

# Deep Interest Network을 활용한 옥외광고 매체 추천 서비스의 설계 및 구현

조승규, 김원섭, 박효진, 이규상, 유상기, 조수필, 노민영, 김지인, 손종수  
CJ올리브네트웍스

## Design of Out-of-home advertising media recommendation service using Deep Interest Network

Jo Seung-Kyu, Kim Won-Seob, Part Hyo-Jin, Lee Gyu-Sang, Ryu Sang-gi, Cho Su-phil, Noh Min-Young, Kim Jean, Sohn Jong-Soo  
CJ OliveNetworks

E-mail : seungkyu.jo@cj.net, wonseob.kim@cj.net, hyojin1.park@cj.net, gyusang.lee@cj.net, sanggi.ryu1@cj.net, sphil.cho@cj.net, my.noh@cj.net, jeein.kim@cj.net, jongsoo.sohn@cj.net

### 요 약

최근 옥외광고 미디어의 디지털화 추세에 힘입어 시장 규모가 급성장하고 있다. 이에 따라 효과적인 광고집행을 위해 옥외광고 매체의 공급 인프라 구축 또한 매우 중요해졌다. 하지만 온라인으로의 디지털전환의 더딘 속도와 체계화 되어있지 않은 매체 공급자의 생태계로인해, 정량적 데이터에 대한 신뢰부족 문제가 발생하고 있다. 이러한 문제를 극복하기 위해 본 논문에서는 딥러닝 기반의 추천 서비스 설계와 구현을 보인다. 딥러닝 모델은 Click-Through Rate Prediction 기반의 Deep Interest Network 모델을 활용한다. 제안하는 서비스를 통해 광고주는 정량적인 데이터에 대한 신뢰도를 향상시킬 수 있으며, 매체 공급자는 최적의 비용으로 옥외광고 매체 제공에 대한 디지털 전환을 가능하게 할 것으로 기대한다.

### 1. 서론

IT 기술이 발전하면서 오프라인 위주의 옥외광고 시장에서 변화가 일어나고 있다. 그중 디지털 기술과 옥외광고가 결합한 디지털 옥외광고 매체가 전체 옥외광고 시장의 성장을 견인하고 있다. 디지털 옥외광고 매체의 성장은 방대한 양

의 데이터를 만들어낼 것이고, 옥외광고 매체의 특징인 베타적 점유에 대한 문제가 해소될 것으로 예상된다. 이것은 기존 마케팅 활동을 더욱 복잡하게 만드는 요소라고 할 수 있다. 반면, 광고주 또는 광고대행사 입장에서 어떤 위치에 있는 옥외광고 매체에 광고집행을 행할 것인지는

여전히 영업사원의 노하우와 과거의 경험을 통해 이루어지고 있다. 임정일 외 (2021) [1] 에 따르면, 기존 광고 매체들과 옥외광고매체는 집행 의사결정 요인이 다르며, 특히 정량적인 데이터의 경우 신뢰 문제 이슈로 인해 거의 활용되지 않는다고 밝혔다. 이러한 원인으로 진흥근 (2013) [2] 에서는 TV, 라디오, 신문과 같은 전통적 매체와는 달리 옥외광고 매체에 대한 광고집행의 정량적 효과를 측정하는 것이 어렵다는 것을 밝혔다.

딥러닝 기반의 Click Through Rate(CTR) 모델은 온라인 플랫폼에 등록된 상품을 클릭할 확률을 예측해주며 사용자의 과거 구매이력, 상품의 속성과 같은 데이터를 사용한다. 일반적으로 높은 확률일수록 상품의 선호도가 높다고 해석된다. 이러한 데이터의 특성은 광고주의 과거 계약이력, 옥외광고 매체의 속성으로 대응할 수 있으며, CTR 모델을 오프라인 옥외광고 매체 추천 서비스에 활용하는 것이 가능하다.

