

미국 캘리포니아 교통 데이터를 활용한 인공지능 알고리즘 기반 고속도로 교통량 예측 연구

최석진¹, 김선희², 신유민³, 안소현⁴, 조석현*

전북대학교¹, 국립안동대학교², 한남대학교³, 국립금오공과대학교⁴,

*University of California, San Diego (UCSD)

sjin9026@gmail.com, tjs4576@gmail.com, youmin1009@gmail.com,

dksth7878@gmail.com, *justinshcho@gmail.com

Study on Traffic Flow Prediction on Highways based on Artificial Intelligence Algorithms Using Traffic Data Measured in California, U.S.

Seokjin Choe¹, Seonhui Kim², Youmin Shin³, Sohyeon Ahn⁴, and Seokheon Cho*

Jeonbuk National University¹, Andong National University², Hannam University³,
Kumoh National Institute of Technology⁴, *University of California, San Diego (UCSD)

요약

Traffic congestion is one of the major problems that modern cities face. In addition, traffic delays caused by increased traffic flow on highways lead to various adverse effects. In this study, we propose an artificial intelligence algorithm-based model to predict traffic flow using traffic data collected on Highway 78 in San Diego County, California, USA and provided by the California Department of Transportation (Caltrans). Multiple Linear Regression, Random Forest Regression, and Multi-layer Perceptron algorithms were used to predict the traffic flow at a certain location. Moreover, we considered traffic data measured as well as 10-minutes historical data with 30-second or 60-second intervals at its upstream locations to enhance the performance of our proposed prediction models. As a result of our analysis, the traffic flow prediction model based on the Multi-Layer Perceptron algorithm using the historical data with larger intervals showed the best performance.

I. 서론

교통 혼잡은 현대 도시가 직면한 주요 문제 중 하나다. 특히 출퇴근 시간대 고속도로 교통량 증가로 인한 교통 지체와 지연은 이동 시간 및 연료 손실 그리고 환경 오염 증가 등 다양한 부작용을 초래한다. 교통 데이터 분석업체 “INRIX”가 전 세계 50 개국 1 천여 개의 도시를 대상으로 조사하여 공개한 2022 년 교통 현황 보고서에 의하면 교통 혼잡이 심각한 전 세계 10 개 도시 중 절반인 5 개 도시가 미국의 도시였다 [1]. 미국 내에서도 캘리포니아주의 교통 혼잡 문제는 매우 심각한데, 교통 혼잡이 심한 미국 상위 10 개 도시 중에서 캘리포니아주의 샌프란시스코와 로스앤젤레스가 각각 6 위 및 7 위를 차지했다. 미국 캘리포니아주에서는 인공지능 (Artificial Intelligence: AI) 기술을 활용해 이러한 극심한 교통 혼잡 문제를 해결하고자 하고 있다. [2]. 교통 혼잡 문제를 해결할 수 있는 다양한 방법들이 존재한다. 그 중에서도 가장 기본이 되는 연구 사항은 상류부 (upstream)의 교통 데이터를 활용해 하류부 (downstream)의 교통량에 대한 최적 예측 모델 개발이다. 기존에는 측정된 교통 데이터를 이용하여 기본 교통 흐름 다이어그램 (fundamental traffic flow diagram)을 제안하고 이 다이어그램의 공식에 따른 하류부의 교통량을 예측해 왔었다. 따라서 본 연구에서는 기존 방식이 아닌 인공지능 알고리즘을 이용하여 교통량 예측 모델을 제시하고자 한다.

