

Accurate prediction of lane speeds by using neural network

Dong hyun Pyun*, Changwoo Pyo**

*Student, Dept. of Computer Engineering, Graduate School, Hongik University, Seoul, Korea

**Professor, Dept. of Computer Engineering, Hongik University, Seoul, Korea

[Abstract]

In this paper, we propose a method predicting the speed of each lane from the link speed using a neural network. We took three measures for configuring learning data to increase prediction accuracy. The first one is to expand the spatial range of the data source by including 14 links connected to the beginning and end points of the link. We also increased the time interval from 07:00 to 22:00 and included the data generation time in the feature data. Finally, we marked weekdays and holidays. Results of experiments showed that the speed error was reduced by 21.9% from 6.4 km/h to 5.0 km/h for straight lane, by 12.9% from 8.5 km/h to 7.4 km/h for right turns, and by 5.7% from 8.7 km/h to 8.2 km/h for left-turns. As a secondary result, we confirmed that the prediction accuracy of each lane was high for city roads when the traffic flow was congested. The feature of the proposed method is that it predicts traffic conditions for each lane improving the accuracy of prediction.

▶ **Key words:** ITS, estimate the travel time, route analysis, lane speeds, neural network

[요 약]

본 연구는 신경망을 이용하여 링크 속도로부터 각 차로의 속도를 예측하는 방법을 제시하였다. 예측 정확도를 높이기 위해 학습 데이터 구성에 있어 3가지 사항을 고려하였다. 첫 번째는 링크의 시작점과 끝점이 연결된 14개의 링크를 포함하여 데이터 소스의 공간적 범위를 확장하였다. 또한 시간 간격을 07:00에서 22:00로 늘리고 특성 데이터에 데이터 생성 시각을 포함했다. 마지막으로 요일과 공휴일을 표시했다. 실험 결과 직진 차로는 속도 오차가 6.4km/h에서 5.0km/h로 21.9%, 우회전은 8.5km/h에서 7.4km/h로 12.9%, 좌회전은 8.7km/h에서 8.2km/h로 5.7% 감소한 것으로 나타났다. 두번째 결과로 교통 정체시 도심부 도로의 차선별 예측 정확도가 높은 것을 확인하였다. 제안한 방법의 특징은 도로 소통 상황을 차로 단위로 예측하여 도로 소통 상황을 보다 정확하게 예측한 것이다.

▶ **주제어:** 지능형 교통시스템, 통행 시간 예측, 경로 분석, 차로 속도, 신경망

• First Author: Dong hyun Pyun, Corresponding Author: Changwoo Pyo
*Dong hyun Pyun (peterpyun@empas.com), Dept. of Computer Engineering, Graduate School, Hongik University
**Changwoo Pyo (pyo@hongik.ac.kr), Dept. of Computer Engineering, Hongik University
• Received: 2023. 01. 06, Revised: 2023. 05. 24, Accepted: 2023. 05. 24.

I. Introduction

1994년 경부고속국도에서 시범 사업으로 시작한 지능형 교통 시스템(ITS)¹은 도심 교통망으로 확대되어 다양한 실시간 교통 관련 데이터를 사용할 수 있게 되었다. 실시간 교통 데이터를 활용한 교통 상황 예측은 빅데이터 분석이 확산됨에 따라 수리적 알고리즘을 적용하여 교통 상황을 예측하는 방식으로부터 [1] 기계 학습 기반의 빅데이터 분석을 사용한 교통 상황의 예측 방식으로 발전하고 있다 [2].

도로 소통 상황을 정확히 예측하기 위해서는 도로의 흐름 상황을 링크²의 속도 하나로만 나타내는 것보다 차로 별로 세분화된 단위로 주행 상황을 추적하고 예측하는 것이 필요하다 [3],[4]. 실제 예로서 고속도로에서 합류 또는 이탈부의 교통 흐름이 나머지 부분과 다른 양상을 보이는 현상은 자주 발생한다 [5]. 이와 유사하게 도시의 교차로에서 직진, 우회전, 좌회전과 같이 주행하는 차로가 명확히 구분된 경우, 링크를 통과하는 속도는 주행 차로에 따라 다르게 나타난다 [6].

