성 값을 바탕으로 임베딩 벡터를 생성하여 기존 모델에서는 사용되지 않은 속성 정보를 반영하였다.

최근 GNN을 이용한 추천 시스템 중 하나인 LightGCN<sup>[9]</sup> 기술이 추천 정확도 측면에서 좋은 성능을 보임에 따라, 본 연구에서 이를 적용하고자 한다. 주어진 이분 그래프  $G = (U, V, E)$  에서 한 노드  $x \in U \cup V$  의 이웃 노드 집합을  $N_x$ 라고 하고,  $l$ 번째 layer에서의 임베딩 벡터를  $e_x^l \in \mathbb{R}^d$  라고 할 때,

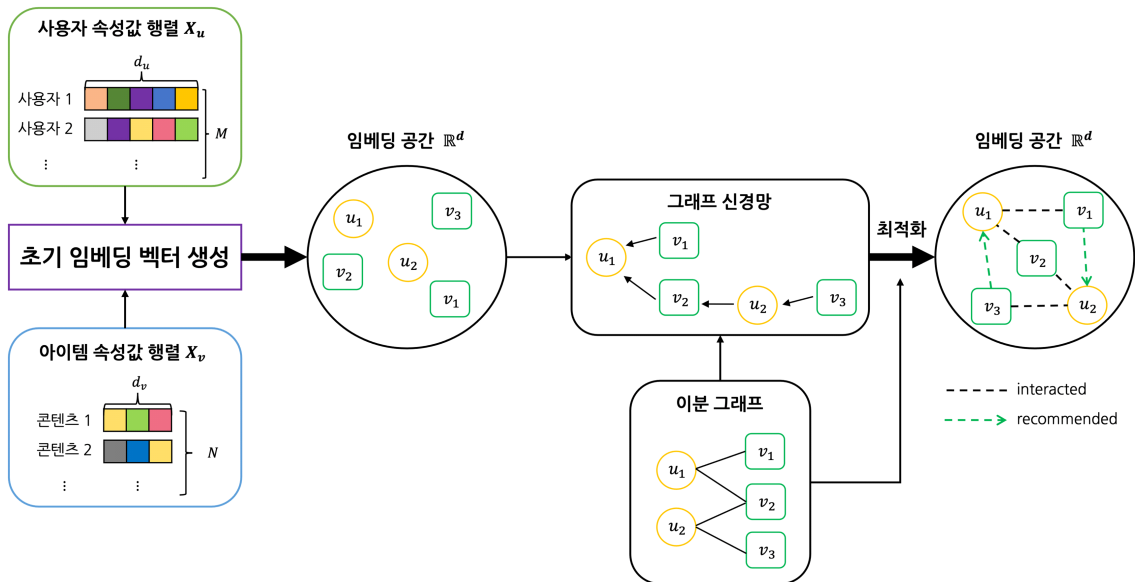


그림 1. 제안하는 추천 시스템 개요  
Fig. 1. A schematic overview of the proposed recommender system

LightGCN<sup>[9]</sup> 기술에서  $l$  번째 layer에서의 임베딩 벡터는 다음과 같이 업데이트된다.

$$e_x^{l+1} = \sum_{y \in N_x} \frac{1}{\sqrt{|N_x|} \sqrt{|N_y|}} e_y^l \quad (1)$$

또한 GNN의 layer 수가 증가함에 따라 생기는 오버 스무딩 (over-smoothing; 정점의 임베딩 벡터가 서로 유사해지는 현상) 문제를 예방하기 위해, 노드  $x$ 의 최종 임베딩 벡터  $e_x$ 를 각 layer의 임베딩 벡터의 averaged sum을 활용하여 모든 layer의 임베딩 벡터를 총 layer 수  $L$ 과 함께  $x$ 의 최종 임베딩 벡터  $e_x$ 를 다음과 같이 획득하였다.

$$e_x = \frac{1}{L+1} \sum_{l=0}^L e_x^l \quad (2)$$

사용자  $u \in U$ , 아이템  $v \in V$ 의 임베딩 벡터  $e_u, e_v$ 를 활용한 예측 선호도  $\hat{r}_{uv}$ 를 다음과 같이 정의한다.

$$\hat{r}_{uv} := e_u^T e_v \quad (3)$$

최적화를 위해 추천 시스템에서 널리 쓰이는 Bayesian Personalized Ranking (BPR)<sup>[34]</sup> 목적 함수를 활용하며, 이는 다음과 같다.

