

Digital Signage service through Customer Behavior pattern analysis

Min-Chan Shin*, Jun-Hee Park*, Ji-Hoon Lee*, Nammee Moon**

*Student, Dept. of Computer Science, Hoseo University, Asan, Korea

*Student, Dept. of Computer Science, Hoseo University, Asan, Korea

*Student, Dept. of Computer Science, Hoseo University, Asan, Korea

**Professor, Division of Computer and Information Engineering, Hoseo University, Asan, Korea

[Abstract]

Product recommendation services that have been researched recently are only recommended through the customer's product purchase history. In this paper, we propose the digital signage service through customers' behavior pattern analysis that is recommending through not only purchase history, but also behavior pattern that customers take when choosing products. This service analyzes customer behavior patterns and extracts interests about products that are of practical interest. The service is learning extracted interest rate and customers' purchase history through the Wide & Deep model. Based on this learning method, the sparse vector of other products is predicted through the MF(Matrix Factorization). After derive the ranking of predicted product interest rate, this service uses the indoor signage that can interact with customers to expose the suitable advertisements. Through this proposed service, not only online, but also in an offline environment, it would be possible to grasp customers' interest information. Also, it will create a satisfactory purchasing environment by providing suitable advertisements to customers, not advertisements that advertisers randomly expose.

▶ **Key words:** Intelligent digital signage, Behavior pattern analysis, Skeleton modeling, Behavior big data, Sensor data analysis

[요 약]

최근 연구된 상품 추천 서비스들은 고객들의 구매 이력을 통해서만 추천이 이루어졌다. 본 논문에서는 구매 이력을 통해 추천뿐만 아니라 고객이 상품을 고를 때 취하는 행동 패턴을 분석하여 관심도가 높은 광고를 노출하는 행동 패턴 분석 기반 디지털 사이니지 서비스를 제안한다. 이 서비스는 고객 행동 패턴을 분석하여 실질적으로 관심을 가지는 상품에 대해 관심도를 추출한다. 추출된 관심도와 고객들의 구매 이력을 Wide & Deep 모델을 통해 학습하고, 이를 바탕으로 MF(Matrix Factorization) 모델을 통해 다른 상품들의 희소 벡터를 예측한다. 예측된 상품 관심도에 대한 순위를 도출하고, 적합한 광고를 노출하기 위해 고객과 상호 작용할 수 있는 인도어 사이니지를 활용한다. 본 논문의 서비스를 통해 온라인뿐만이 아닌 오프라인 환경에서도 고객의 관심 정보를 파악하고 단순히 무작위로 노출하는 광고가 아닌 고객에게 적합한 광고를 제공하여 만족도 높은 구매 환경이 조성될 것이다.

▶ **주제어:** 지능형 디지털 사이니지, 행동 패턴 분석, 스켈레톤 모델링, 행동 빅 데이터, 센서 데이터 분석

- First Author: Min-Chan Shin, Corresponding Author: Nammee Moon
- *Min-Chan Shin (shinmc0322@gmail.com), Dept. of Computer Science, Hoseo University
- *Jun-Hee Park (cach456@gmail.com), Dept. of Computer Science, Hoseo University
- *Ji-Hoon Lee (developmona@gmail.com), Dept. of Computer Science, Hoseo University
- **Nammee Moon (mnm@hoseo.edu), Division of Computer and Information Engineering, Hoseo University
- Received: 2020. 08. 13, Revised: 2020. 09. 09, Accepted: 2020. 09. 09.

I. Introduction

최근 몇 년간 디스플레이와 반도체 기술이 발달하면서, 시장성과 성능을 모두 만족할 솔루션도 지속해서 개발되어 디지털 사이니지의 수요가 최근 몇 년간 급격히 늘고 있다[1,2]. 디지털 사이니지(Digital signage)는 유무선 네트워크를 통해 원격 제어가 가능한 디지털 디스플레이를 공공 또는 상업 공간에 설치하여 정보엔터테인먼트 광고 등을 제공하는 디지털 미디어이다[3].

대표적으로 백화점이나 영화관, 상점 등 다양한 곳에서 활용되고 있는 디지털 사이니지는 키오스크(Kiosk)와 같이 원격 디스플레이로 광고를 노출하는 형태를 보인다. 디지털 사이니지는 단순히 광고를 노출 시키는 것뿐만이 아니라 사람과 매체 간의 상호 작용이 가능한 디지털 사이니지를 선보이고 있다[1,3]. 상호 작용하는 디지털 사이니지 종류에는 화면에 사람이 입력한 선택지에 따른 정보 노출 디지털 사이니지, 상황 인지 또는 불특정 사용자의 정보를 실시간으로 받아들여 적합한 콘텐츠를 제공하는 디지털 사이니지가 존재한다.

이러한 디지털 사이니지를 통해 정적 이미지, 동적 콘텐츠 혹은 비디오 등 디지털 디스플레이를 통해 생동감 있는 영상과 강력한 시각적 메시지를 통해 디지털 사이니지는 사람들의 주목을 이끌고 넓은 선택의 기회를 제공한다[2].

대부분의 추천 방법들은 온라인 환경에서 쿠키 추적 및 구매 이력을 통해 추천이 이루어지며, 최근 O2O(Online to Offline) 서비스의 확산으로 인해 오프라인 상품을 기반으로 개개인의 추천 서비스에 관한 연구가 진행 중이다. 현재 오프라인 추천의 경우 매장의 점원을 통한 추천이 이루어지며, 이는 고객의 관심사에 맞춰진 추천이 아닌 매장 입장에서의 주관적인 추천이 이루어진다[4]. 소비자는 점원의 추천을 통한 방식으로 인해 자신이 오프라인에서 실질적으로 필요로 하는 상품이 아닌 다른 상품을 구매하여 이후에 환불, 교환 등의 불편함이 존재한다.

