

Collaborative Filtering based Recommender System using Restricted Boltzmann Machines

Soojung Lee*

*Professor, Dept. of Computer Education, Gyeongin National University of Education, Anyang, Korea

[Abstract]

Recommender system is a must-have feature of e-commerce, since it provides customers with convenience in selecting products. Collaborative filtering is a widely-used and representative technique, where it gives recommendation lists of products preferred by other users or preferred by the current user in the past. Recently, researches on the recommendation system using deep learning artificial intelligence technologies are actively being conducted to achieve performance improvement. This study develops a collaborative filtering based recommender system using restricted Boltzmann machines of the deep learning technology by utilizing user ratings. Moreover, a learning parameter update algorithm is proposed for learning efficiency and performance. Performance evaluation of the proposed system is made through experimental analysis and comparison with conventional collaborative filtering methods. It is found that the proposed algorithm yields superior performance than the basic restricted Boltzmann machines.

▶ **Key words:** Collaborative Filtering, Recommender System, Deep Learning, Neural Network, Restricted Boltzmann Machine

[요 약]

추천 시스템은 전자 상거래 시에 고객들의 상품 선택의 편의를 제공하므로 반드시 구비되어야 할 기능이다. 협력 필터링은 다른 사용자들이 선호하였던 상품이나 현 사용자가 과거 선호하였던 상품들을 위주로 추천 리스트를 제공하는 기법으로서, 가장 널리 활용되는 대표적 기법이다. 최근 딥러닝 인공지능 기술을 활용하여 추천 시스템의 성능 향상을 달성하는 연구가 활발히 진행되고 있다. 본 연구에서는 사용자가 부여한 평가등급만을 이용하여 딥러닝 기술의 일종인 제한 볼츠만 기계 학습을 통해 협력 필터링 기반의 추천 시스템을 개발한다. 또한 학습의 효율성과 성능을 위하여 학습 파라미터 변경 알고리즘을 제시한다. 제안 시스템의 성능 평가를 위하여 실험 분석을 통해 기존의 다양한 전통적 협력 필터링 기법들과 비교 분석을 실시하였으며, 제안 알고리즘은 기본적인 제한 볼츠만 기계 모델보다 우수한 성능을 가져오는 것으로 확인되었다.

▶ **주제어:** 협력 필터링, 추천 시스템, 딥러닝, 신경망, 제한 볼츠만 기계

• First Author: Soojung Lee, Corresponding Author: Soojung Lee
*Soojung Lee (sjlee@gin.ac.kr), Dept. of Computer Education, Gyeongin National University of Education
• Received: 2020. 08. 04, Revised: 2020. 08. 26, Accepted: 2020. 09. 06.

I. Introduction

전자 상거래의 발달로 인해 소비자들은 정보의 홍수 속에서 그들이 원하는 상품을 검색하는데 많은 시간을 소비하는 추세이다. 이러한 어려움을 해소하기 위한 주요 방안으로 추천 시스템이 대두되어 상업적으로 활발히 이용되고 있다. 고객들은 추천 시스템을 통해 보다 효율적으로 온라인 상품들을 검색하고 다양한 추천 상품을 제공받는다. 성공적인 추천 시스템의 예로서 아마존, 유튜브, 이베이 등이 있다[1].

추천 시스템의 종류로는 내용 기반 필터링, 협력 필터링, 인구통계학적 필터링, 지식 기반 필터링, 하이브리드 필터링 등이 있다[2]. 이들 중에서 가장 많이 활용되고 연구되는 협력 필터링(Collaborative filtering, CF) 기법은 현 사용자와 유사한 사용자, 또는 현 사용자가 선호했던 항목들과 유사한 항목들을 참조하여 추천 리스트를 결정하는 방법이다.

CF 방식은 대개 메모리 기반(memory-based)과 모델 기반(model-based) 시스템으로 나뉘는데[2][3], 전자는 사용자가 부여하였던 항목에 대한 평가등급을 유지 보관하여 이 자료로부터 추천 항목들을 산출한다. 이 방식의 가장 큰 장점은 구현이 용이하며 매우 효율적이고 데이터 환경에 쉽게 적응한다는 점이다. 그러나, 과거 선호하였던 항목들과 유사한 항목들 또는 현 사용자와 유사한 사용자들을 구하기 위한 소요 시간 비용이 보관된 평가등급 정보량에 비례하기 때문에, 데이터 확장성 문제(data scalability problem)가 발생할 수 있다. 또한 이와 반대로 데이터량이 너무 적으면 유사한 항목들이나 사용자들을 구하기 어려우므로 데이터 희소성 문제(data sparsity problem)가 발생할 수 있다[3]. 이같은 단점들을 해결하고자 개발된 모델 기반 기법은 다양한 데이터 마이닝이나 기계학습 알고리즘을 활용하여 모델을 구축한다. 알고리즘의 예로서, 행렬 분해(matrix factorization), 서포트 벡터 머신(support vector regression), 베이저안 네트워크(Bayesian networks), 군집화(clustering) 등이 있다[2][3]. 그러나 모델 구축에 따른 비용 및 최신 상태 유지를 위한 지속적 학습 필요 등의 단점이 있다.