$$L_{BPR} = - \sum_{u \in U} \sum_{i \in N_u} \sum_{j \notin N_u} \ln \sigma(\hat{r}_{ui} - \hat{r}_{uj}) + \lambda \|E\|^2 \quad (4)$$

이 때  $\lambda$ 는  $L_2$  정규화를 위한 하이퍼파라미터이고,  $E$ 는 최종 임베딩 벡터의 집합 (즉,

$$E = \begin{bmatrix} e_{u_1} \\ \dots \\ e_{v_N} \end{bmatrix} \in \mathbb{R}^{(M+N) \times d} ) \text{이다.}$$

목적 함수를 이용하여 학습된 임베딩 벡터를 활용하여, 각 사용자 노드마다 이전에 경험했던 아이템을 제외한 모든 아이템에 대해 예측 선호도를 획득하고, 높은 순으로  $N$ 개의 아이템을 해당 사용자에게 추천한다. 즉, 사용자 노드  $u \in U$ 에 대하여 경험하지 않은 모든 아이템  $i_k \in V$ ,  $k = \{1, \dots, M\} \setminus N_u$  과의 예측 선호도  $\hat{r}_{ui_k}$ 를 획득하고, 이 중 예측 선호도가 가장 높은  $N$ 개의 아이템을 해당 사용자에게 추천한다.

## IV. 실험 및 성능 검증

### 4.1 실험 환경

본 논문에서 제안한 추천 알고리즘의 성능을 검증하기 위해, II장에서 생성된 데이터셋을 활용한다. 해당 데이터셋은 9개의 속성 값을 가진 50명의 환자, 7개의 속성 값을 가진 30개의 운동. 그리고 207개의 환자-운동 엣지로 이루어진 이분 그래프이다. 성능 검증을 위해 207개의 환자-운동 엣지 집합을 무작위로 167/40, 127/80개의 엣지 집합으로 나누고 이를 학습/평가 데이터셋으로 나누어 활용한다.

### 4.2 비교 알고리즘 설명

#### 4.2.1 Matrix Factorization (MF)<sup>[11]</sup>

MF<sup>[11]</sup> 기술은 사용자 및 아이템 노드의 속성값을 활용하지 않고 무작위로 임베딩 벡터를 생성한 후, 엣지 정보를 활용하여 최적화하는 방법이다. 즉, 무작위로 사용자 노드  $u \in U$ 에 대해 임베딩 벡터  $e_u \in \mathbb{R}^d$ 를 생성하고, 아이템 노드  $v \in V$ 에 대해 임베딩 벡터  $e_v \in \mathbb{R}^d$ 를 생성하여 임베딩 벡터

$$E = \begin{bmatrix} e_{u_1} \\ \dots \\ e_{v_N} \end{bmatrix} \in \mathbb{R}^{(M+N) \times d} \text{를 구성하는 것이다. 또한 본}$$

논문에서 제안한 알고리즘과 동일하게 예측 선호도  $\hat{r}_{uv}$ 를 사용자  $u \in U$ , 아이템  $v \in V$ 의 임베딩 벡터  $e_u, e_v$ 를 내적하여 (3)과 같이 정의한다. 이를 활용한 BPR 목적 함수<sup>[34]</sup>를 (4)와 같이 활용하여 최적화를 수행한다.

#### 4.2.2 Multi-layer perceptron (MLP)

MLP 기술은 앞서 소개한 사용자 및 아이템의 속성 행렬  $X_u, X_v$ 을 활용하여, 비선형 및 선형 변환을 반복적으로 수행하여 임베딩 벡터를 얻는 방법이다. 본 논문에서 비선형 활성화 함수로 tanh 함수를 사용하였다.  $X_u^0 = X_u, X_v^0 = X_v$ 라 하고,  $W_u^{l-1}, W_v^{l-1}$ 를 훈련 가능한 선형 변환 행렬,  $b_u^{l-1}, b_v^{l-1}$ 를 bias 벡터라 할 때,  $l$ 번째 레이어의 사용자, 아이템의 임베딩 벡터  $X_u^l, X_v^l$ 은 다음과 같다.