차로 각각의 주행 속도를 사용하기 위해서는 차로별 주행 속도의 상시 측정이 요구되나, 이 방법은 현재의 ITS를 세밀한 차량 추적이 가능한 장치로 보강해야 하는 비용이 소요된다. 이에 대한 대안으로 하나의 소통 속도로 링크의 소통 상황을 나타내는 ITS의 기본 틀은 유지하며 기계 학습을 사용하여 링크 속도로부터 차로별 속도를 분해하는 방식이 제시되었고, 긍정적인 결과를 보이고 있다 [3].

이 논문은 신경망을 사용하여 링크 속도로부터 직진, 좌회전, 우회전 3 개 차로에 대한 속도 예측의 정확성을 높이는 방법을 제시하고 있다. 주요 특징으로 신경망에 입력으로 주어지는 링크 속도를 수집하는 지역을 확대하였다. 또한 흐름이 다르게 관찰되는 하루 중 시간대와 주간 요일도 입력 특성 데이터³로 사용하여 차로 속도를 예측하였다.

다음의 2절과 3절은 관련 연구와 예측 정확도를 높이기 위한 학습 데이터 구성 방안을 제시하고 있으며, 4절은 학습 데이터를 생성하는 과정을 기술하고 있다. 5절은 학습된 신경망으로 실험한 결과를 분석하고 있다. 정확성의 척도로 평균 제곱근 오차(RMSE)⁴를 사용하였다.

II. Related Work

소통 상황을 예측하는 연구는 동적 선형 모델(Dynamic Linear Model)을 사용하여 교통 흐름 분석 [7], 앙상블을 사용하여 도시의 통행 속도 예측 [8], 완전 연결 네트워크(fully-connected network)의 회귀 모델(regression model)을 사용하여 도시 간선 도로의 속도 예측 [9], 다계층 k-최근접 이웃 알고리즘(multilevel k-Nearest Neighborhood algorithm)을 사용하여 교통 사고나 도로 공사 등의 돌발 상황에 대응 가능한 교통 예측 알고리즘을 개발한 [10] 사례들이 있었다.

인공 신경망을 활용한 사례는 ResNet을 사용한 통행 속도 예측 [11], RNN을 사용하여 도심부 간선 도로의 소통 상황 예측 [12], LSTM을 사용하여 시내 도로의 소통 상황 예측 [2]과 고속 도로 구간의 소통 상황을 예측 [13]한 사례, ConvLSTM을 사용하여 도로 속도 예측 [14], GNN을 사용하여 속도 예측과 인근 도로에 대한 영향력을 분석 [15]한 사례가 있다. 이외에 CNN과 LSTM을 같이 사용하여 사고 발생 시 속도를 예측한 사례도 있다 [16]. Table 1에 교통 예측 알고리즘과 모델에 대한 관련 기존 연구를 정리하였다.

Table 1. Machine learning models for predicting road conditions

Methods	Features
Dynamic Linear Model	Time series analysis for traffic flow, [7]
Ensemble model	Short-term prediction of travel speed, [8]
Regression model of fully-connected network	Traffic speed prediction, [9]
Multilevel k-Nearest Neighborhood algorithm	Traffic prediction in incident situations, [10]
ResNet	Road network traffic data prediction, [11]
RNN	Traffic congestion estimation, [12]
LSTM	Traffic speed prediction, [2] Traffic speed prediction on multiple-roads, [13]
ConvLSTM	Traffic speed, [14]
GNN	Speed prediction and analysis of nearby road causality, [15]
CNN and LSTM	Speed prediction of urban freeway, [16]

사용된 학습 데이터는 대부분이 5분 주기 링크 속도이었으나 15분 주기 링크 속도가 사용되거나 [12], 1시간 간격의 속도 데이터가 사용된 사례도 있다 [10]. 속도 데이터 이외에도 날씨, 시간, 이벤트 데이터 [13], 4개 그룹으로 구분된 요일 데이터가 사용되기도 했다 [10]. 교통사고 데이터와 기상 데이터도 교통 흐름 예측에 사용될 수 있다 [16].

