

산업 현장에서의 트랜스포터 경로 예측에 관한 연구

A Study on Transporter Trajectory Prediction in Industrial Environments

김지연¹ · 김기환² · 강영진² · 정석찬^{3*}

동의대학교 대학원 인공지능학과¹, 동의대학교 인공지능그랜드ICT연구센터²,
동의대학교 e비즈니스학과, 인공지능그랜드ICT연구센터, 부산IT융합부품연구소³

요약

산업 현장에서 발생하는 사고를 방지하기 위해 정책 및 제도적인 변화를 하고 있으나 산업 재해는 계속해서 발생하고 있다. 산업 현장에서의 안전에 관한 사고는 다양한 변수를 생각해야 하는 과제로 이를 해결하고 사고를 최소화하기 위한 연구가 지속적으로 이루어지고 있다. 본 논문에서는 산업 현장에서 사용되는 트랜스포터의 경로 예측에 관한 연구를 진행하였다. 가로 3.4km, 세로 2.3km 트랜스포터 작업환경에서 트랜스포터의 좌표를 PECNet을 통해 학습한 결과 평균오차는 ADE가 1.27m, ADE가 1.13m를 나타냈다. 본 연구를 통해 트랜스포터에 한정하여 경로를 예측할 수 있을 뿐만 아니라 다양한 분야에서의 이동체나 보행자의 이동 경로를 예측할 수 있어 사고를 예방하고 방지하는데 기여할 것으로 생각된다.

■ 중심어 : 산업 현장, 경로 예측, 사고 예방

Abstract

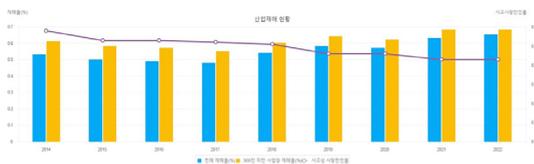
Despite policy and institutional changes to prevent accidents in the workplace, industrial accidents continue to occur. Accidents related to safety at industrial sites are complex tasks that involve considering various variables, and research to address and minimize these accidents is ongoing. In this paper, we studied the trajectory prediction of transporters used in industrial areas. In a transporter work environment measuring 3.4km by 2.3km, the coordinates of transporters were learned through PECNet, resulting in an average error of ADE 1.27m and FDE 1.13m. This research will contribute to preventing and avoiding accidents by predicting not only the path of transporters but also the paths of mobile vehicles and pedestrians in various fields.

■ Keyword : Industrial Environments, Trajectory Prediction, Accident Prevention

I. 서론

지난 몇 년간의 산업 재해 현황을 살펴보면, 그림 1[1]에서 볼 수 있듯이 전체 재해율은 일정한 추세를 보이고 있다. 하지만 사고사망률은 시간이 지남에 따라 감소하고 있다. 그럼에도 불구하고 최근 2022년까지도 사고가 계속 발생하고 있음을 확인할 수 있다.

보도에 따르면, 2019년 2월 생수 제조 공사에서 이동 중인 지게차가 작업자를 발견하지 못하고 충돌해 사망사고가 발생했으며[2] 2021년 12월에는 물류센터 공사장에서 안전 고리를 착용하지 않고 물류센터 외벽 끝에서 콘크리트 타설 하던 중 추락하여 사망한 사고가 발생하였다[3]. 같은 해 7월, 시멘트 공장에서는 시멘트 포대를 적재하는 기계의 작동이 멈춰 이를 살펴보던 중 설비 전원 차단 장치가 작동하지 않아 기계가 재가동 되면서 끼임으로 인해 사망하는 사고가 있었다[4]. 이처럼, 수많은 산업 현장에서 안전 불감증, 안전하지 못한 환경, 예기치 못한 일의 발생 등으로 다양한 사고가 지속적으로 일어나고 있다.