$$X_u^l = \tanh(X_u^{l-1} W_u^{l-1} + b_u^{l-1}) \in \mathbb{R}^{M \times d} \quad (5)$$

$$X_v^l = \tanh(X_v^{l-1} W_v^{l-1} + b_v^{l-1}) \in \mathbb{R}^{N \times d} \quad (6)$$

층 레이어 수가  $L$ 일 때, 사용자, 아이템의 최종 임베딩 벡터  $E$ 는 다음과 같이 초기화된다.

$$E^0 = \begin{bmatrix} e_{u_1} \\ \dots \\ e_{v_N} \end{bmatrix} = \begin{bmatrix} X^{L_u} \\ X^{L_v} \end{bmatrix} \in \mathbb{R}^{(M+N) \times d} \quad (7)$$

MF<sup>[1]</sup> 기술과 동일하게 (3)을 활용한 BPR 목적 함수<sup>[35]</sup>를 (4)와 같이 활용하여 최적화를 수행한다.

#### 4.2.3 LightGCN<sup>[9]</sup>

LightGCN<sup>[9]</sup> 모델은 사용자, 아이템 노드의 속성 값이 없는 경우에 제안된 GNN 기반 알고리즘으로, MF<sup>[1]</sup> 모델과 동일하게 사용자  $u \in U$ , 아이템  $v \in V$ 에 대하여 초기 임베딩 벡터  $e^0_u \in \mathbb{R}^d$ ,  $e^0_v \in \mathbb{R}^d$ 를 무작위로 생성하여 모든 사용자, 아이템 노드에 관한 임

베딩 벡터  $E^0 = \begin{bmatrix} e^0_{u_1} \\ \dots \\ e^0_{v_N} \end{bmatrix} \in \mathbb{R}^{(M+N) \times d}$ 를 생성한다. 이후

$l$ 번째 layer의 임베딩 벡터는 (1)에서와 같이 업데이트되고, MF<sup>[1]</sup> 기술과 동일하게 (3)을 활용한 BPR 목적 함수<sup>[35]</sup>를 (4)와 같이 활용하여 최적화를 수행한다.

#### 4.3 성능 척도

본 논문에서 제안하는 방법의 성능은 Top- $N$  추천 시스템에서 사용하는 정밀도, 재현율, normalized discounted cumulative gain (nDCG)<sup>[35]</sup>를 성능척도로 검증하였다.  $Te_u$ 를 평가 데이터셋에서 사용자  $u$ 와 연결되어 있는 아이템 집합,  $R_u(N)$ 을 사용자  $u$ 에게 추천된  $N$ 개의 아이템 집합이라고 할 때, 추천된  $N$ 개의 아이템에 대한 정밀도  $P@N$ , 재현율  $R@N$ 은 다음과 같이 정의된다.

$$P@N = \frac{1}{M} \sum_{u \in U} \frac{|Te_u \cap R_u(N)|}{N} \quad (8)$$

$$R@N = \frac{1}{M} \sum_{u \in U} \frac{|Te_u \cap R_u(N)|}{|Te_u|} \quad (9)$$

정밀도는 추천된 아이템 중 실제 평가 데이터셋에서 사용한 아이템의 비율을, 재현율은 평가 데이터셋에서 경험했던 아이템 중 실제로 추천된 아이템의 비율을 의미한다.  $N$ 개의 아이템에 대한 normalized discounted cumulative gain (nDCG@ $N$ )<sup>[35]</sup>은 실제 평가 데이터셋에서 사용한 아이템이 top- $N$  추천 리스

트의 앞 순서에 위치할수록 높은 점수를 줌으로써 추천 리스트의 추천 순서까지 검증할 수 있는 척도이다. 사용자  $u$ 에 대하여  $y_k$ 를  $R_u(N)$ 의  $k$ 번째 아이템이  $Te_u$ 에 속하면 1, 속하지 않으면 0이라고 할 때, 사용자  $u$ 에 대한 nDCG@ $N$ 은 다음과 같이 정의한다.

$$nDCG_u@N = \frac{DCG_u@N}{IDCG_u@N} \quad (10)$$

$$DCG_u@N = \sum_{i=1}^N \frac{2^y_i - 1}{\log_2(i+1)} \quad (11)$$

$$IDCG_u@N = \sum_{i=1}^{\min(|Te_u|, N)} \frac{1}{\log_2(i+1)} \quad (12)$$

IDCG <sub>$u$</sub> @ $N$ 은 DCG <sub>$u$</sub> @ $N$ 의 이상적인 경우로  $Te_u$ 의 모든 아이템이  $R_u(N)$ 의 앞 순서에 추천된 경우이다. 이를 통해 nDCG@ $N$ 은 다음과 같이 정의한다.

