

Predicting lane speeds from link speeds by using neural networks

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, a method for predicting the speed for each lane from the link speed using an artificial neural network is presented to increase the accuracy of predicting the required time of a driving route. The time required for passing through a link is observed differently depending on the direction of going straight, turning right, or turning left at the intersection of the end of the link. Therefore, it is necessary to predict the speed according to the vehicle's traveling direction. Data required for learning and verification were constructed by refining the data measured at the Gongpyeong intersection of Gukchaebosang-ro in Daegu Metropolitan City and four adjacent intersections around it. Five neural network models were used. In addition, error analysis of the prediction was performed to select a neural network experimentally suitable for the research purpose. Experimental results showed that the error in the estimation of the time required for each lane decreased by 17.4% for the straight lane, 4.4% for the right-turn lane, and 3.9% for the left-turn lane. This experiment is the result of analyzing only one link. If the entire pathway is tested, the effect is expected to be greater.

▶ **Key words:** ITS, estimate the transit time, AI, route analysis, lane speeds

[요 약]

본 논문에서는 주행 경로의 소요 시간 예측의 정확도를 높이기 위해 인공 신경망을 사용하여 링크 속도로부터 각 차로 별 속도를 예측하는 방법을 제시하였다. 링크를 통과하는 차량의 소요 시간은 해당 링크 끝의 교차로에서 직진하거나 우회전하거나 좌회전하는 방향에 따라 링크를 지나가는 소요 시간이 다르게 관찰된다. 따라서, 차량의 진행 방향에 따라 속도를 예측하는 것이 필요하다. 대구광역시 국채보상로의 공평네거리와 이를 중심으로 인접한 4개 교차로에서 측정한 데이터를 정제하여 학습과 검증에 필요한 데이터를 구성하였고, 5개의 신경망 모델을 사용하였다. 또한 예측 결과의 오류 분석을 수행하여 연구 목적에 적합한 신경망을 실험적으로 선별하였다. 실험 결과, 각 차로 별 소요 시간 예측에 대한 오차가 직진 차로는 17.4%, 우회전 차로는 4.4%, 좌회전 차로는 3.9% 감소하였다. 이 결과는 링크 하나의 분석 결과로 경로 전체를 대상으로 한다면 효과는 더욱 커질 것으로 예상된다.

▶ **주제어:** 지능형 교통시스템, 교통 상황 예측, 인공지능, 경로 분석, 차로 별 속도

-
- 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: 2022. 08. 04, Revised: 2022. 08. 29, Accepted: 2022. 08. 29.

I. Introduction

지능형 교통 시스템(ITS)¹⁾ 구축 사업은 1994년 경부고속국도의 ITS 시범 사업과 과천시 ITS 시범 사업을 시작으로 서울시, 전주시, 대전시, 제주시를 포함하여 전국 여러 주요 도시로 점차 확장 구축되었다. 2002년 월드컵 개최 시기에 맞추어 각 지방 주요 도시에서 ITS 시스템을 구축하여 효율적인 교통 관제와 실시간 교통 정보 서비스로 시민들에게 실질적인 편의를 제공하였다. 점차 서비스를 확대하여 과거 데이터를 분석하여 명절과 휴가 기간에 빠른 길 찾기 서비스와 같은 생활 밀착형 서비스도 제공하기 시작했다. 2007년에는 ITS의 한 분야로 하이패스²⁾가 전국 고속도로에 개통되었으며, 2008년부터는 해외 진출이 시작되어 아제르바이잔과 몽골에 ITS 시스템을 수출하였다.

2010년대에는 기계 학습 기술이 발전하면서 ITS 시스템의 누적된 데이터를 활용하여 소통 상황을 예측하는 연구가 점차 확산되어 실제로 서울시 교통정보시스템(TOPIS)³⁾에서 도시고속도로의 예측 정보를 제공하고 있다. 소통 상황 예측에 대한 연구는 예측 시간에 따라 1시간 이내의 단기 예측과 1시간 이상의 장기 예측이 있고, 도로의 유형에 따라 교차로가 없이 흐름이 연속된 도로의 연속류 예측과 교차로가 있어 흐름이 끊어지는 도로에 대한 단속류 예측이 있다. 사고나 돌발 상황 유무에 따라 정상 상태의 예측과 돌발 상황 발생시 예측과 같이 다양한 상황에서 연구가 활발하게 이루어지고 있다.