〈그림 1〉 2014~2022 산업 재해 발생 현황

이에 따라, 고용노동부는 2022년 1월, 산업 재해를 방지하기 위해 중대재해처벌법을 시행하였고 2022년 11월에는 사고사망인율을 0.29%로 감축하는 것을 목표로 하는 ‘중대재해 감축 로드맵’을 수립하여 발표하였다. 안전에 대한 이러한 관심과 중요성은 최근에만 생긴 것이 아니다. 오랜 시간 동안, 그리고 2022년 이전부터도 산업 재해를 예방하고, 그 영향을 최소화하기

위한 다양한 연구와 전략이 계속해서 진행되어 왔다. Zigbee기반의 비콘 기술과 셀룰러 이동 통신 기술을 활용한 IoT기반의 위험구역 경보 시스템은 작업자의 위험 지역 접근을 방지하고자 연구되었다[5]. 또한, 안전모에 다중 센서를 부착하여 가스 사고와 낙상 사고를 인지하여 관리자에게 위험 상황을 알려주는 연구를 수행했으며[6], 건설 현장에서의 작업자가 안전 문제를 해결하기 위해 웨어러블 장비를 통해 위치 정보와 장비에 부착된 센서 정보를 조회할 수 있는 안전 장비 플랫폼에 관한 연구[7]도 진행되어왔다. 이처럼, 산업 현장에서 사고를 예방하기 위한 연구는 보편적으로 센서 정보를 이용하여 현재 작업자의 상태 및 위치 정보에 대한 모니터링에 집중되어있다. 이러한 연구는 사고 발생 직후의 대응하는 것에는 장점이 있지만 사고를 미리 방지하기에는 다소 부족한 면이 있다. 이에, 본 논문에서는 산업 현장에서 흔히 사용되고 있는 트랜스포터의 과거 경로로부터 미래의 경로를 예측하여 사전에 충돌 사고를 방지할 수 있도록 하는 경로 예측에 관하여 연구하였다.

본 논문의 구성은 다음과 같다. 2장에서는 경로 예측과 관련된 연구를 소개하고 3장에서는 활용할 경로 예측 학습 모델에 대해 살펴보고 학습 모델 생성 방법에 관하여 서술한다. 4장에서는 생성한 학습 모델에 테스트 데이터를 활용하여 학습 모델 성능을 평가한다. 마지막으로 본 연구의 결론과 향후 연구를 제시한다.

II. 관련 연구

경로 예측에 관한 연구는 과거에는 경험적인 규칙이나 통계적인 분석 방법을 사용하였고 기계학습의 발달로 점차 인공지능을 활용하여 연구되어지고 있다. 한상준 외 2인(2004)은 GPS 장비로 수집한 사용자의 위치 이동 패턴을 자기조직화지도(self-organizing map, SOM)과 마르

코프 모델을 활용한다. 클러스터링 기법 중 하나인 자기조직화지도를 시퀀스 데이터 처리에 유용하도록 변형한 RSOM을 활용하여 사용자의 이동 패턴을 클러스터링한다. 클러스터링한 이동 패턴을 마르코프 모델에 적용하여 학습하였고 현재 이동 중인 사용자의 다음 이동 패턴을 예측하는 연구를 하였다[8].

윤태복 외 3인(2008)은 이동 경로 요약과 이동 경로 선택 방법을 활용하여 이동 중인 사용자의 시공간 위치 예측을 연구하였다. 시간, 방향, 위치 특성을 갖고 있는 사용자의 이동 경로를 활용하여 경로를 그룹화한다. 그룹화한 경로를 선별하여 현재 이동 중인 사용자의 경로를 비교하여 경로 간의 유사도를 측정하여 경로를 예측하였다[9].

김산민 외 2인(2019)은 다차량 환경에서의 경로를 예측하는 알고리즘을 제안하였다. 가변 길이의 시퀀스 데이터를 처리하고 이전 단계의 정보를 현재 단계로 전달하는 것이 특징인 순환신경망(RNN, Recurrent Neural Network)기반의 Encoder와 Decoder 구조를 활용하였다. 차량의 시계열 데이터 입력을 통해 과거와 미래의 궤적을 고려하여 단일 차량뿐만 아니라 다차량의 환경을 고려한 움직임을 예측하였다[10].

