

단순화된 xDeepFM 을 통한 Attention Network 기반 추천 방법

장이완¹, 조인휘*

¹한양대학교 컴퓨터소프트웨어학과

*한양대학교 컴퓨터소프트웨어학과

zyw0402@hanyang.ac.kr, iwjoe@hanyang.ac.kr

Attention Network-Based Recommendation System with Simplified xDeepFM

Yiwan Zhang¹, Inwhee Joe*

¹Dept. of Computer Science, Hanyang University

*Dept. of Computer Science, Hanyang University

요약

기계 학습에서 데이터 및 기능은 기계 학습의 상환을 결정한다. 이러한 기능은 산업 생산에서 과도한 데이터 양과 유형으로 인해 상당한 추가 비용이 발생할 수 있다. 따라서 적절한 특징 처리 방법이 매우 중요해졌다. 대부분의 기존 특징 처리 방법은 특징 엔지니어링을 기능 검색 문제, 즉 모델 성능을 최적화할 수 있는 기능 변환 작업을 검색하는 것으로 추상화한다. 그러나 자동 특징 엔지니어링의 경우 검색량과 변환 조합의 수가 매우 많기 때문에 요인 분해 기반 모델을 사용하여 벡터 곱셈을 통해 상호 작용을 측정하면 조합 특징의 패턴을 자동으로 학습하는 방법이 특히 효율적이다. xDeepFM 은 명확한 방식으로 특징적인 상호 작용을 생성하도록 설계된 새로운 Compressed Interaction Network (CIN)를 제안한다. 여기에 제시된 Low-rank Compressed Interaction Network (LRCIN)은 xDeepFM 접근 방식에서 CIN 네트워크의 단순화된 개선을 기반으로 하며 xDeepFM 에 주의 메커니즘을 추가하여 보다 정확하게 예측된다. 실험 결과에 따르면 모델은 계산 복잡성을 단순화할 뿐만 아니라 예측 정확도도 다른 모델보다 훨씬 우수하다.

1. 서론

CTR 예측을 기반으로 하는 추천 시스템의 경우 가장 중요한 것은 사용자의 클릭 행동 뒤에 있는 기능의 교차점을 이해하는 것이다. 다른 권장 시나리오에서 저차 기능 교차 또는 고차 기능 교차는 최종 CTR에 영향을 미칠 수 있다. FM(Factorization Machines) 알고리즘은 기능의 숨겨진 변수에 대한 내적 연산을 수행하여 기능 조합을 추출한다. 수년간의 연구 끝에 고차 교차 특성과 저차 교차 특성이 모두 중요하다는 것을 발견했으며 이 두 가지 교차 특징을 동시에 학습하는 것이 이 두 가지 기능 중 하나만 고려하는 것보다 성능이 우수하다. 이러한 교차 특징을 효과적으로 추출하기 위해 고차 및 저차 특징을 효과적으로 포착할 수 있는 xDeepFM 모델이 제안되었다. 우리의 주요 기여는 다음과 같이 요약된다:

- 우리는 학습 기능 간의 가중치를 위해 원래 xDeepFM 에 주의 메커니즘을 추가하는 새로운 모델을 제안한다.
- CIN 부분의 출력을 관심 메커니즘의 입력으로 사용

한 다음 관심 메커니즘을 사용하여 교차 특성을 가중시켜 가중 교차 특성 표현을 얻는다. 가중 교차 특성은 DNN의 출력 및 선형 부분의 출력과 융합된다.

- 우리는 원래 네트워크의 시간 복잡성을 줄이기 위해 low-rank approximation 을 사용하여 CIN 네트워크를 단순화했다.
- 실험 결과에 따르면 이 새로운 모델의 정확도가 원래 xDeepFM 모델보다 우수하다는 것을 발견했다.

2. 제안 방법

이 모델은 원래 CIN 모델의 매개변수 매트릭스를 낮은 순위 근사 방법으로 개선했으며 구체적인 구현 과정은 그림 1 에 나와 있다. 그런 다음 LRCIN 모델의 출력을 주의 네트워크의 입력으로 사용하고 DNN 및 Linear 층과 연결하여 전체 구조가 그림 2 에 표시된 새로운 모델을 형성한다. 이 모델에서 우리는 모든 출력을 결합하고 LRCIN 방법은 초기 CIN 방법에서 진화했으며 출력을 주의 단위로 입력하여 최종적으로 DNN의 출력 및 선형 출력과 결합하여 최종 출력 단

