

# 딥러닝을 이용한 시퀀스 기반의 여행경로 추천시스템 - 제주도 사례 -

(Sequence-Based Travel Route Recommendation Systems Using Deep Learning  
- A Case of Jeju Island -)

이희준\*, 이원석\*, 최인혁\*, 이충권\*\*

(Hee Jun Lee, Won Sok Lee, In Hyeok Choi, Choong Kwon Lee)

## 요약

딥러닝의 발전에 따라 추천시스템에서 딥러닝 기반의 인공지능경향을 활용한 연구가 활발히 진행되고 있다. 특히, RNN(Recurrent Neural Network)기반의 추천시스템은 데이터의 순차적 특성을 고려하기 때문에 추천시스템에서 좋은 성과를 보여주고 있다. 본 연구는 RNN기반의 알고리즘인 GRU(Gated Recurrent Unit)와 세션 기반 병렬 미니배치(Session Parallel mini-batch)기법을 활용한 여행경로 추천 시스템을 제안한다. 본 연구는 top1과 bpr(Bayesian personalized ranking) 오차함수의 앙상블을 통해 추천 성과를 향상시켰다. 또한, 데이터 내에 순차적인 특성을 고려한 RNN기반 추천 시스템은 여행경로에 내재된 여행지의 의미가 반영된 추천이 이루어진다는 것을 확인되었다.

■ 중심어 : 딥러닝 ; 순환신경망 ; 추천시스템 ; 제주도

## Abstract

With the development of deep learning, studies using artificial neural networks based on deep learning in recommendation systems are being actively conducted. Especially, the recommendation system based on RNN (Recurrent Neural Network) shows good performance because it considers the sequential characteristics of data. This study proposes a travel route recommendation system using GRU(Gated Recurrent Unit) and Session-based Parallel Mini-batch which are RNN-based algorithm. This study improved the recommendation performance through an ensemble of top1 and bpr(Bayesian personalized ranking) error functions. In addition, it was confirmed that the RNN-based recommendation system considering the sequential characteristics in the data makes a recommendation reflecting the meaning of the travel destination inherent in the travel route.

■ keywords : Deep learning ; RNN(Recurrent Neural Network) ; Recommendation systems ; Jeju Island

## I. 서론

문화체육관광부의 국민여행조사 결과에 따르면, 2018년 우리나라의 국내여행 경험률이 90%에 가깝고 총 지출액도 43조원을 넘어섰다. 지방자치단체들은 여행객 유치에 위하여 다양한 정책을 개발하기 위해 노력하고 있고[1], 해당 지역에 위치한 볼거리와 먹거리 정보를 온라인을 통해 홍보하고 있다. 그러나, 여행자들은 가장 유명하고 방문객이 많은 여행지들을 위주로 개별고객의 만족 보다는 수익성과 시간을 기준으로 단순한 패키지 상품을 설계하는 경향이 있다. 이러한 한계를 극복하고자

등장한 자유여행은 웹사이트와 사회관계망을 통하여 제공되는 다양한 여행지 정보들을 수집하고 분석하여 개인의 취향에 맞는 여행을 설계할 수 있다. 세종대와 컨슈머인사이드의 '2018~2019 여행행태 조사결과'에 따르면 자유여행객의 비중이 60%에 가까워진 것으로 나타났다.

그러나, 자유여행은 개인이 취향과 이동거리 등을 기준으로 블로그, 사회관계망, 여행정보공유플랫폼 등에서 여행지에 대한 정보를 미리 찾아서 경로를 설계해야 하고, 이러한 과정에는 많은 시간과 노력이 소요된다. 따라서, 기존의 여행객들이 다녀간 곳들을 수집 및 분석하고 개인의 취향과 이동거리 등을 고려한 경로를 설계할 수 있도록 도와주는 것은 여행객들에게 매우 필요한 서비스이다.