1 지능형 교통 시스템: ITS, Intelligent transport systems

2 링크: 교통정보 검지 장치가 설치된 교차로를 노드라 하고, 노드와 노드 사이의 최소 거리 직진 구간을 링크라 하였다.

3 특성 데이터: feature data

4 평균 제곱근 오차: RMSE, Root mean squared error

위의 연구들은 대부분 5분 후, 10분 후, 1시간 후의 링크나 경로의 속도를 예측하거나 사고 발생 시 차로별로 속도 변화를 예측하였다 [4]. 고속도로의 교통 흐름 예측 연구는 교통량이 적을 때는 차로별 속도는 차이가 있으나 교통량이 많을 때는 큰 차이가 없다고 분석한 결과가 있고 [5], 고속도로의 합류부에서 차로별 교통류 특성을 분석한 연구도 있다 [5]. 시내부 도로에 대한 교통 흐름 예측 연구에는 교차로에 대기 차로가 있는 곳의 지체 상황 분석 [6], 고속도로에서 합류부가 있을 때 500m 구간을 100m 단위로 세분화하여 차로별 교통류 상태의 분석 [17] 사례들이 있다. 차로별 속도 예측에는 하나의 교차로에 연결되어 있는 8개 링크의 5분 주기 속도에서 주행 차로별 속도를 예측하는 연구가 있다 [3].

이와 같이 기존 연구는 도로 소통 상황을 링크의 속도 하나만으로 예측하는 한계를 보이고 있어, 본 연구에서 링크의 속도를 주행 차로별로 세분화된 단위로 예측하고자 하였다. 본 연구에서 알고리즘으로 LSTM 모델을 적용하였고, 연구 절차와 방법 및 파라미터는 Fig 1과 같다.




Fig. 1. Procedures of the proposed method

III. Consideration of input data

Fig 2의 교차로 a와 b를 연결하는 링크 L1에 대하여 직진, 좌회전, 우회전 차로별 속도를 예측하고자 한다. 예측의 정확도를 높이기 위하여 학습 데이터 구성에 있어 다음의 3가지 사항을 고려하였다.

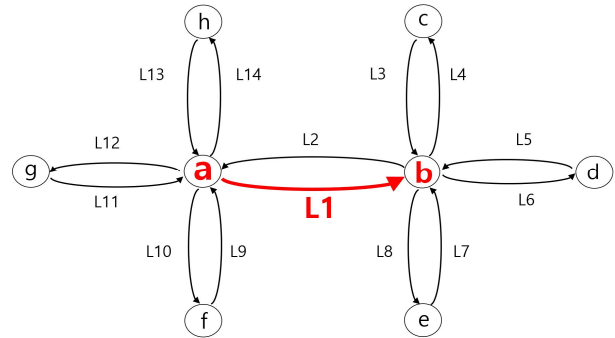


Fig. 2. Configuration of 14 links and 8 nodes

첫째, 공간 범위로 Fig. 2와 같이 링크 L1의 시점 a와 종점 b에 연결된 14개 링크를 포함하였다. 가장 최근에 제안된 방법은 노드 b에 연결된 8개의 링크 속도만 사용하였다. 링크 L1과 인접 링크에 대해서는 링크 당 5분 간격으로 차량들의 평균 주행 속도가 주어진다. 교차로를 나타내는 노드 a에 연결된 링크들은 L1으로의 진입 직후에 영향을 주는 링크들이고, b에 연결된 링크들은 L1 통과를 완료하기 직전에 진행 방향별 흐름에 영향을 주는 링크들이다.

