

GEase-K: 부가 정보를 활용한 선형 및 비선형 오토인코더 기반의 추천시스템

이태범

국민대학교 시빅데이터융합경영학과
(hitesarang@gmail.com)

마민정

국민대학교 시빅데이터융합경영학과
(maminjeong3199@gmail.com)

이승학

국민대학교 시빅데이터융합경영학과
(dltdgkr95@gmail.com)

조윤희

국민대학교 시빅데이터융합경영학과
(www4u@kookmin.ac.kr)

최근 추천시스템 분야에서는 희소한 데이터를 효과적으로 모델링하기 위한 다양한 연구가 진행되고 있다. GLocal-K(Global and Local Kernels for Recommender Systems)는 그중 하나의 연구로 전역 커널과 지역 커널을 결합하여 데이터의 전역적인 패턴과 개별 사용자의 특성을 모두 고려해 사용자 맞춤형 추천을 제공하는 모델이다. 하지만 GLocal-K는 커널 트릭을 사용하기 때문에 매우 희소한 데이터에서 성능이 떨어지고 부가 정보를 사용하지 않아 새로운 사용자나 아이템에 대한 추천을 제공하는 데 어려움이 있다. 본 논문에서는 이러한 GLocal-K의 단점을 극복하기 위해 EASE(Embarrassingly Shallow Autoencoders for Sparse Data) 모델과 부가 정보를 활용한 GEase-K(Global and EASE kernels for Recommender Systems) 모델을 제안한다. 우선 GLocal-K의 지역 커널 대신 EASE를 활용하여 매우 희소한 데이터에서 추천 성능을 높이고자 하였다. EASE는 단순한 선형 연산 구조로 이루어져 있지만, 규제화와 아이템 간 유사도 학습을 통해 매우 희소한 데이터에서 높은 성능을 내는 오토인코더이다. 다음으로 Cold Start 완화를 위해 부가 정보를 활용하였다. 학습 과정에서 부가 정보를 추가하기 위해 조건부 오토인코더 구조를 적용하였으며 이를 통해 사용자-아이템 간의 유사성을 더 잘 파악할 수 있도록 하였다. 결론적으로 GEase-K는 선형 구조와 비선형 구조의 결합, 부가 정보의 활용을 통해 매우 희소한 데이터와 Cold Start 상황에서 강건한 모습을 보인다. 실험 결과, GEase-K는 매우 희소한 GoodReads, ModCloth 데이터 세트에서 RMSE, MAE 평가 지표 기준 GLocal-K 보다 높은 성능을 보였다. 또한 GoodReads, ModCloth 데이터 세트를 4개의 집단으로 나누어 실험한 Cold Start 실험에서도 GLocal-K 대비 Cold Start 상황에서 좋은 성능을 보였다.

주제어 : 추천시스템, 딥러닝, 오토인코더, 부가 정보, 희소성 문제

논문접수일 : 2023년 8월 16일

논문수정일 : 2023년 8월 25일

게재확정일 : 2023년 8월 28일

원고유형 : Regular Track

교신저자 : 조윤희

1. 서론

현대 사회에서 인터넷과 소셜 네트워크 서비스(SNS)가 빠르게 발달하며 개인화를 뛰어넘는 초개인화 사회가 형성되고 있다. 개인은 다양한 상품과 개인화된 경험을 필요로 하고, 따라서 한정된 공간과 자원으로 인해 이전에 주목받지 못했던

롱테일(Long tail) 상품들이 다양한 형태로 시장에 출시되어 이제는 소비자들의 주목을 받을 뿐만 아니라 실질적인 수요를 끌어들이고 있다(전채연, 2010). 이처럼 초개인화 사회에 들어선 현재 소비자에게 적절한 상품을 추천해 주는 추천 시스템의 중요성이 높아지고 있다(Das et al., 2013). 최근에는 빅데이터 처리, 복잡한 패턴 학습,

자동화된 특징 추출, 다양한 데이터 유형의 통합 등에 우수한 성과를 보여주는 딥러닝 기술을 활용하여 다양한 유형의 추천 시스템이 개발되고 있다. 그래프 신경망(Graph Neural Network) 기반의 GHRS(Darban and Valipour, 2022)와 IGMG(Zhang and Chen, 2020), 오토인코더(Autoencoder) 기반의 GLocal-K(Han et al., 2021), VASP(Vančura and Kordík, 2021), H+Vamp Gated(Kim and Suh, 2019), 그리고 대조학습(Contrastive Learning) 기반의 C2-CRS(Zhou et al., 2022) 등이 대표적인 딥러닝 기반 추천시스템으로서 MovieLens, Netflix Prize, Amazon-Book, Douban, Gowalla, ReDial과 같은 벤치마크 데이터셋에서 최고 수준의 SOTA(State-of-the-art) 성능을 보여주고 있다(Papers With Code, 2023).

이중에서 GLocal-K(Global and Local Kernels for Recommender Systems)(Han et al., 2021)는 추천 시스템 분야에서 대표적으로 사용하는 MovieLens 데이터 세트(Harper et al., 2015)에서 가장 높은 성능을 보이는 모델이다. GLocal-K의 방법론은 지역 커널과 전역 커널을 결합하여 고차원의 사용자-아이템 행렬을 저차원 공간으로 매핑하고 중요한 특징을 추출하는 것을 목표로 한다. 이때 지역 커널에는 RBF(Radial Basis Function) 커널, 전역 커널에는 CNN(Convolution Neural Network) 구조를 사용하였고 사전 학습과 미세 조정 과정을 통해 데이터의 전역적인 패턴과 개별 사용자의 특성을 모두 고려한다. 하지만, GLocal-K에서 사용하는 비선형 커널 트릭은 매우 희소한 데이터(Rendle, 2010; Zhang et al., 2019)에서 모델의 파라미터 학습 성능을 떨어뜨린다. GLocal-K의 지역 커널에서 활용하는 RBF 커널은 데이터 포인트 간의 거리에 따라 유사도를 결정하는데, 데이터가 매우 희소할 경우 데이터 포인트 간의 거리

가 제대로 정의되지 않거나 정확한 유사도 계산을 어렵게 만든다. 또한, 추천시스템의 고질적인 문제점 중 하나인 Cold Start 문제가 GLocal-K에서도 발생한다. 희소한 평점 행렬에서는 데이터가 적기에 모델이 충분한 데이터를 기반으로 학습하거나 추론하기 어렵고, 데이터가 편향적일 경우 모델이 일부 사용자나 아이템에 치우친 추천을 하기 때문에 Cold Start 문제가 발생하기 쉽다. 일반적으로는 부가 정보를 활용하여 Cold Start 상황을 극복하지만(Wei et al., 2021; 송경우, 문일철, 2021; 홍태호 등, 2022), GLocal-K는 동일한 구조의 오토인코더 모델을 사전 학습과 미세 조정에 활용하기 때문에 학습 과정에서 부가 정보를 쉽게 사용하기 어렵다. 따라서 본 논문에서는 매우 희소한 데이터에서 학습을 할 때 성능이 떨어지고, Cold Start 문제가 발생하는 GLocal-K 모델의 한계점을 보완한 새로운 모델을 제안한다.