\* 준회원 계명대학교 경영정보학과 석사과정

\*\* 정회원, 계명대학교 경영대학 경영정보학과 교수

접수일자 : 2019년 09월 20일

수정일자 : 2020년 02월 18일

게재확정일 : 2020년 02월 19일

교신저자 : 이충권 e-mail : cklee@kmu.ac.kr

추천시스템은 사용자가 좋아할 만한 서비스나 제품을 추천해주는 서비스로써 상품에 관한 정보를 수집하고 분석하여 더 나은 의사결정을 도와주기 위하여 발전해왔다. 기존의 여행지 추천에 관한 연구는 위치 기반 정보, 관심지점(POI, points of interest), 여행지 정보 등을 사용하여 사용자에게 선별적으로 개인화된 여행지를 추천하였다. 그러나 이러한 연구들은 바로 이전 관광지의 특징은 고려하였지만, 이전 관광지들의 방문순서를 의미하는 시퀀스를 추천시스템에 반영하지는 못하였다.

Hidasi 등[2]은 RNN(Recurrent Neural Network)기반의 알고리즘을 활용하여 시퀀스를 고려한 추천 방법을 제안하였다. 본 연구는 Hidasi 등[2]이 제안한 방법을 활용하여 여행지 추천에서 여행경로 내에 존재하는 여행지들의 방문순서, 즉 시퀀스적인 의미를 고려한 추천시스템을 제안하고자 한다.

## II. 관련 연구

### 1. 추천시스템

필요한 정보를 찾아서 선별적으로 제공하여 의사결정을 지원하기 위한 추천시스템은 많은 연구자들에 의해 개발되고 발전해왔다. 추천 분야에서는 사용자의 행동을 기록하고 있는 로그를 사용자와 사용자가 선택한 아이템과의 관계를 통하여 계산하는 CFR(Collaborative Filtering Recommendation)과 CBR(Content-Based Recommendation)이 널리 사용되고 있다. 안병익 등[3]에서는 다속성 태도 점수와 사용자의 위치를 고려한 CFR 기반의 음식점 추천 모델을 제안하였다. 홍택은과 신주현[4]은 SNS 텍스트와 이미지 데이터를 결합하여 사용자와 유사한 계정을 추천해 주는 방법을 제안하였다. 그러나, CFR과 CBR에서는 사용자가 이전에 선택한 아이템의 시퀀스가 가지는 의미는 고려되지 않는다는 단점이 있다.

### 2. 여행지 추천시스템

여행지를 사용자에게 추천하기 위하여 Zheng 등[5]에서는 TBHG(Tree-Based Hierarchical Graph)를 통하여 GPS 데이터를 생성하고, HITS(Hypertext Induced Topic Search) 모델을 제안하였다. Yu 등[6]은 위치기반의 소셜네트워크 데이터를 통하여 위치, 시간대에 대한 POI(points of interest)를 계산하여 사용자의 현재 위치에서 여행 시작 및 끝 시간을 통해 새로운 여행경로를 제공하는 TRP(Transformation Ring Projection) 알고리즘을 제안하였다. Kurashima 등[7]은 여행 경로 데이터를 수집하여 개인의 취향을 고려한 토픽 모델과 여행 경로를 예측하는 마르코프 모델을 결합한 새로운 모델을 제안하였다. [13]은 특정 유형의 관광지를 선호하는 사용자에게 여행지의 추천을 하기 위해 사용자가 선호하는 관광지를 위치

기반 소셜 네트워크의 사진과 위치 태그 데이터를 활용하며, 위치 태그가 포함된 이미지 분포의 유사도를 계산하여 사용자에게 여행지를 추천하는 방법론을 제안하였다. [14]는 여러 사용자의 GPS 로그 기록을 활용하여 낯선 관광지를 사용자에게 추천하는 방법론을 제안하였다.