본 논문은 위의 불편함을 해소하고자, 고객이 실질적으로 관심을 가지는 상품을 파악하기 위해 카메라와 무게 측정 센서를 이용하여 고객의 관심도를 추출한다. 추출된 관심도와 기존 고객들의 구매 이력들을 Wide & Deep 모델을 통해 학습하여, 학습된 정보를 바탕으로 MF(Matrix Factorization) 모델을 통해 관심도와 측정되지 않은 다른 상품들에 대한 희소 벡터를 예측한다. 추천 모델을 통해 고객의 상품 관심도에 대한 순위를 도출하여 고객과 매칭되는 상품의 광고를 디지털 사이니지를 통해 노출 시킨다. 일련의 과정들을 통해 노출하여 고객들의 만족도 높은 구

매를 도울 수 있는 고객 행동 패턴 분석을 통한 디지털 사이니지 서비스 DSCB(Digital Signage service through Customer Behavior pattern analysis)를 제안한다.

II. Related works

2.1 Recommendation system based on behavior pattern

추천 시스템은 정보 필터링(Information Filtering) 기술의 일종으로, 주로 협업 필터링(Collaborative Filtering)과 콘텐츠 기반 필터링(Content Based Filtering)으로 나뉘어진다. 이 두 가지 필터링 방식의 장점을 혼합하여 사용하는 것으로 데이터의 부족으로 인한 cold start 문제의 개선을 목적으로 한 하이브리드 방식 사용되고 있다[5]. 또한, 최근 딥러닝 모델을 사용한 추천 시스템들이 연구되고 있다.

Wide 모델은 학습 데이터를 기반으로 구체화한 예측 결과를 반환하여 주기 때문에, 정보가 적고 편향된 성향이 있는 사용자에게 정확도 높은 추천을 할 수 있다. 그러나 기존의 기억된 결과에만 의존하여 추천을 진행하기 때문에 반복되는 추천 결과를 제공하는 단점이 있다.

Deep 모델은 DNN(Deep Neural Network)을 기반으로 구성되는 모델로, 학습 데이터를 네트워크가 일반화하고 학습하여 다양한 상품을 추천할 수 있으며 높은 세렌디피티(Serendipity)를 기대할 수 있다. 그러나 Deep 모델은 학습하면서 지나친 일반화의 발생 가능성이 있으며, 구체적인 추천 정보를 전달하기 힘들다.

Wide 모델과 Deep 모델의 단점을 개선하기 위하여 두 가지 결합한 Wide & Deep 모델이 사용되고 있다[6]. Wide & Deep 모델은 선형과 비선형 기능을 동시에 학습할 수 있으며, 일반화의 장점과 암시적 속성을 통해 정확도를 향상 시킨다[7]. P. Covington.은 Wide & Deep 모델을 사용하여 추천 모델 정확성의 우수성을 보였다[8]. 더 나아가 Wide 모델과 Deep 모델의 입력값을 공유하는 WDSI(Wide & Deep learning Sharing Input data) 모델을 제시하여 기존보다 더 높은 성능을 보였다[9].

또한, 최근 cold start 문제를 해결하는 방법으로 협업 필터링의 MF 모델이 정확도의 우수성과 확장성의 이유로 활용되고 있다[10,11]. MF 모델은 등급 매트릭스를 사용자 및 항목 희소 벡터로 분해하여 사용자 및 항목 기능의 희소 벡터를 예측하는 방법으로 cold start 문제 해결과 정확도를 향상한다[12].

추천 시스템에서는 행동 패턴 분석을 통해 암시적 데이터로도 활용되고 있다. 행동 패턴이란 사용자의 반복적인 행동 또는 특정 상황에서 주로 하는 행동이다. 이러한 정보는 사용자의 의도를 내포하고 있으므로 암시적 표현 데이터로 사용된다[13,14]. 암시적인 데이터들은 명시적 데이터를 사용한 추천 시스템의 정확도 향상과 희소 벡터로 인한 cold start 문제에도 도움을 줄 수 있다. 또한, 추천 시스템에서의 행동 패턴 분석은 사용자 행동의 피드백을 시스템에 즉각적인 반영을 할 수 있으므로 높은 서비스 만족도를 제공할 수 있다. Z. Fang,은 사용자의 행동 패턴과 MF 모델을 혼합한 모델의 정확도가 높다는 것을 확인하였다[15]. X. Xu.는 행동 데이터를 융합하는 MF 모델을 제안하여 높은 신뢰도를 검증하였다[16].

2.2 Digital signage service

디지털 사이니지는 공공장소나 상업 공간에서 문자나 영상 등 다양한 정보를 디스플레이 화면에 보여주는 서비스이며, 광고 또는 홍보를 목적으로 사용한다[3]. 디지털 사이니지 플랫폼이란 이를 운영할 수 있도록 제공되는 소프트웨어, 하드웨어 등 모든 시스템이라고 할 수 있다. 관리자가 네트워크를 통해 콘텐츠를 원격으로 전송하고, 정해진 시간에 따라 광고 콘텐츠들이 TV, 전광판 등 다양한 디스플레이를 통해 노출한다.