최근 딥러닝의 발달로 인해 컴퓨터 비전, 음성 인식, 자연어 처리 등과 같은 여러 연구 분야에서 이를 적용한 연구 결과는 전통적인 방식에 비해 획기적인 성능 향상을 이루고 있다[4]. 딥러닝은 기계 학습 알고리즘의 한 종류로서 비선형 변환 레이어들의 연결 모델로서 지도학습 또는 비지도학습을 통해 네트워크 상의 파라미터들의 학습이 이루어진다. 추천 시스템 분야에서도 딥러닝을 비롯한 신경망을 이용하여 기존의 메모리 기반이나 모델 기반 방식에서 벗어나 CF 시

스템의 개발을 위한 연구가 진행되고 있다[5][6][7][8].

본 연구에서는 CF 시스템의 구현을 위해서 사용자들이 부여한 평가등급을 이용하여 신경망의 일종인 제한 볼츠만 기계(Restricted Boltzmann Machine)를 활용한다[9]. 이 모델의 다양한 학습 파라미터들은 성능에 큰 영향을 주는데[10], 본 연구에서는 학습률과 모멘텀의 변경 알고리즘을 제안하고 그 효과를 실험을 통하여 전통적 협력 필터링 방식과 비교 분석한다.

논문의 구성은 다음과 같다. 2절에서 관련 연구에 대해 기술하며 3절에서는 제안 방법을 설명한다. 4절은 성능 측정 실험 결과를 제시하고, 5절에서 논문의 결론을 맺는다.

II. Related Works

1. Recommender System Using RBM

딥러닝은 데이터 내 감추어진 특성들을 발견하기 위한 기술로서, 최근 추천 시스템 분야에 매우 활발히 적용 연구되고 있다[7][8][11][12]. 딥러닝 기술은 추천 시스템의 큰 단점인 확장성과 희소성 문제에 대한 실질적인 해결 방안을 제시한다. 또한 추천 시스템에 통합하기 위하여 특성 추출이나 차원 감소를 위해서 활용된다.

RBM(제한 볼츠만 기계, Restricted Boltzmann Machine) 인공신경망은 추천 시스템에서 사용자의 선호나 항목의 평가등급에 내재된 특성을 추출하는데 활용된다[9][13]. 사용자가 평가한 항목들 간의 상관 관계나 사용자들 사이의 관계를 모델링하여 추천 시스템의 정확도를 향상시킬 수 있다[14]. 집단 프로파일과 집단 특성을 모델링하는데도 RBM은 이용되어 집단 선호도를 통한 추천 시스템 개발에도 도움을 준다[15].

Salakhutdinov 외 2인은 두 개의 레이어만을 가진 RBM 모델을 소개하고 영화에 대한 사용자의 평가등급을 사용하여 학습 및 추론 절차의 진행 과정을 제시하였으며 그 결과로 RBM이 넷플릭스 데이터셋에 성공적으로 적용될 수 있음을 보였다[9].

기존 연구에서 RBM은 추천 시스템 외에 다양한 분야에서 모델 구축을 위해 사용되었다. [16]의 연구에서는 우리나라 지역사회 노인의 경도인지장애 예측 모형을 RBM을 이용하여 개발하고 유의미한 요인들을 밝혀 내었다. [12]는 평점 정보가 전혀 없는 고객의 구매데이터만을 사용하여 평점 정보를 도출해 내고, RBM과 조건부 RBM을 이용하여 구매 추천 항목들을 산출하였다. 이광한은 사용자의 취향을 고려한 패션 상품을 효과적으로 추천해 주기 위해 기존의 추천시스템과 딥러닝을 결합한 하이브리드형 추천

시스템을 개발하였다[17]. Sahoo 외 3인은 RBM-CNN(Convolutional Neural Network)을 활용하여 지능적인 건강 추천 시스템을 개발하였는데, 이를 통해 빅데이터 분석이 환자의 건강 관점에서 의사 결정에 매우 중요한 역할을 함을 보였다[18].