### 3. 시퀀스 기반 추천시스템

시퀀스는 관측치가 이산형이고 변수들 간의 순서가 중요한 데이터를 말한다. 백화점이나 마트 같은 매장이나 등에서 고객의 동선을 분석하여 상품의 진열에 반영하고, 웹사이트에서 방문자의 내비게이션 패턴을 분석하여 사용자들이 좀 더 쉽고 빠르게 이동할 수 있도록 설계하는데 활용되기도 한다. 이처럼 시퀀스는 사람의 행동을 이해하고 예측하는데 있어서 매우 중요한 요소이고, 근사치[8]나 제한조건[9], 그리고 가중치[10,11] 등을 적용하여 시퀀스의 패턴을 연구하였다. 그러나, 이러한 분석기법들은 빈도가 많은 시퀀스를 추출하고 최대 시퀀스를 찾는 데 초점을 맞추었다.

RNN은 이미지, 음성, 자연어처리 등 많은 일에 활용되고 있는데, 이태석과 강승식[12]은 RNN 기반 알고리즘과 attention layer를 통하여 한국어 띄어쓰기 모델의 성능을 향상시켰다. Hidasi 등[2]에서는 이러한 RNN 기반의 알고리즘인 GRU(Gated Recurrent Unit)를 통한 추천방법을 제안하였고, 사용자가 구매한 상품의 순서적 의미를 고려하는 GRU기반 추천시스템이 CFR, CBR 기반의 추천시스템 보다 더 좋은 성능을 보여주었다. 본 연구는 Hidasi 등[2]에서 제안한 RNN기반 추천 시스템을 활용한 여행지 추천 시스템을 제안하고자 하며, 오차함수의 양상분을 통하여 기존 추천 시스템의 성과를 향상시키고자 한다.

## III. 연구 방법

본 연구는 그림 1에서 볼 수 있듯이 세션 기반 병렬 미니배치(Session Parallel mini-batch)기법을 활용하여 입력데이터를 미니배치로 변환하고, 여행지 임베딩을 통하여 나온 벡터를 GRU모델에 학습을 시키는 방식으로 추천시스템을 구성하였다. 모델 학습 시 사용되는 오차함수로 top1과 bpr(Bayesian personalized ranking)을 활용하였으며, 오차함수의 양상분을 통하여 모델의 성능을 향상시키고자 한다.




그림 1. 여행지 추천 프로세스

### 1. 입력 데이터

입력데이터는 세션 ID와 여행지 ID로 구성되어 있다. 이러한 입력데이터를 딥 러닝 알고리즘이 효율적으로 학습할 수 있도록 미니배치를 만들어 주어야 한다. 딥 러닝 기반 알고리즘에서는 미니배치를 통하여 학습의 성능과 속도를 향상시킬 수 있다. 그러나 세션 데이터를 일반적인 미니배치를 만드는 방식으로 미니배치를 만든다면, 여행지의 순서적인 정보가 고려되지 않을 수 있다. 따라서 Hidasi 등[2]에서 제안한 세션 기반 병렬 미니배치 기법을 통하여 학습을 위한 미니배치를 만든다. 세션 기반 병렬 미니배치는 세션 내에서 순서적인 의미가 학습 시에 고려될 수 있도록 미니배치를 만드는 기법이다.

그림 2는 미니배치크기를 3이라 가정하고 세션 데이터를 세션 기반 병렬 미니배치 방법을 통해 미니배치로 변환하는 예시이다. 여기서 세션 데이터는 1일 동안의 여행 경로를 말하며 세션 내에는 여행지들이 여행 경로 순서로 구성되어 있다. 예를 들어, 여행지 1.1은 세션 1에서 첫 번째로 방문한 여행지를 말한다. 또한, 2박 3일의 여행 경로가 있다면, 각각 다른 세션으로 구별되며 총 3개의 세션이 생성된다. 그러나, 여행경로 내 여행지의 길이는 항상 같지 않다는 문제가 있다. 어떤 여행경로는 Session2와 같이 세 군데의 여행지를 방문했을 수도 있고 Session1과 같이 네 군데의 여행지를 방문했을 수도 있다. 세션 기반 병렬 미니배치 기법을 통해 미니배치를 만들게 되면 미니배치 3번의 두 번째 여행지인 여행지2.3 다음 미니배치 4번의 두 번째 여행지로 여행지4.1이 오는 문제가 생길 수 있다. 이 두 여행지는 순서적인 의미가 없는 여행지이다. 이런 문제점을 GRU모델의 업데이트 게이트(Update gate)와 리셋 게이트(Reset gate)에서 보완한다.