S. Cho *et al.*은 고속도로의 교통 흐름을 설명하기 위해 최대 자유 흐름 속도, 일반적인 차량의 안전 길이 및 혼잡한 상황에서 교통 데이터의 시간 간격 평균값 등을 주요 매개 변수를 사용한 time-gap 기반 교통 모델을 제시했고 이 모델을 통해 교통량 예측이 가능하다 [3]. 이 time-gap 기반 교통 모델은 수집한 실제 교통 데이터를 이용해 제안한 모델로 인공지능 알고리즘 기반 모델은 아니다. Y. F. Ai *et al.*은 고속도로 운행 차량 데이터를 이용하여 Support Vector Machine 기반으로 교통 흐름을 예측하였다 [4]. 이 과정에서 결측 데이터에 대해 과거 평균 채우기와 선형 보간법을 사용하여 데이터를 보정했다. D. Kang *et al.*은 시계열 교통 데이터를 바탕으로 고속도로 교통 흐름을 예측하기 위해 1 분 간격의 평균 속도 데이터를 구성하고, 보간법을 활용하여 결측치를 보정했다. 교통량과 평균 속도의 상관관계를 분석하여 입력 데이터 시점으로부터 5 분, 15 분, 30 분 및 60 분 후 시점에서 차선 (lane) 별 평균 속도를 예측했다 [5]. M. S. A. Siddiquee *et al.*은 방글라데시 고속도로의 시간별 교통 데이터로 일일 교통량을 예측하였다. 인공신경망 (Artificial Neural Network)을 통해 간헐적인 데이터를 학습하여 누락된 데이터를 예측하고 일일 교통량 뿐만 아니라 시간별 교통량을 예측하였다 [6]. H. R. Deekshetha *et al.*은 2015년과 2017년의 1 시간 간격으로 집계된 교통 데이터와

회귀모델을 이용하여 교통량을 예측하였으며 Mean Squared Error (MSE)로 모델의 성능을 평가하였다 [7].

본 연구에서는 캘리포니아 교통국 (California Department of Transportation : Caltrans)에서 제공하는 고속도로 교통 데이터를 활용하여 차량 통행량이 활발한 시간대의 교통량을 예측하는 인공지능 알고리즘 기반 모델을 개발하고자 한다.

본 논문의 구성은 다음과 같다. 제 II 장에서는 본 연구에서 사용하는 원본 데이터 세트와 전처리 과정을 설명한다. 또한, 전처리 과정을 통해 생성하여 데이터 세트를 제시한다. 제 III 장에서는 본 연구에 활용한 인공지능 알고리즘들과 성능 지표를 제시한다. 제 IV 장에서는 고려하는 인공지능 알고리즘 기반 모델들에 대한 성능 결과를 비교 및 분석한다. 마지막으로, 제 V 장에서는 본 연구의 결과 및 향후 연구에 관해 설명한다.

II. 교통량 예측을 위한 데이터 및 전처리 과정

2.1 원본 Caltrans 데이터 세트 설명

본 연구에서는 캘리포니아 교통국 (California Department of Transportation: Caltrans)에서 제공하는 샌디에고 카운티 (San Diego County)의 78 번 고속도로에서 측정된 교통 데이터를 사용하였다. 78 번 고속도로에서 ‘Melrose Dr’부터 ‘El-Camino Real’까지 총 7.24 km 구간에 걸쳐 서쪽으로 가는 (westbound) 차량들로부터 수집한 데이터이다. 특히 2022 년 6 월 1 일부터 2022 년 12 월 31 일까지 약 7 개월 동안 측정된 교통 데이터로서 차량 통행량이 활발한 시간대인 5 시 30 분부터 19 시 30 분까지의 하루의 총 14 시간을 30 초 간격으로 측정된 데이터이다. 그림 1 은 78 번 고속도로 본선 (main lane), 고속도로 진입로 (entrance ramp) 그리고 고속도로 진출로 (exit ramp)들에 설치된 루프 감지기 (loop detector)를 보여주고 있다. Caltrans 는 매 30 초 동안 루프 감지기를 통과해 지나가는 차량의 수와 이렇게 30 초 동안 지나가는 차량들이 루프 감지기 위에 머무르는 점유수 (occupancy count)를 측정 및 수집한다. 이 루프 감지기는 30Hz 로 동작하고 있어서 30 초 동안 측정할 수 있는 최대 점유수는 900 이다.