$$nDCG@N = \frac{1}{M} \sum_{u \in U} nDCG_u@N \quad (13)$$

#### 4.4 실험 결과 및 토의

##### 4.4.1 그래프 구조 반영 방법에 따른 결과

MF<sup>[1]</sup> 기술의 경우 노드 간 연결된 정보 (즉, link의 유무)만을 활용한 반면, LightGCN<sup>[9]</sup> 기술은 메시지 전달 기법을 통해 노드 간 연결 정보뿐만 아니라 멀티홉 이웃 (multi-hop neighbor) 정보까지 활용할 수 있기 때문에 주어진 이분 그래프 구조를 보다 진밀히 반영할 수 있다. 표 9와 10에서 알 수 있듯, LightGCN<sup>[9]</sup> 기술이 MF<sup>[1]</sup> 기술보다 모든 정확도 성능 척도 측면에서 우수하다.

##### 4.4.2 속성 정보 사용 유무에 따른 결과

MLP와 본 논문에서 제안한 알고리즘은 MF<sup>[1]</sup>, LightGCN<sup>[9]</sup> 기술과 달리 사용자, 아이템 노드의 속성 값을 활용할 수 있다. 표 9와 10에서 볼 수 있듯이, 사용자, 아이템 노드의 속성 값을 반영한 기술인 MLP가 MF<sup>[1]</sup>보다 우수한 성능을 낼 수 있음을 확인할 수 있고, 속성 값을 활용하지는 않지만 그래프 구조를 보다 진밀히 반영한 LightGCN<sup>[9]</sup> 기술 대비 본 논문에서 제안한 알고리즘이 더욱 우수한 정확도를 낼 수 있음을 관찰하였다.



4.4.3 속성 정보 사용 유무에 따른 복잡도 분석

기존의 LightGCN<sup>[9]</sup>에 비해 본 논문에서 제안한 알고리즘은 메시지 전달 (Message passing) 과정에서 사용자, 아이템 속성 행렬과 훈련가능한 선형변환 행렬의 행렬 곱 연산만큼의 연산량이 추가된다. 본 논문에서 활용한 데이터 기반 실험 시 LightGCN<sup>[9]</sup>과 제안한 추천 알고리즘의 평균 실행 시간은 각각 83.02 초, 83.49초이고 둘 사이 거의 차이가 없음을 확인하였다.

4.4.4 토의

사용자, 아이템의 속성 값과 사용자-아이템 이분 그래프의 구조적 특징은 추천 알고리즘에서 매우 중요한 요소이다. 그래프 구조를 깊숙히 반영하고자 했던 LightGCN<sup>[9]</sup> 기술, 사용자, 아이템 속성 값을 충분히 활용하고자 했던 MLP 기술이 노드 간 연결된 정보만을 활용하고, 속성 값을 활용하지 않는 MF<sup>[11]</sup> 기술 대비 좋은 성능을, 더 나아가 본 논문에서 제안한 알고리즘은 LightGCN<sup>[9]</sup> 기술에서 사용자, 아이템 노드의 속성 값을 추가적으로 활용하면서 모든 정확도 측면에서 더욱 우수한 성능을 나타냄을 표 9, 10에서 확인하였다. 본 연구에서 제안한 알고리즘이 환자, 운동 프로그램의 속성 값과 이전에 경험했던 운동 프로그램 정보를 잘 활용한다면 재활 프로그램을 추천하는 플랫폼에서 보다 알맞은 운동 프로그램을 제공할 수 있을 것으로 기대한다.