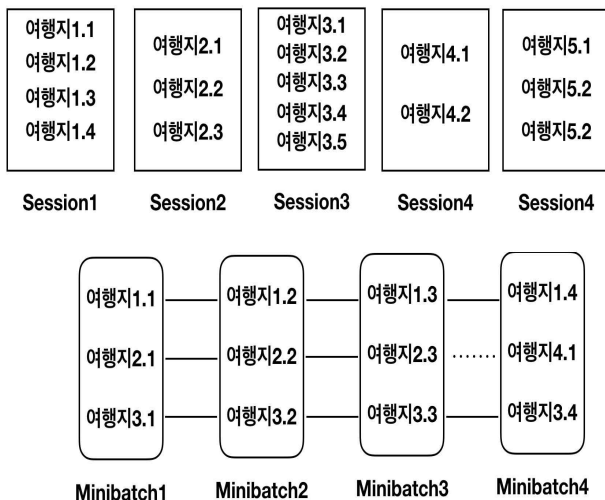


그림 2. Session Parallel Mini-batch 예시

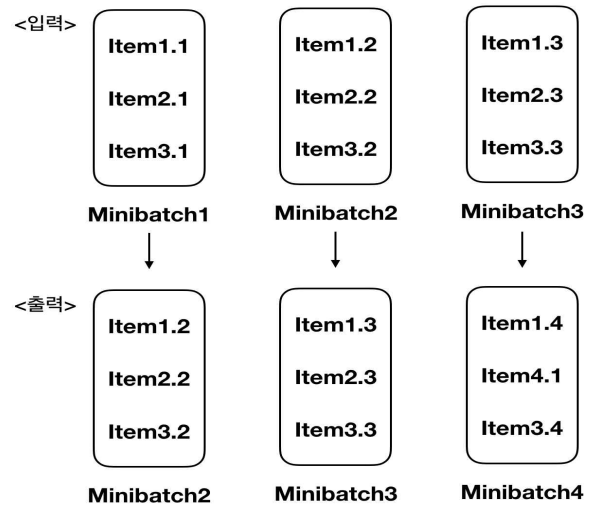


그림 3. 입력데이터와 출력데이터 예시

그림 3은 입력데이터와 출력데이터의 구성을 보여준다. 미니배치는 세션 기반 병렬 미니배치 기법을 통하여 만들어진 미니배치를 뜻하며, 학습 시 입력 미니배치가 미니배치 1번이라면 출력 미니배치는 미니배치 2번이 나오도록 학습이 이루어진다.

### 2. 여행지 임베딩

여행지 임베딩은 단어를 벡터로 표현하는 텍스트 임베딩과 같은 방식이다. 본 연구의 임베딩 벡터 값의 차원은 50, 80, 100, 120, 150으로 변화시키며 어떤 환경에서 생성된 여행지 임베딩 데이터를 이용하였을 때 성능이 가장 높은지 확인해 보았다. 생성된 임베딩 데이터는 1361건의 여행지를 포함한다. 또한, 추천 순위 계산에서 출력 미니배치에 대한 임베딩이 이루어지는데 이는 여행지 임베딩과 다른 별개의 임베딩이다.

