

효율적인 교통 체계 구축을 위한 Conv-LSTM기반 사거리 모델링 및 교통 체증 예측 알고리즘 연구

이승용* · 서부원* · 박승민**

Conv-LSTM-based Range Modeling and Traffic Congestion Prediction Algorithm
for the Efficient Transportation System

Seung-Young Lee* · Boo-Won Seo* · Seung-Min Park**

요약

인공 지능이 발전함에 따라 예측 시스템은 우리의 삶에 필수적인 기술 중 하나로 자리를 잡았다. 이러한 기술의 성장에도 불구하고, 21세기 사거리 교통 체증은 계속해서 문제 되어 왔다. 본 논문에서는 Conv-LSTM(Convolutional-Long Short-Term Memory) 알고리즘을 이용한 사거리 교통 체증 예측 시스템을 제안한다. 제안한 시스템은 교통 체증이 발생하는 사거리에 시간대별 교통 정보를 학습한 데이터를 모델링 한다. 시간의 흐름에 따라 기록된 교통량 데이터로 교통 체증을 예측하며, 예측된 결과를 기반으로 사거리 교통 신호를 제어하고, 일정한 교통량으로 유지한다. VDS(Vehicle Detection System)센서를 활용하여 도로 혼잡도 데이터를 정의하고, 교통을 원활하게 하기 위하여 각각의 교차로를 Conv-LSTM 알고리즘기반 네트워크 시스템으로 구성하였다.

ABSTRACT

With the development of artificial intelligence, the prediction system has become one of the essential technologies in our lives. Despite the growth of these technologies, traffic congestion at intersections in the 21st century has continued to be a problem. This paper proposes a system that predicts intersection traffic jams using a Convolutional LSTM (Conv-LSTM) algorithm. The proposed system models data obtained by learning traffic information by time zone at the intersection where traffic congestion occurs. Traffic congestion is predicted with traffic volume data recorded over time. Based on the predicted result, the intersection traffic signal is controlled and maintained at a constant traffic volume. Road congestion data was defined using VDS sensors, and each intersection was configured with a Conv-LSTM algorithm-based network system to facilitate traffic.

키워드

Convolutional long and short term memory, Vehicle Detection Systems, Traffic Congestion Prediction Systems, Continuous Data Models
컨볼루션 장단기 기억, 차량 감지 시스템, 교통 혼잡 예측 시스템, 연속 데이터 모델

* 동서대학교 소프트웨어학과 연구원
(20171569@g.dongseo.ac.kr, 20171525@g.dongseo.ac.kr)

** 교신저자 : 동서대학교 소프트웨어학과

• 접수일 : 2023. 02. 16

• 수정완료일 : 2023. 03. 15

• 게재확정일 : 2023. 04. 17

• Received : Feb. 16, 2022, Revised : Mar. 15, 2023, Accepted : Apr. 17, 2023

• Corresponding Author : Seung-Min Park

Dept. of Software, Dongseo University,

Email : sminpark@dongseo.ac.kr

I. 서론

오늘날에는 우리가 기계의 정보를 수집하는 것이 나리, 기계가 우리의 정보를 수집하고 분석한다. 우리의 정보를 수집하고 발전하는 인공 지능은 투자, 유통과 같은 산업 분야에서도 각광 받고 있다. 의료, 제조, 교육, 교통 등의 여러 분야에서도 인공 지능 기술은 활발하게 적용되고 있다[1-3]. 그러나 이러한 인공 지능의 발전에도 교통 체증으로 일어나는 난폭운전 사고, 차량의 꼬리 물기로 인한 다중 추돌 사고, 보복 운전으로 인한 사고와 같이 21세기 사거리 교통 체증은 오늘날까지 문제 되고 있다. 이런 경우에는 교통 경찰을 배치하거나, 일정 시간대에 적용되는 가변 차로 시스템 등으로 완화되고 있다[4]. 도시 교통 체증 완화를 위한 효율적인 수송 체계에 관한 연구, 교통 체증을 감소시키기 위한 연구 또한 진행되고 있다. 예를 들면 교통 빅 데이터를 이용한 교통량 정체 지역 신호등 조절로 교통량을 원활하게 미리 조절하는 방법은 다양한 방법으로 제안되어 왔다[5-6].

