

개인맞춤형 재활운동 추천을 위한 Neural Collaborative Filtering (NCF) 기반의 추천 시스템 개발

장운섭*, 전부선*, 박노삼*, 한미경*, 김재철*

Development of a Rehabilitation Exercise Recommender System Based on Neural Collaborative Filtering (NCF)

Yoon-Seop Chang*, Boosun Jeon*, NohSam Park*, Mikyong Han*, Jae-Chul Kim*

요약

재활운동은 환자별로 운동 종류와 강도 등을 주의 깊게 선택하여 처방 및 수행하여야 한다. 재활운동이 잘못 처방될 경우 그 효과가 미비하거나, 역효과를 내고 2차부상 등 위험한 상황을 초래할 수 있다. 본 연구에서는 세종충남대병원에서 수행 중인 재활운동 중재 임상시험 데이터를 대상으로 개인맞춤형 재활운동 추천 시스템을 개발하였다. 어깨 유착성 관절낭염 및 회전근개 손상 환자와 허리 통증 환자를 대상으로 수행 중인 재활운동 중재 임상시험 데이터로부터 학습 데이터셋을 생성하고, NCF의 NeuMF 모델을 기반으로 재활운동 추천 시스템을 개발하여 그 성능을 검증하였다. 검증을 통해 개발된 재활운동 추천 모델이 GMF 및 MLP 모델 기반의 방식에 비해 보다 우수한 성능을 보임을 확인하였다. 본 연구의 개인맞춤형 재활운동 추천 시스템은 재활환자의 기능회복 및 건강증진과 빠르고 안전한 사회복귀를 도울 수 있을 것으로 기대된다.

키워드 : 재활운동, 추천 시스템, 협업 필터링, 신경망, 개인맞춤형

Key Words : rehabilitation exercise, recommender system, collaborative filtering, neural network, personalized

ABSTRACT

Rehabilitation exercises should be prescribed to patients by considering carefully those types and strength etc. In the case of wrong prescription, there will be little effect or it may bring adverse effects like injuries to patients. Rehabilitation exercise recommender system has been developed in this study by adopting the clinical test data of Chungnam National University Hospital. Training data were generated from the exercise execution data of patients with shoulder adhesive capsulitis, shoulder rotator cuff injury and low back pain diseases. Rehabilitation exercise recommender system based on NCF framework's NeuMF model has been developed and validated using the generated training data. Developed recommender algorithm, as a result, showed better performance than GMF and MLP models. Rehabilitation exercise recommender system of this study will help patients to recover their functional ability and return to the society soon.

※ 본 연구는 문화체육관광부 및 한국콘텐츠진흥원의 2022년도 문화기술 연구개발 사업으로 수행되었음(과제명: 지능형 개인맞춤 재활운동 서비스 기술개발, 과제번호: SR202104001, 기여율: 100%)

이 연구의 윤리적 타당성은 세종충남대학교병원 윤리심의위원회가 평가 및 승인하였음(CNUSH-2021-12-013)

•° First and Corresponding Author : Intelligent Human Twin Research Center, ETRI (Electronics and Telecommunications Research Institute), ychang76@etri.re.kr, 정희원

* Intelligent Human Twin Research Center, ETRI (Electronics and Telecommunications Research Institute), bsjeon@etri.re.kr, 정희원; siru23@etri.re.kr, 정희원; mkhan@etri.re.kr, 정희원; kimjc@etri.re.kr, 정희원

논문번호 : 202210-242-C-RU, Received October 11, 2022; Revised October 20, 2022; Accepted October 24, 2022

I. 서 론

1.1 연구배경

신체 건강한 정상인들을 대상으로 하는 운동들과 달리 재활운동은 환자별로 환자별 건강상태, 질병정보, 재활부위, 재활정도 등에 따라 운동 종류와 강도 등을 주의 깊게 선택하여 처방 및 수행하여야 한다. 재활운동이 잘못 처방되어 수행될 경우 그 효과가 미비하거나, 오히려 역효과를 내고 나아가 2차부상 등의 위험한 상황을 초래할 수 있다. 이에 재활운동은 물리치료사, 작업치료사, 건강운동관리사와 같은 일정 자격을 지닌 전문가들에 의해 중재되도록 하고 있다. 그러나 재활운동 중재 과정은 이들 전문가의 교육이수 내용, 근무기간 및 경력, 운동중재 경험, 전문 부위 및 질환, 운동지도 성향 등에 따라 다소 주관적, 경험적으로 이루어질 수 있다. 또한 환자별 건강상태, 질병유무 및 종류, 진단정보, 수술경험, 위험도, 통증유무 및 부위, 기능동작 지표, 과거 운동경험 및 선호도 등 다양하고 방대한 정보로 인해 의사결정이 점점 어려워지고 있다. 방대한 의료정보는 환자와 의료종사자들의 의사결정을 어렵게 하고, 소요되는 시간과 비용을 증가시킨다¹¹². 이에 정보 필터링 기술인 인공지능 특히, 기계학습을 기반으로 추천 기술을 개발하여 재활운동 처방과 수행에 도입할 필요가 있다. 추천 시스템은 건강과 관련하여 보다 효율적이고 정확한 결정을 내릴 수 있도록 한다³⁻⁶.

1.2 관련 연구동향

추천 시스템은 개인별 평가점수 또는 선호도를 예측하는 일종의 정보 필터링 시스템이다⁷. 추천 시스템은 e-러닝, e-커머스, 영화, 음악, 뉴스 등 다양한 분야에서 널리 활용되고 있다⁸⁻¹³. 건강 분야의 추천 시스템은 개인화된 추천 결과를 제공함으로써 사용자의 건강상태 유지 및 증진을 직접적으로 도모하는 이점으로 인해 최신 연구주제로 자리잡아 가고 있다. 추천 시스템은 질병 심각도 예측, 질병 진단 및 치료, 건강관리 및 증진, 생활습관 변화 등에 대해 유용하고 정확한 정보를 제공한다¹⁴⁻¹⁵. Yu 등은 건강 분야의 추천 기술과 응용을 크게 다섯 가지 주제인 식이요법 추천, 라이프스타일(생활양식) 추천, 훈련(운동), 환자 및 의사의 의사결정, 질병 관련 예측으로 나누어 정리하였다¹⁶. Tran 등도 건강 관련 추천 시스템의 대표적인 예들을 식이요법 추천, 의약품 추천, 건강상태 예측, 헬스케어 서비스 추천, 건강전문가 추천 등으로 나누어 살펴보았다¹⁷.

최근 들어 헬스케어 서비스에 정보 기술 및 도구를 결합한 디지털 헬스 관련 추천 시스템 개발이 연구자들 사이에서 새로운 연구주제로 부각되고 있다¹⁸. Dharia 등은 과거 운동이력, 선호도, 신체상태 등 상황 데이터를 기반으로 개인화된 운동 프로그램(세션)을 추천하는 시스템을 제안하였다¹⁹. COHESY는 협업 필터링(Collaborative Filtering) 기반 헬스케어 추천 모델로서 개발되어 이웃 기반 유사도 측정을 기반으로 건강에 도움이 되는 일련의 운동들을 추천하였다²⁰. PRO-Fit도 개인화된 운동 추천 프레임워크로서 협업 필터링을 이용해 사용자의 활동 데이터 및 개인 프로파일에 대해 유사도를 측정하여 운동을 추천하였다²¹. SelfBack 추천 시스템은 사례 기반 추론 기법과 유전자 알고리즘을 함께 이용해 요통 환자를 위해 운동 목록을 생성해 운동계획을 개인화 하였다²². Ali 등은 상황인지 기반 추천과 지식 기반 추천을 결합해 운동과 식이요법을 함께 추천하는 하이브리드 형식의 프레임워크를 개발하였다²³. Vairale과 Shukla는 감상선 환자들을 위해 콘텐츠 기반 추천 기법, 행렬분해(matrix factorization), Restricted Boltzmann Machine (RBM) 모델을 결합하여 개인화된 운동 추천 시스템을 제안하였다²⁴. 김수연 등은 무릎 질환 환자의 속성 데이터를 생성하고 그래프 신경망을 이용해 재활운동 추천 시스템을 개발하였다²⁵.

1.3 제안 연구 내용

본 연구에서는 재활을 필요로 하는 환자에게 개인 맞춤형으로 재활운동을 추천하는 Neural Collaborative Filtering (NCF) 기반의 추천 시스템을 개발하였다. 세종충남대병원에서 수행 중인 임상시험 데이터를 기반으로 추천 시스템을 개발하고 성능을 검증하였다. 해당 임상시험은 유착성 관절낭염(오십견) 및 회전근개 손상 어깨 환자와 허리 통증(요통) 환자를 대상으로 환자별 재활운동들을 중재하는 내용으로 수행되었다. 임상시험 데이터에 개발된 추천 시스템을 적용하여 성능을 검증한 결과 Generalized Matrix Factorization (GMF)과 Multi-Layer Perceptron (MLP)을 결합한 Neural Matrix Factorization (NeuMF) 모델의 경우 Hit Ratio (HR) 기준으로 허리 통증 환자에 대해 약 80% 이상의 정확도를 달성하고, GMF 또는 MLP 모델만을 이용한 경우에 비해 더 우수한 성능을 보이는 것을 확인하였다.