교통 정보 검지 장치가 설치된 교차로를 노드라 하며, 노드와 노드 사이의 최소 거리 직진 구간을 링크라 한다. 도로의 교통 흐름 상황은 링크 속도로 나타낸다. 링크 속도는 링크를 통과하는 차량의 평균 속도에 요일 별, 시간대 별 통행 패턴을 감안한 해당 링크의 대표 속도이다. 대부분의 지방자치단체들이 운영하는 ITS 시스템은 5분 주기로 링크 속도를 산출하여 공공용으로 제공하고, 필요한 경우 그 이상의 주기로 변환하여 연구와 개발에 활용하기도 하였다[2],[3].

도로에서 차량 통행을 보면 동일한 링크일지라도 링크 끝의 교차로에서 직진하거나 우회전하거나 좌회전하는 방향에 따라 링크를 지나가는 소요 시간이 다르게 관찰된다. 예로써, 대구광역시 국제보상로에서 거리가 약1.4km인 링

크의 경우 2021년 11월 11일, 오전 11:30분부터 11:35분까지 링크 속도는 22km/h이었는데, 이 링크를 통과하는 목적에 따라 차로 별 속도를 측정한 결과 직진 차로로 통과한 차량들의 속도는 24km/h, 우회전 차로는 17km/h, 좌회전 차로는 20km/h이었다. 우회전의 경우와 같이 시속 5km/h차이는 실제 속도 대비 오차가 29%로 링크 속도만으로 예상 주행을 예측할 때에는 감내 수준을 벗어날 수 있다.

본 연구는 링크 주행 시 소요 시간 예측의 정확도를 높이기 위해 인공 신경망을 사용하여 링크 속도로부터 차로 별 속도를 예측하는 방법을 제시하였다. 학습 데이터는 특징 데이터와 목표 데이터로 구성되는데, 특징 데이터는 ITS 시스템이 공공용으로 제공하는 링크 속도를 받아서 정제하여 생성하였고, 목표 데이터는 ITS 시스템이 수집한 차량 검지 데이터를 받아서 정제 및 가공하여 생성하였다. 이렇게 생성한 학습 데이터 중 80%는 훈련용으로, 나머지 20%는 검증용으로 하여 LSTM, RNN, CNN, 다항회귀모델, 선형 회귀 모델을 사용한 예측 결과의 오차를 평균제곱근오차(RMSE)⁴⁾로 나타내었다.

2장에서 기계 학습을 활용한 기존의 링크 속도 예측과 링크 단위보다 세부 수준에서 연구를 시도한 사례를 소개하였고, 3장에서 ITS 시스템에서 받은 원천 데이터로부터 학습용 데이터를 생성하는 작업을 기술하였다. 4장에서 각 인공 신경망 모델로 실험한 결과를 3가지로 비교 분석하였는데, 첫번째는 각 인공 신경망 모델 별로 실험한 결과를 분석하였고, 두번째는 오차가 가장 낮은 LSTM 모델에서 훈련용과 검증용 데이터의 오차를 비교하였고, 세 번째는 LSTM 모델에서 직진, 우회전, 좌회전하는 차량이 2개 링크를 통과하는 소요 시간을 비교하였다.

II. Related Work

도로의 소통 정보가 빅데이터로 누적되고 인공 신경망 기술로 교통 소통 상황을 예측하는 연구가 많이 진행되었다[4],[12],[13]. 링크 속도를 '직진 차로의 소통 정보'로 가정한 연구가 있었고[4],[5], 연속류의 경우 경부고속도로의 10개 구간을 예측하는 연구가 있었고[16], 단속류의 경우

1) ITS: Intelligent transport systems

2) 하이패스: 고속도로와 유료도로의 통행료를 정찰할 필요 없이 무선 통신으로 지불하는 시스템

3) TOPIS: Transport operation & information service

4) RMSE: Root mean squared error, 평균제곱근오차

교차로를 중심으로 교차로에 들어오는 구간들의 속도를 예측하여 혼잡도를 산출한 후 신호제어에 활용하는 연구가 있었다[17].