그림 1. 미국 캘리포니아주 샌디에고 카운티의 78 번 고속도로에 설치된 루프 감지기 (loop detector)

표 1 은 캘리포니아주 샌디에고 카운티의 78 번 고속도로에서 측정된 교통 데이터 세트를 구성하는 특성들을 보여준다. 데이터 세트에 포함된 특성들은 다음과 같다. 교통 데이터 측정일 (Date), 매 30 초마다 측정을 완료한 시간 (Time), 측정기 고유 ID (ID), 고속도로 진입 출구 도로의 이름 (Name), 30 초 동안 고속도로 본선의 X 번째 차선을 지나간 차량의 수 (LaneX_Vol)와 이 때 지나가는 차량들의 점유수 (LaneX_Occ), 30 초 동안 진입로의 Y 번째 차선에서 고속도로 본선으로 진입하는 차량의 수 (LaneY_On) 그리고 30 초 동안 고속도로 본선에서 진출로의 Z 번째 차선으로 나가는 차량의 수 (LaneZ_Off)가 있다. 본 연구에서 사용하는 Caltrans 원본 데이터 세트는 30 초마다 측정된 데이터로 총 2,716,496 개의 데이터 샘플을 포함하고 있다.

표 1. Caltrans 시스템에서 수집한 원본 교통 데이터 세트

	Name	Type	Unit
Variable	Date	Year-Month-Day	2022-06-01 to 2022-12-31
	Time	Hour-Minute-Second	05:30:00 to 19:30:00
	ID	Integer	191, 270, 473, 193
	Name	String	El-Camino, ...
	LaneX_Vol	Integer	0, 1, ...
	LaneX_Occ	Integer	{0, 1, ... 900}
	LaneY_On	Integer	0, 1, ...
	LaneZ_Off	Integer	0, 1, ...

그림 2 는 본 연구에서 고려하는 캘리포니아주 샌디에고 카운티의 78 번 고속도로를 지도에 도시하고 있다. 고속도로 본선에 위치한 4 대의 측정기 (루프 감지기)가 존재한다. ID 193, ID 473, ID 270 그리고 ID 191 에 해당하는 고속도로 진입 출구 도로 이름들이 각각 ‘Melrose Dr.’, ‘College Blvd.’, ‘Emerald Dr.’ 그리고 ‘El-Camino Real’이다. ID 193 번이 가장 상류부에 위치하는 루프 감지기이고 ID 191 번이 가장 하류부에 위치하고 있다. 본 연구에서는 ID 193, ID 473 및 ID 270 에서 측정된 다양한 교통 데이터를 이용하여 가장 하류부에 위치하고 있는 ID 191 의 교통량을 예측하는 모델을 개발하는 것이 목표이다.

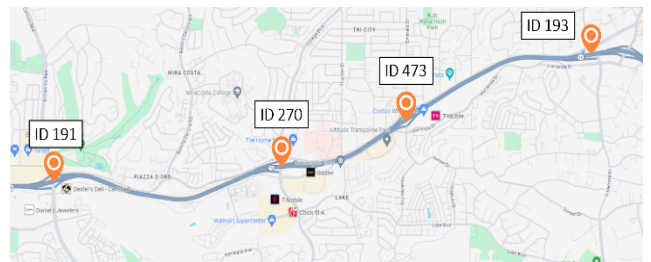


그림 2. 샌디에고 카운티 78 번 고속도로 (교통 흐름: 서쪽)

