

지능형 클라우드 환경에서 지각된 가치 및 행동의도를 적용한 딥러닝 기반의 관광추천시스템 설계

문석재¹ · 유경미[†]

¹광운대학교 정보과학교육원, 정보보호학, 교수

²광운대학교 정보과학교육원, 관광경영, 교수

(2020년 6월 2일 접수: 2020년 6월 23일 수정: 2020년 6월 24일 채택)

Design of Deep Learning-based Tourism Recommendation System Based on Perceived Value and Behavior in Intelligent Cloud Environment

Seok-Jae Moon* · Kyoung-Mi Yoo[†]

¹*Department of Information Security Engineering, Institute of Information Technology,
Kwangwoon University, Seoul, 01897, Republic of Korea*

[†]*Department of Tourism Management, Institute of Information Technology,
Kwangwoon University, Seoul, 01897, Republic of Korea*

(Received June 2, 2020; Revised June 23, 2020; Accepted June 24, 2020)

요약 : 본 논문은 지각된 가치가 적용된 관광 행동의도 정보를 이용한 지능형 클라우드 환경에서의 관광추천시스템을 제안한다. 이 제안 시스템은 관광정보와 관광객의 지각적 가치가 행동의도에 반영되는 실증적 분석 정보를 와이드 앤 딥러닝 기술을 이용하여 관광추천시스템에 적용하였다. 본 제안 시스템은 다양하게 수집할 수 있는 관광 정보와 관광객이 평소에 지각하고 있던 가치와 사람의 행동에서 나타나는 의도를 수집 분석하여 관광 추천시스템에 적용하였다. 이는 기존에 활용되던 다양한 분야의 관광플랫폼에 관광 정보, 지각된 가치 및 행동의도에 대한 연관성을 분석하고 매핑하여, 실증적 정보를 제공한다. 그리고 관광정보와 관광객의 지각적 가치가 행동의도에 반영되는 실증적 분석 정보를 선형 모형 구성요소와 신경망 구성요소를 함께 학습하여 한 모형에서 압기 및 일반화 모두를 달성할 수 있는 와이드 앤 딥러닝 기술을 이용한 관광추천 시스템을 제시하였고, 파이프라인 동작 방법을 제시하였다. 본 논문에서 제시한 추천시스템은 와이드 앤 딥러닝 모형을 적용한 결과 관광관련 앱 스토어 방문 페이지 상의 앱 가입률이 대조군 대비 3.9% 향상했고, 다른 1% 그룹에 변수는 동일하고 신경망 구조의 깊은 쪽만 사용한 모형을 적용하여 결과 와이드 앤 딥러닝 모형은 깊은 쪽만 사용한 모형 대비해서 가입률을 1% 증가하였다. 또한, 데이터셋에 대해 수신자 조작 특성 곡선 아래 면적(AUC)을 측정하여, 오프라인 AUC 또한 와이드 앤 딥러닝 모형이 다소 높지만 온라인 트래픽에서 영향력이 더 강하다는 것을 도출하였다.

주제어 : 지능형 클라우드, 지각된 가치, 관광 행동의도, 와이드 앤 딥러닝, 관광추천 시스템

[†]Corresponding author
(E-mail: casino@kw.ac.kr)

Abstract : This paper proposes a tourism recommendation system in intelligent cloud environment using information of tourist behavior applied with perceived value. This proposed system applied tourist information and empirical analysis information that reflected the perceptual value of tourists in their behavior to the tourism recommendation system using wide and deep learning technology. This proposal system was applied to the tourism recommendation system by collecting and analyzing various tourist information that can be collected and analyzing the values that tourists were usually aware of and the intentions of people's behavior. It provides empirical information by analyzing and mapping the association of tourism information, perceived value and behavior to tourism platforms in various fields that have been used. In addition, the tourism recommendation system using wide and deep learning technology, which can achieve both memorization and generalization in one model by learning linear model components and neural only components together, and the method of pipeline operation was presented. As a result of applying wide and deep learning model, the recommendation system presented in this paper showed that the app subscription rate on the visiting page of the tourism-related app store increased by 3.9% compared to the control group, and the other 1% group applied a model using only the same variables and only the deep side of the neural network structure, resulting in a 1% increase in subscription rate compared to the model using only the deep side. In addition, by measuring the area (AUC) below the receiver operating characteristic curve for the dataset, offline AUC was also derived that the wide-and-deep learning model was somewhat higher, but more influential in online traffic.

Keywords : Intelligent cloud, perceived value, Tourism Behavior Intention, wide and deep learning, tourism recommendation system

1. 서론

일반적으로 관광추천시스템은 사용자 및 연관 정보 집합이 입력에 대한 관광키워드 기반의 질의문이고, 관광품목마다 순위가 정해진 리스트인 검색 순위 시스템 일종으로 볼 수 있다[1]. 이런 추천 작업은 질의문이 주어졌을 때 데이터베이스에서 관련 관광품목을 찾고 클릭 또는 구매 같은 특정 목표에 기반하여 품목 순위를 정하는 과정이다[2, 3]. 그러나, 관광추천검색 시스템의 한 가지 난점은 일반적인 검색 순위 문제와 마찬가지로 암기(Memorization)와 일반화(Generalization)를 모두 달성해야 하는 문제가 존재한다[4]. 암기는 동시에 발생하는 관광품목 또는 변수를 학습하고 과거의 이력에서 이용 가능한 상관관계를 뽑아내는 작업으로 대략 정의된다[5]. 한편, 일반화는 상관관계의 이행성(transitivity)에 기반하고 결코 또는 거의 발생하지 않은 새로운 변수 조합을 탐구한다. 암기에 근거한 추천은 보통 사용자가 이미 행동을 취했던 관광품목과 직접적으로 관련되어 있다. 암기와 비교할 때 일반화는 추천