II. 임상데이터 수집 및 학습 데이터셋 생성

2.1 재활운동 중재 임상시험

2.1.1 임상시험 목적 및 규모

재활운동 추천 알고리즘 개발과 성능 검증을 위해 본 연구에서는 세종충남대병원에서 수행 중인 재활운동 중재 임상시험의 데이터를 활용하였다. 해당 임상시험은 ‘요통과 어깨 통증 환자의 전주기 재활운동 적용 시범 연구’라는 이름으로 수행 중이다. 임상시험은 2021년 12월 27일 계획을 수립하였으며 2023년 3월 31일까지 수행될 예정이다.

임상시험은 만 19세 이상 65세 미만의 성인 남녀 중 어깨 부위의 유착성 관절낭염(오십견) 및 회전근개 손상 진단을 받은 환자와 허리 통증(요통)이 있는 환자들을 대상으로 하였다. 목표로 대상자 수는 어깨 유착성 관절낭염 환자 30명(실험군 15명, 대조군 15명), 어깨 회전근개 손상 환자 30명(실험군 15명, 대조군 15명), 허리 통증 30명(실험군 15명, 대조군 15명)으로 설정되었다.

2.1.2 재활운동 중재 방법

어깨 환자와 허리 환자의 경우 질환별 특성을 반영하여 재활운동의 중재방법을 서로 달리하여 진행하였다. 어깨 유착성 관절낭염 및 회전근개 손상 환자의 경우 병원 내 운동치료실에서 4주간 주 2회 하루에 약 40분씩 재활운동을 중재하였다. 대조군에게는 집에서 수행하는 재활운동에 대한 동영상 자료를 제공하여 수행하게 하였으며, 실험군에게는 병원에 방문하게 하여 연구진의 지도하에 재활운동을 중재하였다. 병원에서 재활운동이 끝난 환자에게는 지역사회 민간체육 시설에서 8주간 주 1회 하루에 약 40분씩 건강운동관리사의 지도하에 운동을 중재하였다. 운동부위는 어깨, 팔꿈치, 손, 손목 등 상지(upper extremity)로 정하였고, 유산소, 근력, 유연성 등의 운동을 중재하였다. 재활운동의 강도를 조절하기 위해 세라밴드, 아령, 짐볼 등의 도구를 사용하였다.

허리 통증 환자는 병원 내 운동치료실에서 2주간 주 2회 하루 약 40분씩 재활운동을 수행하고, 첫 운동 중재 기간 종료 후 2주 동안 휴지기를 갖도록 하였다. 첫 휴지기 종료 후 다시 2주간 주 2회 하루 약 40분 재활운동을 중재하고, 다시 2주간 휴지기를 두었다. 이어서 지역사회에서 4주간 주 1회 하루 약 40분씩 재활운동을 중재하였다. 운동부위는 목과 체간 위주의 전신운동으로 유산소, 근력, 유연성, 균형 및 보행 운

동을 수행하도록 하였다.

본 임상시험을 통한 재활운동 중재의 효과를 확인하기 위해 환자별로 운동중재 기간 중에 총 5회의 평가를 수행하도록 하였다. 평가는 첫 평가, 중간평가 2회, 종료평가, F/U (Follow Up) 평가의 순서로 수행되었다. 평가는 전문가 자문과 레퍼던스를 통해 정해진 근골격계 데이터의 항목들에 대해 이루어졌다.

2.2 임상 데이터 명세 상세정보

2.2.1 재활환자 근골격계 질환 데이터 명세

임상시험에 참여하는 재활환자들의 건강상태, 질병상태, 재활정도 등을 파악 및 관리하고, 재활운동 중재로 인한 효과를 객관적으로 분석하기 위해 근골격계 질환 데이터의 명세를 정의하였다. 근골격계 질환 데이터 명세는 인구통계정보, 진단치료정보, 위험도에 측정정보, 기능평가정보로 나누어 정의하였으며, 그 세부 구성항목은 어깨 유착성 관절낭염 및 회전근개 손상 환자와 허리 통증 환자의 경우를 서로 다르게 정의하였다.

다음은 어깨 질환 환자를 예시로 한 근골격계 질환 데이터 명세에 대한 설명이다. 우선 근골격계질환 데이터 중 인구통계정보는 환자 ID, 성명, 성별, 생년월일, 측정일자, 키, 몸무게, BMI, 복부둘레의 항목들로 구성되었다. 기존 진단 및 치료와 관련된 정보로는 우성수, 기존 상태, 기존 운동, 질병명, 주증상, 증상발현일자, 초진일자, 수술이력, 진단일자, 진단검사, 기타 검사, 시술이력 등이 기록된다. 환자에 대한 위험도 예측을 위한 정보로는 기타 근골격계 질환, 관련 병력, 외상력, 조직수술력, 직업, 취미(운동), 수면장애, 흡연 여부 및 흡연량, 음주여부, 가족력, 약물복용력, 기저 질환 등이 있다. 마지막으로 기능평가정보로서 어깨와 팔꿈치 부위의 기능동작(functional movement)별 근력 및 유연성 측정결과와 통증 관련 발현일자, 통증위치, 통증지수, 통증특징, 그 밖에 활동점수(activity score), 심폐지구, 균형 관련 지표, 운동자각도 등이 기록된다.

2.2.2 운동과 운동프로그램 구조 및 데이터 명세

환자에게 중재되는 재활운동은 개별 운동들이 다양한 형태로 조합되어 구성된 운동프로그램 단위로 제공되었다. 운동과 운동프로그램 사이의 구조는 그림 1과 같다. 각 운동프로그램의 운동 구성은 준비운동, 본운동, 정리운동의 세 단계로 나뉘며 각 단계의 수행 내용은 미리 준비된 운동 풀(pool)로부터 운동들을 선

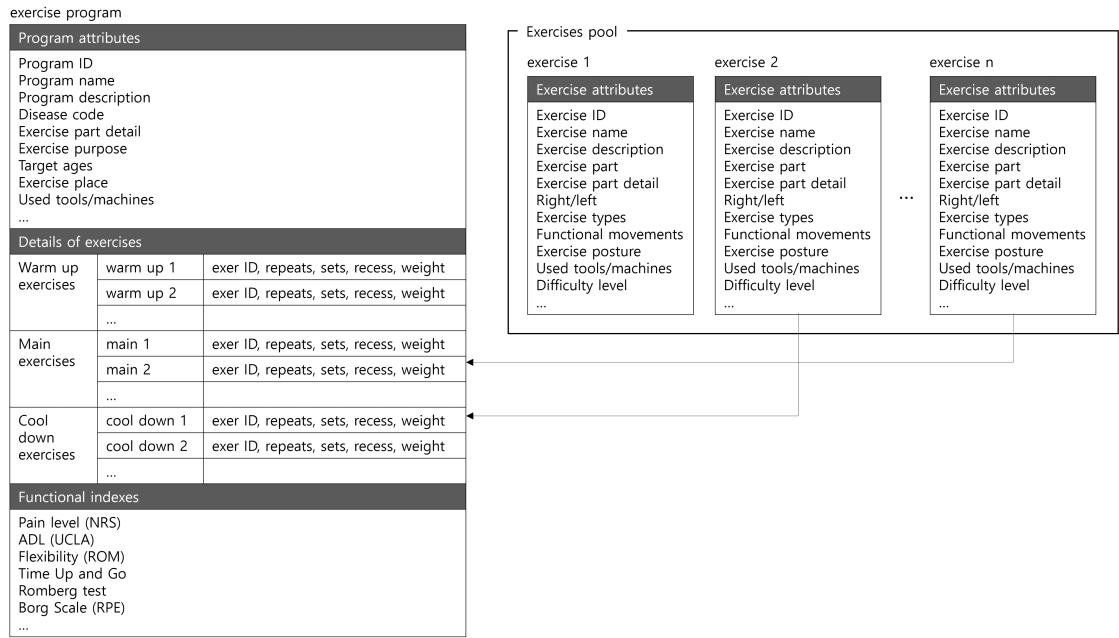


그림 1. 운동과 운동프로그램 사이의 구조적 관계
 Fig. 1. Structural relationship between exercise and exercise program

백하여 구성한다. 각 운동들에 대하여 반복횟수, 세트 수, 세트간 휴식시간, 운동부하(강도, 무게, 밴드색상 등)을 다르게 설정하여 환자별 운동수행 내용을 서로 다르게 중재할 수 있다.

운동 데이터 명세에는 운동 ID, 운동 이름, 운동 설정 정보, 운동부위, 세부운동부위, 좌우측 구분, 운동유형, 기능동작 종류, 운동자세, 기구기기 사용여부 및 목록, 운동 난이도 등이 포함된다. 운동은 그 명명 및 분류를 위해 17가지 운동부위와 26가지 기능동작에 대하여 ‘운동부위 + 기능동작’을 기본으로 하고 여기에 운동자세, 운동이름, 기구기기명, 좌우측 구분 및 그 밖의 사항을 기입하는 방식을 취하였다.

운동프로그램 데이터 명세는 운동프로그램 기본속성, 운동구성 상세내용, 기능지표 목표로 나누어 구성된다. 기능지표 목표의 항목들은 대상 질환에 따라 서로 다르게 구성되며, 운동구성 상세내용은 앞에서 설명한 운동들의 조합으로 구성된다. 운동구성 상세내용의 각 운동들에 대해 운동 ID, 반복횟수, 세트 수, 휴식시간, 운동부하의 항목들이 다르게 설정되어 운동프로그램의 실질적인 내용이 달라진다.

2.3 임상 데이터 수집 현황

본 연구에서는 지역사회에 중재한 임상 데이터만을 대상으로 개인맞춤형 재활운동 추천 시스템을 개발하

고 그 성능을 검증하였다. 지역사회의 임상 데이터를 우선 적용 대상으로 했던 이유는 지역사회에 비해 병원에서 중재한 재활운동의 종류가 더 적고 정형화되어 있어서 이보다 다양한 재활운동들을 추천 및 제공하기 위해서였다.

