



# CNN을 이용한 궤적데이터에 대한 이동성 모드 분류 방법

이권동\*, 맹주형\*\*, 송석일\*\*\*

## Mobility Mode Classification Method for Trajectory Data Using CNN

Gwon-dong Lee\*, Juhyoung Maeng\*\*, and Seokil Song\*\*\*

본 연구는 국토교통기술촉진사업 “세계시장 진출을 위한 구글맵(Google Maps) 기반의 증강현실(AR) 적용 실내공간용 보행자 내비게이션 플랫폼 개발” 과제번호 19CTAPC15272801000000 지원으로 수행하였습니다. 또한, 이 논문은 2019년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. NRF-2019R1A2C1005052)

### 요약

궤적 마이닝(Trajectory mining)에서 사용자 이동 궤적의 이동성 모드(Mobility mode) (버스, 자가용, 기차 등)을 인지하는 것은 더욱 정확한 정보를 추출하는 데 있어 매우 중요하다. 본 논문에서는 CNN(Convolution Neural Network)을 이용하여 사용자들의 이동궤적을 대중교통(버스) 이동궤적과 비 대중교통 이동궤적으로 분류하는 방법을 제안한다. 본 논문에서 제안하는 이동성 모드 분류방법에서는 실제 버스 운행 궤적을 이용하여 버스 탑승자의 이동궤적을 생성하는 방법을 이용하여 학습데이터를 확보한다. 수집한 사용자 궤적과 버스 운행 궤적을 이용해 생성한 레이블링된 궤적을 이용하여 CNN학습을 수행하고 그 결과로 도출한 학습 모델을 이용하여 수집한 사용자 궤적의 이동성 모드를 분류하는 접근 방법을 사용한다. 제안하는 방법을 이용하여 실제 사용자 궤적데이터에 대한 이동성 모드 분류 실험결과 분류 정확도가 95.98%를 보였다. 또한, 기존에 제안된 이동성 모드 분류방법과의 비교 실험을 통해 제안방법이 사용자 이동궤적에 대한 이동성 모드 분류에 더 적합함을 확인하였다.

### Abstract

Recognizing the mobility modes (bus, car, train, etc.) of the users' moving trajectories in trajectory mining is very important for extracting more accurate information. In this paper, we propose a mobility mode classification method for users trajectories based on CNN (Convolution Neural Network). The proposed mobility mode classification method in this paper generates the users' bus trajectories by using the actual bus trajectories. We use the approach of classifying the mobility modes of the collected user trajectories using the derived learning model through CNN using the collected user trajectories and the generated bus users' trajectories. We perform the mobility mode classification experiment using the actual user trajectory data. As the result of the mobility mode classification experiment, the classification accuracy was 95.98%. In addition, it was confirmed that the proposed method is more suitable for the mobility mode classification for the users' trajectories through a comparison experiment with the previously proposed mobility mode classification method.

### Keywords

mobility modes, CNN, classification, trajectory

\* 한국교통대학교 컴퓨터공학전공 석사과정  
 - ORCID: <http://orcid.org/0000-0001-9191-2707>  
 \*\* 한국교통대학교 컴퓨터공학전공 학부과정  
 - ORCID: <http://orcid.org/0000-0003-3341-7323>  
 \*\*\* 한국교통대학교 컴퓨터공학전공 교수(교신저자)  
 - ORCID: <http://orcid.org/0000-0002-0110-7155>

· Received: Oct. 31, 2019, Revised: Dec. 12, 2019, Accepted: Dec. 15, 2019  
 · Corresponding Author: Seokil Song  
 School of Computer Engineering & Information Technology, Korea National University of Transportation, Daehakro 50, Chungju, Chungbuk 27469, Korea  
 Tel.: +82-43-841-5349, Email: [sisong@ut.ac.kr](mailto:sisong@ut.ac.kr)

## 1. 서 론

GPS가 장착된 스마트기기(스마트폰, 네비게이션, 블랙박스 등)의 보급이 증가하면서 스마트기기 사용자들의 이동 궤적 데이터를 실시간으로 수집하는 것이 가능해졌다. 이에 따라 다양한 응용영역에서 사용자 이동 궤적 데이터를 수집하고 있다. 사용자 이동 궤적을 수집하는 사례는 GPS가 장착된 차량, 스마트 폰 사용자의 체크인(Check-in), SNS(Social Network Service)의 위치가 포함된 메시지 등 다양하다. 이와 같은 사용자 이동 궤적 데이터는 이동성 특징과 시공간 특징 등 중요한 정보를 포함하고 있다.

