

# EASE를 이용한 반려동물 동반 관광지 최적 루트 추천시스템

주혜림, 여동현, 전왕수, 이상용\*

경남대학교 컴퓨터공학부

gpfla2030@naver.com, ydh744@naver.com, jws2218@naver.com, syrhee@kyungnam.ac.kr\*

## The Best Companion Animal Tourism Destination Route Recommendation System using EASE.

Hye-Rim Ju, Dong-Hyeon Yeo, Wang-Su Jeon and Sang-Yong Rhee\*

Dept. Computer Engineering, Kyungnam University

### 요약

본 논문은 반려동물 동반 관광지 최적 루트 추천시스템을 제안한다. 관광 추천에서 많이 쓰이는 NCF 모델과 희소 데이터에서 성능이 좋은 EASE 모델을 사용하여 정량적, 정성적 비교를 수행한다. 정량적 평가에서는 NCF보다 EASE가 NDCG@10에서는 0.01, NDCG@20에서는 0.17 높았다. 최적 루트 제공을 위해 OpenRouteService를 사용하여 정성적 결과를 도출한 결과 NCF보다 EASE 모델이 추천범위와 루트정보를 다양하게 제공하는 것을 확인할 수 있었다. 제안하는 시스템을 통해 관광지에 대한 상세정보와 반려동물 동반 관광객들의 편의성을 제공하고자 한다.

### I. 서론

한국관광공사의 조사에 따르면 반려동물을 6개월 이상 양육한 가구 중 반려동물 동반 국내 여행 경험에 있는 비율을 74.1%이고 향후 반려견 동반 여행할 예정은 74.6%로 반려동물 동반 여행에 높은 관심이 높은 것으로 판단된다[1]. 반려동물 동반 여행의 관심이 높아짐에 따라 관광공사에서는 다양한 서비스를 제공하고 있다. 경상남도에서는 ‘2022년도 반려동물 친화 경남형 관광지 조성’이라는 사업을 통해 반려동물 친화적인 경남형 관광지를 만들었으며, 강원도에서는 투어 프로그램으로 ‘바우길 투어’, 반려동물 동반 관광지 정보 제공 프로그램으로 ‘댕댕 여지도’라는 서비스를 제공하고 있다[2].

‘댕댕 여지도’에서는 코스별 여행, 테마별 여행, 대형견 추천 여행을 제공해 주고 있고 사용자가 직접 추가하여 여행 코스를 계획할 수 있는 서비스를 제공해 주고 있다. 사용자가 직접 관광지에 대한 정보를 찾고, 추가해야 하므로 장소별 최적의 루트를 제공해 주지 못하는 단점이 존재한다. 반려동물 동반 패키지 관광 서비스는 ‘펫츠고’를 통해서 제공되고 있다[3]. ‘펫츠고’는 반려동물 동반 관광객들의 선호 여행의 형태인 완전 개별 자유 여행을 고려하지 않는 문제점이 있다.

반려동물 동반 관광에 대한 높은 관심으로 다양한 서비스들이 제공되고 있다. 하지만, 반려동물 동반 여행 시 제약요인은 많이 존재한다. 제약요인으로 ‘정보 부족 및 불일치’, ‘시간 및 에너지 소모’, ‘반려동물의 건강’ 등이 있다[4]. 이러한 제약요인은 반려동물 동반 관광 시 관광객의 만족도를 하락시킬 수 있다.

본 논문에서는 반려동물 동반 관광 제약요인의 해소와 반려동물 동반 관광 관심 증가, 기존 서비스의 단점 개선에 맞추어 반려동물 동반 관광지 최적 루트 추천시스템을 제안한다. 수집한 데이터를 사용하여, 모델의 결과인 추천된 관광지 사이의 최적 루트와 상세 정보를 제공한다.

### II. 반려동물 동반 관광지 최적 루트 추천시스템

반려동물 동반 관광지 최적 루트 추천시스템의 시스템 구성도는 그림 1과 같다. 먼저 공공데이터, AI-Hub 데이터를 수집하고, 수집된 데이터를 모델의 입력에 맞도록 데이터로 전처리한다. 이 데이터는 모델에 학습하고, 테스트하는 과정을 거친 후, 사용자가 원하는 관광지를 추천한다.

이때, 학습에 사용된 모델은 기존 추천시스템에서 많이 사용하는 NCF

모델과 EASE 모델 사용한다.