먼저 매우 희소한 데이터에서 더욱 좋은 성능을 얻기 위해 EASE(Embarrassingly Shallow Autoencoders for Sparse Data) 모델을 활용한다. EASE는 규제화와 아이템 간 유사도 학습을 통해 모델의 최종 연산 결과가 입력 데이터와 동일하도록 파라미터를 학습하여 희소한 데이터에서 좋은 성능을 보이는 모델이다(Steck et al., 2019). 희소한 데이터 환경에서 학습이 잘 이루어지지 않는 GLocal-K의 RBF 커널 대신 파라미터의 최적 해를 닫힌 형태(Closed-form)로 표현할 수 있는 EASE의 선형모델을 활용함으로써 평점이 없는 사용자와 아이템에 대해 보다 잘 학습할 수 있다. 다음으로 매우 희소한 데이터에서 추가로 발생할 수 있는 Cold Start 문제를 해결하기 위해 부가 정보를 활용한다. 많은 추천시스템 연구에서 부가 정보를 사용하여 Cold Start 문제가 상당히 완화될 수 있음을 보여주고 있으나(Lee et al., 2017), GLocal-K

는 부가정보를 수용할 수 없는 모델구조를 갖고 있기 때문에 새로운 접근법이 요구된다. 본 연구에서는 다양한 형태의 부가 정보 중에 아이템과 관련된 부가 정보를 활용하고, 이러한 부가 정보를 효과적으로 모델에 넣기 위해 GLocal-K의 미세 조정(Fine-tuning)을 위한 오토인코더를 AutoRec(Sedhain et al., 2015)과 CVAE(Kingma et al., 2014)에서 사용했던 부가 정보 기반의 비선형 오토인코더로 대체하고자 한다.

본 연구에서는 EASE의 방법론과 부가 정보를 사용한 CVAE 구조를 활용하여 매우 희소한 데이터와 Cold Start 상황에서 나타나는 GLocal-K의 문제점을 극복하고자 하였다. 이를 검증하기 위해 MovieLens-100K, GoodReads(Goodreads, 2017), ModCloth(Misra et al., 2018) 밀집도가 다른 총 세가지 데이터 세트에서 모델의 성능을 비교해 보았으며, 그 중 밀집도가 매우 낮아 Cold Start 문제가 발생하기 쉬운 GoodReads와 ModCloth 데이터 세트에서는 추가적으로 Cold Start 집단을 설정하여 실험을 진행하였다. 그 결과 본 연구에서 제안하는 모델이 매우 희소한 환경과 Cold Start 상황에서 모두 GLocal-K의 성능을 능가하였으며, 선형 및 비선형 연산을 모두 활용한 구조가 매우 희소한 데이터에서 강력한 성능을 얻음을 확인할 수 있었다.

2. 문헌 연구

2.1 GLocal-K (Global and Local Kernels for Recommender Systems)

GLocal-K는 다양한 데이터 세트에서 높은 성능을 달성한 최신 모델이다. 전역 및 지역 커널을

활용하여 사용자와 아이템 간의 상호작용을 모델링하며 해당 관계를 동시에 고려하는 장점을 가지고 있다. GLocal-K는 전역 및 지역 커널 기반의 사전 학습-미세 조정 구조로 이루어져 희소성이 크고 차원이 높은 평점 행렬을 저차원으로 일반화하여 표현한다. 해당 모델은 크게 두 단계로 구성되어 있다. 첫 번째 단계에서는 2차원 RBF 커널(Broomhead et al., 1988)을 지역 커널로 사용하여 오토인코더를 사전 학습한다. RBF 커널을 통해 고차원 공간에서 저차원 공간으로 데이터를 변환하여 데이터 간의 상호작용을 더 잘 파악할 수 있고 이때 새로운 가중치는 기존의 가중치와 RBF 커널 행렬과의 아다마르(Hadamard) 곱으로 계산된다. 두 번째 단계에서는 사전 학습된 오토인코더를 합성곱 전역 커널(Convolution based Global Kernel)로 만들어진 평점 행렬을 이용하여 미세 조정(Fine-tuning)한다. 이때 합성곱 전역 커널은 아이템 기반 평균 풀링(Average pooling)의 결과와 다중 커널과의 연산으로 만들어지고, 이렇게 만들어진 합성곱 전역 커널은 기존 평점 행렬과의 컨볼루션(Convolution) 연산을 통해 새로운 평점 행렬을 만들어 낸다. 이렇게 만들어진 평점 행렬을 사전 학습된 오토인코더를 이용해 미세 조정한다.

GLocal-K는 MovieLens, Douban Monti 데이터 세트(Wu et al., 2016)에서 현재 가장 높은 성능을 달성했으며 부가 정보 없이 사용자-아이템 평점 행렬만 사용하더라도 좋은 결과를 보인다. 하지만 GLocal-K의 단점도 존재한다. 첫째, GLocal-K에서 사용하는 커널 트릭은 매우 희소한 데이터에서 좋은 성능을 내기 어렵다. RBF 커널을 사용할 경우 사용자와 아이템 간의 밀접한 관계는 더 강화하고, 상대적으로 약한 관계는 더 약화하도록 학습되기 때문에 매우 희소한 데이터에서

모델을 학습할 경우 상대적으로 성능이 떨어지게 된다. 둘째, GLocal-K의 구조는 Cold Start 상황을 극복하기 어렵다. Cold Start 상황을 극복하기 위해 일반적으로 부가 정보를 활용하지만, GLocal-K는 커널 기반으로 동일한 구조의 오토인코더 모델을 사전 학습과 미세 조정에 사용하여 부가 정보를 활용하기 어렵다. 원본 평점 행렬에 부가 정보를 붙여 행렬의 크기가 변경되었을 때 아다마르 곱을 사용하여 나오는 출력 행렬은 부가 정보를 붙인 크기의 평점 행렬이 나오게 되며 이는 예측하고자 하는 평점 행렬의 의미가 변색할 수 있어 모델의 적절한 추천을 방해한다. 따라서 GLocal-K는 희소한 환경에서의 성능 저하, 새로운 사용자와 아이템에 대한 추천 등의 한계점을 가지고 있다.

2.2 EASE (Embarrassingly Shallow Autoencoders for Sparse Data)

EASE는 희소한 데이터에 대해 효과적으로 작용하는 오토인코더이다. 이 모델은 ‘당혹스러운 얇은 오토인코더’라고 불릴 정도로 매우 얇은 오토인코더를 사용해 사용자와 아이템 간의 상호작용을 모델링한다. 라그랑주 승수법(Lagrange Multiplier Method)(Lagrange, 1770)을 사용하여 희소한 데이터에서 중요한 패턴과 상호작용을 추출하여 복원할 수 있게 만들고 잠재 요인을 학습하기 위해 목적 함수를 최적화한다. 이때 최적화 과정에서 가중치 행렬이 단위행렬로 수렴하지 않도록 가중치 행렬의 대각행렬 성분을 0으로 고정하는 제약조건을 사용하며 유한한 수의 표준 연산을 사용해 최적화 식을 닫힌 형태로 풀 수 있도록 설계한다. 이와 같은 구조로 EASE는 낮은 계산 비용으로 높은 추천 품질을 제공한다.

EASE는 MovieLens 20k, Million Song (Bertin-Mahieux et al., 2011) 데이터 세트에서 좋은 성능을 발휘하며, 매우 희소한 데이터 세트에서 특히 좋은 성능을 보인다. 또한 사용자-아이템 상호작용을 잘 모델링하여 개인화된 추천을 제공한다. 하지만 EASE는 밀집한 데이터의 경우에는 성능이 저하될 수 있다. 이는 해당 모델이 희소성을 고려하여 설계되었기 때문에 발생하는 문제이다. 모델의 복잡성과 유연성에 제한이 있을 수 있으며 비선형성을 지닌 다른 복잡한 추천 알고리즘과 비교했을 때 상대적으로 단순한 구조로 되어 있어 다양한 데이터 패턴을 모델링하는 데 제약이 있을 수 있다. 이에 따라 EASE는 다양한 외부 정보나 사회적 관계 등을 활용하는 다른 추천 모델보다 개인화된 추천의 다양성이 제한될 수 있다는 한계점을 갖는다.