연구에 이용된 지역사회 임상 데이터는 어깨 질환(유착성 관절낭염, 회전근개 손상) 환자 및 허리 질환(요통) 환자에게 2022년 4월 18일부터 2022년 8월 26일까지 재활운동을 중재했던 내역이다. 표 1은 해당 기간에 수집된 지역사회 임상 데이터에 대한 통계 정보이다. 어깨 질환 환자의 재활운동 중재는 4월 18일부터, 허리 질환 환자에 대해서는 그보다 늦은 5월 2일부터 시작되었다. 임상 데이터에 포함된 환자 수는 어깨 질환의 경우가 12명, 허리 질환의 경우가 15명, 전체 27명이었다. 환자들에게 중재된 운동프로그램 수는 어깨 질환의 경우가 54개, 허리 질환의 경우가 52개, 전체 106개였다. 개별 운동의 경우 어깨 질환에 대해 111개, 허리 질환의 경우 95개 운동이 운동프로그램 구성을 위한 풀(pool)로 제공되었으며, 전체적으로는 두 질환간 중복을 반영하여 189개 운동이 중재에 이용되었다. 이들 운동이 실제 환자들에게 중재된 횟수는 어깨 질환의 경우 446회, 허리 질환의 경우 480회로 전체 926회였다.

운동프로그램별로 해당 운동프로그램에 포함되었

표 1. 질환별 재활운동 수행 데이터 통계
Table 1. Statistics of data from the execution of rehabilitation exercises for each disease

	Shoulder disease	Low back pain	Total
Date	2022.04.18~2022.08.26	2022.05.02~2022.08.26	2022.04.18~2022.08.26
Patients	12	15	27
Exercise Programs	54	52	106
Exercises (pool)	111	95	189
Exercises (execution)	446	480	926
Exercises/program	8 (6~13)	9 (7~12)	9 (6~13)
Programs/patient	5 (1~8)	3 (1~4)	4 (1~8)
Exercises/patient	37 (7~90)	32 (8~44)	34 (7~90)

던 개별 운동의 수는 어깨 질환의 경우가 6~13개 운동이 포함되어 평균 8개, 허리 질환의 경우 7~12개로 평균 9개, 전체적으로는 운동프로그램 당 6~13개 운동이 포함되어 평균 9개 운동이 운동프로그램 구성에 이용되었다.

환자별로는 어깨 질환 환자가 평균 5개 운동프로그램을, 허리 통증 환자는 평균 3개 운동프로그램을 수행하였다. 전체적으로는 환자별로 1~8개의 운동프로그램을, 평균적으로는 4개 운동프로그램을 수행하였다. 개별 운동에 대해서도 어깨 질환 환자의 경우는 평균 37회, 허리 통증 환자의 경우에는 평균 32회를 수행하였다. 전체적으로는 환자별로 개별 운동을 7~90회 수행해 평균 34회의 운동을 수행한 것으로 나타났다.

2.4 학습 데이터셋 생성 및 처리

본 연구의 재활운동 추천 시스템의 DB에는 재활환자의 근골격계 질환 데이터, 미리 구축된 운동 데이터 및 운동프로그램 데이터, 그리고 환자별로 운동프로그램을 처방받은 이력인 처방 데이터와 환자들이 운동프로그램을 실제 수행한 결과인 운동수행 데이터 등이 함께 저장되었다.

학습 데이터셋 생성에 앞서 전체 환자들에 대한 운동수행 현황 데이터셋을 생성하였다. 해당 데이터셋에는 질병코드, 환자 ID, 건강운동관리사 ID, 운동일자, 운동프로그램ID, 운동프로그램 이름, 운동단계, 순번, 운동 ID, 운동이름, 운동설명, 반복횟수, 세트 수, 운동강도, 실행횟수, 실행 세트 수, 실행강도, 통증수준, 통증부위 등이 포함되었다. 그림 2는 운동수행 현황

Disease Code	Patient ID	Coach ID	Date	Program ID	Program Name	Stage	Num	Exercise ID	Exercise Name		
1	RS01	HS01	2022-04-18	1662607403	RS01 shoulder 20220418	1	1	1662603213	Shoulder protraction(lying/elbow extension)		
1	RS01	HS01	2022-04-18	1662607403	RS01 shoulder 20220418	1	2	1662603200	Shoulder protraction(standing)		
1	RS01	HS01	2022-04-18	1662607403	RS01 shoulder 20220418	1	3	1662603241	Shoulder abduction(standing/elbow extension)		
1	RS01	HS01	2022-04-18	1662607403	RS01 shoulder 20220418	2	1	1662603120	Shoulder flexion(prone/elbow extension/diagonal)		
1	RS01	HS01	2022-04-18	1662607403	RS01 shoulder 20220418	2	2	1662603109	Shoulder horizontal abduction(prone/elbow extension)		
1	RS01	HS01	2022-04-18	1662607403	RS01 shoulder 20220418	2	3	1662603113	Shoulder extension(prone/elbow extension)		
1	RS01	HS01	2022-04-18	1662607403	RS01 shoulder 20220418	2	4	1662602984	Shoulder flexion(standing/elbow extension/diagonal/...		
1	RS01	HS01	2022-04-18	1662607403	RS01 shoulder 20220418	2	5	1662603185	Shoulder internal rotation(sit/elbow flexion/band)		
1	RS01	HS01	2022-04-18	1662607403	RS01 shoulder 20220418	2	6	1662603011	Shoulder extension(sit/elbow flexion/high row/band)		
1	RS01	HS01	2022-04-18	1662607403	RS01 shoulder 20220418	3	1	1662603270	Shoulder circumduction(standing/ball/stretch)		
1	RS01	HS01	2022-04-25	1662607421	RS01 shoulder 20220425	1	1	1662603241	Shoulder abduction(standing/elbow extension)		
1	RS01	HS01	2022-04-25	1662607421	RS01 shoulder 20220425	1	2	1662602946	Shoulder extension(standing/two hans on hip/stretch)		
1	RS01	HS01	2022-04-25	1662607421	RS01 shoulder 20220425	1	3	1662603177	Shoulder internal rotation(side.lying/stretch)		
1	RS01	HS01	2022-04-25	1662607421	RS01 shoulder 20220425	2	1	1662603118	Shoulder flexion(prone/elbow extension/diagonal/band)		
1	RS01	HS01	2022-04-25	1662607421	RS01 shoulder 20220425	2	2	1662603109	Shoulder horizontal abduction(prone/elbow extension)		
...											
Exercise description				Repeats	Sets	Strength	Repeats (result)	Sets (result)	Strength (result)	Pain (VAS)	Pain part
Supine scapular Protraction				15	2	low	15	3	low	1	1
Standing Scapular protraction				15	2	low	15	3	low	1	1
Wall Shoulder Stretch				10	2	low	10	2	low	2	1
Prone Y (include raise)				15	2	low	15	2	low	1	1
prone T (include raise)				15	2	low	15	2	low	1	1
prone W (include raise)				15	2	low	15	2	low	1	1
Dumbel Scaption				15	2	low	15	2	low	1	1
Sitting Shoulder Interanl Rotation with TheraBand				15	2	low	15	2	low	1	1
High row				15	2	low	15	2	low	1	1
Wall Shoulder Stretch				10	2	low	10	2	low	2	1
Clasped Hands Extension				15	2	low	15	3	low	1	1
Side-lying internal rotation stretch				10	2	low	10	3	low	1	1
Prone Y raise with Theraband				10	2	low	10	2	low	3	1
prone T (include raise)				15	2	low	15	2	low	1	1
Prone W raise with Theraband				10	2	low	10	2	low	1	1
...											

그림 2. 환자들의 운동수행 현황에 대한 데이터셋
Fig. 2. Dataset of exercise execution status of patients

데이터셋의 일부분을 보여준다. 이를 통해 환자들이 수행한 운동프로그램 및 운동 내역을 전체적으로 파악할 수 있었다.

본 연구의 개인맞춤형 재활운동 추천 시스템 개발은 운동프로그램 단위가 아닌 개별 운동 단위의 추천에 대하여 우선 수행하였다. 그 이유는 운동프로그램의 경우 개별 운동과는 달리 아직까지 여러 재활환자들에게 공통적으로 처방할 수 있는 규모의 운동프로그램 풀(pool)이 확보되지 않았기 때문이었다. 실제로 진행된 임상시험에서도 환자들에게 매회차마다 서로 다른 운동프로그램들이 처방되었고, 결국 환자들 사이에도 공통된 운동프로그램이 생기지 않았다.

반면 개별 운동의 경우에는 어깨 질환에 대해 111개, 허리 질환에 대해 95개의 운동을 풀로 하여 각각 446회, 480회에 걸쳐 환자들에게 처방되는 과정에서 환자들 사이에 여러 운동들을 공통으로 수행하게 되었다. 이렇게 환자들 사이에 공통되어 나타나는 운동과의 상호작용으로부터 환자와 운동의 잠재특징을 추천모델이 학습할 수 있었고, 결과적으로 개인맞춤형 운동 추천이 가능하게 되었다.