표 9. 알고리즘에 따른 정확도 비교 (테스트용 엣지 40개)  
Table 9. Performance comparison (40 edges for testing)

	<i>N</i>	<i>P@N</i>	<i>R@N</i>	<i>nDCG@N</i>
MF	1	0.275	0.221	0.275
	3	0.129	0.309	0.284
	5	0.098	0.39	0.32
MLP	1	0.275	0.243	0.275
	3	0.137	0.353	0.31
	5	0.13	0.537	0.39
LightGCN	1	0.337	0.262	0.337
	3	0.202	0.456	0.401
	5	0.14	0.534	0.434
Proposed	1	0.456	0.384	0.456
	3	0.22	0.534	0.496
	5	0.152	0.618	0.532

표 10. 알고리즘에 따른 정확도 비교 (테스트용 엣지 80개)  
Table 10. Performance comparison (80 edges for testing)

	<i>N</i>	<i>P@N</i>	<i>R@N</i>	<i>nDCG@N</i>
MF	1	0.17	0.079	0.17
	3	0.121	0.207	0.179
	5	0.117	0.341	0.239
MLP	1	0.243	0.136	0.243
	3	0.162	0.274	0.256
	5	0.156	0.455	0.333
LightGCN	1	0.317	0.203	0.317
	3	0.146	0.276	0.277
	5	0.126	0.365	0.32
Proposed	1	0.439	0.237	0.439
	3	0.203	0.323	0.344
	5	0.185	0.477	0.417

V. 결론

본 연구에서는 운동 재활의 대표적인 부위인 무릎 질환 환자의 속성 데이터를 생성하고, 재활 초기 단계부터 마무리 단계까지 다양한 프로그램을 선정하여 데이터 교차 검증을 통해 환자-운동 간의 경험 데이터셋을 생성하였다. 이렇게 생성 및 처리된 데이터셋을 바탕으로 GNN 기술을 적용하여 개인 맞춤형 운동재활 콘텐츠 추천 알고리즘을 설계하였다. 본 논문에서 제안한 알고리즘은 그래프 구조를 반영함과 동시에 사용자, 아이템 노드의 속성 값을 충분히 활용하였기 때문에, 기존 방법들인 MF<sup>[11]</sup>, MLP, 그리고 LightGCN<sup>[9]</sup> 대비 우수한 성능을 보일 수 있고 이를 실험적으로 확인하였다. 본 연구에서 제안한 알고리즘이 실제 데이터에 기반한 환자, 운동 프로그램의 속성 값과 이전에 경험했던 운동 프로그램 정보를 잘 활용한다면, 환자에게 보다 적절한 운동 프로그램을 제공할 수 있을 것으로 기대한다.

References

[1] Y. Koren, R. Bell, and C. Volinsky, "Matrix factorization techniques for recommender systems," *IEEE Comput.*, vol. 42, no. 8, pp. 30-37, 2009.

[2] R. van den Berg, T. N. Kipf, and M. Welling, "Graph convolutional matrix completion," in *Proc. KDD'18 Deep Learning Day*, 2018.