최성진 외 4인(2019)은 딥러닝 기반의 모델을 사용하는 차량 궤적 예측을 제안하였다. 활용한 데이터는 호주 브리즈번 시에서 블루투스 MAC 스캐너를 통해 수집된 데이터이고 이를 교차로에 POI(Point of Interest)를 설정하여 시퀀스 데이터를 생성하였다. 생성한 데이터를 순방향 신경망(Feed-Forward Neural Network)을 기반으로 하는 딥러닝 모델을 활용하여 학습하였다. 생성된 학습 모델은 준수한 예측 결과를 나타내었고 POI를 활용하여 차량의 이동 경로에 영향을 주는 요인을 반영하여 경로를 예측하였다[11].

심성대 외 3인(2020)는 단일 보행자의 경로를 예측하는 알고리즘으로 어텐션 네트워크를 제

안하였다. 주로 자연어처리에 사용되어지는 어텐션 네트워크는 시퀀스 데이터의 중요한 부분에 정보를 추출하는데 유리하다. 보행자 경로를 어텐션 네트워크의 encoder에 과거 경로를 입력하고 decoder를 통해 미래 경로를 예측하였고 기존에 순환신경망을 활용하여 예측하였을 때 보다 높은 예측 결과를 보였다[12].

Zamboni et al.(2022)는 순환신경망을 활용한 방법이 아닌 2D 컨볼루션 모델을 통해 보행자의 궤적을 예측하였다. 다양한 데이터 전처리 기술을 통해서 데이터를 증강하고 2D 컨볼루션으로 이루어진 학습 모델을 통해 학습하였는데 ETH와 TrajNet 데이터 셋을 사용하여 성능을 평가하였을 때 좋은 결과를 달성하는 것을 확인할 수 있다[13].

Henouda et al.(2022)가 제안한 방법은 언어 마스킹 전략을 기반으로 숨겨진 부분을 의도적으로 예측하는 NLP(Natural Language Processing) 분야의 유명한 모델이며 Transformer 기반으로 만들어진 BERT(Bidirectional Encoder Representations from Transformers)의 후속 모델인 ROBERTA(Robustly Optimized BERT approach)에 중점을 둔 위치 예측 모델이다. ROBERTA와 유사한 아키텍처를 따르면서 WP-BERT라고 불리는 위치 예측을 위한 Bertwordpiece 토큰나이저와 ROBERTA의 새로운 조합을 제안하였다. WBERT를 다른 위치 예측 모델인 Markovian 모델, SVM, CNN, LSTM보다 위치 예측에 관한 성능이 우수함을 나타내었다[14].

Hong et al.(2022)는 과거 위치, 시간, 이동 수단을 기반으로 위치를 예측하는 트랜스포머(Transformer) 디코더 기반 신경망을 제안하였다. 시공간 이동 특성을 기반으로 하는 감지 모델로 이동 수단을 식별하고 시간, 이동 수단 및 위치 정보를 기반으로 하는 예측 모델로 다음 위치를 예측하였다. SOTA 선정된 다른 위치 예측 모델과 비교하였을 때 두 개의 데이터 셋에

대한 F1-Score가 훨씬 뛰어난 성능을 보임을 알 수 있다[15].

이처럼 위치 예측 기술은 다양한 연구를 통해 지속적으로 발전해왔다. 초기의 GPS 기반 분석에서 출발하여 순환신경망과 어텐션 네트워크 등의 딥러닝을 활용하여 예측 정확도를 높여왔다. 그러나 대부분의 연구는 단일 이동체를 중심으로 진행되었으며 복잡한 환경에서의 여러 이동체 간의 상호 작용을 고려한 예측은 상대적으로 덜 탐구되어왔다.

이에 본 논문에서는 복잡한 환경인 산업현장에서의 여러 트랜스포터를 고려한 경로 예측에 관하여 연구하였다.

III. 연구 방법

3.1 개요

트랜스포터의 미래 경로를 예측하기 위해서는 과거의 이동 패턴을 분석하고 이를 활용하여 학습 모델 생성 구축해야 한다. 학습 모델 생성 동작 순서는 그림 2와 같은 단계로 진행된다.