이에 우리는 정량적 데이터에 기반한 옥외광고 추천을 위하여 CTR 예측 모델 중 Deep Interest Network(DIN) [4] 를 활용하였고 이를 구현하였다. 본 논문에서는 제안하는 시스템의 설계와 서비스 아키텍처에 대해 설명한다.

2장에서는 사용한 데이터와 딥러닝 기반 추천 시스템 알고리즘에 대해서 소개한다. 3장에서는 플랫폼 구축 아키텍처에 대해서 소개한다. 4장에서는 운영관점에서 부하테스트와 비용에 대해서 소개하고, 5장에서 결론을 맺는다.

## 2. 추천 시스템

본 장에서는 추천시스템 개발에 사용된 데이터와 딥러닝 알고리즘에 대해서 소개한다. 이는 우리가 선행연구로 개발한 방법을 [3] 고도화 한 것이다.

### 2.1 데이터

2016년 1월부터 2021년 3월까지 계약된 옥외

광고 이력 데이터를 사용한다. 선정된 변수로는 옥외광고 매체 지역, 옥외광고 매체 가격, 계약기간, 옥외광고 매체 ID, 광고주ID, 광고 아이템의 산업군이 있다(표 1). 임정일 외 (2021) [1] 의 연구결과에 따르면 마케팅 활용성과, 과시적요인은 옥외광고 매체 선정의 중요한 요인임을 밝혔다. 이러한 특성에 기인하여 외부데이터인 옥외광고 매체 지역의 연령별 성별 유동인구정보와, 지역별 카드데이터를 분석하여 라이프스타일 정보를 추가 메타정보로 활용하였다(표 2).

지역	매체 ID	가격	계약시작	계약종료	광고주 ID	속성
태헤란로	C01	20	16.08.01	16.12.31	B01	등산복
강남대로	C02	25	16.09.01	17.01.31	B02	화장품

<표 1. 옥외광고 이력 정보 예시>

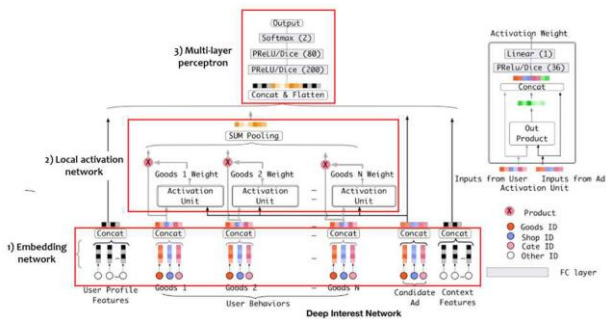
기간	지역	10대남	...	60대여	10대남라이프스타일	10대여라이프스타일	...
19.01	태헤란로	13,225		1,257	게임	맛집추천	
19.01	강남대로	9,254		856	맛집추천	쇼핑	

<표 2. 유동인구 정보 예시>

### 2.2 Deep Interest Network

추천시스템에서 CTR(Click Through Rate) 기반의 딥러닝 모델 Deep Interest Network(DIN) [4] 를 사용한다. DIN은 사용자가 소비했던 아이템의 과거 행동 정보를 입력으로 받아서 사용자-아이템 선호도를 계산할 수 있다. 또한 사용자의 성별, 나이와 같은 부가적인 메타정보를 신경망의 입력으로 사용할 수 있으며, 이는 선호도 계산을 보조하는 정보로 활용된다(그림 1). 본 논문의 사례에서 사용자는 광고주로 대응되며, 아이템의 과거 행동 정보는 계약된 옥외광고 이력으로 대응할 수 있다. 추가로 수집한 연령별 성별 유동인구 정보와 라이프스타일 정보는 부가적인 메타정보로 대응할 수 있으며, 이러한 데이터의 특징을 고려하였을 때 DIN 모델이 적합하다. 연령별 성별 유동인구 정보와 라이프스타일 정보는 지역별로 격차가 상이하기 때문에 정규화를 진행하여 동일한 기

준으로 데이터의 특성이 반영될 수 있도록 전처리를 진행하였다.