둘째, 시간 범위로 07시~22시까지를 대상으로 하였고, 데이터 발생 시각을 특성 데이터에 포함하였다. 오전과 오후의 교통량 첨두시뿐 아니라 그사이 시간대까지 분석 대상에 포함하여 링크 속도의 변화에 대한 목표 데이터 예측의 인과성을 반영하였다. 우선, 교통량이 적을 때에는 도로의 제한 속도에 근접한 흐름이 예상되고, 교통량이 증가하면, 흐름 속도가 점차 둔화하는 현상이 발생하게 된다. 또한 하루의 매 시각마다 교통량을 관찰하면, 출근 시간대에는 교통량이 빠르게 증가하고 빠르게 감소하는 특징이 있고, 퇴근 시간대에는 출근 시간대와 비교하여 완만히 증가하고 완만히 감소하는 경향이 있다.

셋째, 요일과 휴일 유무를 특성 데이터에 포함하였다. 요일별로는 월요일과 금요일의 교통량이 다른 요일보다 많고 화요일, 수요일, 목요일은 비슷한 교통 흐름을 보인다. 토요일, 일요일, 휴일은 주중과 비교하여 다른 흐름을 보이는 특성이 있다.

IV. Construction of learning data

학습 데이터는 대구광역시 국제보상로의 서성네거리를 시점 노드 a, 공평네거리를 종점 노드 b로 하여 이에 연결된 14개의 링크로 구성된 지역에서 ITS가 수집한 링크 속도와 차량 검지 데이터를 사용하여 구성하였다. 시간적인 범위는 2021년 7월1일부터 2021년 12월31일까지 6개월

이며, 데이터 수집 시간은 매일 07:00부터 22:00까지 15 시간이다.

Table 2. Partial instance of feature data

DAY	TIME	Feature data														WEEK DAY	HOL- IDAY
		L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	L11	L12	L13	L14		
2021-07-03	7:00	17	14	21	16	24	33	22	17	48	52	32	4	41	30	7	1
2021-07-03	7:05	22	38	39	36	28	39	26	31	39	56	33	31	34	26	7	1
2021-07-03	7:10	35	34	39	23	22	28	41	22	21	34	35	26	28	25	7	1
2021-07-03	7:15	52	41	22	20	37	48	19	22	12	30	51	26	28	27	7	1
2021-07-03	7:20	23	60	20	30	38	20	24	19	38	16	44	37	31	31	7	1
2021-07-03	7:25	33	46	20	47	40	19	42	60	36	34	32	33	24	24	7	1
2021-07-03	7:30	41	45	47	32	32	23	39	23	33	28	38	28	44	24	7	1
2021-07-03	7:35	49	36	47	54	31	26	21	23	40	40	56	35	44	22	7	1
2021-07-03	7:40	5	48	25	20	33	20	3	36	60	40	37	30	45	19	7	1
2021-07-03	7:45	52	52	8	19	35	22	14	49	12	39	31	31	28	23	7	1
2021-07-03	7:50	34	36	37	43	27	32	25	38	10	44	31	49	12	32	7	1
2021-07-03	7:55	37	53	37	32	28	20	28	28	44	34	17	34	34	42	7	1
2021-07-03	8:00	44	60	25	45	36	25	33	28	48	39	33	35	29	32	7	1
2021-07-03	8:05	46	60	25	31	24	27	26	24	53	34	45	40	30	26	7	1

링크 속도 데이터는 Fig. 2에 나타난 14개 링크의 5분 주기의 속도이고 단위는 시속(km/h)이다. 시각 데이터는 하루 24시간을 0과 1 사이의 숫자로 정규화하여 07:00분 부터 21:55분까지 시각을 5분 단위 간격으로 표시하였다. 요일 데이터는 일요일부터 토요일까지 1부터 7로 표시하였고, 휴일 여부는 휴일이 아닌 날은 1, 휴일은 2로 표시하였다. Table 2는 특성 데이터의 일부를 보여 주고 있다.