품목 다양성이 보통 향상한다. 기업 내 대형 온라인 추천 및 순위 시스템은 로지스틱 회귀 같은 일반화된 선형 모형이 간단하고 확장 가능하며 해석하기 쉽기 때문에 널리 사용한다. 종종 one-hot 인코딩을 사용하여 이진화한 희소 변수에 대해 모형을 훈련시킨다[6]. 예를 들어, 이진값 변수 "user_installed_app = netflix"는 사용자가 Netflix를 키워드 검색한 경우 값1을 가진다. 암기는 $AND(\text{user_installed_app} = \text{netflix}, \text{impression_app} = \text{pandora})$ 와 같이 교차곱 변수 변환을 사용하면 효과적으로 만들 수 있다. 사용자가 Netflix를 검색했고 이후 Pandora에 노출됐으면 값은 1이다. 이는 변수 쌍의 동시 발생이 목표 변수 레이블과 어떻게 연관되는지 설명해준다. $AND(\text{user_installed_category} = \text{video}, \text{impression_category} = \text{music})$ 같이 세분화가 덜 된 변수를 사용해서 일반화할 수 있지만 피쳐 엔지니어링 수작업이 많이 필요하다. 교차곱 변수 변환의 한계점 중 하나는 훈련 데이터에 나타나지 않은 질의문은 관광품목 변수 쌍을 일반화한 것 못한다는 점이다[7]. 분해 기계(factorization

machine) 또는 신경망 같은 임베딩 기반 모형은 피쳐 엔지니어링에 대한 부담을 줄이면서 질의문 및 관광품목 변수마다 저 차원의 밀집 임베딩 벡터를 학습시켜 이전에 보지 못한 질의문으로 관광품목 변수 쌍을 일반화할 수 있다. 그러나 특정 선호도를 가진 사용자나 크게 어필하지 못하는 틈새 관광품목이 같이 희소하고 계수가 높은 경우 기본 질의문은 관광품목 행렬에 대해 저차원 표현으로 질의문과 관광품목을 효과적으로 학습하는 건 어렵다. 이런 경우 대부분의 질의문들은 품목 쌍 간에 교호 작용이 없음에도 밀집 임베딩은 모든 질의문으로 관광품목 쌍에 대해 0이 아닌 값을 예측할 것이고, 따라서 과도하게 일반화하고 별로 관계없는 추천을 할 수 있다. 반면 교차곱 변수 변환을 통한 선형 모형은 훨씬 적은 수의 매개 변수로 이러한 “예외 규칙”을 암기할 수 있다[8].

본 논문은 지각된 가치가 적용된 관광 행동의도 정보를 이용한 지능형 클라우드 환경에서의 관광 추천시스템을 제안한다. 이 제안 시스템은 관광정보와 관광객의 지각적 가치가 행동의도에 반영되는 실증적 분석 정보를 선형 모형 구성요소와 신경망 구성요소를 함께 학습하여 한 모형에서 암기(Memorization) 및 일반화(Generalization) 모두를 달성할 수 있는 Wide & Deep 기술을 이용한 관광추천 시스템을 제시한다. 본 제안 시스템은 다양하게 수집할 수 있는 관광 정보와 관광객이 평소에 지각하고 있던 가치와 사람의 행동에서 나타나는 의도를 수집 분석하여 관광 추천시스템에 적용하였다. 이는 기존에 활용되던 다양한 분야의 관광플랫폼에 관광 정보, 지각된 가치 및 행동의도에 대한 연관성을 분석하고 매핑하여, 실증적 정보를 제공한다. 이로써 기존에 있던 관광지 추천에 대한 효과를 극대화할 수 있다. 본 논문의 주요 기본 조건은 다음과 같다. 입력값이 희소한 일반 추천시스템을 위해 임베딩을 통한 피드-포워드 신경망과 변수 변환을 통한 선형 모형을 함께 훈련시키는 와이드 앤 딥러닝을 적용한 추천시스템이다. 이는 10억 명 이상의 활성 사용자와 100만개 넘는 앱이 있는 모바일 앱스토어인 구글 플레이에서 와이드 앤 딥러닝 추천시스템 제품화 구현에 적용될 수 있다. 또한, TensorFlow 고수준 API를 통한 오픈소스 구현이 가능한 것으로 단순하지만 와이드 앤 딥러닝을 적용한 추천시스템은 모형 훈련 및 서비스 속도 요건을 만족시키면서 모바일 앱스토어 앱 가입률

이 크게 향상시킬 수 있다. 본 논문의 구성은 다음과 같다. 2장에서는 관련연구인 지각된 가치 및 행동의도에 대한 연구모형 및 실증검증을 기술하고, 3장에서는 제안시스템을 기술한다. 4장에서는 마지막으로 5장에서 결론을 맺는다.