<그림 1. Deep Interest Network>

### 3. 시스템 전체 구성

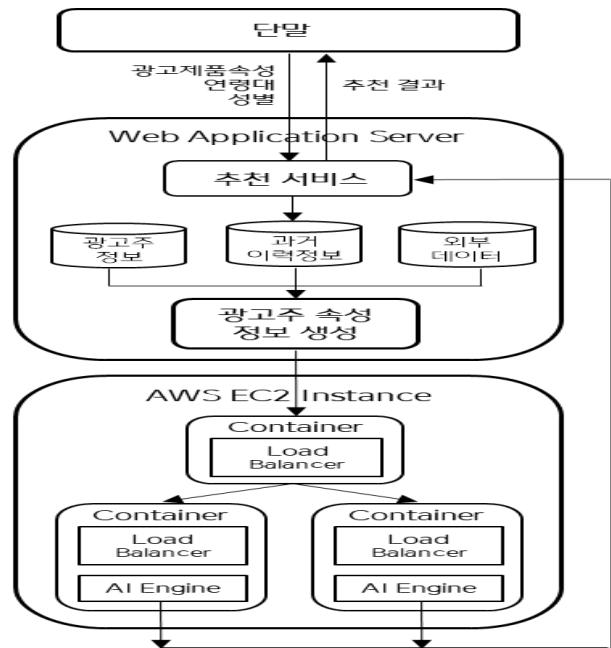
본장에서는 시스템 아키텍처 구성에 대해서 보인다. 광고주가 사용하는 단말에서 광고를 하고자 하는 지역, 광고의 대상이 되는 고객의 연령층, 성별, 제품의 속성을 입력한다. 애플리케이션 서버에서는 입력된 데이터를 광고주의 기본 정보로 사용하여 DIN입력에 넣을 수 있도록 전처리하여 속성값을 생성하고 AWS AI Engine에 전달한다. Load Balancer를 통해 트래픽을 분산시키며, AI Engine에서 입력값을 기반으로 추천된 결과를 단말로 Serving한다. <그림 2>는 본 논문에서 개발한 서비스 아키텍처 구성도의 흐름이다.

### 4. 서비스 아키텍처

본 장에서는 추천 시스템을 서비스하기 위한 아키텍처에 대해서 기술한다. 추천 시스템을 이용하는 주 고객은 광고주와 기업 사용자이다. 제한적 규모의 고객을 대상으로 하기 때문에, 구축 비용의 효율화를 위해 AWS 클라우드 컴퓨팅 시스템을 이용하였다. 스펙은 p2,8xlarge이며 8개의 GPU를 활용할 수 있다

#### 4.1 Docker Container

Docker는 모든 소프트웨어가 이미 설치, 구성 및 테스트된 바이너리 이미지를 통해 실행 환경의 종속성 문제를 해결하는 오픈소스 프로젝트이며,




<그림 2. 서비스 아키텍처 구성도>

Container는 격리된 공간에서 프로세스가 동작하는 기술이다 [5]. Local에서 개발된 추천시스템을 안정적으로 배포하기 위해서는 동일한 환경을 구축하는 것이 중요하다. 또한 비용이나 보안과 같은 문제로 인해 물리 서버를 도입 시, 손쉽게 Migration이 가능하다. 본 논문에서는 AWS EC2에 Docker 환경을 구성하고 3개의 Container를 활용한다

#### 4.2 Load Balancer


Load Balancer는 서버에 가해지는 부하를 분산해주는 장치를 뜻한다. Client와 Server 사이에 위치하여 일대일(1:1), 일대다(1:N) 통신을 가능하게 하며, 특정 서버로 집중되는 트래픽을 적절하게 분산시켜준다. 본 논문에서 사용한 AWS EC2는 500~600TPS 처리가 가능하지만, 안정적으로 추천 시스템을 이용하기 위해서는 GPU 자원을 효율적으로 사용하고, 특정 GPU에 과도하게 집중되는 것을 방지하기 위해 오픈된 Load Balancer를 적용하여 트래픽을 분산하였다. 또한 특정 GPU의 장애가 발생할 경우를 대비하여 2개의 Docker Container에 4개의 GPU를 각각 할당한다.