### 3. GRU

GRU는 RNN 기반의 딥 러닝 모델로, 순차적인 데이터 활용에 있어서 많이 쓰이는 모델이다. GRU모델에는 업데이트 게이트와 리셋 게이트가 있는데 이를 통하여 기존 RNN의 그라디언트 배니싱(Vanishing gradient)문제를 보완한다. 즉, 그림 2의 미니배치 3번의 두 번째 여행지와 미니배치 4번의 두 번째 여행지처럼 순서적인 의미가 없는 경우, 리셋 게이트와 업데이트 게이트는 이전 여행지를 얼마나 반영할지, 현재 정보를 다음 데이터에 얼마나 정해줄지를 결정한다. GRU를 1개의 층으로만 구성하였으며, RNN 셀 크기(RNN size)를 50, 100, 150로 임베딩과 같은 값으로 설정하였으며, 드롭아웃(drop out)을 0.5로, 학습률(learning rate)를 0.001로 설정하였고, 출력층에서는 선형 결합을 하였으며, 은닉층 활성화 함수로 쌍곡 탄젠트 함수

(Hyperbolic Tangent function)를 사용하였다. 또한, 배치 크기를 50으로 두었으며, 20번의 이폭(epoch)동안 가장 높은 recall을 기록하면 학습된 GRU모델을 저장시키는 방식으로 학습을 진행하였다.

#### 4. 추천 순위 계산

그림 4는 추천 순위 계산에서 오차함수를 계산하기 전 단계인 평가 점수(ranking score)를 계산하는 과정을 보여준다. 미니 배치 크기를  $n$ 으로, 임베딩 크기를  $m$ 이라 한다면, 평가 점수는  $n \times n$ 의 차원을 가지며,  $S(I_k, O_l)$ 는 입력 데이터(I)에서  $k$ 번 째 여행지와 출력 데이터(O)에서  $l$ 번 째 여행지 간의 평가 점수를 나타낸다. 본 연구에서는 세션 기반 병렬 미니배치를 사용하기 때문에,  $k$ 와  $l$ 이 같을 경우,  $I_k$  다음으로 방문한 여행지는  $O_k$ 이다.

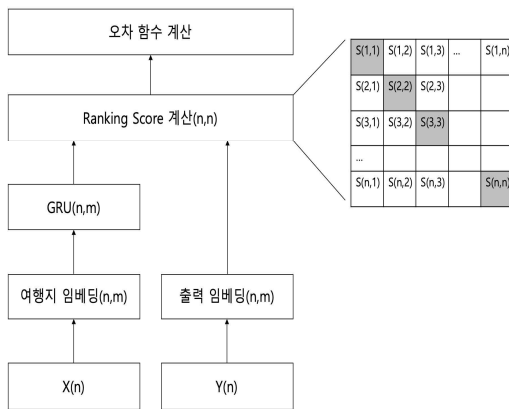


그림 4. 평가 오차 계산

따라서, 평가 점수에서  $k$ 와  $l$ 이 같아지는 대각행렬은 입력 여행지와 실제로 방문한 여행지인 Positive sample의 점수이다. 반면에, 대각 행렬을 제외한 나머지 값은 실제로 방문하지 않은 여행지인 Negative sample의 점수이다. 오차함수를 계산할 때는 Positive sample간 점수는 높도록, Negative sample간 점수는 낮아지도록 학습된다.

오차 함수로 Hidasi 등[2]에서 제안한 top1함수와 bpr함수를 사용한다. 그림 5는 top1함수와 bpr함수의 식을 보여준다. bpr함수와 top1은 모두 negative sample과 positive sample을 비교하는 방식이지만, top1함수는 negative sample의 점수에 대한 정규화 처리가 되어있다. 실험을 통해, bpr오차 함수는 적은 epoch에도 학습이 되지만, 학습이 지속될수록 오차가 낮아지지 않는 것을 확인하였고, top1함수는 학습되는데 bpr에 비해 시간이 소요되지만 오차가 서서히 낮아지는 것을 발견하였다. 이를 통해 bpr함수와 top1함수를 같이 적용을 하였다. 첫 번째 이