2. RBM Model

RBM 인공신경망은 총 두 개의 층(layer)로 구성되는데, 즉, 입력층(visible layer) 한 개와 은닉층(hidden layer) 한 개이다. 이러한 구조는 심층 신뢰 신경망(DBN:Deep Belief Network)을 구성하는 요소로 이용될 수 있다[19]. 두 레이어의 유닛들은 가중치가 부과된 연결을 갖지만, 각 레이어 내의 유닛들 사이는 연결되지 않는다.

가시 유닛(visible units)들의 집합인 입력층은 관찰값들을 입력으로 받고, 은닉층의 유닛들은 관찰 대상들 사이의 의존 관계를 표현한다. 예를 들어, 손글씨 숫자 인식 문제에서, 가시 유닛은 디지털 이미지의 픽셀에 대응하고, 은닉 유닛은 이들 픽셀 간의 관계를 나타낸다[20].

RBM의 각 입력 노드는 데이터에 대한 특징값이나 속성을 출력한다. 예를 들면 입력값으로 x 를 투입하면 해당 가시 유닛과 연결된 은닉층의 노드 사이에 있는 가중치 w 를 곱한 후, 이 결과 값을 활성화함수 f 에 대한 입력값으로 하여 은닉 노드의 출력값을 얻는다. 실제로는 하나의 은닉 유닛은 다수의 가시 유닛과 연결되므로, 연결된 모든 가시 유닛에 대응하는 입력값을 전달받아 그 은닉 유닛의 결과를 산출하게 된다. 또한 가중치 곱 뿐만 아니라 각 은닉 유닛에 대응하는 바이어스값을 더한 출력값에 활성화함수를 적용한다. 실제로는 그림 1에서와 같이 하나의 은닉 노드는 다수의 입력 노드들과 연결되어 있으므로, RBM 인공신경망의 연산은 여러 개의 입력 노드의 데이터를 전달받아서 서로 다른 가중치 w 와 곱해지는 과정을 거친다. 이후 그 총합에 바이어스(그림 1에서 b)를 더한 뒤 활성화함수 결과값을 산출한다. 구체적인 예로서, 은닉 노드 h_1 에 대한 연산은 식 $f(\sum_{i=1}^n w_{i1}x_i + b_1)$ 을 이용한다.




Fig. 1. A restricted Boltzmann machine

III. The Proposed Scheme

1. Utilization of RBM Model

그림 2는 본 연구의 RBM을 제시한다. 모델의 구축에 필요한 데이터셋은 사용자들의 항목에 대한 평가 데이터를 포함하는 것으로 가정하였다. 즉, 사용자id, 항목id, 평가등급의 정보가 이용 가능한 데이터셋으로서, 학계에서 널리 활용되고 있는 MovieLens 또는 FilmTrust와 같은 데이터셋이 이와 같은 정보를 제공한다[2]. 본 연구에서는 정수형 평가등급을 제공하므로 구현이 보다 용이한 MovieLens 데이터셋을 활용하였다.

그림 2의 모델은 [9]의 모델과 마찬가지로, 각 은닉 유닛은 이진값을 갖고, 가시 유닛은 softmax unit으로 구성하였다. 각각의 가시 유닛은 항목에 해당한다. 따라서 전체 가시 유닛 개수는 시스템에서 제공하는 전체 항목 개수와 동일하다. 사용자들은 각기 별개의 RBM을 통해 학습되지만, 가중치와 바이어스는 공유한다.

그림 2에서처럼 만약 사용자가 항목 1에 대하여 평가등급 4를 부여했다면 그림에서 1~5까지의 정수형 평가등급 범위 내에서 4에 해당하는 값만이 1의 초기값을 갖고($v_1^4 = 1$. 그림에서 흑색 네모칸에 해당) 나머지는 0의 초기값을 갖는다. 'Item 2'는 사용자가 미평가한 항목을 나타낸다.