앞서 설명한 전체 환자들에 대한 운동수행 현황 데이터셋으로부터 운동 추천 시스템 개발을 위한 학습 데이터셋을 생성하였다. NCF 기반의 운동 추천 시스템 개발을 위해 환자와 운동 사이의 상호작용 데이터를 중심으로 학습 데이터셋을 생성하였다. 표 2는 생성된 학습 데이터셋의 일부를 보여준다. 학습 데이터셋에는 환자와 운동의 쌍 즉, 상호작용 데이터 외에 질병코드, 운동단계, 순번, 운동프로그램 내 수행횟수, 수행일자 등의 항목이 추가로 포함되었다.

학습 데이터셋 생성 과정 중에 환자 ID만은 별도의 변환을 거쳤다. 이는 동일한 환자도 운동수행 회차마다 다른 재활 상태를 보이기 마련인데, 재활환자의

경우 매 추천 때마다 재활 상태를 고려해 재활운동을 추천해야 하기 때문이다. 결과적으로 본 연구에서는 매 회차마다의 조금씩 다른 재활 상태의 환자를 서로 다른 환자의 개념으로 다루었다. 기존에 어깨 질환 환자의 경우 RS01, RS02, ... 식으로, 허리 질환 환자의 경우 RB01, RB02, ... 식으로 ID가 부여되었는데, 이에 대해 어깨 환자는 'RS'를 '1'로 대체하여 101, 102, ... 식으로, 허리 환자는 'RB'를 '2'로 대체하여 201, 202, ... 식으로 변환하였다. 이어서 RS01 환자의 경우 변환된 ID 101에 뒤의 한 자리를 늘려 1회차, 2회차, 3회차에 대하여 1011, 1012, ... 식으로 변환하였다. 나머지 환자 ID들에 대해서도 같은 변환 과정을 수행하였으며, 아래 표 2에도 이렇게 변환된 ID가 포함된 것을 볼 수 있다. 이러한 변환 과정을 통해 환자 운동 행렬에서 환자 축의 크기를 늘리는 효과도 얻게 되었다.

표 3은 생성된 학습 데이터셋의 질환별 현황을 정리한 것이다. 어깨 질환의 경우 사용자-환자 행렬에서 환자 수와 운동 수는 각각 54명과 111개였으며 상호작용 수는 446건이었다. 허리 질환의 경우에 환자와 사용자 수가 각각 52명과 95개였으며 상호작용은 480건이었다. 참고로 두 질환을 합한 전체 데이터는 환자 수 106명, 운동 수 189개, 상호작용 926건이었다.

표 3. 질환별 학습 데이터셋 현황
Table 3. Summary of training dataset for each disease

	Patients	Exercises	Interactions
Shoulder disease	54	111	446
Low back pain	52	95	480
Total	106	189	926

표 2. 재활운동 추천을 위한 학습 데이터셋 생성
Table 2. Generation of the training data for exercise recommendation

Disease code	Patient ID	Stage	Num	Exercise ID	Count	Date
1	1011	1	1	1662603213	1	2022-04-18
1	1011	1	2	1662603200	1	2022-04-18
1	1011	1	3	1662603241	1	2022-04-18
1	1011	2	1	1662603120	1	2022-04-18
1	1011	2	2	1662603109	1	2022-04-18
1	1011	2	3	1662603113	1	2022-04-18
...						
3	2261	2	4	1662603020	1	2022-08-24
3	2261	2	5	1662603022	1	2022-08-24
3	2261	3	1	1662602886	1	2022-08-24

III. 재활운동 추천 시스템 설계

3.1 재활운동 추천 시스템 개요

본 연구에서는 전체 환자들에게 처방되었던 재활운동 이력 데이터를 학습하여, 특정 환자에 대해 그 환자가 기존에는 수행하지 않았으나 수행하기에 적합한 상위 K개의 새로운 운동을 추천하는 시스템을 개발하고자 하였다. 이때 환자는 사용자(user)에, 운동은 아이템(item)에, 환자의 특정 운동에 대한 수행여부는 사용자와 아이템 사이의 상호작용(interaction)에 대응시킬 수 있다. 다만 앞의 2.4절에서도 설명한대로 동일 환자에 대한 매 운동회차별 다른 재활 상태의 환자를 서로 다른 사용자의 개념으로 다루었다. 결국 재활 상태가 변화하는 환자들에 대해 각 상태별로 적합한 운동을 추천하는 방식이다.

그림 3을 통해 재활환자에 대한 운동 추천 시스템의 흐름을 설명하면 다음과 같다. 사용자(환자)와 아이템(운동)에 대해 one-hot 인코딩된 벡터 $\mathbf{v}_u, \mathbf{v}_i$ 를 임베딩 레이어에 입력하여 사용자에 대한 잠재벡터(latent vector) $\mathbf{P}_u^{GMF}, \mathbf{P}_u^{MLP}$ 와 아이템에 대한 잠재벡터 $\mathbf{Q}_i^{GMF}, \mathbf{Q}_i^{MLP}$ 를 랜덤하게 초기화한다. 이후 모델 전체의 학습 과정 중에 이 임베딩 레이어도 학습을 거치게 되고 환자별, 운동별 잠재벡터의 학습이 마쳐진다. 이어서 잠재벡터 $\mathbf{P}_u^{GMF}, \mathbf{Q}_i^{GMF}$ 는 GMF 레이어에, $\mathbf{P}_u^{MLP}, \mathbf{Q}_i^{MLP}$ 는 MLP 레이어에 적용한다. 마지막으로 GML 레이어와 MLP 레이어의 출력 벡터를 결합해 NeuMF 레이어에 입력하여 Sigmoid (σ) 함수를 통해 예측 점

수 \hat{y}_{ui} 를 계산한다. 정답에 해당하는 y_{ui} 는 식 (1)과 같은 암시적 상호작용(implicit interaction)으로서 여기서는 각 운동이 해당 환자에게 이전에 처방된 적이 있는지 여부를 나타낸다. 결과적으로 예측 점수 \hat{y}_{ui} 에 따라 해당 운동을 환자에게 처방할지 말지를 결정하므로 \hat{y}_{ui} 와 y_{ui} 사이의 log loss가 최소가 되도록 추천 모델의 학습을 진행하게 된다.

$$y_{ui} = \begin{cases} 1, & \text{if interaction is observed;} \\ 0, & \text{otherwise.} \end{cases} \quad (1)$$

3.2 행렬분해 모델 보완

행렬분해 모델은 협업 필터링 방식의 추천 시스템과 관련해 가장 대표적이고 널리 쓰이는 모델이다. 협업 필터링 방식인 행렬분해 모델은 환자별 속성 정보가 아닌 운동 처방이력 자체 즉 상호작용 데이터를 입력으로 하여 이를 대상으로 유사성을 학습해 해당 환자와 유사한 패턴으로 처방을 받아 온 환자들의 운동들 중에서 추천한다. 이때 행렬분해 방식은 환자와 운동간 상호작용 행렬을 환자와 운동의 두 잠재행렬의 곱으로 나타내고, 이렇게 계산되는 상호작용 행렬의 오차를 줄이는 방향으로 두 잠재행렬을 학습하게 된다. 행렬분해 모델이 사용자와 아이템 사이의 상호작용 함수를 학습하는데 있어서, 그 핵심에는 식 (2)와 같이 사용자와 아이템에 대한 두 잠재벡터 $\mathbf{p}_u, \mathbf{q}_i$ 의 내적(inner product)을 계산하는 과정이 포함되어 있다²⁶⁾. 그러나 이러한 내적 연산은 두 잠재벡터 즉, 사용자와 아이템의 잠재요인(latent feature)들에 대한 선




그림 3. 개인맞춤형 재활운동 추천 알고리즘 개요
Fig. 3. An overview of rehabilitation exercises recommender algorithm

형결함으로 볼 수 있으므로 행렬분해 모델 자체를 선형모델로 간주할 수 있다. 결과적으로 행렬분해 모델은 선형 특성으로 인해 사용자와 아이템 사이의 복잡한 상호작용을 해석하는데 제약이 있을 수 있다. 이러한 제약을 보완하기 위해 잠재요인의 수를 늘리는 방법이 있으나, 이는 과적합(overfitting) 등의 문제를 가져올 수 있으며 특히 본 연구와 같이 데이터 희소성이 클 경우 더욱 문제가 될 수 있다.

$$\hat{y}_{ui} = f(u, i | \mathbf{p}_u, \mathbf{q}_i) = \mathbf{p}_u^T \mathbf{q}_i = \sum_{k=1}^K p_{uk} q_{ik} \quad (2)$$

이에 대하여 He 등²⁶⁾은 사용자와 아이템의 두 잠재벡터 사이의 내적연산을 핵심에 둔 선형모델로서의 MF의 한계점에 착안하여 협력 필터링 과정에 신경망을 도입한 NCF 프레임워크를 제안하고, 나아가 NCF를 이용해 구현한 선형모델 GMF와 비선형 모델 MLP를 결합한 NeuMF 모델을 제안하였다. 그리고 MovieLens 및 Pinterest 데이터를 이용한 평가를 통해 그 성능이 GMF 및 MLP 단독 모델들에 비해 우수한 성능을 보임을 확인하였다.

본 연구도 이에 착안하여 이를 재활운동 추천에 적용하기 위해 NCF 프레임워크의 NeuMF 모델을 기반으로 개인맞춤형 재활운동 추천 시스템을 개발하고, 그 결과가 재활운동 추천에 유의미한 성능을 보이는지, 그리고 He 등²⁶⁾의 연구와 마찬가지로 GMF 및 MLP 모델에 비해서도 우수한 성능을 보이는지 실험을 통해 확인하고자 하였다.

