

Bi-LSTM 기반 도시 교통 흐름 예측

염성웅, 최철웅, 김경백
전남대학교 전자컴퓨터공학부

Bi-LSTM based Urban Traffic Flow Prediction

Sungwoong Yeom, Chulwoong Choi, Kyungbaek Kim
Dept. Electronics and Computer Engineering, Chonnam National University
E-mail: yeomsw0421@gmail.com, sentilemon02@gmail.com, kyungbaekkim@jnu.ac.kr

요약

최근 도시가 팽창하면서 한계에 다다른 교통망 운영에 의해 교통 혼잡이 발생하고 있다. 많은 연구원들이 교통 혼잡을 줄이고 교통 효율성을 개선하기 위해 지능형 교통 시스템 (ITS) 개발에 노력하고 있다. 차량 속도, 교통량 및 차량 간 간격과 같은 교통 정보는 특정 지점의 교통량을 예측하는데 사용할 수 있다. 하지만 대부분의 이전 연구들은 단일 지역 정보만을 이용하여 교통 흐름을 예측하였다. 본 논문에서는 종단간의 경로 상의 노드 및 링크 정보를 활용하여 Bi-LSTM 기반의 단기 트래픽 흐름 예측 기법을 제안한다. 실제 데이터 세트를 사용한 실험 결과는 제안된 기법이 향후 교통 흐름을 예측할 때 다른 시계열 예측 기법보다 더 잘 작동함을 입증한다.

1. 서론

도시 인구가 증가함에 따라 도시의 공공 및 민간 교통 체계가 정체되고, 이미 한계에 가깝게 운영되고 있는 도시 네트워크는 작은 문제나 사건에 의해 큰 악영향을 미칠 수 있다. 또한, 교통 정체에 의한 시간 낭비, 오염 증가, 안전 우려, 그리고 경제에 영향을 미치기 때문에 근본적인 문제 해결이 필요하다. 최근 ITS(Intelligent transportation system)의 활성화에 따라 실시간 교통 데이터 피드 및 방대한 데이터 저장소를 활용하여 지능형 교통 관리 시스템이 활성화되고 있다.[1]

지능형 교통 관리 시스템은 도시 교통 수준을 섬세하게 파악하고 가까운 현 교통 상황 인지를 위해 대규모 동적 데이터를 실시간으로 수집할 수 있다.[2] 교통 상황을 모니터링하고 교통 혼잡의 증가나 악화를 방지하기 위해, 교통 관리 시스템은 연결된 IoT 디바이스들을 사용하여 다양한 데이터를 수집 및 분석을 통해 동적으로 교통 흐름을 파악할 수 있다.[3] 예를 들어, 번호판 판독기와 CCTV 카메라와 같

은 IoT 센서들을 거리에 배치하여 실시간으로 수집된 교통 혼잡 상황을 교통 관리 시스템을 통해 모니터링 할 수 있다. 이렇게 수집되는 데이터들을 통해 주어진 시간 내에 경로를 통과하는 차량의 양과 속도를 관측하여 교통 혼잡 패턴을 예측할 수 있다.[4-5]

이 단기 도시 교통 흐름 예측은 도시 교통 탐색 계획 및 도시 교통 최적화 제어의 핵심이다. 단기 트래픽 흐름 예측에 대한 수많은 접근 방식 중 신경망은 다차원 데이터 처리, 유연한 모델 강건, 강력한 일반화 및 학습 능력 및 적응력이 있다. 이러한 트래픽 흐름은 오전에는 증가하고 점심에는 변동적이고 저녁에는 감소하는 계절적 특성을 확인할 수 있다. 시계열 딥러닝 신경망 중 하나인 LSTM은 계절성이 존재하는 트래픽을 활용한 단기 흐름 예측과 같은 시계열 분석에 높은 성능을 보여준다.[6] 하지만, 종단간의 노드 사이의 단기적인 트래픽 흐름을 예측할 때 도착지점에서 얻을 수 있는 정보뿐만 아니라 종단간 사이의 링크 정보를 활용하여 단기 트래픽을 예측할 필요가 있다.

본 논문에서는 종단간의 노드와 링크 정보를 활용하여

Bi-LSTM 기반 도시 교통 단기 흐름 예측 기법을 제안한다. 기본적으로 Bi-LSTM의 입력벡터는 트래픽 흐름 양, 차량 시간 평균 속도, 차량 공간 평균 속도, 도로 시간 점유율 및 타임스탬프로 다섯 가지 도메인으로 구성한다. 이와 같이 서로 다른 입력벡터를 사용할 때, Bi-LSTM을 기반으로 도시 교통 단기 흐름량의 MSE, MAE, RMSE를 측정하여 평가한다.

2. 관련연구

도시 교통 혼잡 예측에 대한 시공간적 데이터의 주요 특징은 시간 지연에 의해 먼 도로 구간에서 교통 흐름 사이의 시공간 관계에 대한 정보이다. 시공간 모델은 도로 네트워크를 통한 트래픽 흐름 또는 정체의 일시적 증가가 포함된다. 시간이 지남에 따라 교통 흐름의 시공간 의존성은 정보화된 운전자의 행동, 도로 구간의 보완적, 경쟁적 특성에 의해 더욱 복잡해진다.