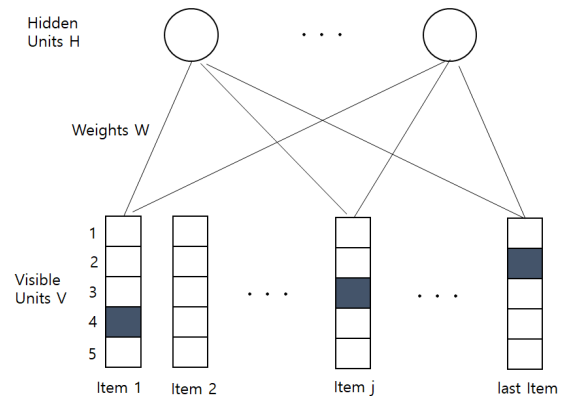


Fig. 2. Restricted Boltzmann machine used by our algorithm

은닉 유닛 개수는 학습을 통하여 최적값을 구할 수 있는데, 본 연구에서는 MovieLens 데이터셋이 제공하는 영화 항목의 장르 개수와 동일하도록 정하였다. 이와 같이 정하면 RBM의 학습 결과로서, 각 은닉 유닛의 값이 1이 되는 확률을 얻을 수 있으므로, 각 사용자의 장르 선호도의 파악이 가능하다.

RBM은 확률모델의 계산이 불가능하기 때문에, 학습 시에 근사법인 CD(Contrastive Divergence) 알고리즘을 사

용한다[9]. CD에서는 alternating Gibbs sampling을 n회 반복한다. 구체적으로 RBM 학습은 표 1의 기호를 사용하여 아래 알고리즘에 따라 진행된다.

[알고리즘 1]

- 1) 가시 유닛들을 훈련데이터로 초기화한다.
- 2) 모든 은닉 유닛, $h_j, j=1, \dots, F$, 들을 아래 식에 의거하여 갱신한다. σ 는 시그모이드 함수이다.

$$p(h_j = 1|V) = \sigma(b_j + \sum_i v_i w_{ij}) \dots\dots\dots(1)$$

- 3) 위와 같이 변경된 가시 유닛 v 와 은닉 유닛 h 의 외적(outer product), $\langle v_i h_j \rangle_{data}$ 을 구한다.

- 4) while number of epochs $\leq N$ begin

- 4.1) 가시 유닛들을 아래 식을 이용하여 모두 동시에 갱신한다 (갱신 결과를 v' 로 표기).

$$p(v_i^k = 1|h) = \frac{\exp(a_i^k + \sum_{j=1}^F h_j w_{ij}^k)}{\sum_{l=1}^K \exp(a_i^l + \sum_{j=1}^F h_j w_{ij}^l)} \dots\dots\dots(2)$$

- 4.2) 은닉 유닛들을 식 (1)을 이용하여 모두 동시에 갱신한다 (갱신 결과를 h' 로 표기).
- 4.3) 갱신된 가시 유닛 v' 와 은닉 유닛 h' 의 외적, $\langle v_i h_j \rangle_{model}$ 을 구한다.
- 4.4) 가중치를 아래와 같이 갱신한다.

$$w_{ij}(t+1) = w_{ij}(t) + \eta \Delta w_{ij} \dots\dots\dots(3)$$

$$\Delta w_{ij} = \frac{\partial \log(P(v))}{\partial w_{ij}} = \langle v_i h_j \rangle_{data} - \langle v_i h_j \rangle_{model} \dots\dots\dots(4)$$

- 4.5) 바이어스를 아래와 같이 갱신한다.

$$\Delta a = \eta(v - v'), \quad \Delta b = \eta(h - h') \dots\dots\dots(5)$$

- 5) end.

학습이 완료되면 사용자가 미평가한 항목에 대해 예측치를 산출할 수 있다. 은닉 유닛 j 가 이진값 1을 가질 확률을 $\hat{p}_j = p(h_j = 1|V)$ 와 같이 표기하자. 미평가 항목을 i 라고 할 때, 사용자가 이 항목에 대해 평가등급 k 를 부여할 확률은 다음과 같이 계산한다.

$$p(v_i^k = 1|\hat{p}_j) = \frac{\exp(a_i^k + \sum_{j=1}^F \hat{p}_j w_{ij}^k)}{\sum_{l=1}^K \exp(a_i^l + \sum_{j=1}^F \hat{p}_j w_{ij}^l)} \dots\dots\dots(6)$$

이제 사용자 u 의 미평가항목 i 의 예측치는 아래와 같다.

$$\hat{r}_{u,i} = \sum_{k=1}^K p(v_i^k = 1|\hat{p}_j) \cdot k \dots\dots\dots(7)$$

2. Adjusting Learning Rate

학습률과 모멘텀은 학습 속도를 좌우하는 중요한 파라미터들이다. 이들의 최적값을 구하기는 매우 어려운 일인데, 자칫 모델의 오류를 급격히 증가시킬 수 있기 때문이다. 대개 학습률은 매우 작은 값으로 정하는 것이 바람직