추천된 관광지는 사용자와 사용자가 선택한 지역, 반려동물 동반 가능 관광지로 필터링하여 최종적으로 제공해 준다. 추천 관광지 사이의 최적 루트를 계산하기 위해 OpenRouteService를 사용한다. 계산된 루트는 애플리케이션의 지도를 통해 나타내고, 지도의 마커를 클릭하면 관광지에 대한 상세 정보를 알 수 있다.




그림 1. 시스템 구성도

### 2.1 데이터 수집 및 전처리

본 추천시스템에서 사용하는 데이터는 AI-Hub에서 제공하는 국내 여행로그 데이터를 사용한다. 이 데이터는 동부권, 서부권, 수도권, 제주 및 도서 지역으로 나뉘어져 있으므로 하나의 데이터로 통합한다. 국내 여행로그 데이터의 종류는 활동 소비내역, 활동내역, 방문지 정보, 여행객 정보 등이 존재하지만, 본 논문에서는 방문지 정보만 사용한다.

방문지 정보 데이터의 결측치 제거, 데이터의 형 변환을 진행하고 사용자가 방문한 모든 장소에서 개인적인 장소인 가족·친인척·지인의 집과 복합 편의시설인 교통시설, 렌터카, 편의점, 마트, 전기·수도 충전소 등 관광과 관련이 적으므로 제거한다.

방문지의 만족도는 사용자의 만족도, 재방문 의향, 추천 의향, 재방문 여부가 존재한다. 만족도, 재방문 의향, 추천 의향의 평균에 재방문하였으면 ‘+1’을 하지 않았다면 ‘-1’을 하여 장소에 대한 만족도를 업데이트했다. 또한 방문지의 이름은 다르지만, 방문지의 아이디어가 동일한 행이 존재해, 방문지의 아이디어를 방문지의 이름을 기준으로 다시 주었다. 사용자가 방문한 장소에 대한 만족도, 방문지·사용자 아이디어를 결합하여 사용한다.

## 2.2 NCF(Neural Collaborative Filtering)

NCF 모델[4]은 전통적인 행렬분해에 기반을 두고 비선형 함수를 통합하여 사용자-아이템 상호작용 간 복잡한 구조를 표현함으로써, 행렬분해 기법의 선형결합 한계를 극복한 모델이다. NCF 모델의 주요 구성요소는 GMF(Generalized Matrix Factorization)와 MLP(Multi Layer Perceptron)이다. GMF는 전통적인 행렬 인수분해 방법을 사용하여 사용자-아이템을 선형구조를 표현한다. MLP는 여러 개의 레이어로 복잡한 비선형성 구조를 학습한다. 두 요소의 출력은 NeuMF(Neural Matrix Factorization)에서 하나로 결합하여 그림 2와 같이 나타낸다.




그림 2. NCF 모델의 구조

$$\phi^{GMF} = P_u^G \odot q_i^G \quad (1)$$

$$\phi^{MLP} = a_L (W_L^T (a_{L-1} (\dots a_2 (W_2^T \begin{bmatrix} p_u^M \\ q_i^M \end{bmatrix} + b_2) \dots)) + b_L) \quad (2)$$

$$\hat{y}_{ui} = \sigma(h^T \begin{bmatrix} \phi^{GMF} \\ \phi^{MLP} \end{bmatrix}) \quad (3)$$

식 (1) ~ (2)의  $P_u^G$ 와  $P_u^M$ 는 GMF와 MLP의 사용자 임베딩이고,  $q_i^G$ 와  $q_i^M$ 는 아이템 임베딩이다. GMF는 사용자, 아이템 임베딩의 원소별 곱으로 계산되고, MLP는 사용자, 아이템 임베딩을 심층 신경망을 사용한다. GMF의 임베딩 레이어와 MLP의 임베딩 레이어를 결합하여 최종적인 결과  $\hat{y}_{ui}$ 를 구한다.

## 2.3 EASE(Embarrassingly Shallow Autoencoder)

EASE 모델[6]은 극단적으로 은닉층의 수를 줄인 선형모델이다. closed-form solve와 가중치  $B$ 행렬에 L2-norm 정규화를 적용하여 학습을 진행한다. closed-form solve와 L2-norm 정규화를 사용하면 최소 데이터에서 높은 성능을 보이며, 그림 3과 같다.