〈그림 2〉 학습 모델 생성 순서도

먼저, 트랜스포터의 경로가 담긴 csv(comma separated values)파일을 입력하여주고 학습 모델에 데이터 입력이 가능하도록 전처리한다. 전처리한 데이터를 경로 예측 학습 모델의 학습 데이터로 입력하였다. 경로 예측 학습 모델로는 PECNet(Predicted Endpoint Conditioned Network) [16]을 사용하였다. PECNet은 다양한 이동체들의 경로를 예측할 수 있는 특징을 가진 모델로, 이를 활용하여 학습 모델을 생성한다.

3.2 데이터 분석 및 전처리

경로 예측 학습 모델 적용에 앞서 수집된 트랜스포터의 원시 경로 데이터 속성은 표 1과 같다. 속성 중에 ID는 트랜스포터의 고유 아이디를 뜻한다. 산업 현장에서 다수의 트랜스포터를 사용하고 있기 때문에 구분을 위해 각 트랜스포터의 경로를 기록할 때 아이디를 부여하여 저장하였다. 트랜스포터의 경로를 저장하기 위해 GPS 좌표로 트랜스포터의 위치를 기록한다. 수신시각은 트랜스포터의 위치가 기록된 시각을 나타낸다.

〈표 1〉 차량 경로 데이터 속성 정보

속성	설명
ID	차량 아이디
Latitude	위도
Longitude	경도
Time	수신시각

트랜스포터의 움직임에 대한 경로 데이터를 살펴보면 GPS가 수신되지 않을 때 위도와 경도가 0인 값으로 저장된 데이터가 있어 잘못된 경로를 나타낼 수 있으므로 결측치는 삭제하여준다. 그리고 현재 수신시각과 다음 수신시각의 시간 차이가 10분 이상 나는 경우가 있는데 이처럼 수신시각의 차이가 크게 나는 경우는 같은

지점을 목표로 하는 트랜스포터의 경로가 아니므로 다른 데이터로 간주하여 데이터를 분리하였다. 경로 예측 학습 모델로 사용하는 PECNet은 수신시각이 아닌 프레임을 통해 움직임의 시간을 구분하기 때문에 수신시각의 초를 더해줌으로써 프레임의 값으로 할당해 주었다. 이와 같은 방법으로 원시 데이터를 전처리하여 경로 예측 학습 모델의 학습 데이터로 입력하였다.

3.3 학습 모델 구축

경로 예측 학습 모델로는 PECNet을 사용하였다. PECNet은 주변 이동체의 이동 움직임을 고려하여 미래 이동 움직임을 예측하는 경로 예측 모델이다. PECNet은 Non-local Social Pooling을 통해 다른 이동체의 움직임에 대한 정보를 인지하고 샘플의 다양성 사이의 균형을 맞추는 truncation-trick 기법을 적용하여 경로 예측 성능을 향상시킨다. Non-local Social Pooling이란, 경로의 시간 순서에 의존하지 않고 개별 이동체의 현재 위치 및 경로뿐만 아니라 다양한 이동체 간의 공간적 상호 작용을 모델링하는 것이다. 이를 통해서 다른 이동체와의 사회적 상호작용을 고려하여 경로를 예측할 수 있다. 그리고 최종 목적지 또는 중간 목적지의 예측을 위해, 과거 이동 경로를 인코딩하고 이를 바탕으로 미래에 도달할 수 있는 가능한 목적지들의 분포를 추론한다. 추론된 분포를 사용하여, 최종 목적지와 이에 도달하기 위한 경로를 예측한다. 이러한 동작을 하는 PECNet을 통해 학습하고 Stanford Drone 데이터 셋과 ETH/UCY 데이터 셋을 통해 평가한 결과 각각 20.9%, 40.8%의 개선을 달성하여 경로 예측에 있어서 예측 성능이 뛰어난 모델임을 알 수 있다[16].

PECNet을 활용하여 학습 모델을 생성하기 위해 표 2에 나타난 바와 같이 50,000개의 학습 데이터와 10,000개의 검증 데이터를 사용하였고

epoch과 batch size는 각각 650과 512로 파라미터 값을 설정하여 데이터에 대한 학습을 수행하였다. 학습환경은 구글맵을 기준으로 가로 3.4km, 세로 2.3km를 이미지로 저장하여 진행하였다. 그 결과 가로 1224픽셀, 세로 1191픽셀로 구성되었으며, 가로는 1픽셀당 2.78m, 세로는 1픽셀당 1.93m로 환산할 수 있었다.