궤적 마이닝(Trajectory mining)은 사용자 이동 궤적 데이터로부터 새로운 지식을 추출하기 위한 것으로 경로 발견, 위치/목적지 예측, 이동성 행동(Mobility behavior) 분석 등 매우 다양한 분야에서 사용된다[1]. 궤적 마이닝에서는 사용자 이동 궤적들의 이동성 모드(Mobility mode)를 인지하는 것이 중요하다. 사용자 이동 궤적은 이동 수단에 따라 전철, 버스, 자전거, 보행, 택시, 개인 차량 등 다양한 이동성 모드로 나타날 수 있다. 궤적 마이닝시 이동성 모드를 인지하면 보다 정확한 정보 추출이 가능하다[2].

이 논문에서는 궤적 마이닝에서 중요하게 다루어지는 궤적의 이동성 모드 분류에 초점을 맞춘다. 기존에 수집되고 있는 사용자 이동궤적 데이터에는 이동성 모드가 명시적인 속성으로 부여되지 않는 경우가 대부분이다. 이 논문에서 사용하는 사용자 궤적데이터는 위드라이브[3] 서비스를 통해 수집한 것이다. 이 서비스는 사용자가 다양한 교통수단(버스, 전철, 승용차, 택시 등)을 이용하면서 생성하는 궤적 데이터를 수집하며 사용자는 자신이 어떤 이동수단을 이용하는지 알려주지 않는다. 이와 같은 이동 궤적 데이터를 이용해 궤적 마이닝을 할 때 각 궤적이 어떤 이동수단을 이용하고 있는지 파악한다면 더 많은 정보를 추출할 수 있을 것이다.

이동성 모드 분류의 중요성을 인식하면서 다양한 방법들이 제안되어 왔다[2][4]-[11]. [9]-[11]에서와 같이 초기에 제안된 방법들은 대부분 SVM(Support

Vector Machine)[12] 등의 기계학습기법들을 기반으로 하고 있다. 최근에는 분류 정확도를 높이기 위해 딥러닝(Deep learning) 기법들 중 CNN을 이용한 이동성 모드 분류 기법들이 제안되고 있다[2][3]-[8]. CNN은 이미지 처리 분야에서 뛰어난 성능을 보이는 대표적 딥러닝 기법들 중 하나이다[13].

[8]에서는 기존의 이동성 모드 분류 기법들이 이동궤적 데이터에서 속성을 추출하는 것을 연구자의 경험에 의존하는 것을 문제로 지적하고 있다. 이 문제를 해결하기 위해 표현학습(Representation learning) 기법을 기반으로 이동 궤적 데이터를 2 차원 이미지로 변환하고 FCDNN(Fully-Connected Deep Neural Network)을 이용하여 심층 속성(Deep feature)을 추출하는 접근방법을 제안하고 있다. 이 방법에서는 위치 데이터 리샘플링(Resampling)을 통해 CNN 입력 데이터를 생성한다. 하지만, 이 접근 방법은 궤적데이터의 이동 특성을 제대로 반영하지 못한다는 문제가 지적되었다[2].

[4]는 [10]에서 제안하는 방법이 다차원속성을 제대로 활용하지 못하는 문제를 해결하기 위해서 위치데이터 뿐아니라 속도, 가속도, 방위 변화율 등을 CNN의 입력으로 하여 이동성 모드를 예측한다. 하지만, 이 방법에서는 사용자에 의해서 레이블링(Labeling)된 데이터를 학습데이터로 이용한다. 별도의 레이블링된 학습데이터 확보 방안에 대한 방법을 제안하고 있지 않다. [5]에서는 스마트폰의 가속도 센서 데이터만을 이용하여 모빌리티 모드를 분류하는 방법을 제안하고 있다.