Fig. 1. Types of digital signage

디지털 사이니지는 아웃도어 디지털 사이니지, 인도어 디지털 사이니지로 나뉘며 세부적으로는 미디어 파사드, 화면을 영사하는 인간형 디지털 사이니지, 군집된 시청자에게 방송하는 내로캐스팅 등 의미가 확대되고 있다.

아웃도어 디지털 사이니지는 현재 가장 흔한 방법이며, 중앙 관제 센터에서 광고를 결정하여 명령하고, 상호 작용이 없는 원시적인 형태를 가지고 있다. 인도어 디지털 사이니지는 얼굴 인식 기술 등 사용자의 특징을 파악하여 사용자에게 맞는 광고를 재생하는 방법이다.

최근 인도어 사이니지가 빠른 속도로 발전하고 있으며 이러한 광고 방식을 통해 사용자에게 맞춰진 광고를 재생하거나, 프로모션 코드를 발행하는 등 다양하게 활용되고 있다.

III. The Proposed Scheme

본 논문에서 제안하는 DSCB 서비스는 고객의 행동 데이터를 이용하고, 고객의 행동 패턴을 분석하여 고객 맞춤 광고를 디지털 사이니지 플랫폼을 통해 노출한다.

기본적인 원시 데이터로는 카테고리 정보, 사용자 행동 패턴 정보가 있으며, 서버에서 사용자의 행동 정보를 통해 관심 품목 식별이 이루어진다. 이어서 사용자의 특정 행동 패턴을 파악하여 사용자가 관심 있는 품목에 대한 가중치를 부여한다. 이렇게 추출된 가중치와 저장된 사용자의 과거 이력 정보를 추천 모델에 입력하여 사용자에게 맞춰진 광고를 디지털 사이니지에 노출한다.

3.1 DSCB service design

DSCB 서비스의 수집 데이터는 카테고리 데이터, 무게 센싱 데이터, 고객 행동 데이터 세 가지로 구분한다. 서버에서는 카테고리 데이터와 품목 매칭, 무게 변화 감지 및 스케틀론 모델링으로 행동 패턴 분석을 통한 가중치 도출, 판매 상품 목록과 고객 구매 이력을 저장하는 데이터베이스, 이들의 입력값으로 순위를 도출하는 추천 모델 부분 네 가지로 구분한다.

3.2 Service structure and process

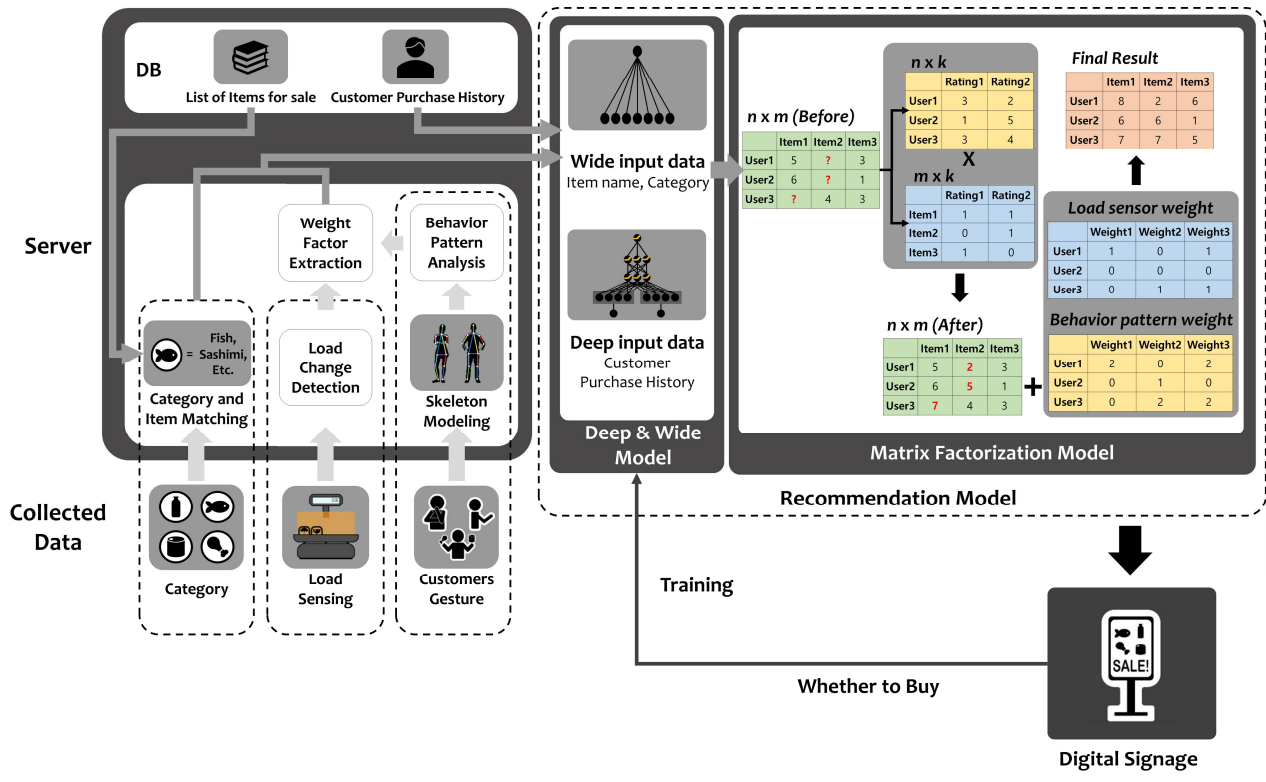


Fig. 2. Overall structure of DSCB service

Fig. 2은 DSCB 서비스의 전체 구조이다. DSCB는 영상 촬영과 무게 센서를 통해 특정 카테고리의 특정 상품에 대한 사용자의 가중치를 구한다. 사용자의 행동을 BRNN (Bidirectional Recurrent Neural Networks) 기반의 스켈레톤 모델링을 통해 확인하고, 해당 카테고리의 무게 센서를 통해 사용자가 어떤 상품을 집었는지 파악한다. 이러한 방법을 통해 사용자가 관심을 가진 상품 및 카테고리를 확인하여 가중치를 부여한다.