폭에서는 bpr로 학습을 시키고 그 다음 15 이폭까지 top1함수로 학습을 시킨 후에 20 이폭까지 다시 bpr함수로 학습을 시켰을 때 성능이 개선되는 것을 확인했다.

$$\text{bpr} : -\frac{1}{N_s} \circ \sum_{j=1}^{N_s} \log(\sigma(\hat{r}_{s,i} - \hat{r}_{s,j}))$$

$$\text{top1} : \frac{1}{N_s} \circ \sum_{j=1}^{N_s} \sigma(\hat{r}_{s,j} - \hat{r}_{s,i}) + \sigma(\hat{r}_{s,i}^2)$$

$\hat{r}_{s,j}$  : negative sample과의 점수

$\hat{r}_{s,i}$  : positive sample과의 점수

$N_s$  : 미니배치 내의 negative sample의 개수

그림 5. 오차 함수의 식

## IV. 검증

### 1. 데이터 셋

데이터 셋은 2017년1월 1일부터 2018년 12월 31일 까지 작성된 블로그, SNS, 여행플랫폼으로부터 수집된 제주도 여행 경로 데이터로 구성되었다. 수집된 데이터에서 같은 여행지나 다르게 표기된 여행지에 대해서는 여행지 사전을 구축하여 통일하였다. 데이터 셋의 지역은 제주도로 한정하였고, 1,355개의 여행경로, 1,361개의 여행지로 구성되어 있으며 데이터의 개수는 10,074이었다. 학습용 데이터는 918개의 여행경로로 구성되었고, 검증용 데이터는 437개의 여행경로로 구성되었다.

### 2. 검증 방식

본 연구에서는 검증 방식으로 recall과 MRR(Mean Reciprocal Rank) 두 가지 지표를 사용하였다. MRR은 추천모델이 추천한 여행지 목록 중에서 실제 사용자가 선택했던 여행지가 얼마나 추천목록의 상위의 순위에 위치에 있는지를 측정한다. 추천모델이 제시한 추천 목록에 대한 정밀함을 측정한다고 할 수 있다. Recall은 추천모델이 추천한 여행지 목록 중에서 실제 사용자가 선택했던 여행지가 있는지 없는지를 확인하는 방법이다. 추천모델의 적중률을 평가하는 지표라 할 수 있다. 추천 모델이 추천할 때 사용자가 다음에 갈만한 확률이 높은 상위  $N$ 개의 여행지를 추천하는데 이를 Top  $N$ 이라고 한다. 이때  $N$ 의 값을 변화시켜가며 모델의 성능을 확인하였다.

본 연구에서는 검증용 데이터 437개의 여행경로에 대해서 다음과 같이 검증하였다. 어떤 여행경로가 5개의 시퀀스를 가지고 있을 때 첫 번째 여행경로를 입력 받아 다음에 갈 여행지 Top

N개를 추천해준다. 추천 목록에 실제로 간 여행지가 n번째 목록에 있었다면 MRR은  $1/n$ , recall 은 1이 된다. 이 방법을 각 시퀀스마다 적용하여 전체 검증횟수 만큼 평균 내어 표 1.과 같은 결과를 얻을 수 있었다.