Table 1. Artificial neural network models used in related papers

Using Models	Related Paper and Prediction
Linear	[1], Time Series Analysis for Traffic Flow
CNN	[13], Road Network Traffic Data Prediction
RNN	[2], Traffic Congestion Estimation
LSTM	[3], Road Traffic Speed Prediction [5], Development of Traffic Speed Prediction
GNN	[4], Speed Prediction and Analysis of Nearby Road Causality [6], Traffic Speed Prediction [12], Asymmetric long time traffic speed prediction
LSTM + CNN, RNN	[7], Prediction Method for Traffic Speed [8], Speed Prediction of Urban Freeway [15], Prediction of urban traffic congestion

각 연구에서 사용한 인공 신경망 모델을 정리하면 Table 1과 같이 선형 모델을 사용한 연구[1]와 CNN 모델과 RNN 모델을 사용하는 연구가 있었으며[2], 과거의 소통 상황과 주변 링크의 소통 상황에 의미를 두면서 LSTM 모델을 사용한 연구[3]와 GNN 모델을 사용하는 연구도 있었다[4]. 대상 도로 측면에서 단속류의 소통 상황 예측에 대한 연구가 많았고[4],[5],[6],[7], 연속류는 소통 상황과 돌발 상황을 연계한 연구가 있었다[8]. 집계 주기 측면에서 5분 주기가 대부분이었고 그 이하는 찾아보기 어려웠다. 지자체 혹은 공공기관에서 산출한 5분단위 구간 소통 정보를 가공하여 사용하거나[5],[6],[7],[16],[18],[19], 다양한 수집원으로 차량의 이동 정보를 수집할 지라도 5분 혹은 5분 이상 단위의 링크 속도로 변환하여 연구를 해왔다 [2],[3],[4],[8]. 소통 상황을 산출하고 예측하는 단위는 대부분 링크 속도로 소통 상황이나 소요 시간을 분석하고 예측하였다[2],[3],[4],[8].

링크 속도를 더 세분화하여 예측하는 측면에서 [9]는 연속류에서 사고가 발생했을 때 사고 지점 상류부에서 각 차로별로 차량 속도가 어떻게 변화하는지 연구하였고, [10]은 교차로에서 우회전 전용차로와 좌회전 전용차로가 있는 경우 통행속도가 감소한다는 연구를 하였고, [11]은 고속도로에서 진입부 혹은 합류부가 있을 때 500m구간을 100m단위로 세분화하여 각 차로의 교통류 상태 예측을 연구하였다. 연속류에서 진출입 차량의 영향이 발생하는

IC, JC 부근과 같은 램프 구간은 본선부와는 다른 양상이 있다고 언급하거나[20], 연속류에서 진입램프가 있는 경우 본선의 교통 상황이 영향을 받는 정도를 차선별로 예측하기도 하였다[11].

III. Composition of learning data

본 연구에서 사용하는 원천 데이터는 링크 속도 데이터와 차량 검지 데이터이다. 링크 속도 데이터는 Fig. 1에 나타난 8개 링크에 대해 매 5분 단위 속도를 저장하고 있으며, 저장된 데이터가 정확한지 검사하고 특성 값 중 하나라도 누락된 불완전한 데이터가 있으면 제거하는 정제 과정을 거친 후, 별다른 가공 작업 없이 특징 데이터로 사용한다.




Fig. 1. Experimental intersection

차량 검지 데이터는 목표 데이터인 차로별 속도 데이터를 만들기 위한 원천 데이터이다. 이 데이터는 노드에 설치된 노변 검지기(RSE)⁵⁾가 수집한 벡터 데이터로 차량 식별자, 검지 시각, 노드 식별자의 3원소로 구성된다. RSE는 모든 차량을 인식하지는 못하고 차내단말기(OBU)⁶⁾를 장착한 차량만 검지 한다. 현재 사용되고 있는 OBU는 하이패스 단말기이다. Fig. 1에 나타난 5개의 노드에서 받은 차량 검지 데이터에서 5분 단위로 링크의 직진, 우회전, 좌회전 3개의 차로별 속도를 계산하여 목표 데이터를 생성한다. 다음은 차량 검지 데이터를 목표 데이터인 차로별 속도 데이터로 가공하는 작업을 서술하였다.

차량 검지 데이터의 수집 범위는 공간적으로 대구광역시 국제보상로의 공평네거리와 공평네거리 노드를 중심으로 인접한 4개 노드로 구성된 지역으로서 Fig. 1과 같고 시간적으로 2021년 5월부터 2021년 12월까지 245일을 대

5) RSE: Road side equipment

6) OBU: On-board unit

상으로 하였고, 차량 데이터 수집 시간은 매일 10시간으로 오전 오후 통행량 첨두시를 포함한 07시부터 12시, 16시부터 21시이다.