추출된 가중치와 서버의 데이터베이스에 저장된 고객 구매 이력, 매칭 데이터를 추천 모델의 입력 값으로 둔다. 추천 모델을 통해서 해당 고객이 필요로 하는 품목의 추천 광고를 불러오고, 추천 순위가 가장 높은 광고를 디지털 사이니지에 노출한다.

3.3 Recommended model

DSCB 서비스의 추천은 Wide & Deep 모델을 통한 학습 결과를 입력데이터로 하여 입력데이터의 희소 벡터를 추출하기 위한 MF 모델을 사용했다.

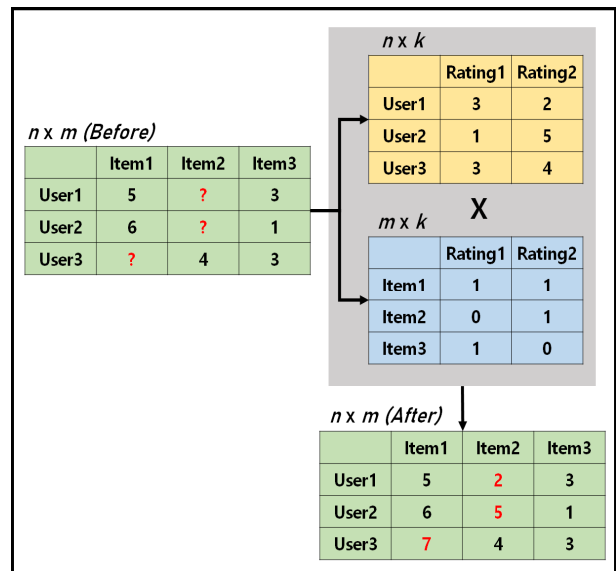


Fig. 3. Sparse vector extraction using MF model

추천 시스템에서는 초기 정보가 부족하여 발생하는 cold start 문제가 항상 대두되어왔고, 해결 방안으로 하이브리드 기법을 사용하는 등 많은 연구가 이루어졌다. 이를 토대로 DSCB 서비스에서 Fig. 3의 그림처럼 Wide & Deep 모델을 통해 나온 결과값을 MF 모델을 사용하

여 User 행렬과 Item 행렬로 분해하여 각 행렬에 해당하는 등급 값을 이용하여 분해된 두 행렬을 곱하여 다시 하나의 행렬로 만들어 기존에 비어있던 벡터에 예측값을 집어넣음으로 문제를 해결한다.

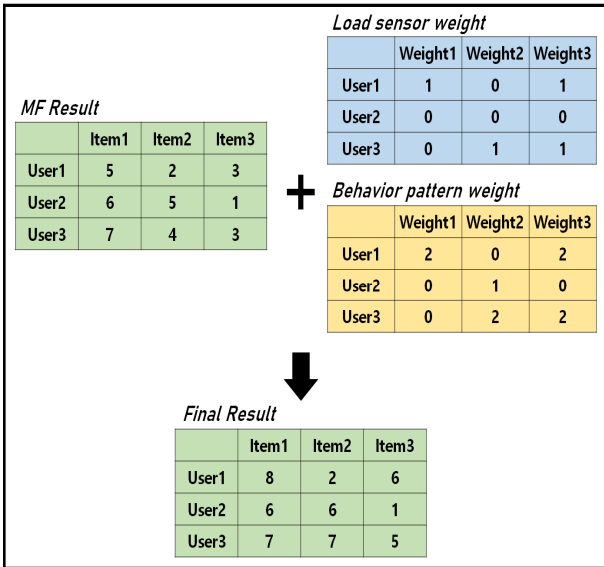


Fig. 4. The final result of combining the weight and the result of MF model

MF 결과값이 도출되면 Fig. 4의 그림과 같이 무게 센서의 변화와 행동 패턴 분석을 통해 얻은 가중치를 이용하여 최종 결과를 도출한다. 일련의 과정으로 도출된 최종 결과를 통해 순위를 매겨 가장 순위가 높은 상품에 대한 광고를 노출한다.

IV. Experiment

4.1 Scenario

DSCB 서비스의 실험 환경 속 모의 상점은 ‘사무용품’ 카테고리 진열대의 모습을 재현하였으며, 상점에서 고객은 사무용품 중 특정 상품을 구매하기 위해 상품을 둘러보고 있는 설정이다. 고객 구매 이력과 판매하는 상품의 목록은 서버 데이터베이스에 저장되어 있으며, 이를 통해 실질적인 추천 및 서비스가 이루어진다.

모의 상점의 진열장에는 각각 무게 센서를 설치하고 센서 모듈 위에는 사무용품을 올려둔다. 실험자의 오른쪽에는 실험자의 실시간 행동 패턴을 파악하기 위한 웹캠을 설치하고, 서버 역할을 하는 Jetson Nano 보드도 설치한다.