2.3 AutoRec

AutoRec(Sedhain et al., 2015)은 오토인코더와 협업 필터링을 결합한 추천 시스템에 관한 연구이다. 이 모델은 사용자-아이템 상호작용 데이터를 활용하여 개인화된 추천을 제공하기 위해 협업 필터링의 장점을 활용한다. 협업 필터링은 사용자의 행동과 선호도를 분석하여 유사한 사용자나 아이템을 기반으로 학습을 진행하는 방법을 말하며, AutoRec은 오토인코더 구조를 추천시스템에 적용한 비선형성을 지닌 협업 필터링 기반 모델이다. 사용자와 아이템 간의 비선형 잠재 표현을 학습할 수 있으며 오토인코더 구조와 동일하게 사용자와 아이템 간의 특성을 잠재 벡터로 매핑하고 복원하는 방식으로 학습한다. 이 과정에서 AutoRec은 사용자와 아이템 간의 상호관계를 학습하며, 입력 데이터를 압축하여 잠재적인

특징을 추출하고 다시 복원하는 과정에서 원래 입력을 재구성하여 사용자에게 적합한 새로운 추천을 제공한다. AutoRec은 당시 MovieLens, Netflix 데이터 세트에서 좋은 성능을 보였으며, 사용자와 아이템 간의 비선형적 특징을 파악할 수 있어 기존의 협업 필터링에 비해 높은 표현력을 보인다. 하지만 딥러닝 모델들의 한계점인 층이 깊어짐에 따라 과적합의 위험이 있다는 한계점을 가지고 있다.

2.4 CVAE (Conditional Variational AutoEncoder)

CVAE(Conditional Variational AutoEncoder) (Kingma et al., 2014)는 VAE(Variational AutoEncoder) (Kingma et al., 2013)를 기반으로 입력 데이터에 조건을 추가한 조건부 생성 모델이다. 일반적인 VAE는 오토인코더 구조를 거쳐 잠재 공간으로 데이터를 압축하고 이를 확률적으로 재생성하지만, CVAE는 입력 데이터에 조건을 추가하여 생성된 출력이 특정 조건을 만족하도록 재생성한다. 추가된 조건은 원하는 출력을 고정된 분포에서 샘플링하여 생성할 수 있도록 하는 역할을 한다. 이러한 특성은 VAE의 연속적이고 확률적인 공간을 유지하면서도 원하는 출력 생성을 가능하게 하며, 잠재 변수의 연속성과 조건 간의 상호작용을 효과적으로 모델링할 수 있게 만든다. 본 연구에서는 추천시스템 분야에서 오토인코더 구조를 활용하고자 하며 사용자와 아이템 간의 상호작용을 효과적으로 파악하기 위해 부가정보를 활용하고자 한다. 이때 CVAE의 구조를 차용하여 오토인코더 구조에 아이템 기반 부가정보를 입력 데이터에 추가하는 방식으로 부가정보를 활용한 모델 구조를 제안한다.

3. GEase-K (Global and EASE Kernels for Recommender Systems)

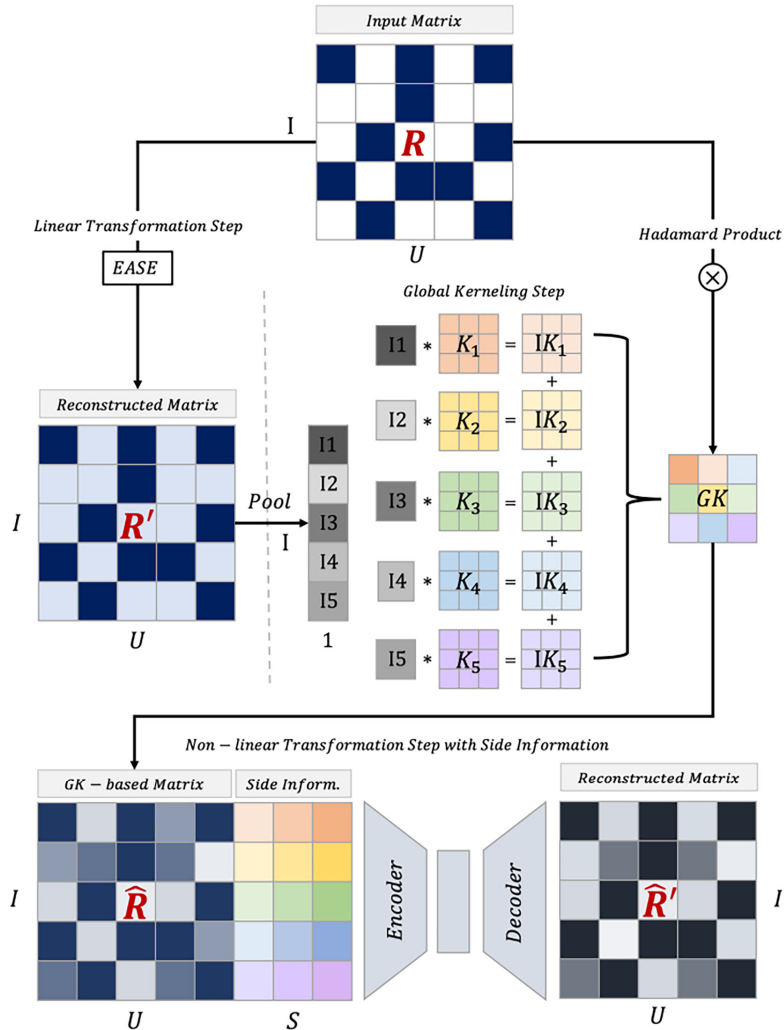
본 논문에서는 GLocal-K를 기반으로 EASE 모델과 부가 정보를 활용한 GEase-K(Global and EASE Kernels for Recommender Systems) 모델을 제안한다. GEase-K의 모델 구조는 선형 변환 단계, 전역 커널링 단계, 비선형 변환 단계의 세 단계로 이루어진다. 첫 번째 선형 단계에서는 원본 평점 행렬을 입력으로 받아 EASE 기반의 선형 연산을 통해 평점 행렬을 재구성한다. 두 번째 전역 커널링 단계에서는 재구성한 평점 행렬의 아이템 벡터에 평균 풀링(Average Pooling)을 적용하고 아다마르(Hadamard Product) 곱 연산을 수행하여 전역 커널을 만든다. 원본 평점 행렬에 이 커널을 적용한 합성곱 연산을 수행하여 다음 단계에서 사용할 새로운 평점 행렬을 만든다. 마지막 비선형 변환 단계에서는 이러한 평점 행렬에 아이템 관련 부가 정보를 추가한 후 비선형 오토인코더를 적용하여 최종 평점 행렬을 생성한다.

3.1 선형 변환 단계

선형 변환을 위해 EASE의 최적화 모델을 적용한다. 입력 평점 행렬에 최적화 모델을 적용한 출력 평점 행렬 R' 는 <수식 1>과 같은 선형 식으로 표현할 수 있다.

$$\hat{R}_{iu} = R_{i,\cdot} \cdot W_{\cdot,u} \quad \text{<수식 1>}$$

u 는 특정 사용자를 의미하며, i 는 특정 아이템을 의미한다. 원본 평점 행렬 R 에서 최적화된 파라미터 W 를 찾기 위한 목적 식은 <수식 2>와 같다.