〈표 2〉 학습 모델 생성 속성 정보

속성	수치
학습 데이터	50,000
검증 데이터	10,000
epoch	650
batch size	512

IV. 결과 분석

학습의 결과는 경로 예측 모델의 성능을 평가하는 지표인 ADE(Average Displacement Error)를 활용하여 평가하였다. ADE란, 매 예측 시점의 예측값과 실제값 차의 절대 평균값을 나타낸다. 그리고 두 번째 성능 평가 지표로 FDE(Final Displacement Error)를 사용하였다. FDE란, 최종 예측값과 최종 실제값 차의 절대 평균값을 나타낸다.

표 3에서 학습한 모델의 성능 평가 지표를 살펴보면 ADE와 FDE는 각각 0.53과 0.46의 수치로, 경로와의 평균 거리 오차를 나타내는 ADE는 FDE와 비교하였을 때 상대적으로 높은 편이었지만 낮은 수치로 나타나 전체적인 경로 추정에 있어 일정 수준의 정확도를 유지하고 있음을 보여준다. 그리고 실제 최종 위치와 최종 예측 위치 간의 거리인 FDE의 값은 0.46의 낮은 수치로, 생성된 학습 모델이 최종 목표 위치를 정확하게 예측하는 경향이 있음을 알 수 있다.

픽셀당 미터로 환산할 경우 가로 2.78m로 가장 큰 오차를 보이고 세로 1.93m로 가장 적은 오

차를 보인다. 이를 고려하여 ADE와 FDE의 최소 및 최대오차를 미터로 환산하면 ADE는 평균 1.27m 오차를 보이며, FDE는 평균 1.09m 오차를 확인할 수 있었다.

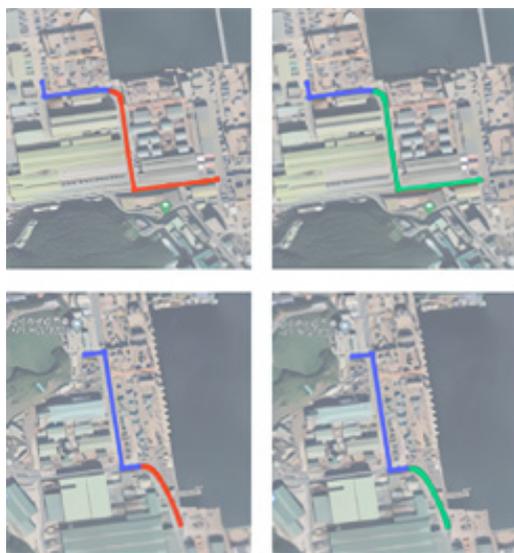
〈표 3〉 학습 모델 결과

속성	수치	최소오차(m)	최대오차(m)
ADE	0.53	1.04	1.50
FDE	0.46	0.89	1.28

생성된 학습 모델에 테스트 데이터를 입력하여 성능 평가를 하였을 때 0.58의 ADE 수치값과 0.49의 FDE 수치값을 얻었음을 표 4에서 알 수 있다. 평균오차는 ADE가 1.27m, ADE가 1.13m로 학습 결과와 크게 다르지 않음을 확인할 수

〈표 4〉 테스트 데이터를 사용한 학습 모델 성능 평가 결과

속성	수치	최소오차(m)	최대오차(m)
ADE	0.54	1.04	1.50
FDE	0.48	0.93	1.33



〈그림 3〉 실제 데이터와 예측 데이터 비교

있다. 그림 3은 테스트 데이터의 실제 데이터와 예측 데이터를 시각화하여 나타낸 그림 이다. 그림 3의 왼쪽 그림은 실제 데이터를 시각화한 그림으로, 파란색으로 표시된 경로는 과거의 경로이고 빨간색으로 표시된 경로는 실제 미래의 경로이다. 오른쪽 그림은 과거의 경로를 기반으로 미래를 예측한 데이터인데 파란색으로 그려진 경로는 앞선 그림과 같이 과거의 경로이고 초록색으로 표시된 경로는 예측한 미래의 경로이다. 왼쪽과 오른쪽의 미래의 경로를 비교해보았을 때 실제 경로와 예측 경로가 일치하여 나타나는 것을 볼 수 있다.