수집한 차량 검지 데이터에서 사전 작업으로 5개 노드의 검지 데이터에서 특정 값 중 하나라도 누락된 불완전한 데이터가 있으면 제거한 후, 검지 시간 순으로 데이터를 정렬한다.

정렬한 차량 검지 데이터에서 각 링크마다 주행한 차량을 추적하여 개별 차량들에 대한 링크의 통행 속도 정보를 추출한다. 추출한 데이터는 주행한 링크ID, 차량ID, 주행 시간, 통행 속도, 진행 차로 방향으로 구성된다. 시간 순서로 정렬된 검지 데이터로부터 차량의 ID와 통과 노드를 순차적으로 검색하여 해당 차량의 주행 차로와 통과 시간을 계산한다. 제한 속도의 1.6배를 초과하거나 3km/h 이하로 흐름과 무관하게 저속으로 주행한 차량의 데이터는 불연속적 주행 또는 RSE의 오작동으로 간주하여 사용하지 않았다. 소통과 무관하게 장시간 정차하였거나, 이면 우회도로를 사용한 경우 지나치게 낮은 속도의 주행으로 관측되기 때문이다.

다음은 가공의 마지막 단계인 주행 차로 데이터에서 각 링크에 대해 5분 단위로 차로별 속도를 구하는 단계이다. 2개 링크를 지나는 차량에 대하여 링크ab의 평균 속도를 계산하여 해당 주행 차로에 대한 차로별 속도를 구한다. 예를 들어 5분 동안 링크ab를 통과하여 노드 e까지 도달한 차량의 링크ab를 통과한 평균 속도가 링크ab의 우회전 차로 속도이다.

5분 단위로 그룹핑하는 과정에서 데이터가 없는 시간대, 즉 결측치가 발생할 경우 연속하여 3시간 이상의 결측치가 발생하면 그 날짜의 데이터는 모두 삭제하였고⁷⁾, 연속 3시간 이하의 결측치는 전후의 데이터로 보정하여 195일에 해당하는 23,400건의 학습용 데이터를 생성했다. 이 중 80%인 156일간 데이터는 훈련용, 20%인 39일간 데이터는 검증용으로 설정했다.

학습 데이터의 특징 데이터는 링크 속도 데이터이고, 목

표 데이터는 차로별 속도 데이터이다. Table 2는 학습 데이터의 예를 보여 주고 있다.

Table 2. Link speeds and lane speeds from 07:00 to 08:00 on May 2, 2021

day	time	feature data (link speeds, km/h)								target data (lane speeds, km/h)		
		ab	ba	bc	cb	bd	db	be	eb	going straight	turning right	turning left
2021-05-02	7:00	39	53	38	23	32	33	31	17	25	35	46
2021-05-02	7:05	36	51	32	22	27	32	31	16	25	32	51
2021-05-02	7:10	37	52	36	19	30	33	32	17	47	29	57
2021-05-02	7:15	36	52	46	19	23	33	34	17	36	26	62
2021-05-02	7:20	36	52	40	17	24	33	27	22	29	23	36
2021-05-02	7:25	36	51	46	21	29	32	25	20	24	20	30
2021-05-02	7:30	35	53	45	19	28	32	28	23	35	21	23
2021-05-02	7:35	31	53	40	19	26	33	31	22	25	21	17
2021-05-02	7:40	33	54	35	21	28	32	31	24	31	27	59
2021-05-02	7:45	34	55	34	24	28	32	34	24	25	26	25
2021-05-02	7:50	36	50	35	20	29	32	30	19	42	25	35
2021-05-02	7:55	34	43	33	19	27	33	26	18	31	24	45
2021-05-02	8:00	35	39	33	22	25	33	30	20	42	22	55

IV. Experimental results and analysis

본 연구에서 차로별 속도 예측 실험은 링크ab를 대상으로 하였다. 따라서 신경망 학습을 위한 특징 데이터는 링크ab를 포함한 8개의 주변 링크에 대한 링크 속도이고, 목표 데이터는 링크ab의 직진, 우회전, 좌회전에 대한 차로별 속도이다. 실험에 사용한 신경망 모델은 선형회귀, 다항회귀, CNN, RNN, LSTM이다. 각 모델 학습 시 특징 데이터와 목표 데이터 입력 순서는 시간 순서로 시계열⁸⁾로 하였고, 활성화 함수는 CNN은 relu⁹⁾, RNN은 tanh¹⁰⁾, LSTM은 tanh-relu¹¹⁾를 사용하였고, RNN과 LSTM에서 윈도우 크기는 하루 5시간 단위인 60¹²⁾으로 설정하여 실험하였다. 실험 결과를 다음과 같이 3가지로 비교 분석하였다.