그림 3. EASE 모델의 구조

$$S_{uj} = X_u \cdot B_j \quad (4)$$

$$\min_B \|X - XB\|_F^2 + \lambda \cdot \|B\|_F^2 \quad (5)$$

$$s.t. \quad \text{diag}(B) = 0 \quad (6)$$

식 (4)의  $X_u$ 는 사용자-아이템 매트릭스이고,  $B_j$ 는 가중치 매트릭스이다.  $B$ 는 L2-norm 정규화를 적용하여 closed-form으로 계산된다.

## 2.4 OpenRouteService & OpenWeatherMap

OpenRouteService는 OpenStreetMap을 기반으로 거리 행렬(Distance Matrix)을 계산하는 API이다. 이때 사용되는 알고리즘은 다익스트라(Dijkstra)이다. 다익스트라는 출발 노드와 도착 노드를 설정하고 현 위치의 노드와의 인접 노드 간의 거리를 계산하여 최단 거리를 테이블로 업데이트하여 노드 간 최단 거리를 계산한다.

OpenRouteService는 오픈소스에 최적화된 엔진인 VROOM이 포함되어 있어 계산 속도가 빠르다. 사용하는 교통수단에 따라, 교통수단의 평균 속도와 루트 계산을 원하는 국가에 따라 다르게 계산하므로 정확한 루트 정보를 제공할 수 있다.

OpenWeatherMap은 GPS의 현재 위치 정보를 이용하여 현재 날씨, 날씨 예보, 온도, 습도 등을 제공해 주는 API이다. 이 정보를 애플리케이션에서 시각화한다.

## III. 실험환경 및 결과

### 3.1 실험 환경

본 논문의 실험 환경은 다음과 같다. CPU는 Intel Gold 6226R, 시스템 메모리는 64GB, GPU는 A100을 사용한다. 그리고 딥러닝 프레임워크는 PyTorch 2.3.0, 그리고 애플리케이션과 서버 개발에 사용된 Flutter 3.24, Flask 2.2.5를 사용한다.

관광 추천모델의 성능 평가를 위한 지표는 추천시스템에서 순위 품질을 검증할 수 있는 NDCG@k를 사용하였다. 관광 추천은 많은 개수의 추천은 필요 없기에 k 값은 {10, 20}으로 설정하여 실험을 진행하였다.

NCF 모델의 하이퍼 파라미터는 다음과 같다. 최적화 함수는 Adam, 손실 함수는 MSE, 잠재 차원(latent dimension)은 8, 레이어는 [16, 32, 16, 8], 에포크(epoch)는 50, 학습률은 1e-4, 배치사이즈는 256로 설정하였다. EASE 모델의 하이퍼 파라미터는  $\lambda$ 는 300으로 설정하였다.

### 3.2 데이터 구성

데이터 전처리를 통해 만든 사용자-관광지 매트릭스는 Liang, D 등[7]의 데이터 전처리 과정과 동일하다. 표 1과 같이 Test와 validation은 하나의 데이터로 결합하여 최종 테스트 데이터로 만들었다.

표 1. 데이터 전처리 후 사용자, 아이템, 상호작용의 수, # held-out users는 validation/test 사용자 수

|                     | korea travel log |
|---------------------|------------------|
| # of user           | 19,572           |
| # of item           | 21,444           |
| # of interactions   | 51,949           |
| # of held-out users | 1,000            |

### 3.3 실험 및 성능 비교

실험 결과의 정량적 지표는 표 2와 같다. 두 모델 비교 시 수치에서 k가 10일 때 EASE 모델이 NCF 모델보다 0.01 높게 나왔고 k가 20일 때 EASE 모델이 NCF 모델보다 0.17 높게 나왔다. 더 많은 관광지에 대한 평가를 진행할 때 NCF 모델보다 EASE 모델이 더 좋은 성능이 보인다.

표 2. 모델별 성능 비교 분석표

|         | NCF  | EASE |
|---------|------|------|
| NDCG@10 | 0.44 | 0.45 |
| NDCG@20 | 0.28 | 0.45 |




그림 4. 모델 별 추천 관광지 지도 매핑 시각화  
(a) NCF 모델 추천 결과 (b) EASE 모델 추천 결과




그림 5. 모델 별 추천 관광지 최적 루트 시각화  
(a) NCF 모델 최적 루트 (b) EASE 모델 최적 루트

모델별로  $k$ 가 10일 때, 수치의 차이가 크지 않아 비교한 결과 그림 4, 5에 나타내었다. 그림 4는 모델별로 상위 20개의 추천 관광지를 비교하니 NCF는 중복된 장소가 많고, EASE 모델보다 적은 추천 장소를 보인다. 또한, NCF에서는 남부 지역은 하나의 장소를 보이나, EASE에서는 4개의 장소를 추천한다. 정성평가를 비교한 결과 EASE가 NCF보다 추천을 잘 하는 것으로 판단된다.