V. 결론

본 논문에서는 산업 현장에서 주로 사용되는 트랜스포터의 위치 좌표를 통해 경로를 예측하는 알고리즘에 관하여 연구하였다. 경로를 예측하는 모델에 적용할 데이터를 생성하기 위해 원시 데이터를 분석하여 잘못된 좌표값을 제거하고 관계가 있는 경로를 구분하기 위해 수신시각에 따라 분리하였다. 그리고 기존에 수신시각으로 트랜스포터의 움직임을 구분하였는데 학습 모델은 프레임 단위로 구별하기 때문에 수신시각을 프레임에 관한 값으로 할당하여 데이터를 전처리하고 이를 사용하여 학습 모델을 생성하였다.

학습 모델의 성능 평가는 ADE와 FDE를 활용하여 평가하였다. 학습 모델의 경우, 실제 경로 간의 평균 거리 오차인 ADE와 최종 위치의 오차를 나타내는 FDE 모두 낮은 수치를 기록하였다. 이는 모델이 전반적인 경로 예측과 최종 목적지 예측에 모두 높은 정확도를 달성했을 보여준다. 해당 모델을 활용하여 테스트 데이터를 평가하였을 때 학습 모델의 성능 수치보다 높은 성능 수치를 얻었지만 차이가 크지 않다. 테스트 데이터를 통해 예측한 경로와 실제 경로를

시각화하여 비교하였을 때 두 경로가 상당히 일치함을 확인할 수 있다.

하지만 산업 현장에서의 안전사고를 예방하는 목적을 가진 모델인 만큼 정확도를 더 향상할 필요가 있다. 따라서, 향후 연구에서는 정확도를 높이기 위해 다양한 방법을 고려할 것이다.

먼저, 학습에 사용되는 파라미터를 수정하거나 트랜스포터의 경로 데이터를 증강하여 학습 데이터의 양을 늘려 예측 성능을 높이는 방안을 탐색하고자 한다. 또한, 산업 현장에서는 트랜스포터뿐만 아니라 지게차, 작업자, 외부 트럭과 같이 다양한 이동체가 함께 작업하기 때문에 다양한 이동체의 경로 데이터를 수집하여 통합적인 경로 예측을 수행하는 방향으로 연구를 범위를 확장해 나갈 것이다. 나아가, 본 논문에서는 실외에 관한 경로에 대해서만 경로 데이터를 활용하여 학습하고 경로를 예측하였는데 지게차나 작업자의 경우에는 실내에서 작업하는 때도 있으므로 향후 연구에서는 실내까지 고려한 경로 예측에 관한 연구할 예정이다.