2. 관련연구

2.1. 지각된 가치 및 행동의도

지각된 가치는 여행객의 행동의도를 파악하는데 있어서 가장 중요한 지표이다. 가치란 상품의 유용성에 기반을 둔 소비자의 전체적인 평가로서, 구매자가 지급한 가격에 대한 희생대비 얻을 수 있는 품질이나 효용 간에 교환 관계로 나타낼 수 있다. 이런 지각된 가치는 소비자에 의해 결정되기 때문에 소비자가 느끼는 차이에 따라 달라지는 주관적인 개념이라고 볼 수 있다. 지각된 가치의 정의 또한 연구자들의 연구 목적과 시각에 따라 매우 다양하게 정의되고 있으며, 통일된 정의는 존재하지 않는다. 가격, 고객에게 제공한 상품이나 서비스에 대한 대가, 지각된 품질과 고객이 지급한 가격과의 상쇄 효과 그리고 고객이 내고 얻는 것, 또는 혜택이라고 Zeithaml (1998)에서는 정의했다[9]. 이 정의는 가장 보편적으로 다수의 연구에서 인용되고 있다. 그의 가치에 대한 정의는 다시 말하자면 고객이 내고 얻은 것, 혜택의 인식을 토대로 상품이나 서비스의 효용에 대한 고객의 전반적인 평가라고 말할 수 있다. 소비자의 경험적 측면과 경제적인 측면이 포함된 지각된 가치는 마케팅 분야에서 활용되고 있으며 관광객의 만족과 재방문 의사에 영향을 미치기 때문에 관광 분야에서 적극적으로 활용하고 있다 [10]. 종합해보면, 지각된 가치는 무엇을 주고(서비스 획득과 이용에서 비용 또는 희생), 무엇을 받았는지(서비스로 제공된 이점)를 바탕으로 한 서비스의 순수한 가치에 대한 소비자들의 전반적인 평가로 정의될 수 있다. 행동 의도는 신념과 태도가 행동화될 주관적 가능성이며 이는 개인의 태도와 행동 사이의 중간 변수로써 인식되는 것이며, 개인의 주관적인 상태를 의미하는 것이다 [10]. 또한, 제품이나 서비스에 대한 지각된 감정은 소비 행동 전, 후에 갖게 되는 내적반응 및 경험 등을 바탕으로 미래 행동을 계획하고 수정하려는 주관적인 개인의 의지 또는 신념이기도 하다[11]. 이 행동의도는 소비자들이 어떤 대상에

대한 태도를 형상화한 후 특정한 미래 행동으로 나타내려는 개인의 의지와 신념으로서[11] 우호적인 행동의도는 긍정적인 구전, 다른 사람에게 추천, 애호도 증진, 다른 사람과 동반하여 재이용, 프리미엄 가격에서도 지급의사 등으로 나타난다. 서비스 분야의 경우는 행동의도를 재이용 의도, 재방문 의도 등으로 불리고 있다. 본 논문에서의 행동의도는 소비자들이 어떤 대상에 대한 태도를 형성한 후미래에 특정한 행동으로 나타내려는 개인의 의지와 신념을 나타내는 행동을 관광 추천시스템에 적용하고자 한다.

2.2. 연구 모형

본 연구는 관광객 대상으로 관광 정보와 지각된 가치가 행동의도에 미치는 영향을 실증적으로 규명하는 데 있다. 이론적 배경을 근거로 <Fig. 1>과 같은 연구 모형을 설정하였다.

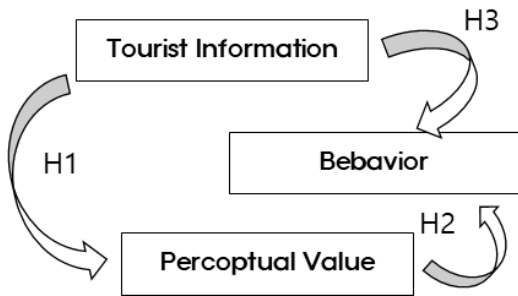


Fig. 1. Study Model.

본 논문의 연구 과제를 수행하기 한 연구의 가설(Hypothesis)을 제시하면 다음과 같다.

- Hypothesis 1. Tourist information will have a significant effect on perceived value.
- Hypothesis 2. The perceived value will have a significant effect on behavioral intention.
- Hypothesis 3. Tourist information will have a significant effect on behavioral intention.

2.3 설문지의 구성 및 분석방법

본 연구의 목적에 적합하도록 선행연구를 참고하여 설문 문항을 작성하였으며, 측정항목은 리커트 5점 척도로 설문 조사를 진행하였으며, 설문지 구성 및 척도는 다음의 <Table. 1>에서 제시하였다. 본 연구는 관광지를 방문할 때 관광정보와 지각된 가치가 미치는 영향 관계를 측정하는데 목적이 있다. 이를 측정하기 위하여 설문 조사를 실시하였다. 본 설문 조사는 관광지 소비자를 대상으로 설문 조사를 실시하였으며, 설문지는 응답자가 설문 항목에 직접 기입하는 자기평가 기입방식을 이용하였다. 조사 기간은 2019년 6월 4일에서 6월 14일까지 203부의 설문지를 배포하고 그중에 불성실한 답변이나 일부 항목에서 응답을 하지 않은 22명을 제외한 총 181명의 설문 응답자를 분석대상에 포함시켰다.

2.4. 가설 검증 분석 결과 연구 가설 채택 및 기각

본 연구에서 SNS 관광 정보와 지각된 가치 및 행동 의도 간 영향 관계를 파악하고자 제시한 가설에 대한 검증 결과를 종합적으로 요약하면 <Table. 2>와 같다.

연구가설을 검증하기 위하여 다중회귀분석(Multiple Regression Analysis)을 실시한 결과는 가설1 관광 정보가 효용적 가치에 미치는 영향은 R2=.186으로서 회귀분석 결과, 독립변수 중 신뢰성(β=.199, p<.01)과 확산성(β=.209, p<.01)이 효용적 가치에 유의한 정(+)의 영향을 미치는 것으로 나타났으며, 가설 1은 부분 채택되었다. 또한 관광 정보가 쾌락적 가치에 미치는 영향은 R2=.224로서 회귀분석 결과, 독립변수 중 상호

Table. 1 Composition of Questionnaire

Division	question	Division	question
Tourist information	1	How to use tourism	3
Tourism information utilization and participation	4	Timeliness of tourist information	2
Interactivity of tourism information	2	Reliability of tourist information	3
Diffusion of tourism information	2	Utility value of perceived value	5
Pleasant value of perceptual value	3	Intention to act	4
Demographic characteristics	7	Total	36