Table 1. Notations used by our restricted Boltzmann machine

Notation	Description	Value
v_i	visible unit i	
h_j	hidden unit j	
w_{ij}	weight connecting visible unit i and hidden unit j	$N(0, 0.01^2)$
a_i	bias for visible unit i	random number in $(-0.1, +0.1)$
b_j	bias for hidden unit j	random number in $(-0.1, +0.1)$
N	number of epochs	200
K	maximum rating value	5
F	number of hidden units	18
η	learning rate	0.01~0.05
$\theta_{\eta,UP}$	learning rate upper bound threshold	3.0
$\theta_{\eta,DOWN}$	learning rate lower bound threshold	1.0
α	momentum	0.1~0.5
α_{dist}	increment/decrement value of momentum	4/N
$\theta_{\alpha,UP}$	momentum upper bound threshold	1.0
$\theta_{\alpha,DOWN}$	momentum lower bound threshold	0.1

하다고 보고되었다. 이 두 가지 파라미터 외에 다른 변수 값들에 대한 상세한 안내는 [10]에 소개되어 있다. 본 연구에서는 모멘텀을 전 세대(epoch)에 걸쳐 다음과 같이 변화시키는 알고리즘을 제안한다. 알고리즘의 내용은 모멘텀의 상승 단계와 하강 단계를 교대로 반복시키는 것으로서, 상승 단계 동안에는 점차적으로 매 주기마다 α_{dist} 만큼 증가시키고, 상한치에 도달하게 되면 하강 단계를 시작한다. 하강 단계에서는 α_{dist} 만큼 매 주기마다 감소시키며 하한치에 도달하게 되면 다시 상승 단계로 회귀한다. 이에 따라, 다음 알고리즘을 매 주기마다 실행하며, 주기의 값은 실험적으로 결정하도록 한다.

[알고리즘 2]

- 1) stage = UP_STAGE
- 2) while(stage=UP_STAGE)
 - 2.1) if ($\alpha + \alpha_{dist} \leq \theta_{\alpha, UP}$)
 - 2.2) $\alpha = \alpha + \alpha_{dist}$
 - 2.3) else stage = DOWN_STAGE
- 3) while(stage=DOWN_STAGE)
 - 3.1) if ($\alpha - \alpha_{dist} \geq \theta_{\alpha, DOWN}$)
 - 3.2) $\alpha = \alpha - \alpha_{dist}$
 - 3.3) else stage = UP_STAGE

위 알고리즘에 따라 매 주기마다 모멘텀이 결정되면 학습률도 변경해야 하는데, [10]에 따르면 모멘텀의 변화에 따라 학습 에러가 증가되는 등의 불안정이 초래될 수 있으며, 에러가 안정될 때까지 학습률을 1/2배로 감소시킬 것을 권유하였다. 이에 따라, 본 연구에서는 다음과 같은 알고리즘을 매 주기마다 적용하여 학습이 안정적으로 진행되도록 학습률을 조정하였다.

[알고리즘 3]

- 1) $\eta = \eta * \frac{1}{1 - \alpha}$
- 2) if $\eta > \theta_{\eta, UP}$ then
 - 2.1) while($\eta > \theta_{\eta, DOWN}$)
 - 2.1.1) $\eta = \eta / 2$
- 3) endif

IV. Experiments

1. Experimental Background

1.1 Dataset

제안한 RBM의 학습 결과 성능을 측정하기 위하여 사용할 데이터셋은 사용자의 항목 평가등급을 정수 형태로 제공하여야 하며, 평가 등급의 범위가 그리 크지 않아 네트워크 학습 소요시간이 되도록 적게 드는 것이 바람직하다. 이러한 조건을 만족하는 데이터셋으로서 본 연구에서는 관련 연구에서 널리 활용되는 MovieLens 1M(<http://www.grouplens.org>)을 선정하였다. 이 데이터셋은 원래 6040명의 사용자들의 3952개의 영화에 대한 평가치를 포함하고 있으나, RBM의 효과적인 학습을 위해 임의의 1000명의 사용자들을 대상으로 구현하여 실험하였다. 실험 데이터셋의 구체적인 특성은 표 2와 같다. 희소성 수준(sparsity level)은 평가치 데이터 개수가 얼마나 적은지를 나타내는 수치로서 $1 - T / (U * I)$ 로서 산출하며, 값이 클수록 데이터셋은 희소하다. 본 연구에서는 훈련데이터 집합과 시험데이터 집합의 비율을 통상적인 8:2로 하여 실험하였다.