표 1. 여행지 추천 모델 성능 비교

Top N (@n)	오차함수			
	top1		bpr + top1	
	recall(%)	MRR(%)	recall(%)	MRR(%)
@1	<b>6.53</b>	<b>6.53</b>	5.32	5.32
@5	15.42	<b>9.75</b>	<b>16.88</b>	9.39
@10	20.45	10.42	<b>25.09</b>	<b>10.67</b>
@15	24.03	10.70	<b>30.19</b>	<b>10.87</b>
@20	26.08	10.82	<b>34.22</b>	<b>11.10</b>

### 3. 여행지 추천 모델 성능

제주도 지역의 여행지를 추천해주는 모델을 오차함수의 변형을 통해 성능비교를 하였다. 결과는 표 1과 같다. Top 1(@1)개의 상품을 추천 할 때는 top1오차함수만 사용하는 것이 성능이 좋았다. 하지만 Top N(@n)의 수가 높아짐에 따라서 bpr오차함수와 top1오차함수를 같이 사용하는 모델이 성능이 좋았다. 특히, Top 20(@20)일 때, recall은 8%정도 향상되었다.

### 4. 의미론적 여행지 추천

RNN 기반 모델은 시퀀스를 고려하여 의미론적인 분석이 가능하다는 장점 때문에, 자연어처리, 이미지 분석, 음성 인식 등 많은 분야에 활용되어 왔다. RNN 기반 모델은 데이터에 내재된 특징을 파악할 수 있다. 즉, 데이터에 관광지의 좌표나 여행지에 대한 정보가 없지만 여행경로 시퀀스 내에 여행지에 대한 특징이 내재되어 있기 때문에 GRU모델은 내재된 관광지의 특징을 고려하여 학습을 한다. 여행지 추천에서도 여행지가 가지는 의미를 파악하여 추천이 이루어지는지 확인하고자 한다. 제주공항에 도착한 관광객은 대중교통 또는 렌트카와 같은 교통수단을 갖추지 못한 상태에서 거리가 먼 관광지로 이동하지 못한다. 따라서 제주공항 다음으로 추천되는 여행지는 제주공항으로부터 가까운 여행지가 추천되어야 한다. 제주공항 다음 @20의 여행지 중 거리가 5km이내인 관광지 평균은 16.36개로 나타났다. 또한 제주공항에서 렌트카 업체를 방문한 뒤의 추천되는 @20 여행지의 평균 거리는 19.97km로 나타났다. 관광객이 식당을 방문한 뒤 다시 식당을 방문하는 경우는 극히 드물다. 따라서 이전 여행지에 식당이 있는 경우, 추천되는 여행지 중 식당의 수는 적어야 한다. 이 경우 추천되는 여행지 @20에서 식당

이 아닌 여행지의 평균 개수는 17.23개로 나타났다.

## V. 결론

본 연구에서는 여행경로 추천에 관한 기존의 연구에서 여행지들의 시퀀스를 고려하지 못한다는 단점을 보완하기 위하여 RNN 기반의 추천 방법론을 적용하였고, 오차함수의 변형을 통하여 성능이 개선되었음을 보여 주었다. 또한, RNN 기반 모델이 데이터에 시퀀스의 특징을 반영한다는 점을 통하여 여행경로내의 여행지가 가지는 의미가 반영된 추천이 이루어진다는 것을 확인하였다. 그러나 본 연구의 모델은 RNN 기반 모델만 고려했다는 한계가 있다. 최근 추천시스템과 관련한 연구가 활발히 이루어짐에 따라, 여행지 추천 연구가 향후 진행된다면 최신 추천시스템 방법론을 적용해 여행지 추천의 성능을 더욱 효과적으로 향상시킬 수 있을 것으로 기대된다. 또한, 지방자치단체들이 문화재와 음식점 등을 중심으로 단순 홍보를 추진하는 것을 넘어서 객관적인 데이터와 근거를 가지고 여행지와 여행경로를 지속적으로 개발하여 추천할 수 있는 시스템을 구축할 수 있을 것으로 기대된다.