Table. 2 Summary of Research and Analysis Results

Hypothesis	Adoption
H1. SNS tourism information will have a significant impact on perceived value.	Partial adoption
H 1-1. Timeliness will have a significant impact on utility value.	
H 1-2. Interactivity will have a significant impact on utility value.	Dismissed
H 1-3. Reliability will have a significant impact on utility value.	selection
H 1-4. Diffusivity will have a significant effect on utility value.	selection
H 1-5. Timeliness will have a significant effect on pleasure value.	Dismissed
H 1-6. Interactivity will have a significant effect on pleasure value.	selection
H 1-7. Reliability will have a significant impact on pleasure value.	selection
H 1-8. Diffusion will have a significant effect on pleasure value.	selection
H2. Perceived value will have a significant effect on behavioral intention.	selection
H 2-1. Utility value will have a significant effect on behavioral intentions.	selection
H 2-2. Pleasant values will have a significant effect on behavioral intentions.	selection
H3. SNS tourism information will have a significant effect on behavioral intentions.	Partial adoption
H 3-1. Timeliness will have a significant effect on behavioral intentions.	Dismissed
H 3-2. Interactivity will have a significant impact on behavioral intentions.	selection
H 3-3. Reliability will have a significant effect on behavioral intentions.	selection
H 3-4. Diffusion will have a significant impact on behavioral intentions.	selection

Table. 3 Multiple Regression Analysis Result

The impact of tourism information on utility value					
구 분	Denormalization factor		Standardization factor	t	p
	B	S.E	β		
(a constant)	1.672	.338		4.954	.000***
Timeliness	.035	.078	.034	.455	.649
Interactivity	.130	.072	.145	1.817	.071
Reliability	.210	.079	.199	2.640	.009**
Reliability	.152	.056	.209	2.702	.008**
R ² =.186, Adj =.168, F=10.084(p=.000***)					
*p<.05 **p<.01***p<.001					
The effect of tourism information on pleasure value					
구 분	Denormalization factor		Standardization factor	t	p
	B	S.E	β		
(a constant)	1.774	.359		4.948	.000***
Timeliness	-.017	.082	-.015	-.201	.841
Interactivity	.164	.076	.168	2.153	.033*
Reliability	.255	.084	.223	3.024	.003**
Reliability	.189	.060	.239	3.166	.002**
R ² =.224, Adj =.206, F=12.671(p=.000***)					
*p<.05 **p<.01***p<.001					

The effect of perceived value on behavioral intention					
구분	Denormalization factor		Standardization factor	t	p
	B	S.E	β		
(a constant)	.598	.205		2.911	.004**
Utility value	.355	.071	.335	5.023	.000***
Pleasant values	.464	.065	.477	7.140	.000***
R2=.551, Adj =.546, F=109.132(p=.000***)					
*p<.05 **p<.01 ***p<.001					

The effect of tourism information on behavioral intention					
구분	Denormalization factor		Standardization factor	t	p
	B	S.E	β		
(a constant)	1.482	.335		4.422	.000***
Timeliness	.005	.077	.005	.069	.945
Interactivity	.151	.071	.159	2.124	.035*
Reliability	.191	.079	.172	2.427	.016*
Reliability	.273	.056	.353	4.881	.000***
R2=.285, Adj =.269, F=17.546(p=.000***)					
*p<.05 **p<.01 ***p<.001					




Fig. 2. Wide and Deep Learning Model.

작용성(=.168, p<.05)과 신뢰성(=.223, p<.01), 확산성(=.239, p<.01)이 쾌락적 가치에 유의한 정(+)의 영향을 미치는 것으로 나타났으며, 가설 1은 부분 채택되었다. 가설 2 지각된 가치가 행동의도에 미치는 영향은 R2=.551로서 회귀분석결과, 독립변수인 효용적 가치(=.335, p<.001), 쾌락적 가치(=.477, p<.001)이 행동의도에 유의한 정(+)의 영향을 미치는 것으로 나타났으며, 가설 2는 채택되었다. 가설3은 관광정보가 행동의도에 미치는 영향은 R2=.285로서 회귀분석결과, 독립변수 중 상호작용성(=.159, p<.05)과 신뢰성(=.172, p<.05), 확산성(=.353, p<.001)이 행동의도에 유의한 정(+)의 영향을 미치는 것으로 나타났으며, 가설 3은 부분 채택되었다.

2.5. 와이드 딥러닝 모델

구글의 와이드-앤-딥러닝 모형으로 와이드 모델은 범주형 데이터를 선형회귀로 계산이 가능하도록 한다. 또한, 범주형의 비선형적인 특성은 범

주형 데이터 사이의 교차곱을 추가적으로 고려하여 와이드 모델에 비선형적인 특성을 추가한다 [12, 13]. 하지만 본 연구에서는 지각된 가치와 행동의도가 반영된 관광키워드 계산 수행을 위하여 교차곱은 제외하고 <Fig. 2>를 참조하여 와이드 모델을 만들 것이다. 둘째로 연속적인 데이터는 딥러닝의 심화신경망(DNN)[14]으로 학습이 가능하다. 딥모델에서는 활성화함수로 ReLU[15]와 오버피팅을 방지하기 위하여 드롭아웃 기법[8]을 적용한다. 와이드 모델에서 범주형 데이터의 일부를 높은 차원으로 임베딩 벡터[16]로 만들어서 계산을 수행한다. 따라서 딥모델은 연속 데이터의 일반적인 특성을 추출 할 수 있다. 마지막으로 와이드 앤 딥러닝 모델은 와이드 모델과 딥모델을 합하는 하이브리드 모델로 활성화함수는 잘 알려진 시그모이드 함수를 사용하고, 역전파 알고리즘[17]을 이용하여 와이드-앤-딥러닝 모델의 각각의 웨이트 값들을 최적화 시키는 구조로 되어 있다.