실험자는 본인이 구매하고 싶은 상품을 살펴보고, 그중

가장 관심 있는 상품을 상세히 보기 위해 집어 올리는 행동을 취한다. 웹캠은 실험자의 옆 자세를 파악하여, 이는 스켈레톤 모델링을 통해 실험자의 행동 패턴을 분석하여 실험자의 관심도에 대한 가중치를 부여하고, 이때 들어 올린 사무용품에 해당하는 무게 센서의 변화를 통해 상품의 관심도에 해당하는 가중치를 부여한다.

위 과정으로 도출된 실험자의 관심도에 대한 가중치와 데이터베이스에 저장된 고객 구매 이력을 포함한 값들을 이용하여 추천 모델을 통해 실험자에게 적합한 광고를 디스플레이를 통해 노출한다.

이 시나리오를 통해 고객의 행동 분석으로 적합한 광고를 노출함으로써 고객에게 만족도를 높일 수 있는 방향성을 보여준다.

4.2 Experiment environment

실험 환경은 구축한 모의 상점에 상품들의 무게 변화를 파악하기 위해 진열대에 9개의 로드 셀 센서와 로드 셀 증폭기를 부착하여 상품들을 올려두고, 우측에 실험자의 행동 분석을 위한 영상 데이터를 수집할 수 있도록 웹캠을 배치한다, 그리고 상품들의 무게 변화와 영상 데이터 수집 및 데이터 처리를 위한 Ubuntu 18.04.4 LTS 운영체제를 포함하는 Jetson Nano 보드와 실험자에게 적합한 상품의 순위를 파악하기 위해 구글 Colaboratory를 이용하여 구성한다.

아래 Table 1.은 DSCB 서비스의 실험 환경 구현에 사용된 모듈 및 프로그램 목록이다.

Table 1. System Environment

Environment	Description
Server	NVIDIA JETSON NANO Developer Kit
OS	Ubuntu 18.04.4 LTS
Webcam for image recognition	Logitech C922 Pro HD Stream Webcam
Load cell for load measurement	Load Sensor (Load Cell) 0~50Kg
Load cell amplification module for load measurement	NER-16059 HX711 Load Cell Amplifier
Programming language version	Python 3.6.9
Cloud-based development environment	Google Colaboratory

실험을 위해 구현한 모의 상점에는 무게 측정용 로드 셀 센서를 설치하고, 센서 위에 품목을 올려둔다. 고객의 우측에 행동 패턴 인식을 위한 웹캠과 무게 측정용 로드 셀 증폭기를 서버인 Jetson Nano 보드와 연결한다.

서버에서는 웹캠을 통해 입력받은 영상을 스킴레톤 모델링을 활용하여 고객의 각 관절의 움직임을 분석하여 행동을 취하고 있는지 파악한다. 고객이 앞의 상품을 향해 손을 뻗는지, 허리를 숙여 상품을 유심히 보는지 등에 관한 행동 패턴을 분석한다.

웹캠은 진열장의 카테고리 이름에 따라 번호가 부여되며, 이 고유번호를 통해 해당 웹캠에 포착된 고객을 웹캠이 속한 카테고리에 관심이 있는 것으로 간주한다. 예를 들어, 웹캠이 '사무용품' 카테고리에 해당한다면 해당 웹캠에 인식된 고객은 사무용품에 관심이 있는 것으로 파악한다.

웹캠을 통해 고객이 관심을 가지는 카테고리를 특정 지은 후 로드 셀 센서를 통해 사용자가 어떤 상품에 대해 관심이 있는지 파악할 수 있다. 로드 셀 센서에는 각각의 고유번호가 지정되어 있으며, 해당 고유번호는 상품과 연결되도록 데이터 셋을 가공한다. 고객의 관심 카테고리를 웹캠으로 파악하고, 이후에 무게 센서를 통해 관심 카테고리의 어떤 품목에 특히 관심이 있는지 파악한다.

실험을 위해 임시로 고객들의 데이터를 생성하여 서버 데이터베이스에 저장한다.

Table 2. Customer dataset

Category code	Category product number	Product name	Kinds	Behavior pattern weight	Load sensor weight	Rating
C5	C5_01	Tape bucket	L1	2	1	7
C5	C5_02	Reading desk	L2	1	0	0
C5	C5_03	Oil pen	L3	2	1	5
C5	C5_04	Clear file	L4	2	1	4
C5	C5_05	Tape measure	L5	1	0	2
C5	C5_06	Label paper	L4	0	0	0
C5	C5_07	Bookshelf	L2	0	0	0
C5	C5_08	Tape	L1	1	0	2
C5	C5_09	Note	L3	0	0	0

Table 2는 고객이 C5(사무용품) 카테고리 내에서 상품에 대한 관심도에 따른 행동 패턴(Stay: 0, Grab: 1, Take: 2)을 파악하여 가중치를 도출한 값과 무게 센서를 이용(들어 올리지 않음: 0, 들어 올림: 1)하여 가중치를

도출한 값을 포함하는 데이터 셋이다. 등급을 0~10점 사이로 설정해 두었고, 고객 데이터 셋의 등급을 이용하여 추천 모델에 적용한다. 행동 패턴과 무게 센서 가중치에 대해서는 MF 모델의 결괏값에 더하여 고객이 상품 구매에 있어서 더욱 정확한 결과를 도출할 수 있다.