표 1 의 Caltrans 원본 교통 데이터 세트에 정의되어 있는 LaneX_Vol, LaneX_Occ, LaneY_On 및 LaneZ_Off는 그림 2 에 도시된 4 개의 측정기마다 매핑되어 존재한다. 예를 들면, ‘Melrose Dr.’를 대표하는 ID 193에 매핑되는 LaneX_Vol, LaneX_Occ, LaneY_On 및 LaneZ_Off 등의 해당 데이터들이 존재하는 것이다. 또한, ‘El-Camino Real’를 대표하는 ID 191에 매핑되는 LaneX_Vol, LaneX_Occ, LaneY_On 및 LaneZ_Off 등의 해당 데이터들이 존재한다. 물론, 동일한 시간에 측정된 ID 193의 LaneX_Vol과 ID 191의 LaneX_Vol은 다르다. 게다가 ‘College Blvd.’와 ‘Emerald Dr.’에 다수개의 고속도로 진입로와 진출로의 루프 탐지기들이 존재하고 있고 이 탐지기들의 ID 번호는 ID 473 또는 ID 270이 아니다. 하지만 연구의 편의성을 위해 ‘College Blvd.’ 지점과 ‘Emerald Dr.’ 지점에 설치된 모든 루프 탐지기들을 각각 ID 473과 ID 270에 매핑하여 사용한다.

2.2 데이터 전처리 및 분석을 위한 데이터 세트 생성 과정

본 연구는 차량 통행량이 활발한 시간대의 교통량을 예측하는 것이 목적이다. 고속도로 본선의 루프 감지기를 통과하는 차량들의 수 (LaneX_Vol), 점유수 (LaneX_Occ)에 결측값이 있을 경우에는 선형 보간법 (linear interpolation) 을 사용하여 결측값을 추정하였다. 이와는 달리, 고속도로 진입로를 통과하는 차량들의 수 (LaneY_On)와 진출로를 통과하는 차량들의 수 (LaneZ_Off)의 결측값들은 0값으로 치환하였다.

표 2는 고속도로 교통량 예측 모델에 사용할 특성들을 정의한 Constructed Feature Dataset (CFD)를 보여주고 있다. 표 2에 정의하고 있는 변수들의 접두어인 ID_num에서 num은 고려하고 있는 3개의 상류부 고속도로 (예: 193, 473 및 270) 진입출구 도로들에 매핑되는 고속도로 본선 루프 탐지기의 ID 번호들을 의미한다. 다시 말해서, num의 값은 집합 {193, 473, 270}에서 선택되어 사용되는 것이다. 또한, 변수들의 접미어인 xxx에는 정수값이 사용된다. 이것의 의미는 사용되는 정수값 초 (sec) 전의 해당 데이터이다. 표 1의 원본 데이터 세트에 포함된 데이터들은 차선별 데이터였지만, 표 2에 정의하고 있는 변수들은 각 ID에 해당하는 차선들을 통합한 값이다. ID_num_MainVol_xxx, ID_num_OnVol_xxx, 및 ID_num_OffVol_xxx는 모든 차선들의 해당 값들을 모두 더한 값이다. 또한, ID_num_MainSpe_xxx는 모든 차선들의 해당 값들의 산술 평균값이다. 표 2의 변수들에 대한 설명은 다음과 같다.

- ID_193_MainVol_000: 현재 (0 초 전) ID 193 에 해당하는 고속도로 본선의 모든 차선들을 일정 시간 동안 통과해 지나간 차량들의 총 수
- ID_473_MainSpe_030: 30 초 전 ID 473 에 해당하는 고속도로 본선의 모든 차선들을 일정 시간 동안 통과해 지나간 차량들의 평균 속도 [km/hr]
- ID_270_OnVol_300: 300 초 (5 분) 전 ID 270 에 해당하는 고속도로 진입로의 모든 차선들을 일정 시간 동안 통과해 고속도로 본선에 진입한 차량들의 총 수
- ID_270_OffVol_600: 600 초 (10 분) 전 ID 270 에 해당하는 고속도로 진출로의 모든 차선들로 나가는 일정 시간 동안 집계한 차량들의 총 수

교통 데이터는 시계열 데이터 (time-series)이기 때문에 현재 교통 데이터는 가까운 과거 시간대의 데이터들과 밀접한 관계를 가질 수 있다. 이 때문에, 3 개의 상류부 고속도로 ID 들 (예: 193, 473 및 270)에 해당하는 10 분 전까지의 모든 데이터들을 독립변수로 고려하였다. 하지만, ID 193 에 해당하는 고속도로 진출로가 없기 때문에, ID_193_OffVol_xxx 변수는 정의하지 않았다.