3. 제안 시스템

3.1. 시스템 개요

관광정보 추천시스템에 대한 개요가 <Fig. 3> 과 같다. 사용자가 관광추천시스템을 방문하면 사용자 본인과 연관(관광정보 + 지각된 가치 + 행동의도) 정보에 관련된 다양한 변수가 포함되어 관광키워드 기반의 질의문이 생성된다. 본 추천시스템은 사용자가 클릭이나 구매 같은 특정 동작을 수행할 수 있는 리스트를(노출이라고도 함)을 반환한다. 사용자 동작은 질의문 및 노출과 함께 학습기를 위한 훈련 데이터로 로그에 기록된다. 데이터베이스에는 100만 개가 넘는 앱이 있기에 요구되는 서비스 대기 시간(대부분 $O(10)$ 밀리세컨드) 이내로 모든 질의문마다 전체 앱에 점수를 철저히 매기는 건 어렵다. 따라서 질의문 수신 후 첫 번째 단계는 검색이다. 검색 시스템은 다양한 신호(일반적으로 기계 학습 모형과 사람이 정의한 규칙 조합)를 사용하여 질의문과 가장 일치하는 관광품목의 짧은 목록을 반환한다. 후보 범위를 줄인 후 순위 시스템은 모든 품목마다 점수 순위를 매긴다. 점수는 대개 $P(y|x)$ 즉, 사용자 변수(예: 국가, 언어, 인구통계학적), 맥락 변수(예: 기기, 시간대, 요일)와 노출 변수(예: 앱 출시 후 경과 기간, 앱 통계 이력)를 포함하여 변수 x 가 주어졌을 때 사용자 동작 각 레이블 y 의 확률이다. 본 논문은 와이드 앤 딥러닝을 사용한 순위 모형에 초점을 맞출 것이다.

3.2. 와이드 앤 딥러닝

- 넓은 쪽 구성 요소는 Fig. 2에 그려진 일반화 선형 모형 $y = w^T x + b$ 의 형태이다. y 는 예측, $x = [x_1, x_2, \dots, x_d]$ 는 d 개의 변수 벡터, $w = [w_1, w_2, \dots, w_d]$ 는 모형 매개변수이고 b 는 편의이다. 변수 집합은 원천 입력값과 변환한 변수를 포함한다. 가장 중요한 변환 중 하나는 다음과 같이 정의되는 교차곱 변수 변환이다.

$$\phi_k(x) = \prod_{i=1}^d x_i^{c_{ki}} \quad c_{ki} \in \{0, 1\} \quad (1)$$

여기서 c_{ki} 는 i -th번째 변수가 k -th번째 변환 ϕ_k 의 일부이면 1이고, 그렇지 않으면 0인 불리언 변수이다. 이진값 변수의 경우 구성 변수들("gender=female"과 "language=en")이 모두 1인 경우에만 교차곱 변수 변환(예: "AND(gender = female, language = en)")은 1이다. 그렇지 않으면 0이다. 이것은 이진값 변수 간 교호 작용을 잡아내고 일반화 선형 모형에 비선형성을 더한다.

- 깊은 쪽 구성 요소는 Fig. 2와 같은 피드-포워드 신경망이다. 범주형 변수의 경우 원래 입력값은 문자열 변수(예: "language = en")이다. 이런 희소하고 고차원인 범주형 변수 각각은 먼저 임베딩 벡터라고 하는 저 차원의 밀집한 실수값 벡터로 종종 변환된다. 임베딩 차원은 일반적으로 $O(10)$ 에서 $O(100)$ 수준으로 정한다. 임베딩 벡터는 임의로 초기화된 후 모형 훈련 과정을 통해

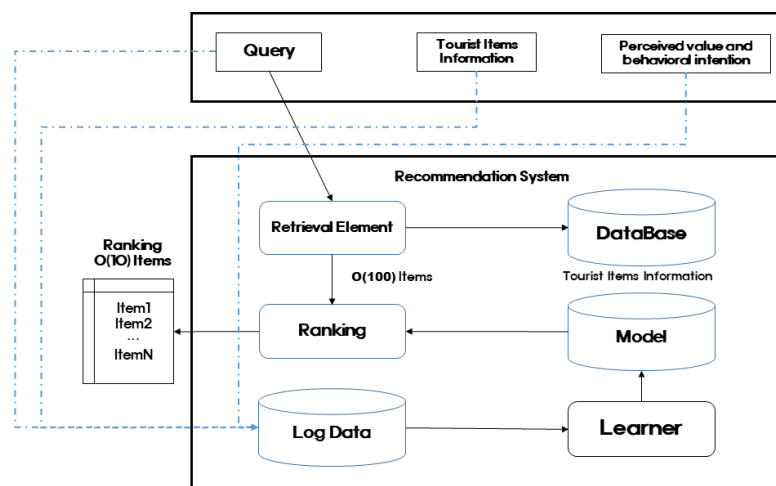


Fig. 3. Recommendation System Overview.

최종 손실 함수를 최소화하도록 값이 훈련된다. 이러한 저 차원의 밀집한 임베딩 벡터는 순방향 전달 때 신경망 은닉층으로 전해진다. 구체적으로 각 은닉층은 다음 계산을 수행한다.

$$a^{(l+1)} = f(W^{(l)} a^{(l)} + b^{(l)}) \quad (2)$$

여기서 l 은 층의 서수이고 f 는 종종 정류된 선형 단위(ReLU)라고 불리는 활성화 함수이다. $a^{(l)}$, $b^{(l)}$ 와 $W^{(l)}$ 는 l -번째 층의 출력값, 편의, 모형 가중치이다.