[2]에서는 기존 CNN기반 이동성 분류 방법들이 다차원속성을 제대로 활용하지 못한다는 문제를 해결하고 동시에 이동궤적에 대한 레이블링을 효과적으로 하기 위한 방법을 제안하고 있다. 이 방법에서는 먼저, 이동성 모드를 검출을 위해서 OPTICS(Ordering Points To Identify the Clustering Structure) [14] 기반의 OD(Origin Destination) 지점들에 대한 클러스터링을 수행한다. 이를 통해 궤적들의 이동성 모드를 찾아내고 궤적에 이동성 모드를 레이블링한 후 CNN 학습 데이터로 이용한다. CNN학습에 사용되는 속성으로 위치데이터 뿐 아니라 속도를 추가하여 이동 특성을 반영한다. 학습된 이동성 모드 분

류 모델을 통해 이후 생성되는 궤적에 대해 실시간 분류를 수행한다.

이 방법은 선박과 같이 중간 기점이 많지 않은 궤적에는 효과적일 수 있다. 하지만, 버스, 전철과 같이 중간 기점이 매우 다양하고 이를 이용하는 사용자가 다양한 기점에서 타고 내리며 생성한 궤적에 대해서는 OD 클러스터링을 통해서 이동성 모드를 부여하기가 쉽지 않다. 또한, 다양한 이동성 모드(전철, 버스, 택시 등)에 해당하는 궤적이 겹칠 수도 있으므로 OD 클러스터링만으로 이동성 모드를 찾아내기는 쉽지 않다.

이상 기술한 바와 같이 기존에 제안된 딥 러닝 기반의 이동성 모드 분류 기법들은 다음과 같은 문제로 인해 실제 응용에 적용하기에 어려운 점이 있다. 첫 번째, 일부 방법들은 지도학습을 이용하지만 레이블링된 학습데이터 확보 방안을 제시하지 못한다. 두 번째 사용자 이동 궤적의 기점과 종점을 클러스터링해서 레이블링하는 방법은 선박의 운행 궤적처럼 사용자 이동궤적의 기종점이 일정해야 적용이 가능하다. 버스, 택시 등과 같이 기종점이 상대적으로 다양한 이동 궤적에서는 적용이 어렵다.

본 논문에서는 [2][4]와 유사하게 CNN기반의 이동성 모드 분류방법을 제안한다. 기존 방법과는 다르게 본 논문에서는 레이블링된 학습데이터를 확보하기 위하여 실제 버스 운행 궤적을 수집한다. 하지만, 버스 운행 궤적은 해당 노선의 기점에서 종점까지의 궤적을 포함하므로 실제 사용자의 버스 승하차 궤적과는 다르다. 본 논문에서는 실제 사용자 버스 승하차 궤적을 생성하기 위해서 버스 운행 궤적을 다양한 길이로 분할(Segmentation)하는 접근 방법을 취한다.

이 논문의 구성은 다음과 같다. 2장에서는 제안하는 이동성 모드 분류방법을 설명하고, 3장에서는 실험결과를 제시한다. 마지막으로 4장에서는 논문의 결론을 맺는다.

## II. 제안하는 CNN기반 이동성 모드 분류 방법

그림 1은 본 논문에서 제안하는 이동성 모드 분류 방법의 전체적인 구조를 보여주고 있다. 분류에 사용하는 데이터는 위드라이브[8] 서비스에 의해서 수집된 사용자 궤적 데이터이다.