참 고 문 헌

- [1] e-나라지표, https://www.index.go.kr/unity/potal/main/EachDtlPageDetail.do?idx_cd=1514
- [2] 송락규, “60대 용역업체 직원 지게차에 참변… 안전사고 되풀이”, KBS뉴스, 2019, 02.16, <https://news.kbs.co.kr/news/pc/view/view.do?ncd=4139981&ref=A>
- [3] 김희경, “인천 물류센터 건설 현장에서 60대 노동자 추락사”, YTN, 2022, 01.01, https://www.ytn.co.kr/_ln/0103_202201011431187070
- [4] 김민준, “한일시멘트 하청 노동자 사망사고, 전 원 차단 장치 미작동으로 밝혀져”, 메디컬투데이, 2021, 12.10, <https://mdtoday.co.kr/news/view/1065587422657567>
- [5] 김승호, 강창순, 류한국, “건설 현장 안전관리를 위한 IoT 기반의 위험구역 경보 시스템”, 한국융합학회논문지 10(10), pp.107-115, 2019.
- [6] 최우용, 김효상, “다중 센서를 이용한 위험 상황 감지 안전모”, 한국전자통신학회논문지 17(6), pp.1267-1274, 2022.
- [7] 방찬우, 김봉현, “건설 현장 노동자를 위한 스마트 안전 장비 플랫폼 설계.” 차세대융합기술학회 논문지 6(7), pp.1182-1188, 2022.
- [8] 한상준, 강현지, 조성배, “지능형 에이전트의 위치기반 서비스를 위한 사용자의 위치이동패턴 학습”, 한국정보과학회 학술발표논문집 31(1(B)), pp.562-564, 2004.
- [9] 윤태복, 이동훈, 정제희, 이지형, “시공간 위치 예측을 위한 사용자 이동 경로의 선택과 요약 방법”, 한국HCI학회 학술대회 pp.298-303, 2008.
- [10] 김산민, 최준원, 금동석, “자율 주행 차량을 위한 순환 신경망 기반 차량 경로 예측”, 한국자동차공학회 추계학술대회 및 전시회, pp.810-811, 2019.
- [11] 최성진, 김지원, 유화평, 가동호, 여화수, “딥러닝 기반의 도시 지역 차량계적 예측 알고리즘 개발 연구.” 대한교통학회지 37(5), 2019.
- [12] 심성대, 민지홍, 김병준, 김준모, “어텐션 네트워크를 이용한 보행자 경로 예측 방법”, 대한전자공학회 학술대회, pp.552-555, 2020.
- [13] Zamboni, Simone, et al. “Pedestrian trajectory prediction with convolutional neural networks”, Pattern Recognition 121, p.108252, 2022.
- [14] Henouda, Salah Eddine, et al. “Next location prediction using transformers.” International Journal of Business Intelligence and Data Mining 2, pp.247-263, 2022.
- [15] Hong, Ye, Henry Martin, and Martin Raubal. “How do you go where? improving next location prediction by learning travel mode information using transformers.” Proceedings of the 30th

International Conference on Advances in Geographic Information Systems, 2022.

- [16] Mangalam, Kartikeya, et al. "It is not the journey but the destination: Endpoint conditioned trajectory prediction." Computer Vision - ECCV 2020: 16th European Conference, Glasgow, UK, August 23-28, 2020, Proceedings, Part II 16. Springer International Publishing, 2020.

저자 소개



김지연(Ji Yeon Kim)

- 2020년 2월: 한국해양대학교 제어계측공학과 (공학사)
- 2023년 8월: 동의대학교 인공지능학과 (공학석사)
- 2023년 9월~현재: 동의대학교 인공지능학과 (박사과정)

<관심분야> 인공지능, 빅데이터, IoT 융합



김기환(Ki-Hwan Kim)

- 2013년 2월: 동서대학교 정보통신학과 (공학사)
- 2015년 2월: 동서대학교 유비쿼터스IT (공학석사)
- 2021년 2월: 동서대학교 유비쿼터스IT (박사)

• 2021년 3월~2023년 2월: 동서대학교 International College 컴퓨터공학과 초빙교수

• 2023년 3월~현재: 동의대학교 인공지능그랜드 ICT연구센터 연구교수

<관심분야> 인공지능, 암호학, 네트워크



강영진(Young-Jin Kang)

- 2013년 8월: 동서대학교 정보통신학과 (공학사)
- 2020년 8월: 동서대학교 유비쿼터스IT (공학석사, 박사)
- 2021년 3월~2022년 2월: 동서대학교 소프트웨어 융합대학

초빙교수

• 2022년 3월~현재: 동의대학교 인공지능그랜드 ICT연구센터 연구교수

<관심분야> 인공지능, 암호이론, IoT융합



정석찬(Jeong, Seok Chan)

- 1987년 2월: 부산대학교 기계설계학과 (공학사)
- 1993년 3월: 오사카부립대학 경영공학과 (공학석사, 박사)
- 1993년 2월~1999년 2월: 한국전자통신연구원 선임연구원

• 1999년 3월~현재: 동의대학교 e비즈니스학과 교수

• 2019년 1월~현재: 부산IT융합부품연구소 소장

• 2020년 7월~현재: 인공지능그랜드ICT연구센터 센터장

<관심분야> 정보시스템, IoT 융합, 빅데이터, 클라우드, 블록체인, 인공지능