- 와이드 앤 딥러닝 모형의 공동 훈련

넓은 쪽 구성 요소와 깊은 쪽 구성 요소는 결합되어 출력한 log odds 가중치 합계를 예측치로 사용하며 공동 훈련을 위해 단일한 공동 로지스틱 손실 함수에 제공된다. 공동 훈련과 앙상블 사이에 구별이 있다는 걸 유의해라. 앙상블에서는 개별 모형을 서로 알지 못하게 각기 훈련하며 그 예측치들은 추론 시기에만 결합하고 훈련 시기에 결합하지 않는다. 대조적으로 공동 훈련은 넓은 쪽과 깊은 쪽 모두와 그 합계 가중치들을 훈련 시기에 고려하면서 매개변수 모두를 동시에 최적화시킨다. 모형 크기에 영향을 미친다. 앙상블의 경우 훈련이 분리되어 있으므로 합리적인 정확도를 얻기 위해 모형 각각이 좀 더 커야 한다(예: 더 많은 변수와 변수 변환). 이와는 다르게 공동 훈련의 경우 넓은 쪽은 전체 크기의 와이드 모형보다 적은 수의 교차곱 변수 변환으로 깊은 쪽 약점을 보완하기만 하면 된다. 와이드 앤 딥러닝모형 공동 훈련은 미니 배치 확률적 최적화를 이용하여 출력 값 기울기를 모형 넓은 쪽과 깊은 쪽 동시에 역전파시킨다. 실험에서 모형 넓은 쪽에 대한 최적화로 L_1 정규화를 따르는 Follow-the-regularized-leader(FTRL) 알고리즘을 사용했고 깊은 쪽에 대해서는 AdaGrad[22]를 사용했다. 결합 모형은 <Fig. 2>의 가운데 그림과 같다. 로지스틱 회귀 문제의 경우 모형 예측은 다음과 같다.

$$P(Y = 1|x) = \sigma(w_{wide}^T [x, \phi(x)] + w_{deep}^T a_f^{(l)} + b) \quad (3)$$

여기서 Y 는 이진값 클래스 레이블이고 $\sigma(\cdot)$ 는 시그모이드 함수, $\phi(x)$ 는 원래 변수 x 의 교차곱 변수 변환, b 는 편의 항이다. w_{wide} 는 Wide 모형

의 모든 가중치 벡터이고 w_{deep} 은 최종 출력 값 $a_f^{(l)}$ 적용한 가중치이다.

4. 관광 추천 파이프라인

관광추천 파이프라인 구현은 데이터 생성, 모형 훈련 및 모형 서비스 같은 3단계로 <Fig. 4>와 같이 구성된다.

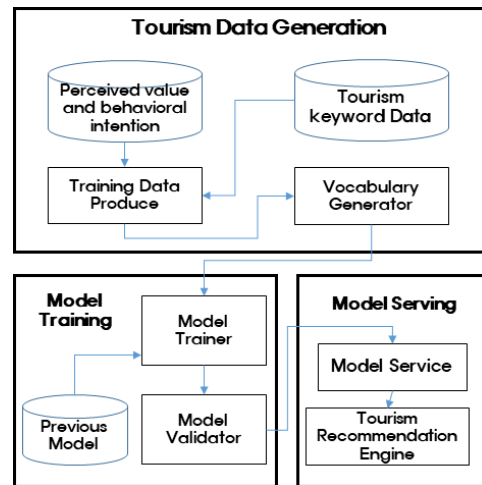


Fig. 4. Tourist Recommendation Pipeline.

4.1. 관광정보 생성

이 단계에서는 일정 기간 내 사용자 및 관광 키워드 노출 데이터를 사용하여 훈련데이터를 생성한다. 각 샘플은 노출 한 번에 해당한다. 레이블은 앱 가입이다. 즉, 노출한 관광키워드 검색하면 1이고 그렇지 않으면 0이다. 범주형 문자열 변수를 정수 ID로 연결하는 어휘 테이블도 이 단계에서 생성한다. 시스템은 정한 최소 횟수 이상으로 발생하는 모든 문자열 변수에 대해 ID 공간을 계산한다. 연속적인 실수값 변수는 변수값 x 를 누적 분포 함수 $P(X \leq x)$ 에 연결하여 n_q 분위 수로 나누어 $[0, 1]$ 로 정규화한다. 정규화한 값은 i -번째 분위 수 값에 대해 $\frac{i-1}{n_q-1}$ 이다. 데이터 생성 동안 분위값 경계를 계산한다.

4.2. 모형 훈련

실험에서 사용한 모형 구조는 <Fig. 5>와 같다. 훈련 과정에서 입력층은 훈련 데이터와 어휘를

받아들여 레이블과 함께 희소하거나 밀집한 변수를 생성한다. 넓은 쪽 구성 요소는 사용자가 설치한 앱과 노출된 앱의 교차곱 변수 변환으로 구성한다. 모형 깊은 쪽은 32차원 임베딩 벡터가 각 범주형 변수에 대해 학습한다. 모든 임베딩을 밀집 변수와 연결하여 약 1,200차원 밀집 벡터를 생성한다. 연결한 벡터를 3개의 ReLU 층으로 전달하고 마지막으로 로지스틱 출력 단위로 전달한다.