그림 5는 ‘제주특별자치도 제주시’를 기준으로 추천된 관광지와 최적 루트를 시각화한 결과이다. 초록색 마커는 시작 지점, 파란색 마커는 경유 지점, 빨간색 마커는 종료 지점을 나타낸다. 그림 5와 같이 NCF의 추천 결과는 처음과 경유점 사이의 거리가 멀지만, EASE의 추천 결과는 2개씩 묶여있으므로 경유점을 기준으로 나누어 일정을 계획하기 좋다. 그러므로 정량적, 정성적으로 좋은 성능을 보이는 EASE 모델을 사용하여 서비스하 려고 한다.

### 3.4 구현결과

본 논문에서 제안하는 애플리케이션의 동작 과정은 그림 6과 같다. 메인화면에서 코스 만들기를 선택하고 시·도 단위의 지역 선택 후, 시·군·구 단위의 지역을 선택하면 로딩 화면 후 추천 결과 화면이 보인다. 추천 화면에는 추천 관광지의 자세한 정보와 최적 루트를 교통수단 별로 보여 준다.




그림 6. 애플리케이션 동작 과정

## IV. 결론

본 논문에서는 반려동물 동반 관광지 최적 루트 추천 시스템을 제안하였다. 실험에 사용된 데이터는 AIHub의 국내 여행로그 데이터를 사용하였고, 모델의 입력에 맞춰 전처리하였다. 그리고 NCF와 EASE 모델을 사용하여 정량적, 정성적 평가를 통하여 비교하였다. 정량적 평가에서는 NCF 모델보다 EASE 모델이 NDCG@10에서는 0.01, NDCG@20에서는 0.17의 성능 향상이 있었다. 정량적, 정성적 평가에서 좋은 성능을 보인 EASE 모델을 사용하였다.

그리고 애플리케이션에서는 모델의 추천 관광지를 사용자, 방문을 원하는 지역, 방문지역의 반려동물 동반 가능 등을 필터링하여 추천을 수행하였으며, 추천된 관광지를 시작점, 경유점, 종료 지점을 나누어 최적 루트를 계산하여 지도에 시각화하였다.

향후 연구에서는 반려동물 동반 관광지 데이터를 추가로 수집하고, 딥러닝 기반의 추천알고리즘을 적용하여 정확도를 개선하여 더 많은 관광지를 추천할 수 있는 시스템을 만들 예정이다.

## ACKNOWLEDGMENT

본 과제(결과물)는 2021년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과입니다. (2021IRIS-003) 본 연구는 정부 산업통상자원부의 재원으로 제조산업특화 초거대제조AI서비스 개발 및 실증사업의 지원을 받아 수행된 연구임 (SG20240201)

## 참 고 문 헌

- [1] KTO, “Pet Travel Status and Survey Report”, 2024.
- [2] Lee, “‘Come to Gangwon-do with your pet’... ‘Dang Daengyeojido’ opened”, Available :<https://www.yna.co.kr/view/AKR20210908082600062>, 2021, [Accessed: September, 08, 2021.]
- [3] Kang, ‘PetsGo, launches travel product for traveling with pets’, Available: <https://www.fnnews.com/news/201710301635469595>, 2017, [Accessed: October, 30, 2017.]
- [4] KTO, “2024 Plan to Promote Pet-Friendly Travel”, 2024.
- [5] He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T. S. “Neural collaborative filtering”, In Proceedings of the 26th international conference on world wide web, pp. 173-182, 2017.
- [6] Steck, H, “Embarrassingly shallow autoencoders for sparse data” In The World Wide Web Conference, pp. 3251-3257, 2019.
- [7] Liang, D., Krishnan, R. G., Hoffman, M. D., & Jebara, T. “Variational autoencoders for collaborative filtering”, In Proceedings of the 2018 world wide web conference, pp. 689-698, 2018.