- [3] R. Ying, R. He, K. Chen, P. Eksombatchai, W. L. Hamilton, and J. Leskovec, "Graph convolutional neural networks for web-scale recommender systems," in *Proc. 24th ACM SIGKDD Int. Conf. KDD'18*, pp. 974-983, London, UK, Aug. 2018.
- [4] W. Hamilton, Z. Ying, and J. Leskovec, "Inductive representation learning on large graphs," in *Proc. 28th Int. Conf. NIPS'17*, pp. 1025-1035, Long Beach, CA, Dec. 2017.
- [5] L. Zheng, C.-T. Lu, F. Jiang, J. Zhang, and P. S. Yu, "Spectral collaborative filtering," in *Proc. 12th ACM Conf. RecSys'18*, pp. 311-319, Vancouver, Canada, Oct. 2018.
- [6] T. N. Kipf and M. Welling, "Semi-supervised classification with graph convolutional networks," in *Proc. 5th ICLR'17*, Toulon, France, Apr. 2017.
- [7] X. Wang, X. He, M. Wang, F. Feng, and T.-S. Chua, "Neural graph collaborative filtering," in *Proc. 42nd Int. ACM SIGIR'19*, pp. 165-174, Paris, France, Jul. 2019.
- [8] L. Chen, L. Wu, R. Hong, K. Zhang, and M. Wang, "Revisiting graph based collaborative filtering: A linear residual graph convolutional network approach," in *Proc. 34th AAAI'20*, pp. 27-34, New York, NY, Feb. 2020.
- [9] X. He, K. Deng, X. Wang, Y. Li, Y. Zhang, and M. Wang, "LightGCN: Simplifying and powering graph convolution network for recommendation," in *Proc. 43rd Int. ACM SIGIR'20*, pp. 639-648, Virtual Event, China, Jul. 2020.
- [10] *Health Care Big Data Hub Classification of Disease*(2020), Retrieved Nov. 17, 2021 from <http://opendata.hira.or.kr/op/opc/olap3thDsInfo.do>.
- [11] *Size Korea 7th human body measurement*, Retrieved Nov. 17, 2021, from <https://size.korea.kr/page/report/1>.
- [12] *Statistics of 120 Parts of Body(Female)* (1997~2015), Retrieved Nov. 17, 2021, from [https://kosis.kr/statisticsList/statisticsListIndex.do?vwcd=MT\\_ZTITLE&menuId=M\\_01\\_01#content-group](https://kosis.kr/statisticsList/statisticsListIndex.do?vwcd=MT_ZTITLE&menuId=M_01_01#content-group).
- [13] *Statistics of 120 Parts of Body(Male)* (1997~2015), Retrieved Nov. 17, 2021, from [https://kosis.kr/statisticsList/statisticsListIndex.do?vwcd=MT\\_ZTITLE&menuId=M\\_01\\_01#content-group](https://kosis.kr/statisticsList/statisticsListIndex.do?vwcd=MT_ZTITLE&menuId=M_01_01#content-group).
- [14] *Weight Change in the elderly(Male)* (2015~2019), Retrieved Nov. 17, 2021, from [https://kosis.kr/statHtml/statHtml.do?orgId=113&tblId=DT\\_113\\_STBL\\_1029882&vw\\_cd=MT\\_ZTITLE&list\\_id=113\\_](https://kosis.kr/statHtml/statHtml.do?orgId=113&tblId=DT_113_STBL_1029882&vw_cd=MT_ZTITLE&list_id=113_).
- [15] *Weight Change in the elderly(Female)* (2015~2019), Retrieved Nov. 17, 2021, from [https://kosis.kr/statHtml/statHtml.do?orgId=113&tblId=DT\\_113\\_STBL\\_1029883&vw\\_cd=MT\\_ZTITLE&list\\_id=113\\_](https://kosis.kr/statHtml/statHtml.do?orgId=113&tblId=DT_113_STBL_1029883&vw_cd=MT_ZTITLE&list_id=113_).
- [16] J. Y. Kim, D. W. Lee, and M. B. Jeong, "Effect of a telerehabilitation exercise program on the gait, knee function and quality of life in patients with knee osteoarthritis," *J. Korean Soc. Phys. Med.*, vol. 15, no. 1, pp. 143-152, 2020.
- [17] Billy C. L. So, Iris S. Y. Kong, Roy K. L. Lee, Ryan W. F. Man, William H. K. Tse, Adalade K. W. Fong, and William W. N. Tsang, "The effect of Ai Chi aquatic therapy on individuals with knee osteoarthritis: a pilot study," *Phys. Ther. Sci.*, vol. 29, no. 5, pp. 884-890, 2017.
- [18] K. E. Roach and T. Miles, "Normal hip and knee active range of motion: the relationship to age," *Phys. Ther.*, vol. 71, no. 9, pp. 656-665, 1991.
- [19] *Normal Joint Range of Motion Study / CDC(Centers for Disease Control and Prevention)*, Retrieved Nov. 17, 2021 from <https://www.cdc.gov/ncbddd/jointrom/index.html>.
- [20] D. Mukherjee, "Muscle strength testing using wearable wireless sensors," *BodyNets '15*, pp. 58-61, 2015.
- [21] W. E. Prentice, *Rehabilitation techniques for sports medicine and athletic training*, Boston : McGraw-Hill, pp. 524-578, 2004.
- [22] Y. M. Na, et al., *Sport Injury & Rehabilitation*, Hannibook, pp. 190-228, 2002.

[23] *Osteoarthritis Center Sports Medicine Center / Samsung Seoul Hospital*, Retrieved Nov. 17, 2021 from [http://www.samsunghospital.com/dept/medical/healthSub01View.do?content\\_id=484&DP\\_CODE=SCC&MENU\\_ID=003014&d\\_s\\_code=D0001193](http://www.samsunghospital.com/dept/medical/healthSub01View.do?content_id=484&DP_CODE=SCC&MENU_ID=003014&d_s_code=D0001193).

[24] *Department of Rehabilitation Medicine / Seoul National University Bundang Hospital*, Retrieved Nov. 17, 2021 from [https://www.snubh.org/dh/main/index.do?DP\\_CD=RH&MENU\\_ID=006046024](https://www.snubh.org/dh/main/index.do?DP_CD=RH&MENU_ID=006046024).