와이드 앤 딥러닝 모형을 5천억 개가 넘는 샘플로 훈련시킨다. 일련의 새로운 훈련 데이터가 수집될 때마다 모형을 다시 훈련시켜야 한다. 그러나 매번 처음부터 재훈련시키는 건 계산 비용이 많이 들고 데이터수집부터 업데이트된 모형 서비스까지 시간이 많이 소요된다. 이 문제를 해결하기 위해 임베딩과 이전 모형의 선형 모형 가중치를 사용하여 새 모형 초기값을 설정하는 식의 warm-starting 시스템을 구현했다. 모형 서버에 모형을 적재하기 전에 실제 트래픽을 처리하는 데 문제가 없는지 예행연습 삼아 모형을 돌려보았다. sanity-test로써 이전 모형 대비 모형 품질을 직접 확인해보았다.

4.3. 모형 서비스

모형을 훈련하고 검증이 끝나면 모형 서버에 모형을 적재한다. 각 요청마다 서버는 앱 검색 시스템에서 앱 후보군을 수신하고 사용자 변수를 사용하여 모든 앱에 점수를 매긴다. 앱은 가장 높은 점수부터 가장 낮은 점수까지 순위를 매기

며 그 순서로 사용자에게 노출한다. 점수는 Wide & Deep 모형에 대한 순방향 추론을 시행하여 계산한다. 10ms 단위로 각 요청을 처리하기 위해 추론 단계를 단일 배치로 후보 앱 전체에 점수를 매기는 대신 멀티스레딩 병렬 처리를 통해 미니 배치를 병렬로 돌려서 성능을 최적화했다.

4.4. 실험 결과

본 논문에서 제안한 관광추천시스템에서 와이드 앤 딥러닝 학습 효과를 평가하기 위해 실제 실험을 진행하였고, 앱 가입 및 서비스 성능 두 가지 측면에서 시스템을 평가하였다. 본 실험은 3주 동안 A/B 테스트 프레임워크로 온라인 실험을 실제 환경에서 진행했다. 대조군으로 사용자 1%를 무작위로 선정해서 이전 버전의 순위 모형 즉 교차곱 변수 변환을 다수 집어넣어 높은 수준으로 최적화시킨, 넓은 쪽만 이용한 로지스틱 회귀 모형을 적용해 추천했다. 실험군인 1%의 다른 사용자에게는 동일한 변수 집합으로 훈련시킨 와이드 앤 딥러닝 모형을 적용하여 추천했다. <Table 4>에서와 같이 와이드 앤 딥러닝 모형은 앱 스토어 방문 페이지 상의 앱 가입률이 대조군 대비 3.9% 향상했고, 이는 통계적인 의미가 있는 수치이다. 또한, 다른 1% 그룹에 변수는 동일하고 신경망 구조의 깊은 쪽만 사용한 모형을 적용하여 결과를 비교했고 와이드 앤 딥러닝 모형은 깊은 쪽만 사용한 모형 대비해서 가입률을 1% 증가시켰고, 이는 통계적인 의미가 있는 수치이다.

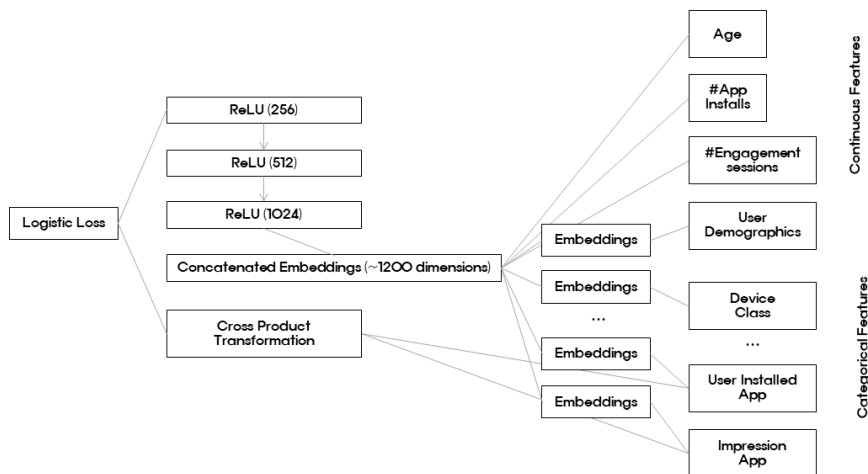


Fig. 5. Wide and Deep Learning Model Structure for Tourism Recommendation.

Table 4. Offline and Online metrics of different models.

Model	Offline AUC	Online Acquisition Gain
Wide(control)	0.727	0%
Deep	0.720	+2.9%
Wide & Deep	0.729	+3.9%

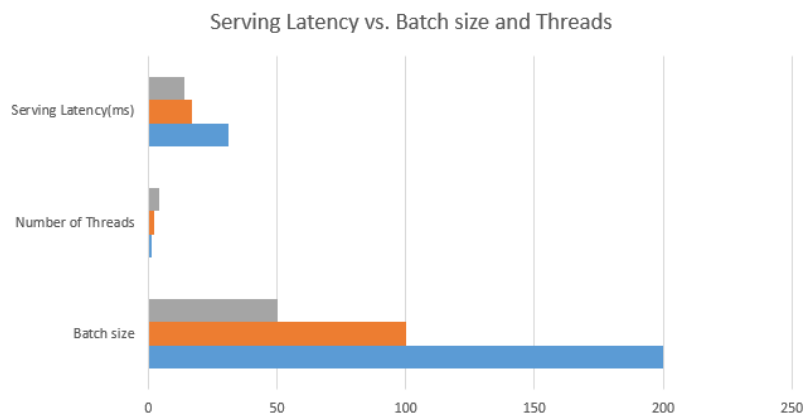


Fig. 6. Serving Latency vs. Batch size and Threads.