첫번째는 각 인공 신경망 모델 별로 실험한 결과이다. 각 모델을 주행 차로 별로 실험하여 목표 데이터의 차로별 속도와 예측한 차로별 속도의 오차를 비교하였다. Fig. 2는 훈련을 마친 각 모델에 검증용 데이터를 입력하여 예측한 직진, 우회전, 좌회전 차로의 오차이다. 실험 결과, 적

7) 해당 날짜의 데이터를 모두 삭제하므로 데이터 중간 중간에 없는 날짜가 있을 수 있으며, 목표 데이터에서 데이터를 삭제하면 특징 데이터도 같은 시간대의 데이터를 삭제하였다.

8) 파일럿 테스트에서 랜덤 입력과 시계열 입력을 사전 시험한 결과 시계열 입력이 오차가 작아, 본 실험에서 시계열 입력 방법을 사용했다.

9) 파일럿 테스트에서 tanh와 relu를 비교한 결과 근소하게 relu함수가 오차가 작았다.

10) 파일럿 테스트에서 tanh와 relu를 비교한 결과 직진은 relu함수가, 우회전과 좌회전은 tanh함수가 아주 근소하게 작았다.

11) 파일럿 테스트에서 tanh-relu함수가 다른 함수보다 근소하게 오차가 작았다.

12) 윈도우 크기를 오전, 오후 단위로 5시간의 데이터 크기인 60으로 하는 방법과 하루 단위로 10시간의 데이터 크기인 120으로 하는 방법을 파일럿 테스트에서 비교한 결과 60으로 설정할 경우 오차가 근소하게 작았다.

용 모델 중에서 LSTM이 예측 오차가 가장 작아 본 연구에 인공 신경망을 적용하는 것이 적합함을 알 수 있었다.




Fig. 2. RMSE of lane speeds in each model

두번째는 예측 결과가 가장 좋았던 LSTM 모델에서 훈련용 데이터의 오차와 검증용 데이터의 오차를 비교하였다. 비교 결과 Fig. 3과 같이 훈련용보다 검증용 데이터의 예측 오차가 직진은 0.3 낮아져 약 4.8% 감소하였고, 우회전은 0.4 낮아져서 약 4.7% 감소하였고, 좌회전은 0.8 낮아져 약 8.3% 감소하였다. 첫번째 분석과 같이 본 연구에 인공 신경망을 적용하는 것이 적합함을 알 수 있었다.




Fig. 3. RMSE between training data and validation data

세번째는 LSTM 모델에서 직진, 우회전, 좌회전하는 차량이 각 방향 별로 2개 링크를 통과하는 소요 시간을 비교하였다. 이때 소요 시간의 단위는 초이며 직진 소요 시간은 링크ab,bd를 통과하는 시간, 우회전 소요 시간은 링크 ab,be를 통과하는 시간, 좌회전 소요 시간은 링크ab,bc를 통과하는 시간을 의미한다. 링크 속도를 사용한 소요 시간과 차로별 속도를 사용한 소요 시간을 구하여 각각 측정된 소요 시간과 오차를 RMSE로 나타내었다. RMSE는 학습 데이터를 하루 단위로 산출하여 195일의 RMSE를 표시하였다. 직진 차로는 Fig. 4, 우회전 차로는 Fig. 5, 좌회전 차로는 Fig. 6에서 보여주고 있다. 직진 차로는 다소 안정적이거나 우회전과 좌회전은 분산된 모습을 가지고 있었다.

마지막으로 검증용 데이터에 대해 차로별 속도를 사용할 경우, 각 차로별 RMSE 감소율을 Table 3에 표시하였다. 직진 차로는 소요 시간의 오차가 94초에서 77초로 감소하였고, 우회전 차로 소요시간은 189초에서 180초로 감소하였고, 좌회전 차로 소요시간은 154초에서 148초로 감소하였다.