사거리의 경우에는 교통량이 많아서 정체가 심화되고 있다. 이러한 도로의 교통 정보(교통량, 차량의 속도, 점유율 등)를 VDS(: Vehicle Detection System) 센서를 활용하여 수집하고, 수집한 데이터를 기반으로 기상 예측에 사용되는 Conv-LSTM (: Convolutional Long Short-Term Memory) 알고리즘을 이용하여 교통 체증이 일어날 시간대를 예측한다. 이렇게 교통 체증이 일어날 시간대를 예측하고, 교통을 원활하게 하는 것은 효율적인 도로 사용과 시간 손해를 줄이기 위함도 있지만, 운전자들의 안전을 목적으로 한다. 가장 사고가 많이 발생하는 사거리, 교차로에서도 교통 체증으로 인한 교통사고와 부상 또한 발생 되고 있다.

본 논문에서 교통 체증이 일어날 시간을 예측하고 제한한 알고리즘을 적용하는 것은 Conv-LSTM 모델을 사용한다. 최초 제안은 LSTM만 생각했으나 도로의 특성상 하나의 도로는 다른 도로와 연결되어 있다는 특수성을 고려했을 때, Conv-LSTM 모델이 더 적합하다는 결론을 내렸다. 하나의 도로가 다른 도로와 연결되어 있다는 것은 하나의 사거리 또한 다른 사거리와 연결될 수 있다는 것이다. 우리는

단순히 하나의 사거리의 교통 상황과 교통을 제어하는 것이 목적이 아니다. 하나의 사거리에서 다른 사거리로 이어지는 교통 제어를 목표로 하고 있다. 여기에는 교통량 측정을 위한 부가적인 VDS 센서도 필요로 한다. 이 정보들을 하나의 사거리만 가지고 있는 것이 아닌, 다른 사거리와 정보를 공유한다. 그리고 신호 체계 시스템을 적용하여 신호 체계를 미리 바꿔 넓은 지역의 교통 체증을 완화하는 것이 연구의 주된 토픽이다.

II. 이론적 배경

2.1 LSTM

RNN같은 경우 관련 정보와 그 정보를 사용하는 지점 사이 거리가 멀 경우 역전파시 gradient가 점차 줄어 학습 능력이 크게 저하되는 현상이 일어난다[7]. 이를 Vanishing gradient problem이라고 한다. 은닉층이 많은 은닉층을 거칠수록 전달되는 오차가 크게 줄어들어, 학습이 되지 않는다. 이 현상이 지속된다면 네트워크의 학습이 매우 느려지고 학습이 다 이루어지지 않은 상태에서 멈추게 된다. 본 논문에서는 RNN의 hidden state에 cell-state를 추가한 LSTM 모델을 선택하였다[8]. cell state는 일종의 컨베이어 벨트 역할을 한다. state가 꽤 오래 경과 해도 gradient가 전파가 잘 되게 한다. LSTM은 이전 셀($t-1$)의 정보를 받아서 현재의 상태(t)를 업데이트하고 다음 셀($t+1$)로 전달하는 구조를 가진다. 각각의 cell에서는 시그모이드 함수로 다음 셀에 전달할 정보와 누락 할 정보를 구분한다.

LSTM의 게이트 중 forget gate(f_t)와 input gate(i_t)에 대하여 수식으로 나타내면 식(1), 식(2)와 같다. 먼저 f_t 는 과거 정보를 잊기 위한 게이트로 사용된다. i_t 는 현재 정보를 기억하기 위한 게이트로 사용된다. f_t 와 다르게 시그모이드를 취한 뒤 또 같은 입력으로 하이퍼볼릭 탄젠트를 취해준 뒤 아다마르 곱 연산을 한 값을 내보낸다.

$$f_t = \sigma(W_{x_{h-f}}x_t + W_{hh-f}h_{t-1} + b_{h-f}) \quad \dots (1)$$

$$i_t = \sigma(W_{xh-i}x_t + W_{hh-i}h_{t-1} + b_{h-i}) \quad \dots (2)$$

LSTM은 다양한 분야의 문제를 해결하는데 이용된다. 장기적인 주가 예측이나, 동영상의 압축, 사람의 행동 인식 등에 사용되어 좋은 모습을 보였다.