종속변수는 가장 하류부 고속도로에 해당하는 ID 191 번에 일정 시간 동안 예측할 교통량 (ID_191_MainVol)이다.

표 2. 고속도로 교통량 예측 모델을 위한 Constructed Feature Dataset (CFD)의 특성 구성

Independent Variable	Date, Time
	ID_num_MainVol_xxx, ID_num_MainSpe_xxx, ID_num_OnVol_xxx, ID_num_OffVol_xxx*
Dependent Variable	ID_191_MainVol

- Note: num {193, 473, 270}
*: ID_193_OffVol_xxx is not defined.

본 연구에서 고속도로 교통량을 예측하는데 있어서, 모든 ID들에서 데이터들을 집계하는 시간을 30초와 60초 (1분)으로 달리하여 데이터 수집 시간에 따른 예측 모델 성능을 비교하고자 한다. 그러므로 2개의 데이터 세트를 생성할 수 있는데, CFD_30sec와 CFD_60sec는 표 2에 포함된 모든 변수들의 집계 단위 시간이 각각 30초와 60초이다. CFD_60sec 데이터 세트의 데이터 값들은 CFD_30sec 데이터 세트의 연속된 2개의 데이터 샘플들 값을 1분 단위로 통합한 데이터 세트이다. CFD_30sec 데이터 세트에 있어서, 종속변수는 ID 191번에서 30초 동안 예측하는 현재 교통량이다. 또한, 이 데이터 세트의 과거 교통 데이터는 30초 단위로 30초 전부터 10분 전까지 데이터들이다. 이로서, 독립변수 Date와 Time이 포함하여 총 222개의 독립변수가 생성된다. 또한, 총 데이터 샘플 수가 331,482개이다. 이 CFD_30sec와 CFD_60sec

데이터 세트들을 생성하는 과정에서 매일 시작 시점인 5시 30분부터 15분 후까지 그리고 종료 시점인 19시 30분에서 5분 전까지의 해당하는 시간대들을 제외하여 총 측정시간은 13시간 40분으로 변경되었다. CFD_60sec 데이터 세트에 있어서, 종속변수는 ID 191번에서 60초 동안 예측하는 현재 교통량이다. 또한, 이 데이터 세트의 과거 교통 데이터는 60초 단위로 60초 전부터 10분 전까지 데이터들이다. 이로서, 독립변수 Date와 Time이 포함하여 총 112개의 독립변수들이 생성된다. 또한, 총 데이터 샘플 수가 165,842개이다.

III. 알고리즘 및 성능 지표

본 연구에서는 Multiple Linear Regression (MLR), Random Forest Regression (RFR) 및 Multi-Layer Perceptron (MLP) 등 총 세 가지 인공지능 알고리즘을 사용하여 교통량을 예측하였다.

위에서 사용된 알고리즘들의 최적의 하이퍼 파라미터는 다음과 같다. RFR 알고리즘의 트리 깊이 (tree depth)와 트리 모델 개수는 각각 30 과 300 이다. MLP 알고리즘의 반복 횟수, 은닉층 개수 및 은닉층의 노드 개수는 각각 500, 10 그리고 25 이다.

예측 모델의 성능 지표로 R^2 (R-squared), Mean Absolute Error (MAE) 그리고 Root Mean Squared Error (RMSE)를 사용하였다. R^2 는 회귀 모델에서 모델의 설명력을 나타내는 지표로 0부터 1 사이의 값을 가지고, 이 값이 1에 가까울수록 모델의 설명력이 높다는 것을 의미한다. MAE는 모델의 예측값과 실제값의 절댓값 차이를 의미하고, RMSE는 예측값과 실제값의 차이를 제곱하여 평균한 값의 제곱근을 의미한다. MAE와 RMSE 모두 값이 작을수록 모델의 성능이 좋다고 판단할 수 있다.