<그림 3. Transaction을 분산하는 과정>

### 4.3 AI Serving

AI 모델을 배포하기 위한 방법으로는 Tensorflow Serving과 같은 머신러닝 워크플로우 배포 서비스를 활용하거나 Flask와 같은 웹 프레임워크를 사용하는 방법이 있다. 옥외광고 추천 시스템에 사용된 DIN모델은 단말에서 입력받은 광고주의 정보를 기반으로 과거의 광고 이력 정보와 그와 관련된 연령, 성별, 라이프 스타일 등 메타정보를 추가로 전처리하여 모델의 입력으로 사용해야하기 때문에, 이 과정에서 다양한 저장매체로의 빠른 접근과 이력정보 관리가 중요하다. GO와 비슷한 성능과 안전성으로 최근에 주목 받고 있는 FastAPI [6] 웹 프레임워크를 사용하였다. Flask보다 가벼우며 Database, Json 등 여러 비즈니스 처리와 오픈 솔루션과의 연계가 용이하다는 장점이 있다. <그림 4>은 FastAPI가 애플리케이션에서의 요청에 대하여 처리하는 과정을 보여주는 AI Serving 로직이다.



<그림 4. FastAPI를 이용한 AI Serving>

## 5. 결론

본 논문에서는 딥러닝을 활용한 옥외광고 매체 추천 서비스의 아키텍처에 대해서 보였다. 옥외광

고 이력과 유동인구, 라이프스타일과 같은 메타정보를 추가하여 광고주의 선호도를 계산하는 DIN을 활용하여 추천 시스템을 구축하였다. 또한, 실제 서비스 배포를 위해 AWS, Docker, Load Balancer, AI Serving를 활용한 아키텍처를 보였다. 이를 통해 광고주에게는 딥러닝에 의한 추천을 통해 정량적 데이터의 신뢰성을 향상시키고, 옥외광고 공급자는 추천 서비스 아키텍처를 통해 비용 친화적으로 서비스 환경을 구축과 디지털전환을 할 수 있을 것으로 기대한다.

앞으로, 본 연구팀에서는 FastAPI 웹 프레임워크를 쿠버네티스에서 머신러닝 워크플로우를 배포할 수 있게 도와주는 시스템인 쿠베플로우로 교체하여 모델과 서비스를 분리할 예정이다. 이를 통해 모델은 추천에 필요한 데이터를 확보하여 고도화를 진행하고, 서비스는 변화하는 옥외광고 시스템 환경에 따라 유연하게 대응하고자 한다.

### [참고문헌]

- [1] 임정일, 이인성, 김나경, (2021), “국내 광고 실무자들의 옥외광고 매체 선정요인 연구”, *Journal of OOH Advertising Research* Vol.18, No.3, pp.29~61.
- [2] 진홍근, (2013), 옥외광고 매체집행 의사결정 과정 연구, *옥외광고학연구*, 10(2), 135-158.
- [3] 서현우, 김수혁, 유상기, 조승규, 조수필, 손종수, 임치현, (2021), “Negative Sampling과 Deep Interest Network를 활용한 오프라인 옥외광고 추천시스템 개발”, 대한산업공학회 학술대회.
- [4] Zhou, G, et al, (2018), “Deep interest network for click-through rate prediction”, *In Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining* (pp. 1059-1068).
- [5] Boettiger Carl, (2014), “An introduction to Docker for reproducible research, with examples from the R environment” *arXiv preprint arXiv:1410.0846*
- [6] FastAPI, (Oct 8, 2021), <https://fastapi.tiangolo.com/>