2.2 Conv-LSTM

Conv-LSTM은 기존의 Fully connected LSTM (CNN+LSTM)이 공간적 특성을 반영하지 못하는 단점을 보완한 모델이다. 기존 모델과 비교 하였을 때 학습 방법은 동일하다. 그러나 입력이나 출력 상태의 레이어가 3차원 벡터로 연산된다. 따라서 시간적, 공간적인 특성을 동시에 학습할 수 있다는 장점을 지닌다. 교통 체증 예측에 필요한 주변 환경인 센서 사이의 거리와 신호가 바뀌는 주기, 신호 대기 중인 차량의 길이와 차량의 개수 등을 이용하기에 적절한 모델이라고 판단하였다. Conv-LSTM은 학습 시 예측된 자료를 다시 입력 자료로 활용하는 특징이 있다. Conv-LSTM을 수식으로 나타내 보았을 때 각각의 f_t 와 i_t 은 식(3), 식(4)와 같다.

$$f_t = \sigma(W_x f \times X_t + W_h f \times H_{t-1} + W_c f \circ C_t \dots -1 + b_f) \quad (3)$$

$$i_t = \sigma(W_x i \times X_t + W_h i \times H_{t-1} + W_c i \circ C_t \dots -1 + b_i) \quad (4)$$

식 (3), (4)를 (1), (2)와 비교하였을 때 결정적인 차이는 Conv-LSTM에서 forget과 input은 모두 3차원 텐서이다. 모든 요소가 1차원 벡터인 LSTM과는 다른 부분이다. 행렬 곱이 행해지던 항에서 모든 행렬 곱이 Convolution operation으로 대체되기도 하였다. 본 논문에서 교통 체증 예측 시스템을 LSTM이 아닌 Conv-LSTM을 사용한 이유는 시공간적 관계를 더 잘 포착해내어 주기 때문이다. 이는 우리가 하나의 사거리의 교통상황만 제어하는 것이 아닌, 사거리와 또 다른 사거리, 그리고 또 연결 되어있는 사거리를 연결하여 시공간적 관계를 만들고자 한다[9].




그림 1. 시각화 한 Conv-LSTM 구조
Fig. 1. \ Visualized Conv-LSTM structure.

그림 2의 Conv-LSTM의 레이어들은 24x30으로 이루어진다. 이는 24시간인 하루인 데이터를 30개로, 즉 한 달의 데이터를 VDS 센서를 이용하여 입력으로 사용한다. F값 같은 경우 24시간x30일의 VDS 데이터를 F값으로 변환 한 것이다. J값은 차로 체증 지수에 대한 값을 다중 입력으로 사용하게 된다. 이 입력 값이 Conv-LSTM 알고리즘을 거치면 결과 값이 출력된다.




그림 2. Conv-LSTM 사거리 교통 체증 시스템
Fig. 2 Conv-LSTM Traffic Congestion Forecasting System

III. 연구 방법

3.1 교통 체증 예측 시스템

교통 체증 예측 시스템의 정의를 하기에 앞서서 먼저 그림 3의 구성도에 대하여 다음과 같이 정의 하였다. 먼저 각 도로를 A, B, C, D라고 정의하고 각 차로에 대하여 1번부터 8번까지 차로별로 숫자를 부여하였다. 이때 F는 사거리의 전체 차로에 포화 지수로 정의하고, J는 각 차로의 체증 지수, C_t 는 중형차의 평균 길이, C_n 은 차량의 개수, R_t 은 차로의 길이, t는 신호가 바뀌는 주기, 센서 a와 b에 지나가는 차의 개수는 각각 a_n , b_n 으로 정의하였다. 본 논문에서의 교통 체증은 출발 신호 후 일정 시간 안에 F가 70% 이상이 되면 체증으로 정의한다.