3.3 NCF 모델 기반 운동 추천 시스템 개발

본 연구에서는 앞서 설명한 것처럼 기존의 협업 필터링 방식의 추천에서 많이 쓰여 온 행렬분해 모델의 제약을 보완하기 위해 NCF 기반으로 운동 추천 시스템을 개발하였다. 우선 비선형의 다층퍼셉트론 모델 기반 학습 과정을 설명하고, 행렬분해 모델을 함께 적용하는 앙상블 기법의 흐름을 이어서 설명하겠다.

입력 레이어는 환자와 운동 입력이 각각 one-hot 인코딩된 벡터 \mathbf{v}_u^U 와 \mathbf{v}_i^I 로 구성된다. 이들 희소한(sparse) 벡터는 임베딩 레이어를 통해 보다 조밀한(dense) 벡터(latent vector)로 바뀌는데, 환자와 운동에 대응하는 잠재요인행렬(latent factor matrix) $\mathbf{P} \in \mathbb{R}^{M \times K}$ 및 $\mathbf{Q} \in \mathbb{R}^{N \times K}$ 와의 연산에 의해 잠재벡터(latent vector) $\mathbf{P}^T \mathbf{v}_u^U$ 와 $\mathbf{Q}^T \mathbf{v}_i^I$ 로 변환된다. 이들 잠재

벡터가 다음의 다층퍼셉트론 레이어에 입력되면 식 (3)에 의해 그 결과로 예측 점수 \hat{y}_{ui} 를 얻을 수 있다²⁶⁾. 이때 ϕ_{out} 과 ϕ_x 는 각각 출력 레이어와 x 번째 은닉 레이어의 매핑 함수이다. 예측 점수를 통해 환자에게 해당 운동의 처방할지 여부를 결정할 수 있으며 이 점수와 실제 정답 y_{ui} 사이의 log loss가 최소화되도록 학습을 진행한다.

$$\hat{y}_{ui} = f(\mathbf{P}^T \mathbf{v}_u^U, \mathbf{Q}^T \mathbf{v}_i^I) = \phi_{out}(\phi_L(\dots \phi_2(\phi_1(\mathbf{P}^T \mathbf{v}_u^U, \mathbf{Q}^T \mathbf{v}_i^I))\dots)) \quad (3)$$

위의 다층퍼셉트론 레이어의 구조를 아래의 식 (4)와 같이 보다 자세히 살펴보면 비선형적 특성을 알 수 있으며, x 번째 은닉 레이어의 활성화 함수 α_x 로는 ReLU 함수가, 출력 레이어에는 Sigmoid 함수가 적용된다²⁶⁾. 이는 앞서 설명한 선형적 특성의 행렬분해 모델의 제약을 보완하며, 사용자-아이템간 복잡한 상호작용 함수를 보다 효과적으로 학습할 수 있다.

$$\begin{aligned} \mathbf{z}_1 &= \phi_1(\mathbf{p}_u, \mathbf{q}_i) = \begin{bmatrix} \mathbf{p}_u \\ \mathbf{q}_i \end{bmatrix}, \\ \phi_2(\mathbf{z}_1) &= \alpha_2(\mathbf{W}_2^T \mathbf{z}_1 + \mathbf{b}_2), \\ &\dots \\ \phi_L(\mathbf{z}_{L-1}) &= \alpha_L(\mathbf{W}_L^T \mathbf{z}_{L-1} + \mathbf{b}_L), \\ \hat{y}_{ui} &= \sigma(\mathbf{h}^T \phi_L(\mathbf{z}_{L-1})) \end{aligned} \quad (4)$$

위의 식을 변경하면 MF 모델의 내적 연산 식 (2)를 대신 아래의 식 (5)로 나타낼 수 있다. \odot 는 성분별 곱하기(element-wise product) 연산이며, 이때 활성화 함수 α_{out} 을 항등함수(identity function)로 가중치 벡터 \mathbf{h} 를 원소가 1로만 이루어진 벡터로 가정할 경우 MF의 내적 연산과 동일해진다. 이와 같이 NCF 모델은 MF 모델을 모사할 수 있으며, 실제로 이를 GMF 모델이라고 하고, 이를 MLP 모델과 함께 결합해 NeuMF 모델을 제시하였다²⁶⁾. GMF 모델과 MLP 모델에 입력되는 사용자와 아이템의 임베딩 벡터를 서로 다르게 하면 보다 좋은 성능을 기대할 수 있는데, 이를 포함해 두 모델이 결합되는 과정을 식으로 나타내면 (6)과 같다²⁶⁾. \mathbf{p}_u^G 와 \mathbf{q}_i^G 는 GMF 모델로의 입력을 위한 임베딩 벡터이며 \mathbf{p}_u^M 와 \mathbf{q}_i^M 는 MLP 모델로의 입력을 위한 임베딩 벡터이다. ϕ^{GMF} 와 ϕ^{MLP} 는 각각 GMF 및 MLP 모델의 결과로서 NeuMF 모델로 입력

되어 최종 예측 점수 \hat{y}_{ui} 를 도출하게 된다. 본 연구에서도 이 앙상블 모델을 기반으로 재활운동 추천 알고리즘을 개발하였다.

$$\begin{aligned} \phi_1(\mathbf{p}_u, \mathbf{q}_i) &= \mathbf{p}_u \odot \mathbf{q}_i, \\ \hat{y}_{ui} &= a_{out}(\mathbf{h}^T(\mathbf{p}_u \odot \mathbf{q}_i)) \\ \phi^{GMF} &= \mathbf{p}_u^G \odot \mathbf{q}_i^G, \\ \phi^{MLP} &= a_L(\mathbf{W}_L^T(a_{L-1}(\dots a_2(\mathbf{W}_2^T \begin{bmatrix} \mathbf{p}_u^M \\ \mathbf{q}_i^M \end{bmatrix} + \\ &\mathbf{b}_2) \dots)) + \mathbf{b}_L), \\ \hat{y}_{ui} &= \sigma(\mathbf{h}^T \begin{bmatrix} \phi^{GMF} \\ \phi^{MLP} \end{bmatrix}) \end{aligned} \quad (5)$$

마지막으로 NeuMF 모델의 학습을 진행할 때 파라미터 초기화가 중요한데, 이에 GML 모델과 MLP 모델을 각각 별도로 미리 학습하여 최적화를 진행한 후 그 결과 파라미터를 NeuMF 모델 학습의 초기값으로 입력하여 진행하였다. 이때 미리 학습한 두 모델의 파라미터가 동일한 비중으로 반영되도록 하였다.

IV. 운동 추천 시스템 실험 및 검증

4.1 실험 및 검증 환경

재활운동 중개 임상 데이터를 대상으로 추천 시스템 개발 결과에 대한 실험 및 검증을 수행하였다. 어깨 질환과 허리 통증 질환으로 둘로 나누어 학습과 추천을 진행하였다.

어깨 질환의 경우에 환자 54명, 운동 111개로 이루어진 54 x 111의 환자-운동 행렬에 446개의 환자-운동간 상호작용이 포함되어 추천모델에 입력되었으며, 허리 질환의 경우에는 52 x 95의 환자-운동 행렬에 480개 상호작용이 포함되었다.

환자별 운동 데이터를 훈련용과 실험용으로 나누기 위해 계층화된 K-fold 교차검증(Stratified K-fold cross validation) 방식으로 진행하였다. 구체적으로는 훈련용과 실험용 데이터를 75%와 25%로 나누고 4-fold 교차검증 방식으로 진행하였다. GMF와 MLP를 함께 이용하는 NeuMF 모델을 기반으로 추천 시스템 학습을 진행하며 파라미터 튜닝을 통해 모델 최적화를 수행하고, 최종적으로 GML 및 MLP 모델과 그 성능을 비교하였다.

4.2 성능지표 선정

개발된 재활운동 추천 시스템의 성능 측정을 위한 지표로는 Top-K 추천방식의 K 값에 따른 Hit Ratio (HR), Normalized Discounted Cumulative Gain (NDCG), Precision, Recall을 선정하였다. Precision과 Recall은 추천보다는 분류 문제에 주로 활용되는 지표이나 본 추천 시스템의 성능을 보다 전반적으로 살펴보기 위해 포함하였다. 다만, 추천 시스템에 있어서는 HR과 NDCG가 주로 활용되는 지표로서 본 연구에서도 이 두 지표를 중심으로 결과 분석을 수행하였다.