목표 데이터는 5분 주기의 직진, 좌회전, 그리고 우회적 차로 속도이다. 특성 데이터의 링크 속도의 주기와 동일하게 하였다. 목표 데이터는 노드에 설치된 차량 검지기가 수집한 데이터를 사용하여 생성하였다. 차량 검지기가 수집하는 검지 데이터는 ‘차량 식별자’, ‘검지 시각’, ‘노드 식별자’로 구성되며, Fig. 2의 a, b, c, d, e 5개 노드에서 수집하였다. 차량이 검지된 위치와 시각 데이터를 사용하여 차로별 주행 속도를 추정하였다. 예를 들어 어떤 차량 x가 노드 a, b, c에서 시각 t_1 , t_2 , t_3 에 검지 되었을 때 시각 t_1 , t_2 , t_3 는 순차적이며, 각각 시각 사이의 차이가 과도하게 크지 않다면, 차량 x는 좌회전 차량임을 확인할 수 있다. 이때 링크 L1의 좌회전 차로 속도는 $(L1의 길이)/(t_2 - t_1)$ 이다.

차로별 속도는 5분 단위로 동일한 진행 방향의 속도를 평균하여 산출한다. 차로 속도를 구할 때 속도 데이터가 없는 결측치가 연속하여 1시간 이상 발생하면 그 날짜의 데이터는 모두 삭제하였다. 삭제할 때 목표 데이터뿐 아니라 해당 날짜의 특성 데이터도 같이 삭제하였다. 연속 1시간 이하의 결측치는 결측 전과 후 속도의 중간값으로 보정하여 158일에 해당하는 28,440건의 학습용 데이터를 생성했다. Table 3은 목표 데이터의 일부를 보여 주고 있다. 이렇게 생성한 입력 데이터와 목표 데이터를 사용하여 신경망을 학습시킨다.

Table 3. Partial instance of target data

DAY	TIME	Target data(lane speeds, km/h)		
		Going straight	Turning right	Turning left
2021-07-03	7:00	41	43	55
2021-07-03	7:05	56	51	55
2021-07-03	7:10	17	39	43
2021-07-03	7:15	38	28	28
2021-07-03	7:20	38	16	34
2021-07-03	7:25	41	4	40
2021-07-03	7:30	41	29	43
2021-07-03	7:35	42	37	48
2021-07-03	7:40	21	28	41
2021-07-03	7:45	24	36	29
2021-07-03	7:50	34	44	47
2021-07-03	7:55	44	51	41
2021-07-03	8:00	58	41	36
2021-07-03	8:05	51	32	30

V. Experimental results and analysis

실험에는 2계층으로 구성된 LSTM을 사용하였다. 파일럿 테스트를 시행하여 밀집 계층이 2계층일 때 오차가 최소화되는 것을 확인하였다. 실험 결과, 특성 데이터에 휴일과 요일을 포함하면 오차가 오히려 높아졌고, 포함하지 않는 것이 오차가 가장 낮았다. Table 4는 휴일과 요일을 특성 데이터에 포함한 오차와 제외한 오차를 비교하고 있다. 이후의 실험은 휴일과 요일을 제외한 특성 데이터로 실험한 결과이다.

Table 4. Comparison of RMSE according to whether holiday and day of the week are included in the feature data.

Test condition	Going straight	Turning right	Turning left
Including holidays and days of the week in feature data	5.1km/h	7.5km/h	8.3km/h
Excluding holidays and days of the week from feature data	5.0 km/h	7.4 km/h	8.2 km/h

검증용 데이터를 대상으로 링크 속도를 사용하는 경우와 차로별 속도를 사용하는 경우에 대하여 속도 오차를 비교하였다. Fig. 3에 나타난 결과를 보면, 직진 차로 속도는 오차가 6.4km/h에서 5.0km/h로 21.9% 감소하였고 우회전은 8.5km/h에서 7.4km/h로 12.9% 감소하였고 좌회전 차로는 8.7km/h에서 8.2km/h로 5.7% 감소하였다.