<그림 1> 구조 도식화

$$\min_W \|R - RW\|_F^2 + \lambda \cdot \|W\|_F^2 \quad \text{<수식 2>} \\ \text{s.t. } \text{diag}(W) = 0$$

<수식 2>에서 λ 는 모델에 사용되는 매개변수이다. 이를 닫힌 형태로 풀 수 있도록 $\text{diag}(W) = 0$ 제약 조건을 <수식 2>에 적용하여 다음과 같은

<수식 3>을 만든다(Ning et al., 2011).

$$L = \|R - RW\|_F^2 + \lambda \cdot \|W\|_F^2 + 2 \cdot \lambda^T \cdot \text{diag}(W) \quad \text{<수식 3>}$$

이때 $\lambda = (\lambda_1, \dots, \lambda_{|I|})^T$ 로 라그랑주 승수 벡터 (Lagrange Multiplier Vector)이다. 이렇게 생성된

<수식 3>은 라그랑지안(Lagrangian)를 최소화함으로써 해결할 수 있으며 최종적으로 나오게 되는 추정값 \hat{W} 은 <수식 4>와 같이 나오게 된다.

$$\hat{P} := (R^T R + \lambda I)^{-1} \quad \text{<수식 4>}$$

$$\hat{W} = I - \hat{P} \cdot \text{diagMat}(\vec{1} \oslash \text{diag}(\hat{P})).$$

결과적으로 W 의 가중치는 <수식 5>와 같이 계산된다.

$$\hat{W}_{i,j} = \begin{cases} 0 & \text{if } i = u \\ -\frac{\hat{P}_{iu}}{\hat{P}_{uu}} & \text{otherwise.} \end{cases} \quad \text{<수식 5>}$$

EASE 모델은 대다수의 추천 시스템 모델들과는 다르게 선형 연산을 활용하여 0인 값이 많은 희소한 평점 행렬에서의 연산에 장점을 가진다 (Steck et al., 2019). 이에 희소한 입력 평점 행렬을 적은 연산만으로 밀집한 평점 행렬로 재구성할 수 있고, 이는 이후 전역 커널링 단계에서 아이템의 특징을 더 잘 파악할 수 있게 만든다.

3.2 전역 커널링 단계

선형 변환 단계를 거친 후 전역 커널 기반 평점 행렬(Global Kernel based Matrix)을 구축하기 위해 먼저 아이템 기반 평균 풀링 단계를 거친다. <수식 6>의 μ_i 는 i 번째 아이템의 특징을 나타낸 값이다.

$$\mu_i = \text{avgpool}(r'_i) \quad \text{<수식 6>}$$

이후 각 특징마다 $t \times t$ 행렬을 곱하여 $t \times t$ 크기의 전역 커널의 요소를 만들고, 모두 합하여 최종 전역 커널(GK)을 만든다. <수식 7>의 k 는 각 아이템 벡터와 곱해지는 커널을 의미한다.

$$GK = \sum_{i=1}^I \mu_i \cdot k_i \quad \text{<수식 7>}$$

마지막으로 <수식 8>과 같이 원본 평점 행렬과 전역 커널 간의 합성곱 연산으로 최종 전역 커널 기반 평점 행렬을 구축하게 된다.

$$\hat{R} = R \otimes GK \quad \text{<수식 8>}$$

전역 커널 크기는 GLocal-K와 마찬가지로 3×3 크기의 커널을 사용한다.

3.3 비선형 변환 단계

기존 추천시스템에서는 매우 희소한 상황에서 모델을 학습할 때 과적합이 일어나거나 모델이 제대로 된 예측을 하지 못한다는 문제점을 가진다. 또한 충분한 데이터가 존재하지 않을 경우 사용자에게 적절한 상품을 추천해 주지 못하는 Cold Start 문제가 발생한다. 이를 해결하기 위해 추천시스템에서는 고전적으로 부가 정보를 활용해 왔으며, 부가 정보는 위 문제들을 해결하는데 도움을 줄 뿐만 아니라 더욱 개인화된 추천을 가능하게 한다. 기존 GLocal-K는 전역 커널과 입력 행렬의 합성곱 연산을 거친 \hat{R} 을 그대로 미세 조정하기 때문에 새로운 부가 정보를 넣기 어렵다. 이러한 GLocal-K의 구조는 모델이 극도로 희소한 데이터를 학습하거나 학습 데이터가 적을 경우 발생하는 문제들을 해결하기 어렵게 만든다.

GEase-K는 사전 학습 과정 대신 EASE를 활용한 선형 변환 단계를 거쳤기 때문에 GLocal-K와 달리 \hat{R} 을 미세 조정하지 않는다. 대신 다음과 같은 이유로 조건부 오토인코더 구조를 사용한다.

첫째, 깊은 오토인코더 구조를 활용하여 모델의 일반화 성질을 강하게 만들었다. 입력 데이터를 재구성하는 과정에서 비선형성을 도입하여 모델이 더 복잡한 표현을 학습할 수 있도록 설계하였다. 이를 통해 GEase-K는 선형 변환 단계에서 희소한 데이터에 대해 강건하도록, 비선형 변환 단계에서는 일반화 성능이 향상되도록 학습되어 더 유연한 예측을 할 수 있게 된다(Le et al., 2018).

둘째, 조건부 오토인코더 구조를 활용하여 부가 정보를 용이하게 넣고 Cold Start 문제를 해결하고자 한다. 조건부 오토인코더는 입력 데이터와 조건 데이터를 같이 입력으로 받아 출력 데이터를 생성하는 신경망으로 조건 데이터를 추가로 입력 받기 때문에 데이터의 특정 부분을 강조하거나 추출하여 모델의 예측 성능을 높일 수 있다. GEase-K는 조건 데이터로 부가 정보를 받아 모델이 사용자나 아이템에 대한 더 많은 정보를 학습하여 사용자에게 더 적절한 아이템을 추천할 수 있다. 따라서 이러한 구조는 Cold Start 문제를 완화하는 데 도움이 된다.

GEase-K의 비선형 변환 단계를 거치는 과정은 <수식 9>와 같다.

$$\begin{aligned}
 h(\hat{R}, S; \theta) &= f(W_d \cdot g(W_e \cdot (\hat{R} \oplus S) + b_e) + b_d) \\
 \hat{R}' &= h(\hat{R}_i; \theta) \\
 \theta &= \{W_e, W_d, b_e, b_d\}
 \end{aligned}$$

<수식 9>

<수식 9>는 오토인코더에 부가 정보를 추가한 조건부 오토인코더 수식이다. 전역 커널링 단계를 거친 \hat{R} 에 부가 정보 S 를 추가한 뒤 오토인코더의 입력으로 들어간다. 인코더의 가중치 W_e 를 곱하고 편향 b_e 를 더해 활성화 함수 g 를 거친다.

디코더 역시 가중치 W_d 를 곱하고 편향 b_d 를 더해 활성화 함수 f 를 거친다. 최종적으로 나오는 평점 행렬은 \hat{R}' 이며 이때 학습하는 파라미터는 $\theta = \{W_e, W_d, b_e, b_d\}$ 4가지이다.

GEase-k는 아이템에 대한 조건을 단순하게 입력 행렬에 붙여주는 방식으로 비선형 변환 단계에서도 이를 차용하여 간단하게 부가 정보를 주입할 수 있도록 하였다. 이렇게 넣은 부가 정보는 유의미한 잠재 벡터를 포착할 수 있도록 해준다. \hat{R} 에 붙이는 방향에 따라 아이템 기반 부가 정보(예: 저자, 리뷰 수, 평점 수, 간행물 수)나 사용자 기반 부가 정보(예: 나이, 성별, 구매 기록)를 쉽게 결합할 수 있다.