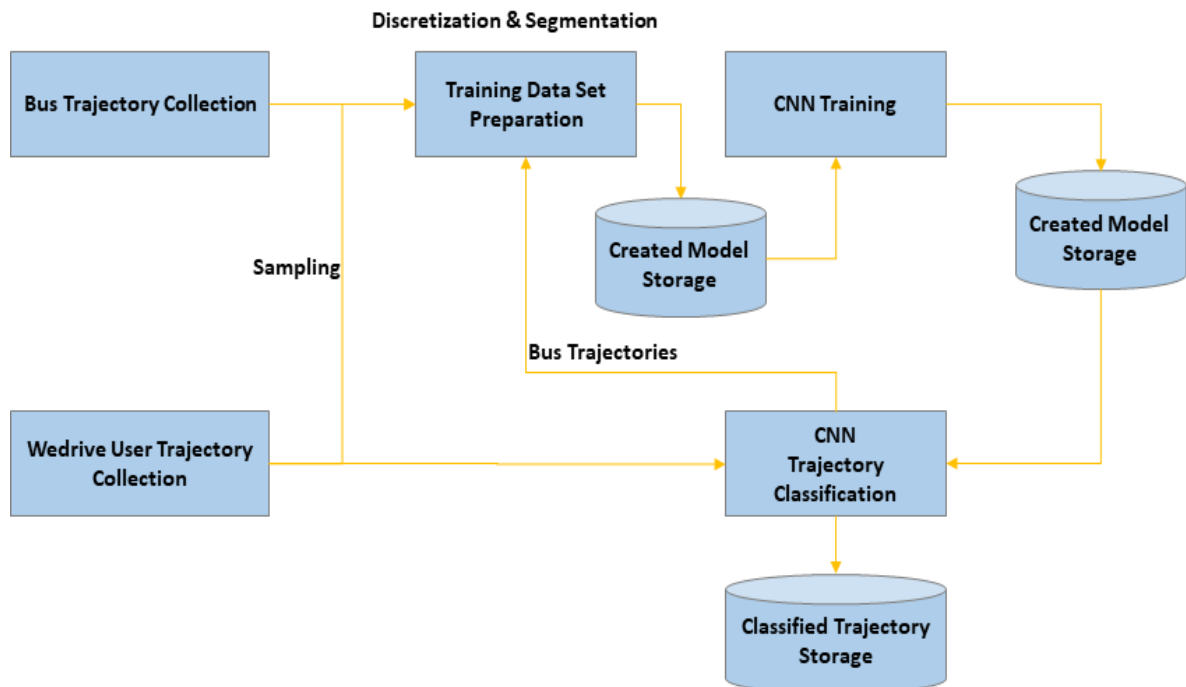


그림 1. 제안하는 CNN기반 이동성 모드 분류 기법의 전체 구조

Fig. 1. Overall architecture of the proposed mobility modes classification method based on CNN

위드라이브 서비스는 사용자가 다양한 교통수단 (버스, 전철, 승용차, 택시 등)을 이용하면서 생성하는 궤적 데이터를 수집한다. 수집한 데이터는 사용자에 대한 특성은 알수 없으며 사용자는 자신이 어떤 교통수단을 이용하는지 알려주지 않는다. 이 궤적 데이터를 이용하여 궤적 마이닝 수행하기 위해서는 각 궤적의 이동성 모드 분류를 선행하는 것이 정확도 향상에 중요한 요인이 된다.

그림 1에서처럼 초기 학습데이터를 확보하기 위해서 공공데이터 포털에서 제공하는 API를 이용하여 버스 운행 궤적을 수집한다. 버스 운행 궤적과 함께 학습하기 위해서 사용자 궤적으로부터 일부를 추출하여 버스 운행 궤적과 함께 학습에 사용한다. 학습에 사용할 버스 운행 궤적과 사용자 궤적 일부는 전처리 과정을 통해 학습 데이터로 생성된다. 특히 버스 운행 궤적은 노선의 기점부터 종점까지의 궤적이므로 실제 사용자의 궤적데이터와는 거리가 있다. 이를 보완하기 위해서 버스 운행 궤적데이터를 다양한 길이로 분할하여 학습에 사용한다. 또한, CNN에 입력할 수 있도록 학습을 위해 사용되는 일부 사용자 궤적과 분할을 통해 생성된 버스 운행 궤적 데이터를 일정 크기의 그리드로 이산화 (Discretization) 한다.

그림 2는 어떤 노선을 운행한 버스의 운행 궤적을 지도에 표시한 것이다. 이 그림에서 분석 대상이 되는 영역은  $25 \times 25$  그리드로 분할되어 있다.

그림 3은 버스 궤적을 그리드에 사상한 것을 보여준다. 그림의 각 그리드 셀들 중 궤적이 거쳐간 셀들에 대해서 궤적의 속성을 인코딩하여 CNN 학습 데이터로 사용한다. 위드라이브를 통해 수집한 사용자의 궤적도 그림 3에서와 동일하게 같은 크기의 그리드에서의 셀들의 집합으로 변환한다.

실제 학습에 사용되는 궤적은 그림 4와 같이 2차원 행렬로 변환된다. 그리드에 매핑된 궤적의 셀에 해당하는 행렬값으로 해당 셀에서 궤적의 이동방향과 이동속도를 기록한다. 그림의 숫자는 이동 속도를 나타내며 이동방향은 그림의 단순화를 위하여 생략하였다.