Table 2. Description of MovieLens dataset

Feature	Value
Number of users (U)	1000
Number of items (I)	3952
Rating range	1~5 (integer)
Number of ratings per user	≥ 20
Total number of ratings (T)	359,916
Sparsity level	0.9089
Recommendation threshold	4

1.2 Performance Metrics

협력 필터링 시스템에 대해 일반적으로 세 가지 측면에서 성능을 평가하는데, 즉, 예측 성능, 추천 성능, 그리고 순위 성능이다. 본 연구에서는 이들 모두를 고려하여 시스템의 성능을 평가한다. 예측 성능은 대개 MAE(Mean Absolute Error)와 RMSE(Rooted Mean Squared Error)를 산출하여 평가한다. 각 척도의 정의는 아래와 같다[2][3].

$$MAE = \frac{1}{n} \sum |\hat{r}_{u,i} - r_{u,i}| \dots\dots\dots (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum (\hat{r}_{u,i} - r_{u,i})^2} \dots\dots\dots (9)$$

추천 성능의 대표적 평가 척도는 정밀도(precision)와 재현율(recall)이다. 정밀도는 시스템의 전체 추천항목 수 대비 사용자가 실제로 선호하는 항목수를 말한다. 시스템이 산정한 현 사용자의 미평가항목의 평가예측치가 추천

기준값 보다 크면 이 항목을 추천한다. MovieLens 데이터셋에서는 평가값의 범위가 1부터 5이므로, 본 실험에서는 추천 기준값을 4로 정하였다. 재현율은 사용자가 선호하는 전체 항목들 중에서 얼마나 많은 항목들이 실제로 추천되었는지의 비율이다. 마지막으로 순위 성능을 측정하기 위하여 기존 연구에서 주로 활용하는 nDCG(normalized Discounted Cumulative Gain)를 선정하였다.

1.3 Methods for Performance Evaluation

협력필터링 시스템의 성능은 대개 시스템이 얼마나 정확하게 미평가항목의 평가치를 예측하는가에 달려 있다. 기존의 메모리 기반 방식에서는 시스템이 활용하는 유사도 척도에 따라 현 사용자의 인접이웃들을 선정한 후, 이들의 평가치를 종합함으로써 평가 예측치를 산출한다. 따라서 성능에 대한 유사도 척도의 영향은 매우 강조되었고, 여러 관련 연구 결과가 보고되었다[3].

본 실험에서는 성능 비교 대상으로서, 기존 연구를 통해 우수성이 입증되고 비교 척도로서 널리 활용되는 피어슨(Pearson, COR), 또다른 대표적인 메모리 기반 방식의 유사도 척도인 평균자승차이(Mean Squared Differences, MSD), 그리고 회귀 모델 기반이며 메모리 기반 방식보다 더 신속한 예측이 가능하다고 보고된 Slope One 알고리즘을 선택하였다[2]. 본 연구에서 제안한 RBM의 학습을 위하여 표 1에 나열한 다양한 파라미터값을 변화하여 실험할 수 있으나, 학습률과 모멘텀의 학습 에러에 대한 영향이 크다고 보고된 연구 결과[10]를 토대로 하여, 다음과 같이 세가지 서로 다른 조건을 적용하여 실험하였다.

- RBM-LM: 학습률과 모멘텀을 모두 변화 및 적용 (III.2의 [알고리즘 2]와 [알고리즘 3] 적용)
- RBM-L: 학습률만 변화, 고정값(0.1)의 모멘텀 적용 (III.2의 [알고리즘 3]만을 적용)
- RBM: 학습률을 고정(0.01)하고 모멘텀은 미적용.

2. Evaluation Results

2.1 Effect of Learning Rate and Momentum

가장 적합한 학습률과 모멘텀 값을 알아내기 위하여 이들을 변화시켜 실험하였다. 그림 3은 RBM-LM를 학습 후 측정된 MAE 결과이다. 그림에서 제시한 값들은 학습 시작 시에 RBM을 위한 초기값이므로 [알고리즘 2]와 [알고리즘 3]에 의하여 학습 과정에서 지속적으로 변화한다. 그림에도 불구하고 두 파라미터 값이 달라지면 MAE 성능 차이가 큰 것을 알 수 있다. 대체적으로 학습률을 고정하였을 때 모멘텀이 커질수록 성능은 저하되는 경향을 보인다. MAE 기준으로 가장 좋은 성능을 보인 학습률=0.01과 모멘텀=0.1을 초기값으로 추가 실험을 진행하였다.