4. 실험

4.1 데이터 세트

본 논문에서는 <표 1>과 같이 MovieLens-100K, GoodReads, ModCloth 세 가지 데이터를 실험에서 사용하였다. MovieLens-100K(Harper et al., 2015)는 미네소타 대학의 GroupLens 프로젝트에 의해 만들어진 데이터로 IMDB 사이트에서 수집한 대규모 영화 평점 데이터이다. 943명의 사용자와 1,682개의 아이템으로 이루어져 있으며 원본 데이터는 5.04%의 밀집도(Density Ratio)를 보인다. GoodReads 데이터 세트(Zajac et al., 2017)은 GoodReads 웹사이트의 다양한 독서 데이터를 크롤링해 수집한 대규모 도서 평점 데이터이다. 원본 데이터 중 12,050명의 사용자와 9,929개의 아이템으로 이루어진 약 60만 개의 도서 평점 데이터를 분석에 사용하였고, 데이터의 특성상 평점 데이터 개수에 비해 평점 행렬의 크기가 매우 크

다는 특징을 가진다. 사용한 데이터의 밀집도는 0.45%로 MovieLens 대비 11배 이상 희소하다는 특징을 지닌다. ModCloth 데이터 세트(Misra et al., 2018)은 ModCloth 온라인 의류 판매 사이트의 데이터를 크롤링해 수집한 제품 평점 데이터이다. 17,000명의 사용자와 1,018개의 아이템으로 이루어진 약 7만 2천 개의 제품 평점 데이터 세트를 사용하였고 밀집도가 낮아 GoodReads 데이터 세트와 같이 데이터 개수에 비해 평점 행렬의 크기가 매우 크다는 특징을 가진다. 사용한 데이터의 밀집도는 0.38%로 MovieLens 대비 13배 이상 희소하다는 특징을 지닌다. MovieLens-100K는 희소성 실험에서, GoodReads와 ModCloth는 희소성 실험과 Cold Start 실험에서 사용하였다.

<표 1> 전체 데이터 세트

| Dataset | MovieLens-100K | GoodReads | ModCloth |
|--------------|----------------|-----------|----------|
| # of Ratings | 100,000 | 600,086 | 72,109 |
| Density | 5.04% | 0.45% | 0.38% |

4.2 실험방법 및 평가지표

MovieLens-100K와 GoodReads, ModCloth 데이터 세트 모두 훈련 데이터 90%, 평가 데이터 10%로 나누어 10번의 교차 검증(10-Fold CV)을 수행하였다. 세 데이터 모두 평점 데이터를 사용자-아이템 간의 평점 행렬 모양으로 변환하여 모델을 거치게 되고 모델의 예측 평점 행렬과 입력 평점 행렬을 비교하여 성능을 평가하였다.

평가지표로는 추천 시스템 연구에서 주로 사용하는 RMSE(Root Mean Squared Error)와 MAE(Mean Absolute Error)를 이용하였다(박호연, 김경재, 2021; 장동수 등, 2023).

RMSE는 예측값과 실제 값 사이의 차이를 측

정하는 평가지표로 예측값과 실제 값의 차이를 제공하고 평균을 구한 후, 다시 제곱근을 취해주는 방식으로 측정한다.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad \text{<수식 10>}$$

MAE는 예측값과 실제 값 사이의 절대적인 차이를 측정하는 평가지표로 예측값과 실제 값의 차이를 절댓값으로 계산한 후 평균을 내는 방식으로 측정한다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x| \quad \text{<수식 11>}$$

전역 커널의 크기와 오토인코더 은닉층의 차원은 실험을 통해 가장 성능이 좋았던 3x3 커널, 300 차원의 은닉층을 사용하였고 최적화 기법으로는 AdamW(Loshchilov et al., 2017), 학습률은 0.001로 설정하여 실험을 진행하였다.

4.3 희소성 실험

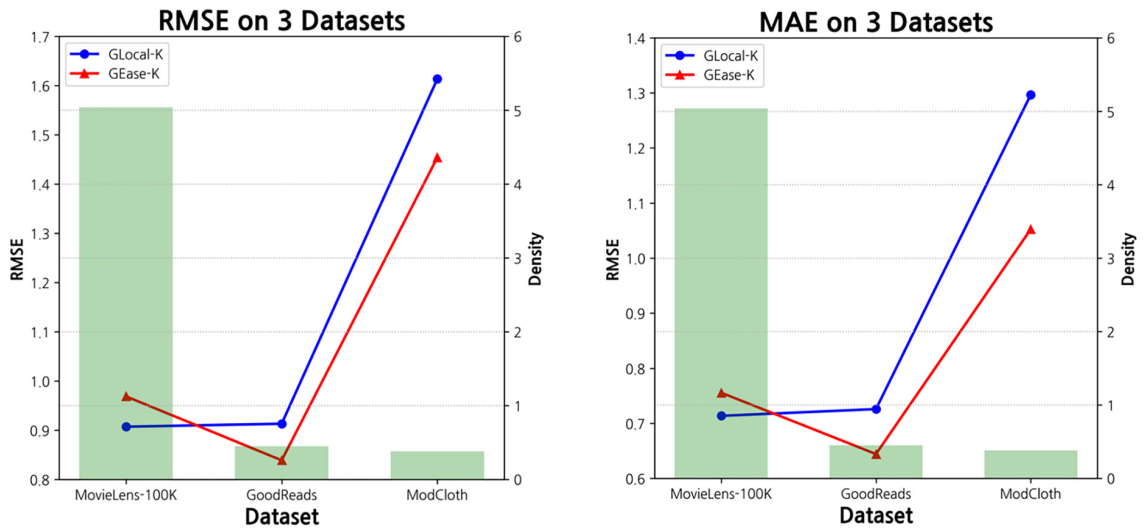
<그림 2>와 <표 2>는 MovieLens-100K, GoodReads, ModCloth 데이터에 대해 GLocal-K와 GEase-K를 적용하여 실험한 평가 결과이다. MovieLens-100K 데이터 세트보다 GoodReads 데이터 세트의 밀집도는 0.45%로 약 11배 희소하며 ModCloth 데이터 세트의 밀집도는 0.38%로 약 13배 더 희소하다. 상대적으로 밀집도가 높은 MovieLens-100K 데이터 세트에서는 GLocal-K의 성능이 6.36% 정도 더 높았지만, 평점 행렬이 희소한 GoodReads, ModCloth에 대해서는 GEase-K가 더 높은 성능을 보였다. GoodReads 데이터 세트에서는 RMSE

기존 GEase-K가 8.14%, MAE는 11.26% 성능이 향상되었고, ModCloth 데이터 세트에서는 RMSE 9.89%, MAE 18.84%만큼 성능이 향상되었다. 밀집도가 낮은 데이터일수록 성능 증가 폭이 더욱 커졌으며, 이를 통해 GLocal-K보다 본 논문에서 제안한 GEase-K가 매우 희소한 환경에서의 성능이 우수함을 확인하였다.

추가로 GEase-K가 매우 희소한 환경에서 효과적인 성능을 보임을 확인하기 위해 기존에 GLocal-K보다 성능이 낮았던 MovieLens-100K 데이터의 상호작용 수를 100%부터 5%까지 조정하여 실험을 진행하였다. 이때 밀집도는 5.04%부터 0.25%까지 낮아지게 되며 그 결과는 <그림 3>에서 확인할 수

있다. RMSE, MAE 모두 절대적인 성능은 GEase-K 대비 GLocal-K가 높았지만, 밀집도가 낮아질수록 그 성능의 차이가 줄어들었다. 특히 원본 데이터 세트보다 상호작용 수가 20배 줄어든 0.25%의 밀집도 환경에서 실험한 결과 GEase-K가 GLocal-K의 성능을 뛰어넘어, 매우 희소한 데이터에서 GEase-K가 효과적임을 입증하였다.