앞서 언급한 것처럼 버스 운행 궤적은 기점부터 종점까지의 궤적이므로 실제 사용자의 버스 이용

궤적과는 다르다. 실제 사용자의 버스 궤적과 유사한 학습데이터를 생성하기 위해서는 버스 궤적에 대한 세그멘테이션이 필요하다.




그림 2. 버스 운행 궤적  
Fig. 2. Bus trajectory




그림 3. 버스 운행 궤적을 25X25 그리드에 사상(Mapping)  
Fig. 3. Bus trajectory on 25X25 grid

0	0	0	0	0	0	0	0	0	0	0	7	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	18	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	34	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	41	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	43	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	43	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	38	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	34	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	41	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	43	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	51	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	52	47	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	38	0	0	0	0	0	0	0	0	0	0	40	43	45
0	0	0	0	0	0	0	0	0	0	0	34	0	0	0	0	0	0	0	0	0	0	42	41	0
0	0	0	0	0	0	0	0	0	0	0	41	0	0	0	0	0	0	0	0	0	0	38	40	0
0	0	0	0	0	0	0	0	0	0	0	53	0	0	0	0	0	0	0	0	0	0	38	0	0
0	0	0	0	0	0	0	0	0	0	0	40	38	0	0	0	0	0	0	0	0	0	34	34	0
0	0	0	0	0	0	0	0	0	0	0	38	0	0	0	0	0	0	0	0	0	0	41	0	0
0	0	0	0	0	0	0	0	0	0	0	34	0	0	0	0	0	0	0	0	0	0	53	0	0
0	0	0	0	0	0	0	0	0	0	0	41	41	40	0	0	0	0	0	0	0	0	40	0	0
0	0	0	0	0	0	0	0	0	0	0	43	44	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

그림 4. CNN 학습 데이터 행렬  
Fig. 4. Trajectory matrix for CNN



사용자의 버스 궤적의 길이는 다양할 것이므로 버스 운행 궤적을 분할할때는 다양한 길이로 수행할 필요가 있다. 그림 5와 6은 버스 운행 궤적을 그리드 셀의 개수를 기준으로 각각 5, 10의 길이로 분할한 것이다.

그리고 길이 5로 분할할때는 분할 간격(Stride)를 3으로 하고 길이 10으로 분할할때는 분할 간격을 5로 하여 분할된 각 궤적이 일부 겹칠 수 있도록 하였다. 이렇게 하는 것은 서로 겹치지 않도록 분할했을 때 사용자 궤적이 분할된 궤적들에 걸치는 경우를 학습할 수 없기 때문이다.

지금까지 설명한 절차에 따라서 학습데이터가 생성이 되면 CNN을 통해서 학습을 수행한다. 본 논문에서 학습을 위해서 사용한 CNN의 구조는 그림 7과 같다. 그림에서와 같이 총 3개의 컨볼루션

(Convolution) 층을 두었으며 활성화 함수는 렐루(ReLu)를 사용하였다. 다중 이동성 모드를 고려하여 출력층은 소프트맥스(Softmax)를 이용하였다. 그림 7의 CNN은 [2][6]에서 제안한 것을 논문에 적용한 그림이다.

### III. 실험 결과

이 논문에서는 위드라이브 서비스를 통해서 수집한 데이터를 이용하여 궤적 분류 실험을 진행하였다. 실험에 사용된 궤적 데이터는 전체 위드라이브 수집 데이터 중 궤적이 상대적으로 많이 밀집되어 있는 서울의 일부 영역 (37.4871671324, 126.915979085) ~ (37.8606989973, 127.458155661)에 해당하는 것을 사용하였다.




그림 5. 궤적 분할 (length=5, stride=3)  
Fig. 5. Trajectory segmentation (length=5, stride=3)




그림 6. 궤적 분할 (length=10, stride=5)  
Fig. 6. Trajectory segmentation (length=10, stride=5)