Fig. 3. RMSE comparison for lane speeds

직진 차로가 다른 차로보다 개선율이 매우 높은 것은 직진 차량은 교통 신호에 의해 제어되기 때문에 변동 폭이나 예측 불확실성이 우회전이나 좌회전 더 적다고 할 수 있다. 우회전의 경우 교통 신호보다도 교차로와 건물목 보행인 점유 상황이 더 큰 지배 요인으로 작동한다고 판단된다. 그러나 신호 대기 시간은 불확실하지만 짧을 수 있다. 좌회전의 경우에는 신호에 의한 제어가 이루어지지만, 신호 대기 시간이 길고, 반대 차선의 우회전 차량과 흐름의 충돌이 예측 불확실성을 크게 할 수 있다.

8개의 링크 속도만 사용하여 차로 속도를 예측한 사례 [3]와 본 연구의 결과를 비교하면 직진 차로 오차는 5.9km/h에서 5.0km/h로 감소하였고 우회전은 8.1km/h에서 7.4km/h로, 좌회전은 8.8km/h에서 8.2km/h로 감소하여 예측의 정확도가 직진은 15.3%, 우회전은 8.6%, 좌회전은 6.8% 개선되었음을 알 수 있었다.

차로별 속도 오차를 하루 단위로 추적하여 158일간의 추이를 비교하면 Fig. 4, 5, 6과 같다. 각각 직진, 우회전, 좌회전 차로의 속도 오차를 나타낸다. 파란색 선이 링크 속도를 사용한 경우 오차이고 주황색 선이 차로 속도를 사용한 경우의 오차이다. 주황색 선이 파란색 선의 아래쪽에 위치하여 오차가 감소함을 알 수 있었고, 특히 직진 차로가 오차 감소 폭이 가장 크게 나타났다.




Fig. 4. Variation of RMSE for 158 days in a straight lane




Fig. 5. Variation of RMSE for 158 days in a right turn lane




Fig. 6. Variation of RMSE for 158 days in a left turn lane

도로의 교통 흐름 상태에 따라 기계 학습을 사용한 속도 예측의 유용성 변화를 살펴보기 위해 도로 소통 상태에 따른 각 차로별 예측 속도 오차 감소율을 분석해보았다. 링크 L1의 제한 속도는 60Km/h인 점을 고려하여 40Km/h 이상의 흐름을 보일 때에는 원활 (no congestion), 20Km/h에서 40Km/h 미만은 지체 (light congestion), 20Km/h는 정체 (heavy congestion) 3가지로 구분하였다. 각 소통 상태에 대하여 차로별 오차 감소율을 분석하여 Fig 7, Fig 8, Fig 9에 나타냈다. 각각 직진 차로, 우회전 차로, 좌회전 차로의 오차 감소율을 나타낸다. 정체일 때 직진 차로는 5.56km/h에서 3.51km/h로, 우회전 차로가 6.05km/h에서 5.36km/h로, 좌회전 차로가 7.10km/h에서 6.34km/h로 감소하였고, 지체일 때 직진 차로는 7.13km/h에서 5.90km/h로, 우회전 차로가 10.02km/h에서 8.79km/h로, 좌회전 차로가 10.48km/h에서 9.91km/h로 감소하였고, 원활할 때는 직진 차로가 8.90km/h에서 7.81km/h로, 우회전 차로가 16.89km/h에서 11.17km/h로, 좌회전 차로가 13.20km/h에서 12.37km/h로 감소하여 교통 흐름이 정체일 때 오차 값 자체가 절대적으로 작았다. 우회전 차로가 교통 흐름이 원활할 때 정확도 개선율이 높은 것은 다른 차로에 비해 신

호등의 영향을 덜 받고, 교통 흐름이 원활할 때 직진 차로로부터 영향을 비교적 덜 받기 때문에 예상된다. 그리고 원활할 때 각 차로 모두 오차값이 큰 이유는 고속도로의 경우는 교통량이 적으면 대부분 규정 속도 범주에서 주행하지만, 도심의 경우는 규정 속도보다 운전자의 상황에 맞춰 주행하는 경향이 많아 오차가 큰 것으로 생각된다.