그림 3. 제안한 교통 체증 예측 시스템 개념도

Fig. 3 Proposed Traffic Congestion Forecasting System Conceptual Diagram

교통 체증 완화는 J 를 기준으로 F 가 50%가 될 때까지 신호 체계를 정리한다. 여러 의미로 해석될 수 있는 교통 체증, 차로 체증, 교통 체증 완화의 의미를 명확하게 정의하였다. 본 논문에서 차로 포화 지수, F 의 기준은 식(5)와 같다.

$$F = \frac{(C_l \times C_n)}{R_l \times t} \times 100 \quad \dots (5)$$

J 는 70%부터 교통 체증이 발생한다고 정의한다. 기본적으로 주어지는 초록불의 신호가 1분이라고 가정하였을 때, J 가 70%일 경우 초록불의 신호를 30초 더 부여한다. 80%일 경우 45초를 부여하고 90%일 때는 60초를 부여한다. 만약 J 가 100%일 경우 Conv-LSTM 알고리즘을 이용하여 AI가 교차로의 상황을 학습한 결과로 교통 체증을 판단하여 신호 체계를 효율적으로 정리한다. 차로 체증 지수, J 의 기준은 식(6)과 같다.

$$J = \frac{C_l(b_n - a_n)}{R_l \times t} \times 100 \quad \dots (6)$$

체증이 없으면 이전처럼 1분 30초의 시간이 흐른 후 측정한다. 본 논문에서의 교통 체증의 정의는 출발신호 후 1분 30초 안에 F 가 70% 이상이 되면 체증으로 인식한다. F 가 0이면 교통 체증이 없다고 인식한다. 차로 체증이란 출발신호 후 1분 30초 안에 F 가 70% 이상이 되면 체증으로 인식한다. 마지막으로 교통 체증 완화의 정의는 위에서 정의한 J 를 기준으로 F 가 50%가 될 때까지 신호 체계를 정리하는 것이다.

3.2 VDS 센서

3.1에서는 교통 체증 예측 시스템에 대하여 정의하였다. 그리고 해당 시스템에 사용되는 관련 기술인 VDS 센서는 도로의 혼잡도를 측정한다. 도로의 교통 정보인 교통량, 속도, 점유율 등을 수집하여 센터에 전송하는 교통량 조사 장비이다. 또한, 차량 길이의 측정과 차량 역주행 판별 그리고 자체 진단 기능이 탑재되어 있다.

3.3 개발환경

본 논문의 연구 진행에 사용된 소프트웨어 환경은 각각 Python(3.7), Anaconda(4.9.2), TensorFlow(2.1.0), 마지막으로 CUDA(10.1.0)을 사용하였다. 이 프로그램을 구동한 컴퓨터의 사양은 다음과 같다. GPU(Nvidia Tesla T4) CPU(Intel(R) Core(TM) i7-9700) RAM(32GB), 마지막으로 운영 체제는 window10 64 비트 운영 체제를 사용하였다 학습을 위한 데이터는 공공데이터 포털(data.go.kr)에서 인천광역시 교통량 정보를 사용하였다.

IV. 시뮬레이션 및 예제

4.1 차로 체증 지수 예제

표 1과 같은 예시를 이용하여 J 에 따라 바뀌는 신호 체계 시스템에 따른 교통 체증 완화를 적용하여 보았다.