Table 3. Customer purchase history dataset

Customer number	Category product number	Product name	Kinds	Rating
P_21	C5_01	Tape bucket	L1	7
P_05	C5_02	Reading desk	L2	5
P_09	C5_03	Oil pen	L3	3
P_15	C5_04	Clear file	L4	6
P_31	C5_05	Tape measure	L5	5
P_18	C5_06	Label paper	L4	4
P_35	C5_07	Bookshelf	L2	5
P_17	C5_08	Tape	L1	2
P_01	C5_09	Note	L3	6

Table 3은 카테고리 C5에 해당하는 고객 구매 이력 데이터 셋이다. 고객들의 C5 카테고리에 해당하는 상품의 구매내용에 대한 정보들이 저장된 데이터이다. 이 데이터 셋의 정보를 이용하여 추천 모델에 적용할 수 있도록 한다.

Table 4. Ranking derivation dataset

Category product number	Product name	Kinds	Behavior pattern weight	Ranking
C5_02	Reading desk	L1	11.1799712	1
C5_03	Oil pen	L2	10.7137735	2
C5_09	Note	L3	9.99050872	3
C5_01	Tape bucket	L4	7.98893500	4
C5_08	Tape	L5	6.99600545	5
C5_05	Tape measure	L4	4.96101590	6
C5_04	Clear file	L2	4.00503637	7
C5_07	Bookshelf	L1	3.02180480	8
C5_06	Label paper	L3	2.81464324	9

Table 4는 MF 모델로 도출된 결과에 행동 패턴, 무게 센서 가중치를 합하여 나온 결과를 통해 각 카테고리 상품들과 매칭하여 순위가 가장 높은 상품명에 해당하는 광고 이미지를 노출할 때 사용할 수 있도록 하는 데이터 셋이다.

4.3 Service structure and process



Fig. 5. Mock store view(left), Office supplies on the load sensor(middle), Jetson Nano board and webcam as server(right)

Fig. 5의 왼쪽 그림은 실험을 위해 구성한 모의 상점의 전경이다. Fig. 5 중간 그림은 모의 상점에서 좌측에 배치된 선반이다. 선반 위에는 사무용 카테고리에 맞는 상품을 무게 측정 센서인 로드 셀 센서를 배치하였다. 이 센서 위에 사무용품에 해당하는 각 상품을 배치하고 실험자가 어떠한 상품을 집었는지에 대해 파악할 수 있게 구성하였다. Fig.5의 오른쪽 그림은 모의 상점에서 우측에 배치된 선반이다. 실험자가 상품을 고르기 위해 고민하거나 상품에 관심을 보이는 행동에 대한 영상 데이터를 수집하기 위한 웹캠과 로드 셀 센서의 측정 및 영상 데이터를 분석 및 서버 역할을 하는 Jetson Nano 보드를 배치하였다.

위 내용과 같이 모의 상점 실험 환경을 구성하였다. Fig. 6은 실험자가 모의 상점에 진입했을 때, 웹캠을 통해 실험자의 모습을 포착하여 스켈레톤 모델링을 통해 실험자의 몸에 나타난 모습이다.

Fig. 7은 실험자의 행동 변화와 행동에 따른 무게 센서의 값 변화를 나타낸 그림이다.




Fig. 6. Modeling experimenter's skeleton in mock store

Stay 부분은 실험자가 상품을 고를 때 대기하거나 고민하는 상황이다. 상품을 고르지 않고 상품들을 살펴보고 있을 때는 무게 센서에서 측정된 값이 변화 없이 일정하게 나타나고 있다.

Grab 부분은 실험자가 상품을 만지는 모습으로 상품에 관한 관심을 나타내고 있는 행동을 취하고 있다. 그림



Fig. 7. Changes of the experimenter's behavior and the value of the load sensor according to the behavior

에서 나타나 있듯이 상품을 만지는 경우 기존 상품의 무게와 실험자의 손의 무게가 더해져 무게가 증가하는 모습을 보이고 상품에 관심이 있다는 결론을 지을 수 있다.

Take 부분은 실험자가 상품을 들어 올리는 모습으로 상품에 관심을 나타내는 행동을 취하고 있다. 상품을 들어 올렸을 때 무게는 0으로 수렴하고 상품을 집어 올렸다는 결론을 지을 수 있다. Stay, Grab, Take 세 부분으로 나누어 실험자의 행동과 무게 센서를 이용하여 상품을 집어 올렸는지, 집어 올리지 않았는지 파악하여 행동에 대한 가중치로 나타내어 행동 분석을 통해 나온 결괏값으로 행동 패턴 분석의 데이터에 부가적으로 보완할 수 있도록 하였다.

위 과정으로 얻어진 배치된 상품들의 등급과 고객 데이터 셋의 행동 패턴, 무게 센서 가중치 칼럼에 도출된 가중치 값들을 삽입한다. 삽입된 각 상품의 관심 등급, 행동 패턴과 무게 센서 가중치를 이용하여 실제 추천 모델을 사용해서 각 상품에 대한 등급을 도출할 수 있도록 실험을 진행했다.

4.4 Experiment result

-----before-----
 4.005248931121219 6.808698807876664 4.719908132869502
 7.393286173718783 6.800284429184624 6.997701792284601
 4.108584214477492 6.998145201436712 4.510633430458249

Fig. 8. Results using Wide & Deep model and MF model

Fig. 8은 Wide & Deep 모델과 MF 모델을 사용해서 1행 1열부터 3행 3열까지 물건을 배치한 순서대로 나온 9가지 상품들에 대한 등급을 도출한 결괏값이다. 이 결괏값은 행동, 무게 가중치를 제외한 기존 고객과 실험자의 관심도 추출에 관한 내용이다.