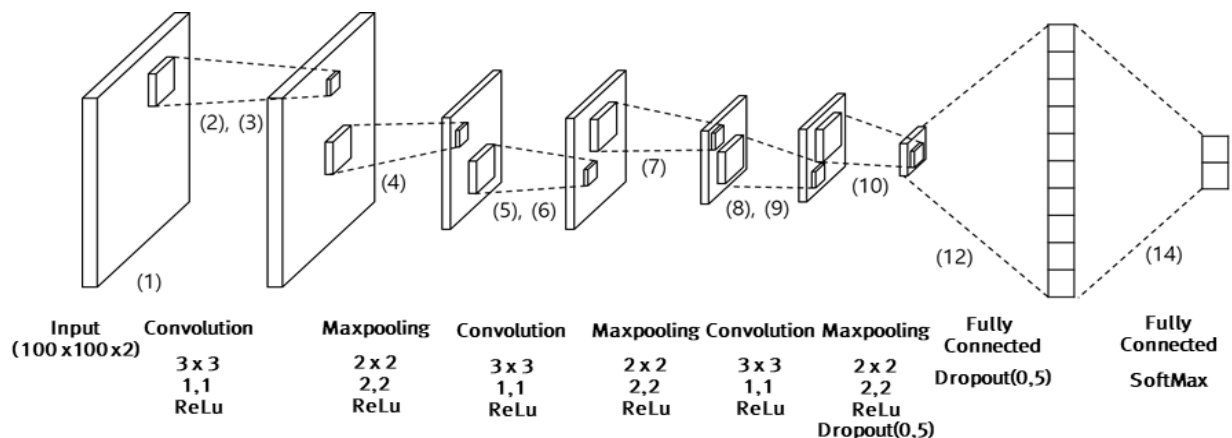


그림 7. 학습 및 분류에 사용한 CNN 구조  
Fig. 7. CNN used for learning and classification




그림 8. 데이터 추출 영역 (37.4871671324, 126.915979085) ~ (37.8606989973, 127.458155661)

Fig. 8. Area used for data extraction (37.4871671324, 126.915979085) ~ (37.8606989973, 127.458155661)

좌표에 해당하는 실제 영역은 그림 8과 같다. 버스 노선도 해당 영역을 통과하는 5개 노선 (143, 152, 153, 160, 272)에 대해서 실제 운행 궤적을 수집하였다. 실험에 사용된 궤적수는 학습궤적데이터가 5,408건이며 이중 위드라이브 사용자 궤적은 3,465건, [15]로부터 수집한 분할된 버스 궤적은 1,943건 이다. 학습된 모델을 이용하여 분류에 사용한 궤적 데이터는 총 3,599건으로 모두 위드라이브 궤적데이터이다. 데이터의 용량은 npz 형식으로 압축했을 때 1.4GB 이다.

실험에 사용한 서버는 Intel(R) Core(TM) i7-7700 CPU @ 3.60GHz, RAM 16G, TITAN Xp GPU, Samsung SSD 960 EVO 250GB의 사양을 가지며 Ubuntu 18.04.3 LTS 운영체제를 설치하여 사용하였다. 이동성 모드 분류 시스템은 Python 3.7.4, Keras 2.3.0, Tensorflow 2.0.0을 이용하여 개발하였다.

학습 데이터의 70%를 이용하여 CNN 학습을 수행하고 모델을 생성하였다. 생성된 모델을 학습 데이터의 나머지 30%를 이용하여 테스트하였다. 테스트과정을 10회 반복하였을 때 평균 정확도는 평균 0.9598이었다. 최종 학습 모델을 이용하여 3,599건의 사용자 궤적을 버스 궤적과 비 버스 궤적으로 분류하였다. 분류 결과 92건의 버스 궤적을 분류하였으며 분류 결과의 TP(True Positive)는 100% 였다.




그림 9. 분류 결과 버스 궤적

Fig. 9. Experimental results (bus trajectories)

이러한 실험 결과들로 볼 때 본 논문에서 제안하는 분류방법이 정확하게 사용자 궤적들에서 버스 궤적을 분류해 낼 수 있음을 확인할 수 있다. 분류 결과로 도출된 버스 궤적들은 그림 9에서처럼 지도 위에 시각화하였다.

마지막으로 기존 방법과 비교하기 위해서 비교적 최근에 제안된 이동성 분류방법[2]을 이용하여 수집한 사용자 궤적을 분류하기 위한 실험을 진행하였다. [2]의 분류방법은 이동 궤적을 레이블링하기 위해서 OPTICS를 이용하여 OD 클러스터링을 수행한다. OD 클러스터링을 수행한 결과를 분석하여 각 클러스터에 속하는 궤적에 레이블링을 하고 이를 이용해서 CNN 학습을 수행한다. 학습을 통해 생성된 모델을 이용해 이후에 수집된 궤적 데이터를 분류한다.