HR은 아래와 같이 정의된다²⁷⁾. $|U|$ 는 전체 환자 수, $|U_{hit}^K|$ 는 상위 K개의 운동을 추천했을 때 적중한 (hit) 환자 수, $HR@K$ 는 전체 환자 수 대비 적중한 환자 수의 비율을 의미한다. 결과적으로 HR은 추천 시스템이 얼마나 많은 환자들에게 실제 적합한 운동을 처방하는가를 의미한다.

$$HR@K = \frac{|U_{hit}^K|}{|U|} \quad (7)$$

NDCG는 아래와 같이 정의된다²⁵⁾. $NDCG@K$ 는 전체 환자에 대한 NDCG, M 은 전체 사용자 수, $NDCG_u@K$ 는 개별 환자에 대한 NDCG이다. $DCG_u@K$ 에서 y_i 는 추천된 K개의 운동 중 i 번째 운동이 환자의 테스트 데이터 T_u 내 운동에 속하면 1, 아니면 0의 값을 가진다. $IDCG_u@K$ 은 $DCG_u@K$ 의 이상적인 경우로서 T_u 의 모든 운동이 상위 K개 운동의 앞순위에 추천된 경우이다. 결과적으로 NDCG는 추천 순위의 개념까지 반영한 지표로서 운동들이 상위 K개의 운동의 앞순위에 옹게 추천될 수록 높게 기록된다.

$$NDCG@K = \frac{1}{M} \sum_{u \in U} NDCG_u@K \quad (8)$$

$$\begin{aligned} NDCG_u@K &= \frac{DCG_u@K}{IDCG_u@K} \\ DCG_u@K &= \sum_{i=1}^K \frac{2^{y_i} - 1}{\log_2(i + 1)} \end{aligned} \quad (9)$$

$$IDCG_u@K = \sum_{i=1}^{\min(|T_u|, K)} \frac{1}{\log_2(i + 1)}$$

Precision (P)과 Recall (R)은 아래와 같이 정의된

다^[25]. R_u^K 는 환자 u 에게 추천된 상위 K 개의 운동을 의미한다. Precision은 상위 K 개의 운동들 중 테스트 데이터에 실제 포함된 것들의 비율을, Recall은 테스트 데이터 내 운동들 중 환자에게 추천된 운동의 비율을 의미한다.

$$P@K = \frac{1}{M} \sum_{u \in U} \frac{|T_u \cap R_u^K|}{K} \tag{10}$$

$$R@K = \frac{1}{M} \sum_{u \in U} \frac{|T_u \cap R_u^K|}{|T_u|}$$

4.3 파라미터 튜닝 및 모델 최적화

추천 시스템의 학습을 진행하며 잠재요인(latent factor) 수, 네거티브 샘플(negative sample) 수와 MLP 모델의 은닉층 수 등을 변화시키며 파라미터 튜닝을 진행하였다. 우선 잠재요인 수를 변화시키며 추천모델의 성능을 살펴보았다.

잠재요인 수를 [4, 8, 16, 32, 64]로 변경하며 모델의 정확도 성능 변화를 살펴보았다. 우선 그림 4와 같이 어깨 질환의 경우 잠재요인 수가 8, 16일 때 성능 증가가 완만하며, 그 이후로는 감소하는 모습을 보였다. 그림 5의 허리 질환의 예를 보면 잠재요인 수가 8인 이후로 성능 증가가 거의 없는 것을 알 수 있다. 이에 이후 학습은 잠재요인 수를 16으로 설정하여 진행하였다.

Log loss를 이용한 추천모델 학습과 관련하여 네거티브 샘플 수를 변화시키며 파라미터 튜닝을 수행하였다. 네거티브 샘플 수는 [2, 4, 6, 8, 10, 12, 14]로 변화시키며 추천모델의 정확도 성능 변화를 살펴보았다.

먼저 어깨 질환의 경우 그림 6을 보면 네거티브 샘플

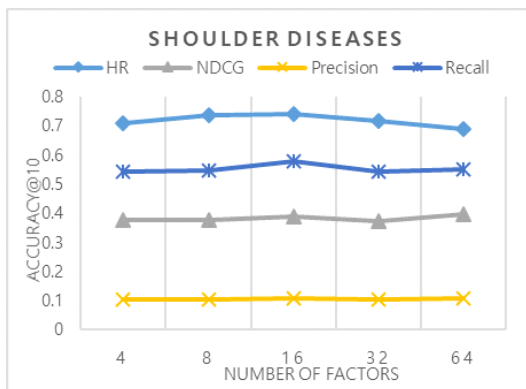


그림 4. 잠재요인 수에 따른 학습 결과(어깨 질환)
Fig. 4. Learning of the model with respect to the number of factors (shoulder diseases)

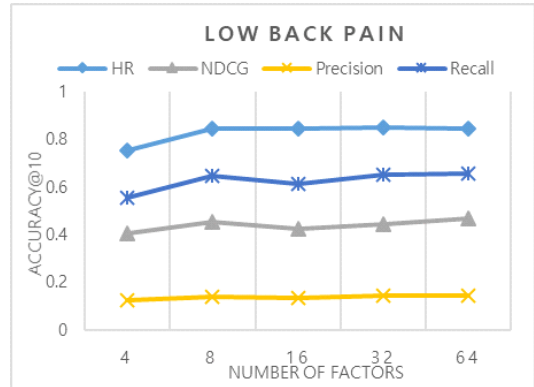


그림 5. 잠재요인 수에 따른 학습 결과(허리 통증)
Fig. 5. Learning of the model with respect to the number of factors (low back pain)

플 수가 8일 때까지 성능이 점차 증가하다 그 이후로 감소하는 것을 알 수 있다. 허리 질환의 경우에는 그림 7과 같이 네거티브 샘플 수가 4~10인 동안 성능

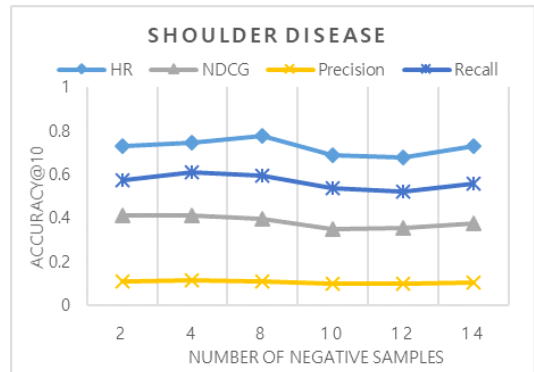


그림 6. 네거티브 샘플 수에 따른 학습 결과(어깨 질환)
Fig. 6. Learning of the model with respect to the number of negative samples (shoulder diseases)




그림 7. 네거티브 샘플 수에 따른 모델의 성능(허리 통증)
Fig. 7. Performance of the model with respect to the number of negative samples (low back pain)

증가가 거의 없다가 이후에 감소하는 모습을 보였다. 이후 추천모델 학습은 네거티브 샘플 수를 8로 정하여 진행하였다.

4.4 운동 추천 시스템 실험 결과

4.4.1 NeuMF 기반 운동 추천 모델 학습 결과

그림 8은 어깨 질환 대상 재활운동에 대한 Top-K 추천모델의 학습 결과를 보여준다. 추천모델 학습이 초기에 빠르게 수렴하는 것을 알 수 있었다. 8번 반복한 후에 정확도 성능이 거의 일정하거나 다소 감소하는 모습을 보였으며, HR 기준으로 최대 0.766의 성능을 보였다.

그림 9는 허리 통증 질환 대상 재활운동에 대한 Top-K 추천모델의 학습 결과를 보여준다. 이 경우에도 추천모델 학습이 빠르게 수렴하는 것을 알 수 있었다. 허리 통증 질환의 경우에도 8번 학습을 반복한 후

에 정확도 성능이 감소하거나 거의 일정한 모습을 보였으며, HR 기준으로 최대 0.880의 성능을 보였다.

4.4.2 추천 모델들간 정확도 성능 비교

본 절에서는 지금까지 설명한 NeuMF 모델 기반의 재활운동 추천 시스템의 성능을 GMF 및 MLP 모델을 이용한 경우의 성과와 비교하여 정리하였다. 표 4의 어깨 질환 환자에 대한 재활운동 추천모델간 성능 비교 결과를 살펴보면, NeuMF 모델의 경우가 나머지 두 모델에 비해 좋은 성능을 보였다. 구체적으로는 K = 5, 10일 때 NeuMF 모델이 좋은 성능을 보였는데, K = 5 일 때 GMF 모델의 HR 수치가 더 높기는 했으나 그 차이가 작고 나머지 세 가지 지표들은 NeuMF 모델이 모두 높았다. K = 7일 때는 GMF 모델이 제일 좋은 성능을 보였으나, 상위 K개의 추천 결과를 제시하는 Top-K 추천 방식에 있어서는 보다 작은 K = 5에서도 더 높은 성능을 보이는 NeuMF 모델이 더 우수하다고 판단할 수 있다. 어깨 질환 환자에 대한 재활운동 추천모델의 경우 HR 기준 최소 0.641, 최고 0.766의 수치를 보였다.

표 5의 허리 통증 환자에 대한 추천모델간 성능 비교를 살펴보면 K = 5, 7인 경우 GMF의 Precision을 제외하고는 NeuMF 모델이 가장 좋은 성능을 보였다. 반면 K = 10인 경우에는 GMF의 성능이 더 우수하였다. 다만, Top-K 방식의 추천에서 보다 작은 K = 5에서 좋은 성능을 보인 NeuMF가 더 우수하다고 판단할 수 있다. 전체적으로 보면 허리 통증 질환 환자에 대한 재활운동 추천 모델은 HR 기준으로 최소 0.740부터 최고 0.885의 성능을 보였다.

이때 K가 증가함에 따라 HR, NDCG 그리고 Recall 지표는 함께 증가하나 Precision은 점차 감소하는 것을 확인하였다. 이는 Precision이 다른 지표들과 달리 K에 대한 비율로서 K값 증가에 따라 낮아지게 된 것으로 판단된다. 다만, Precision은 추천보다는 분류 문제에 주로 활용되는 지표로서 HR이나 NDCG에 비해 추천 시스템의 설계에 미치는 영향은 보다 적다고 생각된다. HR 및 NDCG 관련해서는 K를 크게 설정할 수록 사용자 효용성은 낮아지므로 성능변화를 보며 적절히 정해야 할 것으로 판단된다.