-----after-----
 4.005248931121219 7.808698807876664 4.719908132869502
 10.393286173718783 9.800284429184625 9.997701792284602
 4.108584214477492 6.998145201436712 7.510633430458249

Fig. 9. Result of sum of behavior pattern and load sensor weight

Fig. 9는 Fig. 8에서 도출된 상품들에 대한 등급 값과 실험자의 행동 패턴과 무게 센서 가중치 값의 합을 통해 9가지 상품들에 대한 등급을 도출한 결과이다.

-----Derivation of ranking-----
 ['C5_04', 'Clear file', 'L4', 10.393286173718783, 1]
 ['C5_06', 'Label paper', 'L4', 9.997701792284602, 2]
 ['C5_05', 'Tape measure', 'L5', 9.800284429184625, 3]
 ['C5_02', 'Reading desk', 'L2', 7.808698807876664, 4]
 ['C5_09', 'Note', 'L3', 7.510633430458249, 5]
 ['C5_08', 'Tape', 'L1', 6.998145201436712, 6]
 ['C5_03', 'Oil pen', 'L3', 4.719908132869502, 7]
 ['C5_07', 'Bookshelf', 'L2', 4.108584214477492, 8]
 ['C5_01', 'Tape bucket', 'L1', 4.005248931121219, 9]

Fig. 10. The result of deriving the recommended ranking for each product using the final result value

Fig. 10은 최종 결과를 통해서 각 상품에 대한 등급을 매겨 등급에 따라 순위를 도출하여 나타난 그림이다. 순서대로 카테고리 상품번호, 상품명, 레이블 명, 등급, 순위를 의미한다.

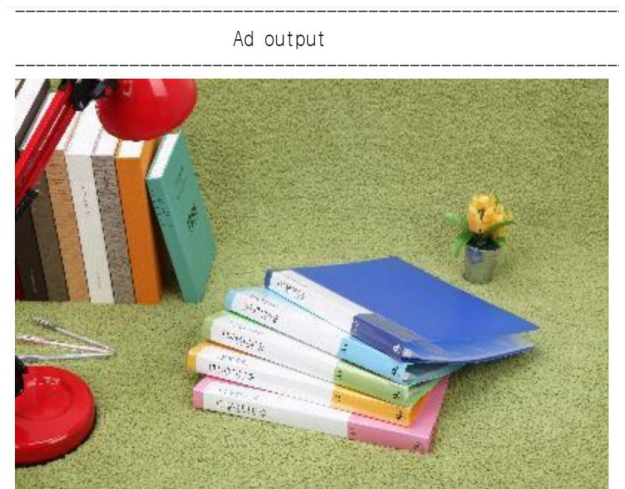


Fig. 11. The most suitable product advertisement output among the recommended ranking result

Fig. 11은 Fig. 10에서 도출한 순위 중 고객에게 가장 적합한 광고를 나타내도록 하였으므로, 가장 등급이 높은 'Clear file'에 대한 이미지를 출력한다.

V. Conclusions

본 연구는 O2O 서비스의 확산에 따라 행동 패턴 분석을 활용하고 오프라인 환경의 상점에서 고객의 관심도를 파악하여 적합한 광고를 추천하는 DSCB 서비스를 제안하였다. 제안된 서비스는 Wide & Deep 모델을 통해 DNN의 일반화 문제를 해소하고, 행동 패턴을 통해 고객의 비언어적인 의사를 파악하여 관심도를 추출한다. 오프라인 환경에서 사용자의 행동 패턴을 분석함으로써 사용자의 직접적인 구매

데이터가 없어도 관심을 가지는 상품 및 카테고리를 파악할 수 있으며, 이는 온라인뿐만 아니라 오프라인 환경에서도 직접적인 추천이 가능할 것으로 기대된다.

하지만 Wide & Deep 모델을 사용함과 더불어 영상 데이터 처리 등 처리 속도에서의 문제점이 대두되어 엣지 컴퓨팅의 도입이 필요로 하다. 또한, 고객 개인의 추천을 위해 영상 데이터의 다수의 사람이 인식되어도 개인별 행동 패턴 인식이 이루어져야 한다.

향후 연구는 이러한 점을 보완하여 영상을 통한 고객들의 얼굴 감정을 분석하고, 분석한 감정 데이터를 통해 결과의 정확도 향상과 실내 위치 측위를 통해 사용자의 행동 패턴뿐만이 아닌 동선에서도 나타나는 관심도를 추출할 수 있을 것으로 기대된다.