Fig. 7. RMSE of straight lane according to traffic congestion




Fig. 8. RMSE of right turn lane according to traffic congestion




Fig. 9. RMSE of left turn lane according to traffic congestion

VI. Conclusion

신경망을 활용하여 링크 속도에서 차로별 속도를 분리 예측하면 링크 전체의 평균 속도를 사용할 때보다 정확도가 개선되었음을 신경망 학습 실험을 통해 확인하였다. 이 연구가 달성한 예측 오차는 직진 5.0Km/h, 우회전 7.4Km/h, 좌회전 8.2Km/h이며, 이는 해당 차로 별로 각각 21.9%, 12.9%, 5.7% 개선에 해당한다. 또한 교통 흐름의 정도에 따라 차로별 오차를 분석한 결과는 정체일 때 직진 차로가 5.56km/h에서 3.51km/h로, 우회전 차로가 6.05km/h에서 5.36km/h로, 좌회전 차로가 7.10km/h에서 6.34km/h로 감소하였고, 원활할 때는 직진 차로가 8.90km/h에서 7.81km/h로, 우회전 차로가 16.89km/h에서 11.17km/h로, 좌회전 차로가 13.20km/h에서 12.37km/h로 감소하여 교통 흐름이 정체일 때 오차 값 자체가 절대적으로 작았다. 원활할 때 오차값이 큰 이유는 고속도로의 경우는 교통량이 적으면 대부분 규정 속도 범주에서 주행하지만, 도심의 경우는 규정 속도보다 운전자의 상황에 맞춰 주행하는 경향이 많아 오차가 큰 것으로 생각된다.

신호제어기의 방향별 신호 표출 시간 데이터를 반영하면 차로별 속도 예측의 정확도를 높일 수 있을 것으로 예상된다. 또한 결측 데이터의 빈도를 줄이기 위한 차량 검지기 개선도 예측 정확도 개선에 기여할 것으로 예상된다.

REFERENCES

- [1] Yeonsoo Kang and Beomcheol Cho and Beomil Kim, "Dynamic Path Finding System using Travel Time Prediction," Proceedings of The Korea Institute of Intelligent Transport Systems, pp 154-162, Fall 2004
- [2] Youngchan Kim and Junwon Kim and Yohee Han and Jongjun Kim and Jewoong Hwang, "Development of Traffic Speed Prediction Model Reflecting Spatio-temporal Impact based on Deep Neural Network," Vol.19, No.1, pp.1-16, February 2020, DOI: 10.12815/kits.2020.19.1.1
- [3] Dong hyun Pyun and Changwoo Pyo, "Predicting lane speeds from link speeds by using neural networks," Journal of The Korea Society of Computer and Information, Vol. 27 No. 8, pp. 69 - 75(6 pages), August 2022. <https://doi.org/10.9708/jksci.2022.27.08.069>
- [4] Hee-Sub Rim and Cheol Oh and Kyeong-Pyo Kang, "A Novel Method for Estimating Representative Section Travel Times Using Individual Vehicle Trajectory Data," J. Korea Inst. Intell. Transp.