이와 동일한 접근방법을 사용하기 위해서 위드라이브를 통해 수집한 사용자 궤적 데이터에 대한 OD OPTICS 클러스터링을 수행하였다. 그림 10은 그 결과를 보여준다. minsample과 Xi를 다양하게 변화시켜 가면서 OPTICS 클러스터링을 수행한 결과 중 minsample을 25, Xi를 0.10으로 했을때의 결과를 그림에서 보여주고 있다.

클러스터링 결과를 분석하여 각 클러스터의 이동성 모드를 분석해 본 결과 주로 주유소, 도로상의 정체 지점, 신호대기, 고속 버스 터미널 등으로 파악되었으며 버스 OD 로 보이는 클러스터는 발견되지 않았다. 버스 궤적의 경우 이미 설명한 바와 같이 기준점이 서로 다른 경우가 많으므로 문헌[2]에서와 같이 OD 클러스터링을 이용하여 버스 궤적을 찾는 것은 매우 어렵다고 판단된다.

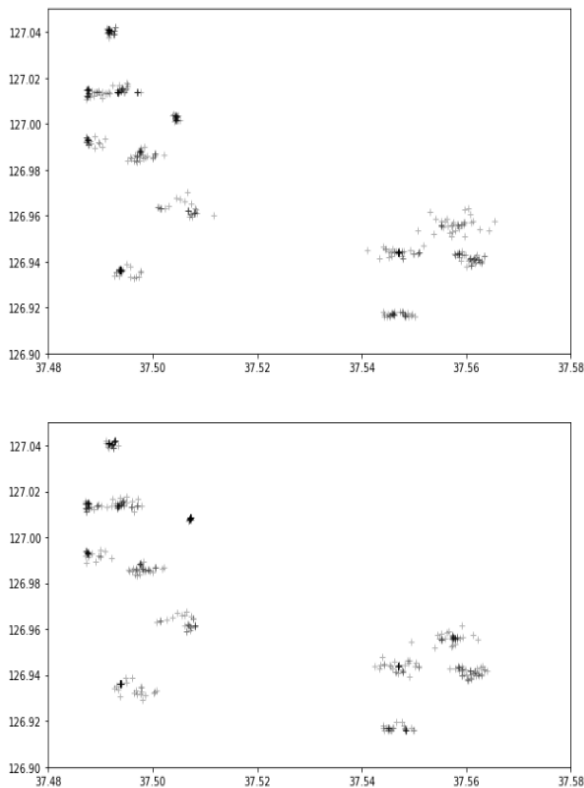


그림 10. OD에 대한 OPTICS 클러스터링 결과 (minsample=25, Xi=0.10)  
 Fig. 10. Results of OPTICS clustering for OD (minsample=25, Xi=0.10)

결과적으로 [2]와 제안방법을 본 논문에서 수집한 데이터를 이용하여 비교하는 것은 불가능 하였으며 제안방법이 버스 궤적을 분류하는데 있어 더 적합한 방법이라는 결과를 도출할 수 있었다.

## V. 결 론

이 논문에서는 스마트폰 GPS를 통해 수집된 레이블링되어 있지 않은 궤적 데이터에 대한 CNN 기반의 이동성 모드 (버스, 일반)을 분류하는 방법을 제안하였다. 사용자 버스 궤적과 흡사한 궤적을 확보하기 위해서 실제 버스 운행 궤적을 수집하고 이를 분할하는 방법을 사용하였다. 또한, 궤적을 특정 크기의 그리드에 매핑하고 그리드의 각 셀에서의 이동속도 및 이동 방향을 추출하여 이를 학습 데이터로 이용하였다. 실험 결과 정확도는 0.9598 이었으며 실험에 사용한 궤적 데이터에 대해서 분류를 수행한 결과 92개의 버스 궤적을 찾아내었으며 TP

는 100%에 달하였다. 사용자 버스 궤적의 기종점이 매우 다양하므로 기존에 제안된 방법으로는 버스 궤적을 분류하는 것이 거의 불가능함을 실험을 통해 확인할 수 있었다.