따라서 본 연구의 방법을 사용할 경우, 링크 속도를 사용하는 것보다 직진 소요 시간은 오차가 17.4% 감소하고 우회전은 4.4%, 좌회전은 3.9% 감소함을 알 수 있었다. 이 결과는 하나의 링크를 분석한 경우이며, 링크가 여러 개인 경로 전체를 대상으로 한다면 효과가 링크의 개수만큼 증폭될 것으로 예상된다.




Fig. 4. RMSE of time of going straight




Fig. 5. RMSE of time of turning right




Fig. 6. RMSE of time of turning left

Table 3. RMSE between link speeds and lane speeds

RMSE	Going straight time	Turning right time	Turning left time
Using link speeds	94 seconds	189 seconds	154 seconds
Using lane speeds	77 seconds	180 seconds	148 seconds
Reduction rate	17.4%	4.4%	3.9%

V. Conclusions

일반적으로 동일한 링크에서도 주행 차로에 따라 소요 시간이 다르게 나타난다. 본 연구는 인공 신경망을 활용하여 소요 시간을 주행 차로별로 구분하여 예측하여 오차가 직진 차로는 17.4%, 우회전은 4.4%, 좌회전은 3.9% 감소하였다. 이 효과는 링크 하나를 분석한 것으로 경로 전체를 분석하거나, 시내 전체를 대상으로 할 경우 효용성은 더욱 커질 것으로 예상된다.

향후 연구의 효용성을 높이려면 예측 오차를 줄이고, 실시간 단위로 예측하는 것이 필요하다. 이를 위해 원천 데이터의 품질이 높아져야 하는데, 개선 사항으로는 첫째 검지 수단을 보완하여 단위 주기당 검지하는 차량 데이터의 개수를 지금보다 현저히 늘려야 할 것으로 보인다. 본 연구는 하이패스 단말기를 장착한 차량만 검지하므로 통행 차량을 모두 검지하는 것이 아니어서 전체 차량을 검지하면 오차율이 더욱 낮아질 것으로 예상된다. 둘째는 검지기를 교차로 지점에 설치할 것이 아니라, 링크의 양끝의 진입, 진출을 모두 파악하도록 링크 당 2개의 검지기를 설치하면 회전 유무와 회전시 교차로에서 지체 시간을 더욱 빠르고 정확하게 반영할 수 있을 것이다. 후속 연구로 좌회전 차로에서 신호 시스템을 연계하는 연구가 필요할 것으로 예상된다.

REFERENCES

- [1] 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
- [2] 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
- [3] Jeon, Seung Bae and Oh, Haeng Yeol and Lee, Tae Young and Kim, Gun, Jeong and Myeong-Hun "Road Traffic Speed Prediction Using LSTM Recurrent Neural Network," KOREAN SOCIETY OF CIVIL ENGINEERS, pp434-435 (2 pages), October 2020.
- [4] 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
- [5] 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
- [6] Sunghoon Kim and Jonghyuk Park and Yerim Choi, "Traffic Speed Prediction Based on Graph Neural Networks for Intelligent Transportation System," J. Korea Inst. Intell. Transp. Syst., Vol.20 No.1, pp.70~85, February 2021, DOI: 10.12815/kits.2021.20.1.70
- [7] 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
- [8] Boogi Park and Sang hoon Bae and Bokyung 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. 2021.20.1.86
- [9] 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
- [10] 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,
- [11] 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
- [12] 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.
- [13] 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

- [14] Dongmin Kim and Suseong Chae and Hojin Kang and Gitae Jang, "Deep learning-based prediction of the travel speed for short term on an arterial road," Proceedings of the KOR-KST Conference, pp571-576(7 pages), November 2021,
- [15] Huijin Jeong and Jinseok Seo and Hongsek Lee, "Prediction of urban traffic congestion through LSTM-RNN model," Proceedings of the KOR-KST Conference, pp64-69(7 pages), February 2019,
- [16] 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,
- [17] Jionseok Seo and Huijin Jeong and Hongseok Lee, "Development of traffic congestion prediction and signal control solution based on deep learning," Proceedings of the KOR-KST Conference, pp70-75(7 pages), February 2019.
- [18] 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,
- [19] Young-Jung Yu and Sang-Ho Moon and Seong-Ho Park, "Analysis of KNN Algorithm for Speed Prediction in Urban Roads," Asia-pacific Journal of Multimedia Services Convergent with Art, Humanities, and Sociology Vol.7, No.2, pp245-253, February 2017, DOI: 10.14257/AJMAHS.2017.02.0

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.