- Syst., Vol.8 No.6, pp.23~35, December 2009
- [5] Hwangseong Lee and Jangbae Park, "Traffic State predictability analysis by lane based on vehicle trajectory data," Proceedings of the KOR-KST Conference, pp662-666 (6 pages), 2021.11
- [6] Do Hoon Kim and Tae Ho Kim, "Development of Travel Speed Prediction Model based on Urban Traffic Information System," The Seoul Institute, Vol.18 No.3, pp101-112(12 pages), September 2017,
- [7] Kim Hong Geun and Park Chul Young and Shin Chang Sun and Cho Yong Yun and Park Jang Woo, "Time Series Analysis for Traffic Flow Using Dynamic Linear Model," KIPS Tr. Comp. and Comm. Sys., Vol.6, No.4, pp.179~188, June 2017. DOI: 10.3745/KTCCS.2017.6.4.179
- [8] Kim, Eui-Jin and Kim, Dong-Kyu, "Short-term Prediction of Travel Speed in Urban Areas Using an Ensemble Empirical Mode Decomposition," JOURNAL OF THE KOREAN SOCIETY OF CIVIL ENGINEERS 38(4), pp579-586(8 pages), August 2018,
- [9] Namhyuk Kim and Junho Song and Sunghwan Park and Sang-wook Kim, "Traffic Speed Prediction Based on Deep Learning," The Korean Institute of Information Scientists and Engineers, pp 166-168(3 pages), 166-168(3 pages), Jeju, South Korea, June 2019
- [10] Yeeun Kim and Sunghoon Kim and Hwasoo Yeo, "A Study on Traffic Prediction Using Hybrid Approach of Machine Learning and Simulation Techniques," The Korea Institute of Intelligent Transport Systems, Vol 20, No 5, pp 100~112(13 pages), October 2021, DOI:https://doi.org/10.12815/kits.2021.20.5.100
- [11] Jeon, Seung Bae and Muhammad Sarfraz Khan and Lee, Jung Hwan and Jeong, Myeong Hun, "Road Network Traffic Data Prediction Using ResNet," Journal of Korean Society for Geospatial Information Science Vol. No.2, pp75-84 (10pages), June 2021, DOI: 10.7319/kogsis.2021.29.2.075
- [12] Hee jin Jung and Jin su Yoon and Sang hoon Bae, "Traffic Congestion Estimation by Adopting Recurrent Neural Network," J. Korea Inst. Intell. Transp. Syst., Vol.16 No.6, pp.67~78, December 2017. DOI: 10.12815/kits. 2017.16.6.67
- [13] Jiwon Son and Junho Song and Namhyuk Kim and Taeheon Kim and Sunghwan Park and Sang-wook Kim, "A Deep Learning Based Traffic Speed Prediction on Multiple-Roads," Proceedings of the online fall academic conference 2020, 27(2), November 2020,
- [14] Gwondong Lee and Seok-Hee Lee and Ariunerdene Nyamdavaa and Seokil Song, "Prediction Method for Traffic Speed based on ConvLSTM," Journal of KIIT. Vol. 19, No. 12, pp. 27-33, December 2021, DOI: 10.14801/jkiit.2021.19.12.27
- [15] Yoo Jin Kim and Young Yoon, "Speed Prediction and Analysis of Nearby Road Causality Using Explainable Deep Graph Neural Network," Journal of The Korea Convergence Society, Vol. 13. No. 1, pp.51-62, January 2022. DOI: 10.15207/JKCS.2022.13.01.051
- [16] Boogi Park and Sang hoon Bae and Bokyoung Jung, "Speed Prediction of Urban Freeway Using LSTM and CNN-LSTM Neural Network," J. Korea Inst. Intell. Transp. Syst., Vol.20 No.1(2021), pp.86~99, February 2021, DOI: 10.12815/kits.
- [17] Jiyoung Hwang and Byeongjun Ro and Hwansu ryu, "Asymmetric long time traffic speed prediction using Graph Multi-Attention algorithm," Proceedings of the KOR-KST Conference, pp378-383(7 pages), November 2021.

Authors



Dong hyun Pyun received his B.S.E.in computer engineering in 1992 from Myung-Ji University, Yong-In, Korea and M.S. in computer science in 1994 from Hong-Ik University, Seoul, Korea.

He was a research fellow in the KIA Information Systems in 1994. He has been Software developer at the Department of Intelligent Transport Systems, POSDATA, Korea in 2002. He has been Project Manager at the Department of Intelligent Transport Systems, SK C&C, Korea in 2006. His research interests AI for Intelligent Transport Systems.



Changwoo Pyo was born in Seoul, Korea in 1957. He received his B.S.E. in electronics engineering in 1980 and M.S. in computer engineering in 1982 from Seoul National University, Seoul, Korea, and Ph.D. in

computer science from the University of Illinois at Urbana-Champaign, IL, USA, in 1989. He was a research fellow in the US Army Corps of Engineers from 1989 until 1991. Since then, He has been a professor at the Department of Computer Engineering, Hongik University, Seoul, Korea. His research interests include program analysis and translation for self-protection, program hardening, and machine learning-based program security.