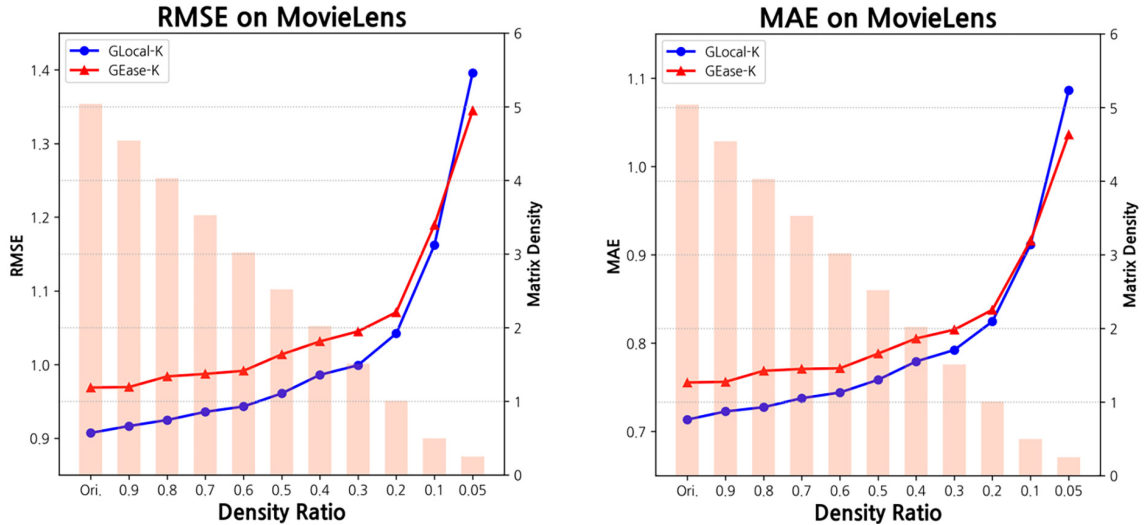
결론적으로 EASE 모델을 활용한 선형 변환 과정이 매우 희소한 데이터에서 GEase-K 모델의 성능 향상을 돕는다는 것을 알 수 있다. MovieLens-100K, GoodReads, ModCloth 세 가지 데이터에서 모두 EASE 연산을 거쳤을 때 희소한 평점 행렬이 각각 98.09%, 100%, 97.87%로 밀집하게 변환되며,



<그림 2> RMSE, MAE 희소성 실험

<표 2> 희소성 실험 결과

| | MovieLens-100K | | GoodReads | | ModCloth | |
|----------|----------------|---------------|---------------|---------------|---------------|---------------|
| | RMSE | MAE | RMSE | MAE | RMSE | MAE |
| GLocal-K | 0.9071 | 0.7135 | 0.9131 | 0.7258 | 1.6135 | 1.2969 |
| GEase-K | 0.9687 | 0.7555 | 0.8388 | 0.6441 | 1.4539 | 1.0526 |



〈그림 3〉 MovieLens 밀집도 비율 별 희소성 실험

이를 통해 EASE의 출력 결과는 원본 평점 데이터와 거의 동일한 성질을 지니고 있는 밀집 행렬을 반환 하기에 매우 희소한 데이터에서 사용자와 아이템 간의 상호작용을 잘 파악할 수 있음을 알 수 있다.

4.4 Cold Start 실험

Cold Start 상황에서 성능의 차이를 비교하기 위해 기존의 Cold Start 연구(Wang et al., 2019; Togashi et al., 2020)의 실험 방법과 동일한 실험을 진행하였다. 전체 데이터를 사용자별 평점 내역 수 기준 4개의 집단으로 나누어 비교하였다. 집단 1은 평점 내역 수가 전체 사용자들의 1분위수 이하인 사용자들, 집단 2는 1분위수와 2분위수 사이에 해당하는 사용자들, 집단 3은 2분위수와 3분위수 사이에 해당하는 사용자들, 집단 4는 3분위수 이상의 사용자들로 분류하였다. 따라서 타 집단에 비해 평점 내역 수가 매우 적은 집단 1을 Cold Start 사용자로 볼 수 있다(Togashi et

al., 2020). Cold Start 실험에는 상대적으로 밀집도가 낮아 Cold Start 문제가 발생하기 쉬운 GoodReads와 ModCloth 데이터 세트를 사용하였다. 각 데이터 세트에서 Cold Start 문제 해결을 위해 사용한 부가정보는 <표 3>에서 확인할 수 있다.

〈표 3〉 데이터 세트 별 활용 부가 정보

| 활용 부가 정보 | |
|-----------|--------------------|
| GoodReads | 작가, 출판 연도, 리뷰 수 |
| ModCloth | 카테고리, 구매 연도, 구매 연월 |

<표 4>는 GoodReads 데이터 세트에서 GLocal-K와 GEase-K의 집단 간 성능을 측정된 실험 결과이다. 이때 Cold Start 문제 해결을 위한 부가 정보는 작가, 출판 연도, 리뷰 수 등의 부가 정보를 활용하였다. GEase-K는 모든 집단에서 GLocal-K보다 좋은 성능을 보였으며, 특히 Cold Start 상황에 놓인 집단 1에서 성능이 많이 향상된 것을

〈표 4〉 GoodReads Cold Start 실험 결과

| GoodReads | | Group1 | Group2 | Group3 | Group4 |
|-----------|------|---------------|---------------|---------------|---------------|
| GLocal-K | RMSE | 1.1461 | 0.9877 | 0.8878 | 0.8549 |
| | MAE | 0.9689 | 0.8140 | 0.7137 | 0.6612 |
| GEase-K | RMSE | 0.8733 | 0.8484 | 0.8356 | 0.8315 |
| | MAE | 0.6750 | 0.6540 | 0.6420 | 0.6363 |

〈표 5〉 ModCloth Cold Start 실험 결과

| ModCloth | | Group1 | Group2 | Group3 | Group4 |
|----------|------|---------------|---------------|---------------|---------------|
| GLocal-K | RMSE | 2.3577 | 1.5512 | 1.3848 | 1.1086 |
| | MAE | 2.0843 | 1.3484 | 1.1783 | 0.8961 |
| GEase-K | RMSE | 1.9745 | 1.3241 | 1.3047 | 1.1502 |
| | MAE | 1.4423 | 0.9612 | 0.9655 | 0.8719 |

확인할 수 있다. GLocal-K에 비해 집단 1에서는 RMSE 23.8%, MAE 30.3%만큼 향상되었으며 집단 2에서는 RMSE 14.1%, MAE 19.7%만큼, 집단 3과 집단 4에서도 두 모델보다 RMSE와 MAE 모두 2% 이상 증가하였다.