## REFERENCES

- [1] 이정민, "지역분권화에 따른 지역관광 발전 방안," *한국관광정책*, 제73호, 40-49쪽, 2018
- [2] B. Hidasi, A. Karatzoglou, L. Baltrunas, and D. Tikk, "Session-based recommendations with recurrent neural networks," *arXiv preprint arXiv:1511.06939*, 2015.
- [3] 안병익, 정구임, 최혜림. "다속성 태도 모델과 협업적 필터링 기반 장소 추천 연구," *스마트미디어저널*, 제5권, 제2호, 1-6쪽, 2016
- [4] 홍택은, 신주현. "이미지와 텍스트 정보의 카테고리 분류에 의한 SNS 팔로잉 추천 방법," *스마트미디어저널*, 제5권, 제3호, 1-8쪽, 2016
- [5] Y. Zheng, L. Zhang, X. Xie, and W.Y. Ma, "Mining interesting locations and travel sequences from GPS trajectories," *In Proceedings of the 18th international conference on World wide web, ACM*, pp. 791-800, 2009.
- [6] Z. Yu, H. Xu, Z. Yang, and B. Guo, "Personalized travel package with multi-point-of-interest recommendation based on crowdsourced user footprints," *IEEE Transactions on Human-Machine Systems*, vol. 46, no. 1, pp. 151-158, 2016.

- [7] T. Kurashima, T. Iwata, G. Irie, and K. Fujimura, "Travel route recommendation using geotags in photo sharing sites," *Proc. of the 19<sup>th</sup> ACM international conference on Information and knowledge management, ACM*, pp. 579-588, 2010.
- [8] H.C. Kum, J.H. Chang, and W. Wang, "Sequential Pattern Mining in Multi- Databases via Multiple Alignment," *Data Mining and Knowledge Discovery*, vol. 12, no. 2, pp. 151-180, 2006.
- [9] Ji, X., J. Bailey. and G. Dong., "Mining Minimal Distinguishing Subsequence Patterns with Gap Constraints," *Knowledge and Information Systems*, vol. 11, no. 3, pp. 259-296, 2007.
- [10] U. Yun, "A New Framework for Detecting Weighted Sequential Patterns in Large Sequence Databases," *Knowledge-Based Systems*, vol. 21, no. 2, pp. 110~122, 2008.
- [11] 장중혁, "발생 간격 기반 가중치 부여 기법을 활용한 데이터 스트림에서 가중치 순차패턴 탐색," *지능정보연구*, 제16권, 제3호, 55-75쪽, 2010
- [12] 이태석, 강승식, "LSTM 기반의 sequence-to-sequence 모델을 이용한 한글 자동 띄어쓰기," *스마트미디어저널*, 제7권, 제4호, 17-23쪽, 2018
- [13] Clements, M., Serdyukov, P., De Vries, A. P. and Reinders, M. J. "Using flickr geotags to predict user travel behaviour." *Proceedings of the 33rd international ACM SIGIR conference on Research and development in information retrieval*. 2010.
- [14] Yoon, H., Zheng, Y., Xie, X. and Woo, W. "Social itinerary recommendation from user-generated digital trails." *Personal and Ubiquitous Computing*, vol. 16, no. 5, pp. 469-484, 2012.

---

 저 자 소 개
 

---



이희준(준회원)

2019년 계명대학교 경영정보학전공  
학사 졸업.  
2020년 계명대학교 경영정보학과  
석사 재학.

<주관심분야 : 딥러닝, 추천시스템>



이원석(준회원)

2019년 계명대학교 통계학전공  
학사 졸업.  
2020년 계명대학교 경영정보학  
석사 재학.

<주관심분야 : 딥러닝, 이미지분석>



최인혁(준회원)

2019년 계명대학교 경영정보학전공  
학사 졸업.  
2020년 계명대학교 경영정보학  
석사 재학.

<주관심분야 : 딥러닝, 머신러닝>



이충권(정회원)

1995년 계명대학교 경영정보학과  
학사 졸업.  
1999년 Southeast Missouri State  
University MBA 졸업.  
2003년 University of Nebraska-  
Lincoln 경영학박사 졸업.  
2003-2006년 Georgia Southern  
University 조교수.

<주관심분야 : Big Data, Text Mining, IT Jobs>