먼저 센서와 센서 사이의 거리는 83m로 가정하였고 t 는 신호가 바뀌는 주기이며 기본적인 주기는 1

표 1. 시간에 따른 연산교차로 방면 버스 이동 횟수
Table 1. Number of bus movements according to the 'Yeonsan' intersection time zone

	November							
	16	17	18	19	20	21	22	23
(a)	34	32	30	31	33	30	28	33
(b)	22	24	21	21	24	18	19	23
(a)-(b)	12	8	9	10	9	12	9	10

이라고 가정하였다. 차량의 수는 임의로 지정하였고 연산 시, 소수점 첫째 자리에서 반올림하였다. 차량 12대가 60초의 주기의 신호를 기다리고 있을

때 차로 체증 지수 J 를 구해보자면 식(7)과 같다.

$$J = \frac{4.9 \times 12}{83 \times 1} \times 100 = 70(\%) \quad \dots (7)$$

J 가 70% 이상이기 때문에 30초의 신호 시간을 증가시키고 $t=1+x$ 로 구한다. 여기서 x 는 추가되는 시간/신호가 바뀌는 주기(30sec/60sec)이다. 소수점 둘째 자리에서 반올림하기 때문에 t 는 1.5라는 값이 나오고 이를 통해 J 를 구한다면 식(8)과 같다.

$$J = \frac{4.9 \times 12}{83 \times 1.5} \times 100 = 47(\%) \quad \dots (8)$$

J 값이 약 23% 감소로 체증이 완화됨을 알 수 있다.

4.2 실험을 통한 결과 그래프

설계한 알고리즘과 동일하게 교통 체증 지수가 낮아지는지 실제로 실험을 통하여 시각화하였다. 사용한 데이터는 본문 3.3에서 언급했던 인천광역시 교통량 정보를 사용하였다. 2021년 1월 1일부터 일 년 동안 24시간 유입량을 모은 데이터를 사용하였다.

데이터의 크기는 8,952(373*24), 1월~12월 * 24시간으로 구성 되어 있다. 그림 4는 한 달 동안 시간대별 교통량 통계이다. 특정 구간에 유입된 차량을 다 더하고 평균 낸 수치를 Traffic, 그리고 24시간을 Time으로 나타내었으며, 1월부터 12월의 차량 유입 데이터를 데이터셋을 토대로 Conv-LSTM 알고리즘을 적용하여 차량의 이동량을 예측한 그래프의 결과이다.




그림 4. 한 달간 시간대별 교통량 통계
Fig. 4 Traffic statistics by hour for a month

교통 체증 예측 시스템 구현을 위한 데이터 총량을 100%로 가정하였다. 예측의 정확도를 높이기 위해 학습데이터 80%, 테스트 데이터 20%로 사용하였고, 교차 검증을 시행한 것을 그림 5와 같이 나타내었다. 17시부터 18시까지의 교통량에 대해 평균 상대 오차(MRE)를 본 논문에서 제안한 알고리즘과 기존 유사 연구의 오차율을 비교하여 표2와 같이 나타냈다[10].




그림 5. 교차 검증을 시행한 결과
Fig. 5 Results of cross-validation.

표 2. 기존 교통량 예측 유사연구와의 오차율 비교
Table 2. Comparison of error rates with existing similar traffic volume prediction studies

Task	C-LSTM	RW	SVM
	M		
Traffic Prediction	8	22.3	22.1

그림 6은 인천시 교통량 정보의 실제 데이터(actual)와 본 논문에서 제안한 알고리즘으로 0~10시간까지의 유입 데이터의 평균으로 예측(predict)하여 차량 유입률(차량 개수)을 증가시킨 그래프이다.




그림 6. 9시간 동안 교통량 그래프
Fig. 6 Traffic graph for 9 hours

여기서 예측값이 증가한 것은 교통 체증이 증가한 것이 아닌 차량 유입률이 늘어난 것이며 교통 체증이 완화되어 원활하게 유입되었다는 것을 의미한다. 해당 데이터를 통해 교통 체증이나 특정 교통 상황에 대응하는 것이 가능할 것이다. 또한, 검증 데이터의 양이 증가한다면 표 2에서의 오차율을 더 줄일 수 있을 것으로 예상된다.