2.2 Performance Evaluation of Different Methods

표 3은 각 방법의 예측 성능을 제시한다. 전통적이며 대표적인 피어슨 유사도 척도는 가장 좋은 성능을 나타냈고, 표에 나타난 기존의 세 방식들보다 RBM 방식들은 전체적으로 저하된 성능을 보였다. 이는 [12]의 결과와 마찬가지로이며, 그 원인들 중 하나는 RBM 학습에서는 유사한 성향의 이웃들만을 참조하여 예측치를 산출하는 것이 아니라, 모든 사용자들이 가중치와 바이어스를 공유하기 때문이며 2개 층 만을 활용하였으므로 보다 정밀한 학습이 이루어지지 못한 것으로 판단된다. RBM-LM은 RBM을 사용한 방식들 중에서 가장 좋은 성능을 보였으므로, III.2에서 제안한 알고리즘의 효과가 입증되었다.

그림 4는 추천 성과와 순위 성능을 나타낸다. 정밀도와 순위 성능은 MAE 결과와 마찬가지로 COR, MSD, SlopeOne의 순으로 우수함을 보였다. 다만 재현율은 SlopeOne이 매우 경쟁력이 있는 것으로 나타났다. RBM 방식 또한 MAE 결과의 성능 순서와 유사한데, RBM이 가장 저하된 성능을 보였고, 학습률과 모멘텀을 학습 과정 중에 변화시킨 RBM-LM이 RBM-L 보다 미세하나마 우수한 성능을 보였다.




Fig. 3. MAE results of RBM_LM with varying learning rate(LR) and momentum(MT)

Table 3. Results of prediction accuracy

	COR	MSD	Slope One	RBM -LM	RBM-L	RBM
MAE	0.7253	0.7351	0.7786	0.9479	0.9688	1.0153
RMSE	0.9239	0.9285	1.0049	1.1506	1.1708	1.2453

V. Conclusions

협력필터링 기반의 추천 시스템의 개발을 위하여 딥러닝 기술이 최근 활발히 이용되고 있고, 딥러닝 기술의 체계적이고 분석적인 연산을 통한 학습의 효과로 인해, 기존 방식에 비하여 우수한 성능을 나타내고 있다. 본 연구에서는 제한 볼츠만 기계를 이용하여 사용자의 평가데이터로부터 사용자가 미평가한 항목들의 평가점수를 예측하는 협력 필터링 모델을 제시하였고, 학습의 효율성과 성능을 위하여 학습 파라미터 변경 알고리즘을 제안하였다. 제안 방법의 성능 평가를 위하여, 다양한 네트워크 파라미터 값들에 대해 모델을 학습하였으며, 기존의 협력 필터링 기법들의 성능과 비교 분석하였다. 그 결과, 제안한 학습 파라미터 변경 알고리즘은 기본적인 제한 볼츠만 기계 모델보다 우수한 성능을 나타냄을 확인하였다.

본 연구에서는 단순한 제한 볼츠만 기계만을 활용하였으나, 향후 심층적 모델의 구축을 통한 학습에 대한 연구가 실행될 계획이며, 또한 제한 볼츠만 기계를 통해 예측 평가치만을 구하였으나, 사용자 특성 분석 등과 같은 다른 목적을 위해 활용하고 이를 협력 필터링 연구와 접목하는 것이 필요하다.