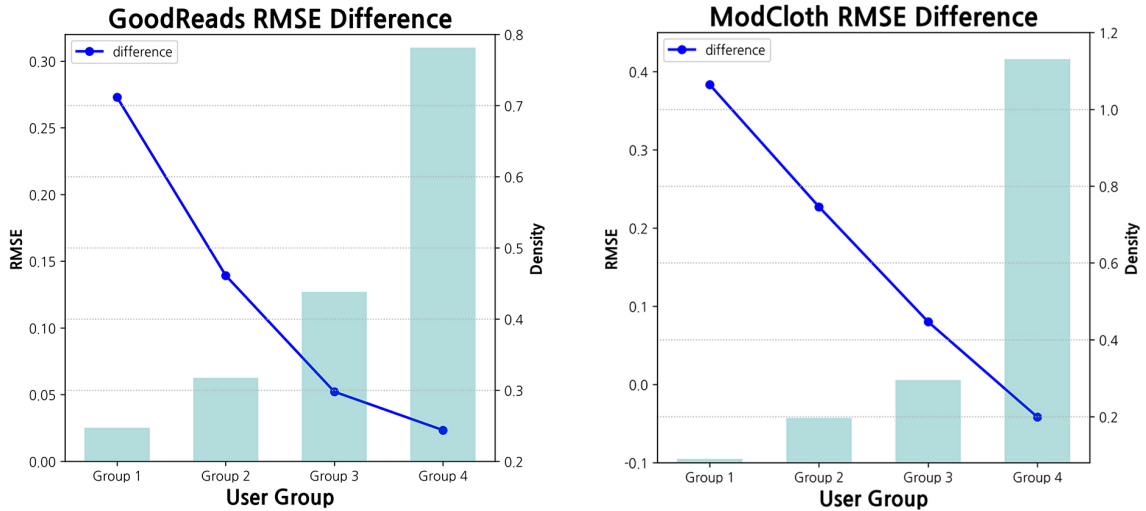
<표 5>는 ModCloth 데이터 세트에 대한 GLocal-K와 GEase-K의 실험 결과이다. 이때 GEase-K의 부가 정보로는 카테고리, 구매 연도, 구매 연월 등의 부가 정보를 활용하였다. GEase-K는 RMSE 기준 집단 4를 제외한 모든 집단에서 GLocal-K보다 높은 성능을 보였으며, Cold Start 상황인 집단 1에서 GLocal-K에 비해 RMSE 16.3%, MAE 22.6%만큼 성능이 우수함을 확인할 수 있다.

<그림 4>는 앞서 GLocal-K와 GEase-K로 진행한 Cold Start 실험을 두 모델의 RMSE 차이를 기준으로 나타낸 그래프이다. 그래프 속 바 차트는 집단별 밀집도를 나타내고 밀집도가 낮은 집단 1로 갈수록 Cold Start가 악화하는 상황임을 알 수 있다. 실험 결과를 살펴보면, 두 가지 데이터

세트에서 모두 Cold Start 문제에 놓여있는 집단 1에서 RMSE의 차이가 가장 큰 것을 확인할 수 있다. GLocal-K 대비 GEase-K는 GoodReads 데이터 세트에서 0.2728, ModCloth 데이터 세트에서 0.3832만큼 좋은 성능을 보인다. 본 실험을 통해 조건부 오토인코더 구조로 부가 정보를 활용한 GEase-K가 학습 데이터가 적은 Cold Start 상황에서 GLocal-K보다 성능이 우수함을 확인할 수 있었다. 추가로 본 논문의 실험에서 사용한 부가 정보는 제약된 정보만을 사용하였는데, 더 많은 부가 정보를 사용한다면 더 높은 성능 향상을 기대할 수 있을 것이다.

5. 결론

본 논문은 GLocal-K의 구조를 기반으로 하여 선형 모델인 EASE와 비선형 모델인 AutoRec의 구조를 결합한 GEase-K를 제안하였다. GEase-K



〈그림 4〉 데이터 세트 별 RMSE 차이 실험

의 장점은 다음과 같다. 첫째, GEase-K는 매우 희소한 데이터에서 좋은 성능을 보인다. 특히 밀집도가 0.5% 보다 낮은 매우 희소한 데이터 세트에서의 성능이 크게 향상된 것을 확인할 수 있으며, 이는 선형 구조인 EASE를 활용하여 희소 행렬의 정보를 잘 파악하고 전역 커널과 비선형 오토인코더 구조를 거쳐 모델이 사용자와 아이템 간의 중요한 상호작용 정보를 학습하게 돕기 때문이다. 이때 선형 모델과 비선형 모델을 순차적으로 거쳐 유연한 예측이 가능하고 매우 희소한 데이터에서도 학습이 잘 이루어졌음을 확인하였다. 둘째, 부가 정보를 사용하여 Cold Start 상황에서도 소비자에게 더욱 정확한 추천이 가능하다. 비선형 단계에서 원하는 사용자 혹은 아이템에 대한 부가 정보를 쉽게 넣을 수 있으며 실제로 매우 희소한 GoodReads 데이터 세트와 ModCloth 데이터 세트에서 아이템 기반 부가 정보를 넣은 GEase-K가 기존 GLocal-K보다 안정적인 성능을 보였다. 본 논문에서는 GoodReads

데이터 세트와 ModCloth 데이터 세트에 대한 많은 양의 데이터를 부가 정보로 사용하지 않았는데, 따라서 더 많은 부가 정보를 추가할 경우 더욱 좋은 성능을 보일 것으로 기대된다.

하지만 GEase-K는 다음과 같은 한계를 가진다. 우선, 본 논문에서 구현한 GEase-K는 비선형 단계의 오토인코더 구조를 사용하여 많은 매개변수가 존재한다. 이에 데이터에 따라 과적합이 발생할 수 있으며, 비선형 단계에서 학습 시간이 오래 걸리는 문제를 초래할 수 있다. 이는 추후 연구에서 매개변수 수를 줄일 수 있도록 다양한 형태의 오토인코더, 정규화, 가지치기(Pruning) 등 다양한 방법론을 활용하여 조정한다면, 더 적은 컴퓨팅 파워로 더 빠른 학습을 가능하게 만들 수 있을 것이다. 또한, GEase-K는 MovieLens 데이터 세트와 같이 밀집도가 높은 데이터 세트에서는 GLocal-K에 비해 다소 낮은 성능을 보인다. 따라서 향후 연구에서는 본 논문에서 사용한 총 세 가지 데이터 세트 이외의 더 다양한 밀집도를

가지는 데이터 세트로 실험을 진행하여 GEase-K가 효율적으로 작동하는 구체적인 밀집도를 찾는 연구를 진행할 예정이다. 추가로 대용량 데이터에 대해서도 Precision, Recall, NDCG 등 다른 평가지표를 활용하여 GEase-K의 성능을 확인하고자 한다.

참고문헌(References)

[국내 문헌]

- 박호연, 김경재. (2021). BERT 기반 감성분석을 이용한 추천시스템. *지능정보연구*, 27(2), 1-15.
- 송경우, 문일철. (2021). 추천시스템 최근 연구 동향 및 향후 연구 방향 소개. *정보과학회지*, 39(3), 16-23.
- 장동수, 이청용, 김재경. (2023). 딥러닝 기반 온라인 리뷰의 언어학적 특성을 활용한 추천 시스템 성능 향상에 관한 연구. *지능정보연구*, 29(1), 41-63.
- 전채연. (2010). [Bad to Good, Good to Great] 사소한 다수에 실리는 힘, 룡테일 법칙. *브레인* 25, 28-31.
- 홍태호, 홍준우, 김은미, 김민수. (2022). 영화 리뷰의 상품 속성과 고객 속성을 통합한 지능형 추천시스템. *지능정보연구*, 28(2), 1-18.

[국외 문헌]

- Bertin-Mahieux, T., Ellis, D. P., Whitman, B., & Lamere, P. (2011). The million song dataset [Data set]. <http://millionsongdataset.com/>.
- Broomhead, D. S., & Lowe, D. (1988). Radial basis functions, multi-variable functional interpolation and adaptive networks. Royal Signals and Radar Establishment Malvern (United Kingdom).