ACKNOWLEDGEMENT

This research was supported by the Academic Research fund of Hoseo University in 2019. (20190820)

REFERENCES

- [1] S. Chang, and D. Youm, "The Effects of Media Creativity and Interactivity of Indoor Digital Signage on the Attitude," *Journal of Outdoor Advertising Research*, Vol.16, No.4, pp.5-23, November 2019.
- [2] S. Yoo, and M. Jung, "The Effects of In-store Augmented Reality Virtual Fitting Digital Signage on Shoppers : Focusing on VMD Production Components and Types of Advertised Product," *The Korean Journal of Advertising and Public Relations*, Vol.21, No.4, pp.135-167, October 2019.
- [3] J. Lee, K. Ae, and J. Ryu, "Development of Hand Recognition Interface for Interactive Digital Signage," *Journal of the Korea Industrial Information Systems Research*, Vol.22, No.3, pp.1-11, June 2017, DOI: 10.9723/jksis.2017.22.3.001
- [4] C. Kim, C. Jo, and J. Jeong, "A Recommendation Technique Based on Offline Product Using Similarity," *Journal of Knowledge Information Technology and Systems*, Vol.14, No.4, pp.335-344, August 2019, DOI: 10.34163/jkits.2019.14.4.003
- [5] J. Wei, J. He, K. Chen, Y. Zhou, and Z. Tang, "Collaborative filtering and deep learning based recommendation system for cold start items," *Expert Systems with Applications*, Vol.69, pp.29-39, March 2017, DOI: 10.1016/j.eswa.2016.09.040
- [6] H. Cheng, L. Koc, J. Harmsen, T. Shaked, T. Chandra, H. Aradhye, G. Anderson, G. Corrado, W. Chai, M. Ispir, R. Anil, Z. Haque, L. Hong, V. Jain, X. Liu, and H. Shah, "Wide & Deep learning for recommender systems," In *Proceedings of the 1st workshop on deep learning for recommender systems*, pp.7-10, September 2016. DOI: 10.1145/2988450.2988454
- [7] A. Imran, M. Amin, and F. Johora, "Classification of Chronic Kidney Disease using Logistic Regression, Feedforward Neural Network and Wide & Deep Learning," In *2018 International Conference on Innovation in Engineering and Technology (ICIET)*, pp.27-29, December 2018. DOI: 10.1109/CIET.2018.8660844
- [8] P. Covington, J. Adams, and E. Sargin, "Deep neural networks for youtube recommendations," In *Proceedings of the 10th ACM conference on recommender systems*, pp.191-198, September 2016. DOI: 10.1145/2959100.2959190
- [9] M. Kim, S. Lee, and J. Kim, "A Wide & Deep Learning Sharing Input Data for Regression Analysis," In *2020 IEEE International Conference on Big Data and Smart Computing (BigComp)*, pp.8-12, February 2020. DOI: 10.1109/BigComp48618.2020.0-108
- [10] I. Al-Hadi, M. Sharef, N. Sulaiman, and N. Mustapha, "Review of the temporal recommendation system with matrix factorization," *Int. J. Innov. Comput. Inf. Control*, Vol.13, No.5, pp.1579-1594, October 2017.
- [11] D. Agarwal, and C. Chen, "Regression-based latent factor models," In *Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining*, pp.19-28, June 2019. DOI: 10.1145/1557019.1557029
- [12] Y. Yu, C. Wang, H. Wang and Y. Gao, "Attributes coupling based matrix factorization for item recommendation," *Applied Intelligence*, Vol.46, No.3, pp.521-533, April 2017. DOI: 10.1007/s10489-016-0841-8
- [13] B. Ahn, K. Jung, and H. Choi, "Mobile Context Based User Behavior Pattern Inference and Restaurant Recommendation Model," *Journal of Digital Contents Society*, Vol.18, No.3, pp.535-542, May 2017. DOI: 10.9728/dcs.2017.18.3.535
- [14] Q. Li, and D. Liu, "Research of music recommendation system based on user behavior analysis and word2vec user emotion extraction," *International Conference on Intelligent and Interactive Systems and Applications*, Vol.686, pp.469-475, November 2017. DOI: 10.1007/978-3-319-69096-4_65
- [15] Z. Fang, L. Zhang, and K. Chen, "A behavior mining based hybrid recommender system," In *2016 IEEE International Conference on Big Data Analysis (ICBDA)*, pp.1-5, March 2016. DOI: 10.1109/ICBDA.2016.7509785
- [16] X. Xu, and D. Yuan, "A novel matrix factorization recommendation algorithm fusing social trust and behaviors in micro-blogs," *2017 IEEE 2nd International Conference on*

Cloud Computing and Big Data Analysis (ICCCBDA),
pp.283-287, April 2017, DOI: 10.1109/ICCCBDA.2017.7951
925

Authors



Min-Chan Shin received the B.S. degrees in Computer Science and Engineering from Hoseo University, Korea, in 2020. He is currently pursuing the M.S. degree in Department of Computer Science with

Hoseo University, Korea. He is interested in Artificial Intelligence, Image Processing, Big-data



Jun-Hee Park received the B.S. degrees in Computer Science and Engineering from Hoseo University, Korea, in 2020. He is currently pursuing the M.S. degree in Department of Computer Science with

Hoseo University, Korea. He is interested in Artificial Intelligence, Sentiment Analysis, Big-data



Ji-Hoon Lee received the B.S. degrees in Computer Science and Engineering from Hoseo University, Korea, in 2020. He is currently pursuing the M.S. degree in Department of Computer Science with

Hoseo University, Korea. He is interested in Artificial Intelligence, AR/VR, Big-data



Nammee Moon received B.S., M.S., and Ph.D. degrees in School of Computer Science and Engineering from Ewha Womans University in 1985, 1987 and 1998, respectively.

She served as an assistant professor at Ewha Womans University from 1999 to 2003. From 2003 to 2008, she is a professor of Department Digital Media, Graduate School of Seoul Venture Information. Since 2008, she is currently a professor of Division of Computer and Information Engineering at Hoseo University. She is current research interests include Social Learning, HCI and User Centric Data, Big data Processing and Analysis.