V. 결 론

본 논문에서 제안한 알고리즘을 이용하여 실제로 시스템 도입 후 연산 결과를 확인해 보았을 때 차량 체증 지수는 92.8%에서 46%로 감소하는 것을 확인하였다. 기존의 교통 체증 예측 시스템과 차별화될 수 있는 점은 도로의 차로 포화 지수와 차로 체증 지수를 정의함에 있다. 본 논문의 아이디어를 응용하여 AI를 이용한 교통 체증 예측 및 버스 간 간격 조절 시스템을 구축하는 연구 또한 가능하다. 버스 간의 간격 조절을 통한 대중교통의 이용 증가와 효율적인 대중교통 이용 등으로 부가 가치를 창출해내는 연구를 할 예정이다. 이러한 교통 체증을 완화하는 연구가 지속 되며 언젠가는 완화되는 것뿐만 아닌 쾌적한 도로에서 안전한 운행을 할 수 있도록 지속적으로 연구할 것이다.

감사의 글

본 논문은 2022년도 동서대학교 "Dongseo Cluster Project" 지원에 의하여 이루어진 것임. (DSU-2022002)

References

- [1] Y. Kim, D. Kim, and S. Lee, "Prediction of Temperature and Heat Wave Occurrence for Summer Season Using Machine Learning," *J. of Korean Society of Disaster and Security*, vol. 13, no. 2, June. 2020, pp. 27-38.
- [2] J. Jo, "Time Series Data Processing Deep Learning system for Prediction of Hospital Outpatient Number," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 16, no. 2, Apr. 2021, pp. 313-318.
- [3] S. Jung, J. Koh, and S. Lee, "Recurrent Neural Network based Prediction System of Agricultural Photovoltaic Power Generation," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 17, no. 5, Oct. 2022, pp. 825-832.
- [4] H. Kwon, J. Yoo, and L. Yang, "A Hybrid Inference System for Efficiently Controlling Reversible Lane," *J. of the Korea Society of Computer and Information*, vol. 17, no. 11, Nov. 2012, pp. 19-26.
- [5] S. Kang, "Calculation of appropriate speed limits for urban roads using traffic information big data," Doctoral Thesis, *University of Seoul*, 2017.
- [6] G. Baek, J. Lee, and M. Park, "Development of Auto Traffic Light Control System for Prevention of Traffic Jam," *J. of the Convergence Signal Processing Society*, vol. 15, no. 4, Oct. 2014, pp. 148-154.
- [7] G. Lee and S. Lee, "Universal Prediction System Realization Using RNN," *The J. of Korean Institute of Information Technology*, vol. 16, no. 10, Oct. 2018, pp. 11-20.
- [8] S. Hochreiter, and J. Schmidhuber, "Long Short-Term Memory", *Neural Comput*, vol. 9, no. 8, Nov. 1997, pp. 1735-1780.
- [9] M. Aqib, R. Mehmood, A. Alzahrani, I. Katib, A. Albeshri, and S. Altowajjri, "Smarter Traffic Prediction Using Big Data, In-Memory Computing, Deep Learning and GPUs," *Sensors*, vol. 19, no. 9, May. 2019, pp. 2206-2239.
- [10] Y. Lv, Y. Duan, W. Kang, Z. Li, and F. Wang, "Traffic Flow Prediction With Big Data: A Deep Learning Approach," in *IEEE Transactions on Intelligent Transportation Systems*, vol. 16, no. 2, Apr. 2015, pp. 865-873.

저자 소개



이승용(Seung-Yong Lee)

2023년 동서대학교 소프트웨어학과 졸업(공학사)

※ 관심분야 : Soft Artificial Life, Intelligent Robot, Machine Learning



서부원(Boo-Won Seo)

2023년 동서대학교 소프트웨어학과 졸업(공학사)

※ 관심분야 : Machine Learning, Deep Learning



박승민(Seung-Min Park)

2010년 중앙대학교 전자전기공학부 졸업(공학사)

2019년 중앙대학교 대학원 전자전기공학과 석박사 통합과정 졸업(공학박사)

2019년 ~ 현재 동서대학교 소프트웨어학과 조교수

2021년 ~ 현재 산업인공 지능 표준화포럼 운영위원

2022년 ~ 현재 동서대학교 AI+X융합연구센터장

※ 관심분야 : 인공지능, 패턴인식, 뇌-컴퓨터 인터페이스, 기계학습.