IV. 고속도로 교통량 예측 모델 분석 및 결과

표 3 은 2 개의 데이터 세트인 CFD_30sec 와 CFD_60sec 들에서 ID191 번에 해당하는 고속도로 본선에서 측정하였던 차량들의 수의 평균값 (ID_191_MainVol_{avg})과 최댓값 (ID_191_MainVol_{max})을 나타내고 있다. 30 초마다 데이터 30 초마다 데이터를 집계한 CFD_30sec 데이터 세트에서 'El-Camino Real'의 본선을 지나는 차량들의 최대 수와 평균 수는 각각 67 대와 27.518 대이다. 또한, 60 초마다 데이터를 수집한 CFD_60sec 데이터 세트에서 ID 191 번에 해당하는 본선을 지나는 차량들의 최대 수는 117 대이고 평균수는 55.025 대이다.

표 3. 데이터 세트별 ID 191 번에서 측정하였던 차량들의 수의 평균값과 최댓값

	CFD_30sec	CFD_60sec
ID_191_MainVol _{avg}	27.518	55.025
ID_191_MainVol _{max}	67	117

고속도로 교통량 예측 모델들을 분석하는 데 있어서 2 개의 데이터 세트인 CFD_30sec 와 CFD_60sec 데이터 세트들에 대하여 매월의 마지막 7 일에 속하는 데이터를 테스트용 데이터로 그리고 매월 마지막 7 일을 제외한 나머지에 해당하는 데이터를 학습용 데이터로 사용하였다.

표 4 는 상기 2 개의 데이터 세트들을 활용하여 3 개의 알고리즘 기반 모델들의 성능을 비교한 것이다. CFD_30sec 데이터 세트를 활용하였을 때에는 MLR 알고리즘 기반 모델이 가장 성능이 좋았다. 왜냐하면, MLR 알고리즘 기반 모델이 다른 두 개의 알고리즘 기반 모델들보다 큰 R^2 값과 작은 MAE 값과 RMSE 값을 가졌기 때문이다. 이와는 달리, CFD_60sec 데이터 세트의 경우에 있어서는 MLP 기반 알고리즘이 0.761 의 R^2 값, 5.687 의 MAE 값 그리고

7.322의 RMSE 값을 가지면서 MLR 및 RFR 기반 모델들보다 성능이 우수하다. 또한, CFD_30sec 데이터 세트를 살펴볼 때, 표 3에서 ID 191의 차량 수 최댓값인 67과 표 4에서 가장 우수한 성능을 보이는 MLR 알고리즘 기반 모델의 RMSE 값인 5.472를 비교하면 차량 수 최댓값 대비 RMSE 값 비율이 약 8.17%이다. 마찬가지로, CFD_60sec 데이터 세트의 경우, 표 3에서 ID 191의 차량 수 최댓값이 117이고 가장 우수한 성능을 보이는 MLP 알고리즘 기반 모델의 RMSE 값이 7.322이다. 이를 통해, 차량 수 최댓값 대비 RMSE 값 비율이 6.26%임을 확인할 수 있다. 따라서, CFD_30sec 데이터 세트와 CFD_60sec 데이터 세트에서 각각 우수한 성능을 보이는 MLR 알고리즘 기반 모델과 MLP 알고리즘 기반 모델들의 성능을 비교했을 때, CFD_60sec 데이터 세트를 이용하였을 때 MLP 알고리즘 기반 모델이 더욱 큰 R^2 값과 작은 RMSE 값을 보임을 알 수 있다.

표 4. 고속도로 교통량 예측 모델 성능 분석

		CFD_30sec	CFD_60sec
MLR	R^2	0.607	0.756
	MAE	4.313	5.732
	RMSE	5.472	7.393
RFR	R^2	0.587	0.754
	MAE	4.414	5.782
	RMSE	5.61	7.43
MLP	R^2	0.603	0.761
	MAE	4.332	5.687
	RMSE	5.501	7.322