REFERENCES

- [1] S. Jaiswal and T. Jaiswal, "Survey on Recommender System Using Deep Learning Networks," *Artificial Intelligence Evolution*, pp. 72-89, 2020. DOI:10.37256/aie.122020435
- [2] M. Jalili, S. Ahmadian, M. Izadi, P. Moradi, and M. Salehi, "Evaluating Collaborative Filtering Recommender Algorithms: A Survey," *IEEE Access*, Vol. 6, pp. 74003-74024, 2018. DOI: 10.1109/ACCESS.2018.2883742
- [3] X. Su and T.M. Khoshgoftaar, "A Survey of Collaborative Filtering Techniques," *Advances in Artificial Intelligence*, 2009. DOI:10.1155/2009/421425
- [4] J. Liu and C. Wu, "Deep Learning Based Recommendation: A Survey," *Lecture Notes in Electrical Engineering*, Vol. 424, pp. 451-458, 2017. https://doi.org/10.1007/978-981-10-4154-9_52
- [5] Z. Batmaz, A. Yurekli, A. Bilge, C. Kaleli, "A review on deep learning for recommender systems: challenges and remedies," *Artificial Intelligence Review*, Vol. 52, No. 1, pp. 1-37, 2019. DOI:10.1007/s10462-018-9654-y
- [6] R. Mu, "A Survey of Recommender Systems Based on Deep Learning," *IEEE Access*, Vol. 6, pp. 69009-69022, DOI: 10.1109/ACCESS.2018.2880197
- [7] H. Wang, N. Wang, and D. -Y. Yeung, "Collaborative Deep Learning for Recommender Systems," *The 21th ACM SIGKDD International ACM Conference on Knowledge Discovery and Data Mining*, 2015, pp. 1235-1244. DOI: 10.1145/2783258.2783273
- [8] S. Zhang, L. Yao, A. Sun, and Y. Tay, "Deep Learning based Recommender System: A Survey and New Perspectives," *ACM Computing Surveys*, Vol. 52, No. 1, pp. 1-38, 2019. DOI: 10.1145/3285029
- [9] R. Salakhutdinov, A. Mnih, and G. Hinton, "Restricted Boltzmann Machines for Collaborative Filtering," *The 24th International Conference on Machine Learning*, 2007. DOI: 10.1145/1273496.1




Fig. 4. Performance results of different methods

273596

- [10] G. Hinton, "A Practical Guide to Training Restricted Boltzmann Machines," *Lecture Notes in Computer Science*, pp. 599-619, 2012. DOI: 10.1007/978-3-642-35289-8_32
- [11] Y. Zheng, B. Tang, W. Ding, and H. Zhou, "A Neural Autoregressive Approach to Collaborative Filtering," *The 33rd International Conference on Machine Learning*, 2016. DOI: 10.5555/3045390.3045472
- [12] S. Kang, "Deep Learning Based Recommender System Using Non-Rating Purchase Data," *Master's Thesis, DanKook Univ.*, 2016.
- [13] S. Deng, L. Huang, G. Xu, X. Wu, and Z. Wu, "On Deep Learning for Trust-aware Recommendations in Social Networks," *IEEE Trans Neural Netw Learn Syst.* Vol. 28, No. 5, pp. 1164-1177, 2017. DOI: 10.1109/TNNLS.2016.2514368
- [14] K. Georgiev and P. Nakov, "A Non-iid Framework for Collaborative Filtering with Restricted Boltzmann Machines," *The 30th International Conference on Machine Learning*, pp. III-1148-III-1156, 2013. DOI: 10.5555/3042817.3043065
- [15] L. Hu, J. Cao, G. Xu, L. Cao, Z. Gu, and W. Cao, "Deep Modeling of Group Preferences for Group-based Recommendation," *The 28th AAAI Conference on Artificial Intelligence, Canada*, pp 1861-1867, 2014. DOI: 10.5555/2892753.2892811
- [16] H. Byeon, "Mild Cognitive Impairment Prediction Model of Elderly in Korea Using Restricted Boltzmann Machine," *Journal of Convergence for Information Technology*, Vol. 9. No. 8, pp. 248-253, 2019. DOI: 10.22156/CS4SMB.2019.9.8.248
- [17] G. Lee, "Development of Collaborative Deep Learning System for Fashion Recommendation," *Master's Thesis, KonKuk Univ.*, 2019.
- [18] 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, pp. 1-25, 2019. DOI:10.3390/computation7020025
- [19] H. Larochelle, M. Mandel, R. Pascanu, and Y. Bengio, "Learning Algorithms for the Classification Restricted Boltzmann Machine," *Journal of Machine Learning Research*, Vol. 13, pp. 643-669, 2012. DOI: 10.5555/2503308.2188407
- [20] D. C. Cirean, U. Meier, L. M. Gambardella, and J. Schmidhuber, "Deep, Big, Simple Neural Nets for Handwritten Digit Recognition," *Neural Computing*, Vol. 22, No. 12, pp. 3207-3220, 2010. DOI: 10.1162/NECO_a_00052

Authors



Soojung Lee received the B.S. degree in Mathematics Education from Ewha University, Korea in 1985. She received M.S. and Ph.D. degrees in Computer Science from Texas A&M University, U.S.A, in 1990 and 1994,

respectively. Dr. Lee joined the faculty of the Department of Computer Education at Gyeongin National University of Education, Gyunggi-do, Korea, in 1998, as a professor. She is interested in recommender systems, information filtering, data mining techniques, and computer education.