온라인 실험에 덧붙여 오프라인에서 미리 떨어 놓은 데이터셋에 대해 수신자 조작 특성 곡선 아래 면적(AUC)을 측정했다. 오프라인 AUC 또한 와이드 앤 딥러닝 모형이 다소 높지만 온라인 트래픽에서 영향력이 더 강하다. 오프라인 데이터셋 노출과 레이블은 고정되어있지만 온라인 시스템은 일반화와 암기를 혼합하여 탐색적으로 추천해 볼 수 있고 그에 따라 사용자 응답으로 학습 가능하다는 점이 이유 중 하나일 것이다.

상용적인 모바일 기반의 앱 스토어는 트래픽이 많기 때문에 짧은 대기 시간 내 처리량을 높게 유지하며 서비스하기 매우 까다롭다. 일반적으로 트래픽 최고 수준에서 추천시스템은 1초당 천만 개 이상 앱에 점수를 매긴다. 단일 스레딩을 사용하는 경우 모든 후보를 일괄 처리로 점수 매기는데 31ms가 걸린다. 멀티스레딩을 구현하고 각 배치 크기를 작게 분할하여 <Fig 6>에 표시된 대로 클라이언트 측 대기 시간을 14ms(서비스 오버헤드 포함)로 크게 줄였다.

5. 결론

본 논문은 지각된 가치가 적용된 관광 행동의도 정보를 이용한 지능형 클라우드 환경에서의 관광추천시스템을 제안하였다. 이 제안 시스템은 관광정보와 관광객의 지각적 가치가 행동의도에 반영되는 실증적 분석 정보를 선형 모형 구성요소와 신경망 구성요소를 함께 학습하여 한 모형에서 암기 및 일반화 모두를 달성할 수 있는 와이드 앤 딥러닝 기술을 이용한 관광추천 시스템을 제시하였고, 파이프라인 동작 방법을 제시하였다.

이는 기존에 활용되던 다양한 분야의 관광플랫폼에 관광 정보, 지각된 가치 및 행동의도에 대한 연관성을 분석하고 매핑하여, 실증적 정보를 제공한다. 이로써 기존에 있던 관광지 추천에 대한 효과를 극대화할 수 있다. 향후에는 모바일 앱스토어인 구글플레이에서 와이드 앤 딥러닝 관광추천앱 제품화 구현에 적용될 수 있다. 또한,

단순하지만 와이드 앤 딥러닝을 적용한 관광추천 앱으로 모형 훈련 및 서비스 속도 요건을 만족시키면서 모바일 앱스토어 앱 가입률이 크게 향상시킬 수 있다.

References

1. Fink, Kevin, and Todd Otis. "Systems and methods for recommended content platform." U.S. Patent No. 10,528,637. 7 Jan. (2020).
2. Wang, Zheng; Yinghao, J. I. A. Systems and methods for determining recommended information of a service request. U.S. Patent Application No 16, pp.729,277, (2020).
3. J. J. Tompson, A. Jain, Y. LeCun, and C. Bregler. Joint training of a convolutional network and a graphical model for human pose estimation. In Z. Ghahramani, M. Welling, C. Cortes, N. D. Lawrence, and K. Q. Weinberger, editors, NIPS, pp.1799–1807. (2014).
4. Duchi, John, Elad Hazan, and Yoram Singer. "Adaptive subgradient methods for online learning and stochastic optimization." *Journal of machine learning research* 12, Jul, pp.2121–2159, (2011).
5. He, Kaiming, et al. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. pp.770–778, (2016).
6. T. Mikolov, A. Deoras, D. Povey, L. Burget, and J. H. Cernocky. Strategies for training large scale neural network language models. In *IEEE Automatic Speech Recognition & Understanding Workshop*, (2011).
7. Rendle, Steffen. "Factorization machines with libfm." *ACM Transactions on Intelligent Systems and Technology (TIST)* 3.3: pp.1–22, (2012).
8. H. Wang, N. Wang, and D.-Y. Yeung. Collaborative deep learning for recommender systems. In *Proc. KDD*, pages 1235–1244, (2015).
9. A. Dion, Paul, Rajshekhar Javalgi, and Janet Dilorenzo-Aiss. "An empirical assessment of the Zeithaml, Berry and Parasuraman service expectations model." *Service Industries Journal* 18.4: pp.66–86, (1998).
10. Fyall, Alan, et al. *Marketing for Tourism and Hospitality: Collaboration, Technology and Experiences*. Routledge, (2019).
11. Srivastava, Medha, and Saurabh Kumar Srivastava. "Revisiting the Inter-relations of Service Quality & Customer Loyalty: An Empirical Examination of Effects on Two Dimensional Model of Loyalty." *PURUSHARTHA-A journal of Management, Ethics and Spirituality* 12.1: pp.50–72, (2019).
12. GUO, Huifeng, et al. Deepfm: An end-to-end wide & deep learning framework for CTR prediction. *arXiv preprint arXiv:1804.04950*, (2018).
13. Burel, Grégoire, Hassan Saif, and Harith Alani. "Semantic wide and deep learning for detecting crisis-information categories on social media." *International Semantic Web Conference*. Springer, Cham, (2017).
14. Seide, Frank, Gang Li, and Dong Yu. "Conversational speech transcription using context-dependent deep neural networks." *Twelfth annual conference of the international speech communication association*. (2011).
15. AGARAP, Abien Fred. Deep learning using rectified linear units (relu). *arXiv preprint arXiv:1803.08375*, (2018).
16. Ba, Jimmy, and Brendan Frey. "Adaptive dropout for training deep neural networks." *Advances in neural information processing systems*. (2013).
17. Truong, Trung, Dinh-Liem Nguyen, and Michael Klibanov. "A numerical reconstruction algorithm for the inverse scattering problem with backscatter data." *arXiv preprint arXiv:2002.08427* (2020).