V. 결론

본 연구에서는 미국 캘리포니아 교통국 (California Department of Transportation: Caltrans)에서 제공하는 샌디에고 카운티 (San Diego county)의 78번 고속도로에서 2022년 6월 1일부터 2022년 12월 31일까지 약 7개월 동안 수집한 교통 데이터를 활용하여 교통량을 예측하는 모델을 제시하였다. 특히 차량 흐름이 활발한 시간대의 교통량을 예측하기 위해 5시 30분부터 19시 30분까지의 데이터를 가지고 78번 고속도로의 가장 하류부 (most downstream) 지점인 'El-Camino Real'에서의 교통량 예측을 진행하였다. 이때 교통량을 예측하기 위해서 Multiple Linear Regression, Random Forest Regression, Multi-Layer Perceptron 알고리즘들을 이용하였다. 또한, 제시하는 교통량 예측 모델의 성능을 향상시키기 위해 교통 데이터가 시계열 데이터인 특징을 활용하고자 'El-Camino Real'의 상류부인 3개 지점에서 과거 10분 동안 수집한 데이터를 이용하였다. 과거 10분 데이터를 수집하는 데 있어서 데이터 샘플들을 30초 단위 또는 60초 단위로 분리한 2개의 다른 데이터 세트를 생성하여 다양한 예측 모델들의 성능을 비교하는 데 사용하였다. 제시한 교통량 예측 모델 성능 분석 결과 60초 단위로 과거 10분 데이터 샘플들을 나눈 데이터 세트를 활용한 Multi-Layer Perceptron 알고리즘 기반 모델이 가장 우수한 성능을 보였다.

향후 연구에서는 본 연구에서 접근했던 것보다 더욱 작은 독립변수를 사용하면서 동시에 예측 성능이 향상된 인공지능 알고리즘 기반 모델 개발을 수행하고자 한다. 또한 교통 혼잡도가 극심한 평일 출퇴근 시간에 집중된 교통량 예측과 현재 시각이 아닌 짧은 미래 시간에 대한 교통량 예측도 또 다른 확장된 향후 연구 주제이다.

ACKNOWLEDGMENT

Following are results of a study on the "Leaders in INdustry-university Cooperation 3.0" Project, supported

by the Ministry of Education and National Research Foundation of Korea.

We really appreciate efforts and help from Mr. Anush Badii who is working for California Department of Transportation (Caltrans) District 11, San Diego, CA, USA.

참고 문헌

- [1] INRIX, "INRIX 2022 Global Traffic Scoreboard," May 2, 2024, Available: <https://inrix.com/scorecard>
- [2] Los Angeles Times, "California Wants to Reduce Traffic, the Newsom Administration Thinks AI Can Help," May 2, 2024, Available: <https://www.latimes.com/california/story/2024-01-08/california-traffic-roads-safer-generative-ai-help>
- [3] S. Cho, R. Cruz, R. Rao, and A. Badii, "Time-Gap Based Traffic Model For Vehicular Traffic Flow," in Proceedings of the IEEE 79th Vehicular Technology Conference (VTC Spring), May 2014.
- [4] Y.F. Ai, Z.M. Bai, H. Su, N. Zhong, Y.H. Sun, and J.D. Zhao, "Traffic Flow Prediction Based on Expressway Operating Vehicle Data," in Proceedings of the IEEE 11th International Conference on Intelligent Computation Technology and Automation, pp. 322-326, Sep. 2018.
- [5] D. Kang, M. Lee, Y. Kim, S. Yoon, D. Shin, and S. Jang, "A Study on Highway Traffic Flow Prediction Model Based on Time Series Traffic Data," Summer Annual Conference of IEIE, pp.2143-2146, Jun. 2021.
- [6] M.S.A. Siddiquee and S. Hoque, "Predicting the Daily Traffic Volume from Hourly Traffic Data Using Artificial Neural Network," Neural Net World, pp.283-294, Jul. 2017.
- [7] H. R. Deekshetha, A. V. S. Madhav, and K. T. Amit, "Traffic Prediction Using Machine Learning," in Evolutionary Computing and Mobile Sustainable Networks, pp. 969-983, Mar. 2022.