4.5 토의 및 향후 연구방향

허리 질환에 비해 어깨 질환 재활운동 추천의 성능이 좋지 못한 이유로는 데이터가 보다 적었던 점도 들 수 있겠으나, 실제로 어깨와 허리 질환의 경우 환자운동 행렬의 크기가 각각 54 x 111과 52 x 95, 상호작




그림 8. 어깨 질환 재활운동 추천모델 학습
Fig. 8. Learning of the exercise recommender model for shoulder diseases




그림 9. 허리 통증 질환 재활운동 추천모델 학습
Fig. 9. Learning of the exercise recommender model for low back pain diseases

표 4. 어깨 질환 환자 재활운동 추천모델간 성능 비교
Table 4. Performance comparison of recommender models for shoulder disease patients

	K	HR	NDCG	Precision	Recall
NeuMF	5	0.637	0.352	0.167	0.450
	7	0.694	0.380	0.138	0.516
	10	0.766	0.410	0.111	0.601
GMF	5	0.641	0.342	0.163	0.440
	7	0.714	0.398	0.139	0.532
	10	0.747	0.419	0.109	0.588
MLP	5	0.527	0.275	0.131	0.347
	7	0.617	0.307	0.114	0.423
	10	0.680	0.332	0.096	0.514

표 5. 허리 통증 환자 재활운동 추천모델간 성능 비교
Table 5. Performance comparison of recommender models for back pain disease patients

	K	HR	NDCG	Precision	Recall
NeuMF	5	0.740	0.415	0.214	0.498
	7	0.832	0.451	0.186	0.598
	10	0.880	0.469	0.142	0.656
GMF	5	0.736	0.400	0.215	0.496
	7	0.817	0.438	0.182	0.588
	10	0.885	0.469	0.145	0.667
MLP	5	0.606	0.334	0.184	0.412
	7	0.697	0.369	0.150	0.484
	10	0.803	0.409	0.128	0.585

용 데이터 수가 446개와 480개로 큰 차이는 없었다. 결국 이보다는 환자와 운동간 상호작용 데이터의 분포에 원인이 있을 것으로 판단하였다.

기본적으로 협업 필터링 방식의 추천은 같은 영화를 여러 사람들이 보는 등 사용자 간에 아이템에 대한 상호작용의 공통된 부분이 많을 수록 보다 좋은 성능을 보인다. 그러나 재활운동 중재의 경우에는 환자별로 운동 조합을 점진적으로 변화시키기도 하지만, 환자가 운동 수행을 지루하게 여기지 않고 지속적으로 참여할 수 있도록 완전히 다른 조합의 운동들로 바꾸어 중재하기도 한다. 결과적으로 같은 환자에 대해서도 공통된 운동이 적을 정도로 데이터 분포 및 희소성에 문제가 발생할 수 있다.

실제로도 임상 데이터를 살펴보면 어깨 질환의 경우가 허리 질환에 비해 이러한 문제가 심한 것으로 나타났다. 그림 10은 어깨 질환에 대한 환자별 운동수행 데이터의 일부분을 보여주는데, 가로축 항목들은 환자 및 운동수행 일자, 세로축 항목들은 운동을 나타내며 가운데 영역의 색칠된 부분은 특정 환자가 특정 운동을 수행한 내역을 나타낸다. 결과적으로 매회차 환자들에게 모두 다른 운동들이 제공되어, 환자들간에도 겹쳐 수행한 운동들이 없는 것을 알 수 있다. 어깨 질환

환의 경우 이러한 운동들의 수가 허리 질환에 비해 2배 가까이 많은 것으로 나타났다.

NeuMF 모델의 성능을 GMF 및 MLP 모델과 비교한 실험에서 특히, 어깨 질환 환자 대상의 경우 예상과 달리 그 성능이 나머지 두 모델에 비해 뚜렷이 우수하지는 못한 것을 확인하였다. 이에 대해서는 그 원인을 계속 분석 중에 있으나 데이터 부족 문제가 가장 큰 것으로 추정하고 있으며, 이에 지속적인 데이터 확충과 추가 실험 진행이 필요할 것으로 판단된다.

위에서 언급한 문제들은 궁극적으로 데이터 부족과 해당 도메인의 고유한 데이터 특징에 따른 것으로 생각되며, 이러한 문제들은 학습 데이터가 더 확충됨에 따라 점차 해결될 수 있을 것으로 판단된다. 이에 본 연구에서는 현재 임상시험을 계속 진행 중이며, 다음 차년도에는 본격적인 실증을 하기 위해 다른 병원들의 추가 참여도 추진하고 있다. 향후 임상 데이터의 지속적인 확충과 추가 연구 및 실험들을 계획 중에 있다. 데이터 분포 및 희소성 문제 관련해서는 비슷한 유형의 운동들을 상위 개념의 운동으로 통합하거나, 준비운동, 본운동, 정리운동별로 나누어 학습 및 추천을 진행하는 등 여러 가지 방안도 향후 연구를 통해 시도할 수 있을 것이다.

	RS05 20220503	RS05 20220510	RS05 20220517	RS05 20220524	RS05 20220531	RS05 20220608	RS05 20220614
1662603009							
1662602907							
1662603026							
1662603232							
1662603196							
1662602986							
1662603091							
1662602976							
1662602973							
1662602980							
1662603070							
1662603228							
1662603072							
1662603077							
1662602905							
1662603079							

그림 10. 어깨 질환 환자의 재활운동 수행 관련 데이터 분포 문제 예
 Fig. 10. An example of data sparsity problem of the shoulder disease patients

협업 필터링 방식의 본 추천 시스템의 경우에 사용자와 아이템 사이의 상호작용 데이터를 입력으로 함에 따라 새로운 환자에 대해 ‘new user problem’이라 불리는 문제가 발생할 수 있다. 다시 말해 새로운 환자의 경우 운동 처방이력이 없기 때문에 학습을 수행할 수 없게 된다. 이 경우에 협업 필터링만으로는 해결이 어렵고 콘텐츠 기반 필터링 방식 등을 병행해 해결하게 된다. 예를 들어 운동 처방이력이 없는 새로운 환자의 경우 환자의 상태 등 속성 정보를 이용해 해당 환자와 유사한 기존 환자들에게 처방되었던 운동들 중에서 추천을 받아 처방하게 되고, 이후에는 이 처방 내역이 해당 환자의 상호작용 데이터로 이용된다. 실제로 본 연구에서도 콘텐츠 기반 필터링 방식의 추천 시스템을 병행해 진행하고 있으며, 새 환자의 경우 이 방식을 대신 이용해 추천하는 서비스 시나리오로 진행 중에 있다.

환자와 운동간 상호작용 데이터로는 운동 처방 여부와 같이 사용자 평가가 반영되지 않은 암시적 데이터를 입력으로 할 수도 있으나, 만족도, 적합도 등의 평가가 반영된 명시적 데이터도 입력으로 할 수 있다. 다만, 명시적 데이터의 경우 사용자 참여가 필요하여 데이터 수집이 어렵고, 편향된 또는 잘못된 정보가 유입 가능한 문제가 있다. 이에 본 연구에서 우선 운동 처방여부인 암시적 피드백 정보만을 우선 이용하여 추천 시스템 개발을 진행하였다. 그리고 본 추천 시스템을 활용하는 건강운동관리사의 평가, 운동을 수행한 후 환자의 평가, 운동 수행 후 집계되는 원수율 등의 데이터를 취득할 수 있도록 관련 기능들을 함께 구현하였으나, 아직까지 데이터 수집이 충분하지 않아 이

에 대한 활용은 향후 연구에서 진행할 계획이다.

본 연구의 결과를 바탕으로 향후 후속연구들이 성공적으로 수행될 경우 개인맞춤형 재활운동 추천을 통해 재활환자의 기능회복 및 건강증진, 빠르고 안전한 사회복귀를 효과적으로 도울 수 있을 것으로 기대된다.

V. 결론

본 연구에서는 재활운동 중재 임상시험 데이터를 대상으로 개인맞춤형 재활운동 추천 알고리즘을 개발하였다. 세종충남대병원에서 어깨 유착성 관절낭염 및 회전근개 손상 환자와 허리 통증 환자를 대상으로 수행 중인 재활운동 중재 임상시험 데이터로부터 협업 필터링 기반의 추천 알고리즘 개발을 위한 학습 데이터셋을 생성하였다. 생성된 학습 데이터셋을 적용해 NCF의 NeuMF 모델을 기반으로 재활운동 추천 알고리즘을 개발하여 그 성능을 검증하였다. 개발된 재활운동 추천 알고리즘을 GMF 및 MLP 모델 기반의 방법과 비교하여 더 좋은 성능을 보임을 확인하였다. 지속적인 임상 데이터 추가 수집과 함께 데이터 희소성 문제 해결, 명시적 상호작용 데이터 활용, 환자 및 운동의 속성정보 활용 등의 향후 연구를 통해 개인맞춤형 재활운동 추천 기술을 개발하여 재활환자의 기능회복과 사회복귀를 도울 수 있을 것으로 기대된다.