## References

- [1] Z. Feng and Y. Zhu, "A survey on trajectory data mining: Techniques and applications", IEEE Access, Vol. 4, pp. 2056-2067, Apr. 2016.
- [2] R. Chen, M. Chen, W. Li, J. Wang, and X. Yao, "Mobility modes awareness from trajectories based on clustering and a convolutional neural network", ISPRS International Journal of Geo-Information, Vol. 8, No. 5, Article No. 208, May 2019. <https://doi.org/10.3390/ijgi8050208>
- [3] <http://www.wedrive.kr>. [accessed: Dec. 09, 2019]
- [4] S. Dabiri and K. Heaslip, "Inferring transportation modes from GPS trajectories using a convolutional neural network", Transportation research part C: emerging technologies, Vol. 86, pp. 360-371, Jan. 2018.
- [5] X. Liang and G. Wang, "A convolutional neuralnetwork for transportation mode detection based on smartphone platform", In Proceedings of the IEEE 14th International Conference on Mobile Ad Hoc and Sensor Systems, pp. 338-342, Oct. 2017.
- [6] H. Wang, G. Liu, J. Duan, and L. Zhang, "Detecting transportation modes using deep neural network", IEICE TRANSACTIONS on Information and Systems, Vol. 100, No. 5, pp. 1132-1135, May 2017.
- [7] Z. Xiao, Y. Wang, K. Fu, and F. Wu, "Identifying different transportation modes from trajectory data using tree-based ensemble classifiers", ISPRS International Journal of Geo-Information, Vol. 6, No. 3, Article No. 57, Feb. 2017. <https://doi.org/10.3390/ijgi6020057>
- [8] Y. Endo, H. Toda, K. Nishida, and J. Ikedo,

"Classifying spatial trajectories using representation learning", International Journal of Data Science and Analytics, Vol. 2, Issue 3-4, pp. 107-117, Jul. 2016.

- [9] R. C. Shah, C. Y. Wan, H. Lu, and L. Nachman, "Classifying the mode of transportation on mobile phones using GIS information", In Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing, pp. 225-229, Sep. 2014.
- [10] A. Jahangiri and H. Rakha, "Developing a support vector machine (SVM) classifier for transportation mode identification by using mobile phone sensor data", In Proceeding of the Transportation Research Board 93rd Annual Meeting, Jan. 2014. 13.
- [11] A. Jahangiri and H. Rakha, "Applying machine learning techniques to transportation mode recognition using mobile phone sensor data", IEEE transactions on intelligent transportation systems, Vol. 16, No. 5, pp. 2406-2417, Mar. 2015.
- [12] B. Scholkopf and A. J. Smola, "Learning with kernels: support vector machines, regularization, optimization, and beyond", MIT press, 2001.
- [13] A. Krizhevsky and I. Sutskever and G. E. Hinton, "ImageNet classification with deep convolutional neural networks", In Proceedings of the Advances in Neural Information Processing Systems, pp. 1097-1105, Dec. 2012.
- [14] M. M. Breunig, H. P. Kriegel, R. T. Ng, and Jörg Sander, "OPTICS-OF: Identifying local outliers", In European Conference on Principles of Data Mining and Knowledge Discovery, pp. 262-270, 1999.
- [15] <https://www.data.go.kr>. [accessed: Dec. 09, 2019]

## 저자소개

### 이 권 동 (Gwon-dong Lee)



2019년 2월 : 한국교통대학교  
컴퓨터공학과(공학사)  
2019년 3월 ~ 현재 : 한국교통  
대학교 컴퓨터공학과 (석사 과정)  
관심분야 : 데이터베이스, 위치  
기반 서비스, 딥러닝 등

### 맹 주 형 (Juhyoung Maeng)



2013년 3월 ~ 현재 : 한국교통  
대학교 컴퓨터공학과(학부 과정)  
관심분야 : 데이터베이스, 위치 기반  
서비스, 딥러닝 등

### 송 석 일 (Seokil Song)



1998년 2월 : 충북대학교  
정보통신공학과(공학사)  
2000년 2월 : 충북대학교  
정보통신공학과(공학석사)  
2003년 2월 : 충북대학교  
정보통신공학과(공학박사)  
2003년 7월 ~ 현재 :  
한국교통대학교 컴퓨터공학과 교수  
관심분야 : 데이터베이스, 센서 네트워크, 스토리지  
시스템 등