- Darban, Z., & Valipour, M. (2022). GHRS: Graph-based hybrid recommendation system with application to movie recommendation. *Expert Systems with Applications*, 200.
- Das, M., Morales, G. D. F., Gionis A., & Weber, I. (2013). Learning to question : Leveraging user preferences for shopping advice. *Proceedings of the 19th ACM SIGKDD international conference on Knowledge discovery and data mining*, 203-211.
- Han, S. C., Lim, T., Long, S., Burgstaller, B., & Poon, J. (2021, October). GLocal-K: Global and local kernels for recommender systems. *Proceedings of the 30th ACM International Conference on Information & Knowledge Management*, 3063-3067.
- Harper, F. M., & Konstan, J. A. (2015). The movielens datasets: History and context. *Acm transactions on interactive intelligent systems*, 5(4), 1-19.
- Kim, D., & Suh, B. (2019). Enhancing VAEs for collaborative filtering: flexible priors & gating mechanisms. *Proceedings of the 13th ACM Conference on Recommender Systems*, 403 - 407.
- Kingma, D. P., & Welling, M. (2013). Auto-encoding variational bayes. *arXiv preprint arXiv:1312.6114*.
- Kingma, D. P., Mohamed, S., Jimenez Rezende, D., & Welling, M. (2014). Semi-supervised learning with deep generative models. *Advances in neural information processing systems*, 27.
- Lagrange, J. L. (1770). Réflexions sur la résolution algébrique des équations. *Prussian Academy*.
- Le, L., Patterson, A., & White, M. (2018). Supervised autoencoders: Improving generalization performance with unsupervised regularizers. *Advances in neural information processing systems*, 31.

- Lee, W., Song, K., & Moon, I. C. (2017, November). Augmented variational autoencoders for collaborative filtering with auxiliary information. *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*, 1139-1148.
- Loshchilov, I., & Hutter, F. (2017). Decoupled weight decay regularization. *arXiv preprint arXiv:1711.05101*.
- Misra, R., Wan, M., & McAuley, J. (2018, September). Decomposing fit semantics for product size recommendation in metric spaces. *Proceedings of the 12th ACM Conference on Recommender Systems*, 422-426.
- Ning, X., & Slim, G. K. (2011). Sparse linear methods for top-n recommender systems. *Proceedings of the 2011 IEEE 11th International Conference on Data Mining*, 497-506.
- Papers With Code (2023). <https://paperswithcode.com/task/recommendation-systems>.
- Rendle, S. (2010, December). Factorization machines. *2010 IEEE International conference on data mining*, 995-1000. IEEE.
- Sedhain, S., Menon, A. K., Sanner, S., & Xie, L. (2015, May). AutoRec: Autoencoders meet collaborative filtering. *Proceedings of the 24th international conference on World Wide Web*, 111-112.
- Steck, H. (2019, May). Embarrassingly shallow autoencoders for sparse data. *The World Wide Web Conference*, 3251-3257.
- Vančura, V., & Kordík, P. (2021). Deep Variational Autoencoder with Shallow Parallel Path for Top-N Recommendation (VASP). *Proceedings of the 30th International Conference on Artificial Neural Networks*, 138 - 149.
- Wang, X., He, X., Cao, Y., Liu, M., & Chua, T. S. (2019, July). Kgat: Knowledge graph attention network for recommendation. *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*, 950-958.
- Wei, Y., Wang, X., Li, Q., Nie, L., Li, Y., Li, X., & Chua, T. S. (2021, October). Contrastive learning for cold-start recommendation. *Proceedings of the 29th ACM International Conference on Multimedia*, 5382-5390.
- Wu, Y., Wu, W., Xing, C., Zhou, M., & Li, Z. (2016). Sequential matching network: A new architecture for multi-turn response selection in retrieval-based chatbots. *arXiv preprint arXiv:1612.01627*.
- Zajac, Zygmunt. (2017). Goodbooks-10k: a new dataset for book recommendations [Data set]. <https://github.com/zygmuntz/goodbooks-10k>.
- Zhang, M., & Chen, Y. (2020). Inductive Matrix Completion Based on Graph Neural Networks. *ICLR 2020*.
- Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. *ACM computing surveys (CSUR)*, 52(1), 1-38.
- Zhou, Y., Zhou, K., Zhao, W., Wang, C., Jiang, P., & Hu, H. (2022). C2-CRS: Coarse-to-Fine Contrastive Learning for Conversational Recommender System. *arXiv preprint arXiv:2201.02732*.

Abstract

GEase-K: Linear and Nonlinear Autoencoder-based Recommender System with Side Information

Taebeom Lee* · Seung-hak Lee* · Min-jeong Ma* · Yoonho Cho**

In the recent field of recommendation systems, various studies have been conducted to model sparse data effectively. Among these, GLocal-K(Global and Local Kernels for Recommender Systems) is a research endeavor combining global and local kernels to provide personalized recommendations by considering global data patterns and individual user characteristics. However, due to its utilization of kernel tricks, GLocal-K exhibits diminished performance on highly sparse data and struggles to offer recommendations for new users or items due to the absence of side information. In this paper, to address these limitations of GLocal-K, we propose the GEase-K (Global and EASE kernels for Recommender Systems) model, incorporating the EASE(Embarrassingly Shallow Autoencoders for Sparse Data) model and leveraging side information. Initially, we substitute EASE for the local kernel in GLocal-K to enhance recommendation performance on highly sparse data. EASE, functioning as a simple linear operational structure, is an autoencoder that performs highly on extremely sparse data through regularization and learning item similarity. Additionally, we utilize side information to alleviate the cold-start problem. We enhance the understanding of user-item similarities by employing a conditional autoencoder structure during the training process to incorporate side information. In conclusion, GEase-K demonstrates resilience in highly sparse data and cold-start situations by combining linear and nonlinear structures and utilizing side information. Experimental results show that GEase-K outperforms GLocal-K based on the RMSE and MAE metrics on the highly sparse GoodReads and ModCloth datasets. Furthermore, in cold-start experiments divided into four groups using the GoodReads and ModCloth datasets, GEase-K denotes superior performance compared to GLocal-K.

Key Words : Recommender Systems, Deep Learning, Autoencoder, Side Information, Sparsity Problem

Received : August 16, 2023 Revised : August 25, 2023 Accepted : August 28, 2023

Corresponding Author : Yoonho Cho

* Department of AI, Big Data & Management, Kookmin University

** Corresponding author: Yoonho Cho

Department of AI, Big Data & Management, Kookmin University

77 Jeongneung-ro, Seongbuk-gu, Seoul, 02707, Korea

Tel: +82-2-910-4950, Fax: +82-2-910-5209, E-mail: www4u@kookmin.ac.kr

저 자 소개



이태범

현재 국민대학교 경영대학 AI빅데이터융합경영학과 학사과정에 재학 중이다. 주 연구 관심 분야는 빅데이터 분석, 컴퓨터 비전, 추천시스템 등이다.



이승학

현재 국민대학교 경영대학 AI빅데이터융합경영학과 학사과정에 재학 중이다. 주 연구 관심 분야는 빅데이터 분석, 컴퓨터 비전, 추천시스템 등이다.



마민정

현재 국민대학교 경영대학 AI빅데이터융합경영학과 학사과정에 재학 중이다. 주 연구 관심 분야는 컴퓨터 비전, 추천시스템, 이상치 탐지 등이다.



조윤희

현재 국민대학교 AI빅데이터융합경영학과 교수로 재직 중이다. 서울대학교 계산통계학과를 졸업하고, KAIST 경영정보공학과에서 석사, KAIST 경영공학과에서 박사학위를 취득하였으며, LG전자(주)에서 6년간 주임연구원으로 재직하였다. 주 연구분야는 추천시스템, 머신러닝, 딥러닝, 빅데이터분석, 디지털마케팅 등이다.