References

[1] B. Stark, C. Knahl, M. Aydin, and K. Elish,

- “A literature review on medicine recommender systems,” *Int. J. Advanced Comput. Sci. and Appl.*, vol. 10, no. 8, pp. 6-13, 2019.
(<https://doi.org/10.14569/ijacsa.2019.0100802>)
- [2] M. Wiesner, and D. Pfeifer, “Health recommender systems: Concepts, requirements, technical basics and challenges,” *Int. J. Environ. Res. and Public Health*, vol. 11, pp. 2580-2607, 2014.
(<https://doi.org/10.3390/ijerph110302580>)
- [3] A. Holzinger, A. C. Valdez, and M. Ziefle, “Towards interactive recommender systems with the doctor-in- the-loop,” *LNI Proc. Series of the Gesellschaft für Informatik*, 2016.
(<https://doi.org/10.18420/muc2016-ws11-0001>)
- [4] J. Pincay, L. Terán, and E. Portmann, “Health recommender systems: A state-of-the-art review,” *2019 Sixth ICEDEG*, pp. 47-55, 2019.
(<https://doi.org/10.1109/ICEDEG.2019.8734362>)
- [5] A. K. Sahoo, C. Pradhan, R. K. Barik, and H. Dubey, “Deepreco: Deep learning based health recommender system using collaborative filtering,” *Computation*, vol. 7, no. 2, 2019.
(<https://doi.org/10.3390/computation7020025>)
- [6] H. Schäfer, S. Hors-Fraile, R. P. Karumur, A. Calero Valdez, A. Said, H. Torkamaan, T. Ulmer, and C. Trattner, “Towards health (aware) recommender systems,” in *Proc. 2017 Int. Conf. DH '17*, pp. 157-161, 2017.
(<https://doi.org/10.1145/3079452.3079499>)
- [7] W. Ismail, IAA-Q. Al-Hadi, C. Grosan, and R. Hendradi, “Improving patient rehabilitation performance in exercise games using collaborative filtering approach,” *PeerJ Comput. Sci.*, vol. 7, pp. 1-29, 2021.
(<https://doi.org/10.7717/PEERJ-CS.599>)
- [8] J. Cao, Z. Wu, B. Mao, and Y. C. Zhang, “Shilling attack detection utilizing semi-supervised learning method for collaborative recommender system,” *World Wide Web*, vol. 16, no. 5-6, pp. 729-748, 2013.
(<https://doi.org/10.1007/s11280-012-0164-6>)
- [9] J. Cao, Z. Wu, Y. Q. Wang, and Y. Zhuang, “Hybrid collaborative filtering algorithm for bidirectional web service recommendation,” *Knowl. Inform. Syst.*, vol. 36, no. 3, pp. 607-627, Sep. 2013.
(<https://doi.org/10.1007/s10115-012-0562-1>)
- [10] S. X. Gao, Z. T. Yu, L. B. Shi, X. Yan, and H. X. Song, “Review expert collaborative recommendation algorithm based on topic relationship,” *IEEE/CAA J. Autom. Sinica*, vol. 2, no. 4, pp. 403-411, Oct. 2015.
(<https://doi.org/10.1109/JAS.2015.7296535>)
- [11] L. H. Li, W. Chu, J. Langford, and R. E. Schapire, “A contextual-bandit approach to personalized news article recommendation,” in *Proc. 19th Int. Conf. World Wide Web*, Raleigh, USA, pp. 661-670, 2010.
(<https://doi.org/10.1145/1772690.1772758>)
- [12] K. Xu, W. Zhang, and Z. Yan, “A privacy-preserving mobile application recommender system based on trust evaluation,” *J. Computational Sci.*, vol. 26, no. 5, pp. 87-107, 2018.
(<https://doi.org/10.1016/j.joics.2018.04.001>)
- [13] N. Zainal, M. Z. M. Faeid, S. M. M. Kahaki, H. Hussain, M. Bahari, and W. Ismail, “Prediction scoring in exergames for rehabilitation patients using K-means clustering,” *2019 6th ICRIS*, pp. 1-6, 2019.
(<https://doi.org/10.1109/ICRIS48246.2019.9073659>)
- [14] L. Duan, W.N. Street, and E. Xu, “Healthcare information systems: Data mining methods in the creation of a clinical recommender system,” *Enterp. Inform. Syst.*, vol. 5, no. 2, pp. 169-181, Jan. 2011.
(<https://doi.org/10.1080/17517575.2010.541287>)
- [15] A. S. Hussein, W. M. Omar, X. Li, and M. A. Hatem, “Smart collaboration framework for managing chronic disease using recommender system,” *Health Syst.*, vol. 3, no. 1, pp. 12-17, Feb. 2014.
(<https://doi.org/10.1057/hs.2013.8>)
- [16] W. Yue, Z. Wang, J. Zhang, and X. Liu, “An overview of recommendation techniques and their applications in healthcare,” *IEEE/CAA J.*

- Automatica Sinica*, vol. 4, no. 4, pp. 701-717, 2021.
(<https://doi.org/10.1109/JAS.2021.1003919>)
- [17] T. N. T. Tran, A. Felfernig, C. Trainer, and A. Holzinger, "Recommender systems in the healthcare domain: State-of-the-art and research issues," *J. Intell. Inf. Syst.*, vol. 57, pp. 171-201, 2021.
(<https://doi.org/10.1007/s10844-020-00633-6>)
- [18] D. Elsweiler, B. Ludwig, A. Said, H. Schaefer, and C. Trattner, "Engendering health with recommender systems," in *Proc. 10th ACM Conf. Recommender Syst.*, pp. 409-410, 2016.
(<https://doi.org/10.1145/2959100.2959203>)
- [19] S. Dharia, V. Jain, J. Patel, J. Vora, S. Chawla, and M. Eirinaki, "Pro-fit: A personalized fitness assistant framework," *Proc. Int. Conf. Softw. Eng. and Knowledge Eng.*, pp. 386-389, 2016.
(<https://doi.org/10.18293/SEKE2016-174>)
- [20] E. Kulev, V. Vlahu-Gjorgievska, V. Trajkovik, and S. Koceski, "Recommendation algorithm based on collaborative filtering and its application in health care," in *Proc. 10th Conf. Informat. and Inf. Technol.*, pp. 34-38, 2013.
- [21] S. Dharia, M. Eirinaki, V. Jain, J. Patel, I. Varlamis, J. Vora, and R. Yamauchi, "Social recommendations for personalized fitness assistance," *Pers. Ubiquitous Comput.*, vol. 22, no. 2, pp. 245-257, 2017.
(<https://doi.org/10.1007/s00779-017-1039-8>)
- [22] T. Prestmo, K. Bach, A. Aamodt, and P. J. Mork, "Evolutionary inspired adaptation of exercise plans for increasing solution variety," *Case-Based Reasoning Res. and Develop.*, pp. 272-286, 2017.
(https://doi.org/10.1007/978-3-319-61030-6_19)
- [23] S. I. Ali, M. B. Amin, S. Kim, and S. Lee, "A hybrid framework for a comprehensive physical activity and diet recommendation system," *Smart homes and health telematics, designing a better future: urban assisted living (ICOST 2018)*, pp. 101-109, 2018.
(https://doi.org/10.1007/978-3-319-94523-1_9)
- [24] V. S. Vairale and Shukla, "Physical fitness recommender framework for thyroid patients using restricted boltzmann machines," *Int. J. Intell. Eng. & Syst.*, vol. 13, no. 5, pp. 247-256, 2020.
(<https://doi.org/10.22266/ijies2020.1031.22>)
- [25] S. Kim, J. H. Oh, D. Oh, C. Seo, and W. Y. Shin, "Personalized exercise recommender systems for rehabilitation using graph neural networks," *J. KICS*, vol. 47, no. 4, pp. 644-655, 2022.
(<https://doi.org/10.7840/kics.2022.47.4.644>)
- [26] X. He, L. Liao, H. Zhang, L. Nie, X. Hu, and T.-S. Chua, "Neural Collaborative Filtering," *Proc. 26th Int. Conf. WWW*, pp. 173-182, Apr. 2017.
(<https://doi.org/10.48550/arXiv.1708.05031>)
- [27] B. Wang, *Ranking Evaluation Metrics for Recommender Systems* (2021), Retrieved Oct., 20, 2022, from <https://towardsdatascience.com/ranking-evaluation-metrics-for-recommender-systems-263d0a66ef54>

장 윤 섭 (Yoon-Seop Chang)



1999년 2월 : 서울대학교 자원공
학과 학사

2001년 2월 : 서울대학교 지구환
경시스템공학부 석사

2005년 8월 : 서울대학교 지구환
경시스템공학부 박사

2005년 9월~현재 : 한국전자통
신연구원(ETRI) 책임연구원

<관심분야> 추천시스템, 기계학습, 혼합현실, 공간정보
시스템

[ORCID:0000-0002-4074-4368]

전 부 선 (Boosun Jeon)



1998년 2월 : 충남대학교 컴퓨터
과학과 학사
2000년 2월 : 충남대학교 컴퓨터
과학과 석사
2000년 1월~5월 : 삼성전자 중앙
연구소 연구원
2000년 6월~현재 : 한국전자통
신연구원(ETRI) 책임연구원


<관심분야> 추천시스템, 데이터 마이닝

한 미 경 (Mikyong Han)



1993년 8월 : 경희대학교 전자
계산공학과 석사
1993년 9월~현재 : 한국전자통
신연구원(ETRI) 책임연구원
<관심분야> 서비스플랫폼, 지능
형 서비스, 추천시스템

박 노 삼 (NohSam Park)



1997년 2월 : 경북대학교 컴퓨터
공학과 학사
1999년 2월 : 경북대학교 컴퓨터
공학과 석사
2013년 12월 : Carnegie Mellon
University Software Engine-
ering 석사

2001년 1월~현재 : 한국전자통신연구원(ETRI) 책임연
구원

<관심분야> 빅데이터, 기계학습

김 재 철 (Jae-Chul Kim)



1999년 2월 : 경북대학교 전자
공학과 학사
2001년 2월 : 경북대학교 전자
공학과 석사
2001년 1월~현재 : 한국전자통
신연구원(ETRI) 책임연구원
<관심분야> 플랫폼, 인공지능,
영상처리