[25] *Seoul Now Hospital*, Retrieved Nov. 17, 2021 from [https://www.nowmed.co.kr/vod/html/rehab04?cate=03&cate\\_sub=04](https://www.nowmed.co.kr/vod/html/rehab04?cate=03&cate_sub=04).

[26] *Massachusetts General Hospital*, Retrieved Nov. 17, 2021 from <https://www.massgeneral.org/assets/MGH/pdf/orthopaedics/sports-medicine/physical-therapy/rehabilitation-protocol-for-ACL.pdf>.

[27] *Sports Injuries Treatment & Rehabilitation / Virtual Sports Injury Clinic*, Retrieved Nov. 17, 2021 from <https://www.sportsinjuryclinic.net/sport-injuries/knee-pain/early-stage-knee-strengthening-exercises>.

[28] *Physiopeedia - universal access to physiotherapy and physical therapy knowledge*, Retrieved Nov. 17, 2021 from [https://www.physio-peedia.com/Balance\\_Training](https://www.physio-peedia.com/Balance_Training).

[29] *Seoul National University Hospital TV - Youtube*, Retrieved Nov. 17, 2021 from <https://www.youtube.com/watch?v=9HdfN1cbu-fQ>.

[30] *Korean Academy of Rehabilitation Medicine*, Retrieved Nov. 17, 2021 from <https://www.karm.or.kr/info/disease07.php>.

[31] *The Korean Orthopaedic Association*, Retrieved Nov. 17, 2021 from <https://m.koa.or.kr/infor/index.php?mv1=5&mv2=3&mv3=7&mv4=>.

[32] *OrthoInfo - Patient Education / American Academy of Orthopaedic Surgeons*, Retrieved Nov. 17, 2021 from <https://orthoinfo.aaos.org/en/recovery/knee-conditioning-program/knee-pdf/>.

[33] *Korean Society for The Study of Obesity*,

Retrieved Nov. 17, 2021 from <http://general.kosso.or.kr/html/?pmode=obesityDiagnosis>.

[34] S. Rendle, C. Freudenthaler, Z. Gantner, and L. Schmidt-Thieme, "BPR: Bayesian personalized ranking from implicit feedback," in *Proc. 25th Conf. UAI'09*, pp. 452-461, Montreal, Canada, Jun. 2009.

[35] K. Jarvelin and J. Kekalainen, "Cumulated gain-based evaluation of IR techniques," *ACM Trans. Inf. Syst.*, vol. 20, no. 4, pp. 422-446, Oct. 2002.

김수연 (Sooyon Kim)



2022년 2월 : 연세대학교 응용통계학과 졸업  
 <관심분야> 기계학습, 통계적 학습이론, 딥러닝  
 [ORCID:0000-0003-1607-6475]

오정현 (Jeong-Heon Oh)



2022년 2월 : 연세대학교 응용통계학과 졸업  
 <관심분야> 데이터마이닝, 기계학습, 딥러닝  
 [ORCID:0000-0002-5251-0649]

오다건 (Dagun Oh)



2019년 2월~현재 : 연세대학교 응용통계학과 학부생  
 <관심분야> 딥러닝, 데이터 마이닝, 임상통계학  
 [ORCID:0000-0002-5900-989X]

서 창 원 (Changwon Seo)



2016년 8월 : 울산과학기술원 (UNIST) 수리과학과 학사  
2020년 3월~현재 : 연세대학교 수학기산학부(계산과학공학) 석박사통합과정  
<관심분야> 기계학습, 그래프 신경망, 추천 시스템

[ORCID:0000-0003-3499-0578]

신 원 용 (Won-Yong Shin)



2002년 2월 : 연세대학교 기계전자공학부 학사  
2004년 2월 : KAIST 전자전산학과 석사  
2008년 8월 : KAIST 전자전산학부 박사  
2009년 5월~2011년 10월 :

Harvard University Postdoctoral Fellow

2011년 10월~2012년 2월 : Harvard University Research Associate

2012년 3월~2019년 2월 : 단국대학교 컴퓨터학과 조교수/부교수(tenured)

2019년 3월~현재 : 연세대학교 수학기산학부(계산과학공학) 부교수

<관심분야> 정보이론, 통신, 모바일컴퓨팅, 기계학습, 데이터마이닝

[ORCID:0000-0002-6533-3469]