위가 된다.

```

Algorithm 1 Compressed Interaction Network with low-rank approximation (LRCIN)


---



Require: inputs with shape  $[None, n, k]$ ,  $cin\_size$ 
Ensure: output with shape  $[None, \sum_{i=1}^n field\_num[i], k]$ 
1: Initialize CIN Layer with  $cin\_size$ 
2: Build method:
3:   Set  $input\_shape: [None, n, k]$ 
4:   Set  $field\_num: [input\_shape[1]] + cin\_size$ 
5:   for  $i$  in  $range(len(field\_num)-1)$  do
6:     Initialize  $W[i]$  with shape  $(1, field\_num[0] * field\_num[i], field\_num[i+1])$ 
7:     Initialize  $V[i]$  with shape  $(1, field\_num[0] * field\_num[i+1])$  (for low-rank approximation)
8:   end for
9: Call method:
10:  Split inputs along last dimension into  $k$  parts:  $X_0$ 
11:  for each layer  $i$  in  $range(len(field\_num[1:]))$  do
12:    Split  $res\_list[-1]$  along last dimension into  $k$  parts:  $X_i$ 
13:    Perform matrix multiplication between  $X_0$  and  $X_i$ , transpose  $X_i$  before multiplication
14:    Reshape the result and transpose it
15:    Apply low-rank approximation using  $W[i] * V[i]$  and perform 1D convolution with input  $x$ 
16:    Transpose the result and append it to  $res\_list$ 
17:  end for
18:  Remove the first element ( $X_0$ ) from  $res\_list$ 
19:  Concatenate  $res\_list$  along axis 1
20:  Set output as the concatenated result


---



```

(그림 1) LRCIN 유사 코드.



(그림 2) 우리 모델.

3. 실험 결과

실험 동안 우리는 Criteo 데이터 세트와 MovieLens 데이터 세트를 사용했다. 그 중 Criteo 데이터 세트는 공개적으로 액세스할 수 있는 광고 클릭 수를 예측하는 모델을 개발하는 데 사용되는 잘 알려진 업계 벤치마크 데이터 세트이다. MovieLens 데이터 세트는 영화 메타데이터 정보 및 사용자 속성 정보를 포함하여 여러 영화에 대한 여러 사용자 등급 데이터가 포함되어 있다. 이 두 데이터 세트의 특정 데이터는 표 1에 나와 있다.

<표 1> 데이터 세트 매개 변수

Dataset	features	fields	instances
Criteo	18	7	10M
MovieLens	39	39	45M

표 2은 Criteo 및 MovieLens 데이터 세트의 다른 기존 CTR 모델과 이 모델의 AUC 비교 결과를 보여준다. BaseModel 과 PNN 의 AUC 지표는 크게 다르지 않지만 Wide&Deep 에 도달한 후 차이가 더 크다는 것을 알 수 있으며 DeepFM 은 Wide&Deep 의 인공 특징 프로젝트를 자동으로 변경하여 어느 정도 효과를 향상시킨 다음 xDeepFM 은 여러 차례의 명시적 교차 그룹을 추가하여 특징 명시적 교차로를 최적화하여 AUC 점수를 크게 향상시킨다. 그리고 이 방법이 MovieLens 데이터 세트의 AUC 점수보다 Criteo 데이터 세트에 더 효과적임을 알 수 있는데, 이는 주로 Criteo 데이터 세트가 많은 희소 특성을 가지고 있고 MovieLens 데이터 세트보다 규모가 훨씬 커서 심층 신경망 모델 학습에 매우 적합하기 때문이다. 우리는 주로 Wide & Deep 모델이 원래 설계된 권장 작업에 더 가깝기 때문에 MovieLens 데이터 세트에서 Criteo 데이터 세트보다 MovieLens 데이터 세트에서 더 잘 수행됨을 알 수 있다. Criteo 데이터 세트에서 높은 희소성과 규모로 인해 더 많은 문제에 직면할 수 있다.

<표 2> 모델 비교

Model	Criteo	MovieLens
PNN	0.7432	0.7210
Wide&Deep	0.7580	0.7643
DeepFM	0.7740	0.7790
xDeepFM	0.8136	0.7970
Our Model	0.8230	0.8078

4. 결론

실험 결과에서 모델의 연산량을 줄일 뿐만 아니라 모델의 정확도를 효과적으로 향상시켰음을 알 수 있다. 향후 작업에서 우리는 많은 효과적인 실험을 계속 추가하고 보완 방법을 개선하며 CTR 분야에 기여할 것이다.

참고문헌

- [1] Chen J, Zhang H, He X, et al. Attentive collaborative filtering: Multimedia recommendation with item-and component-level attention[C]//Proceedings of the 40th International ACM SIGIR conference on Research and Development in Information Retrieval. 2017: 335-344.
- [2] Dong X, Yu L, Wu Z, et al. A hybrid collaborative filtering model with deep structure for recommender systems[C]//Proceedings of the AAAI Conference on artificial intelligence. 2017, 31(1).
- [3] Cheng H T, Koc L, Harmsen J, et al. Wide & deep learning for recommender systems[C]//Proceedings of the 1st workshop on deep learning for recommender systems. 2016: 7-10.
- [4] Ko H, Lee S, Park Y, et al. A survey of recommendation systems: recommendation models, techniques, and application fields[J]. Electronics, 2022, 11(1): 141.