논문[7]은 신경망을 이용하여 실시간 교통 예측이 수행되었다. 고속도로에서 낮 시간 동안 15분의 트래픽 양을 검사하고 신경망을 포함한 여러 방법을 사용하여 다음 15분 간격의 불륨을 예측한다. 논문[8]은 도로 네트워크에서 공간적 및 시간적 상관관계를 모두 고려한 모델의 파라미터를 추정한다. 이들은 매우 많은 수의 매개 변수를 추정하지만 운송 네트워크의 몇 가지 중요한 특성을 고려하지는 않는다. 공간 상관은 링크 사이의 거리에 의존하는 고정된 매트릭스 세트라고 가정한다. 그러나 운송 네트워크에서는 링크가 정체되었는지 여부에 따라 트래픽 흐름에 영향을 미치는 다른 네트워크 링크가 상당히 달라질 수 있다. 우리는 다변량 시계열 데이터 학습에 유용한 시계열 신경망 Bi-LSTM 모델을 사용하여 학습하고 성능을 평가한다.

3. Bi-LSTM 기반 공간-시간적 도시 교통 흐름 예측

교통 혼잡의 증가나 악화를 방지하기 위해, 지능형 교통 관리 시스템은 도로 또는 차량 내 설치된 센서 및 카메라와 같은 IoT 기기들과 도시 교통 흐름을 클라우드에서 수집 후 모니터링하여 동적으로 트래픽 흐름을 유도하는데 사용될 수 있다.[9]

3.1 시공간 트래픽 흐름 변수 정의

일반적으로 교통 흐름 및 도로 혼잡 상태는 세 가지 변수 Speed, Flow 및 Occupancy 세 가지 변수를 통해 나타낼 수 있다. 이러한 트래픽 흐름 변수의 정의는 아래와 같다.

첫째, 트래픽 흐름 양(Traffic flow quantity) Q_i 은 단위 시간 동안 도로의 기준점(노드) A 를 통과하는 차량의 수이다. 여기서 i 는 단위 시간 T 분 간격으로 기록된 타임스탬프, N_A 은 A 구간을 통과하는 차량의 수이다. A 구간의 트래픽 흐름 양 Q_i^A 의 수식은 아래와 같다.

$$Q_i^A = \frac{N_A}{T}$$

둘째, 트래픽 흐름 속도 V 는 단위 시간당 구간을 통과한 차량의 속도이다. 동일한 도로 구간에서 관찰되는 차량의 속도는 제각기 다르다. 따라서, 이 평균 속도는 일정 시간 동안 도로 구간 상태로 나타낼 수 있다. 이러한 평균 속도는 시간 평균 속도 V_t 와 공간 평균 속도 V_s 로 표현할 수 있다.

시간 평균 속도(Time mean speed) V_{ti}^A 는 단위 시간 동안 도로의 기준점(노드) A 에서 측정되는 차량의 평균 속도이다. 여기서 v_k 는 k 번째 차량의 속도이다. 이 시간 평균 속도 V_{ti}^A 는 산술 평균으로 계산된다. 시간 평균 속도 V_{ti}^A 의 수식은 아래와 같다.

$$V_{ti}^A = \frac{1}{N_A} \sum_{k=1}^{N_A} v_k$$

공간 평균 속도(Space mean speed) V_{si}^{AB} 는 기준점 A 와 B 사이의 도로 구간(링크)에서 관찰된 차량들의 속도이다. 이 공간 평균 속도 V_{si}^{AB} 는 고조파 평균(Harmonic mean)으로 계산되며 보통 시간 평균 속도보다 크지 않다. 공간 평균 속도 V_{si}^{AB} 의 수식은 아래와 같다.

$$V_{si}^{AB} = \left(\frac{1}{N_{AB}} \sum_{k=1}^{N_{AB}} \frac{1}{v_k} \right)^{-1}$$

마지막으로, 도로 점유율(Occupancy) O_{ti}^{AB} 은 기준점 A 와 B 사이의 도로 구간(링크)의 차량 밀도를 나타낸다. 동일한 도로 구간에서 관찰된 도로 점유율은 시간과 차량의 크기에 따라 영향을 받는다. 이러한 점유율은 시간 점유율과 공간 점유율로 나타낼 수 있다.

시간 점유율(Time occupancy)은 차량이 검출기를 점유하는 시간의 백분율을 의미한다. 여기서 T 는 관측이 이루어진 단위 시간이고, t_k 는 k 번째 차량이 점유한 탐지기의 시간이다. 시간 점유율 O_{ii}^{AB} 의 수식은 아래와 같다.

$$O_{ii}^{AB} = \frac{1}{T} \sum_{k=1}^{N_{AB}} t_k * 100(\%)$$

공간 점유율(Space occupancy)은 도로 구간의 전체 차량 길이에 의해 정의된다. 하지만, 차량의 유형 및 길이가 다양하기 때문에 공간 점유율을 계산하기가 어렵다. 이처럼 매 순간 수집되는 다양한 트래픽 흐름 특징들을 활용한 트래픽 예측의 안정성을 보장하기 위해 시계열 다변량 데이터를 보다 효과적으로 학습하는 Bi-LSTM 모델이 필요하다.

3.2 Bi-LSTM 기반 도시 교통 흐름 예측 모델

(그림 1) Bi-LSTM 기반 도시 교통 흐름 예측 모델 아키텍처

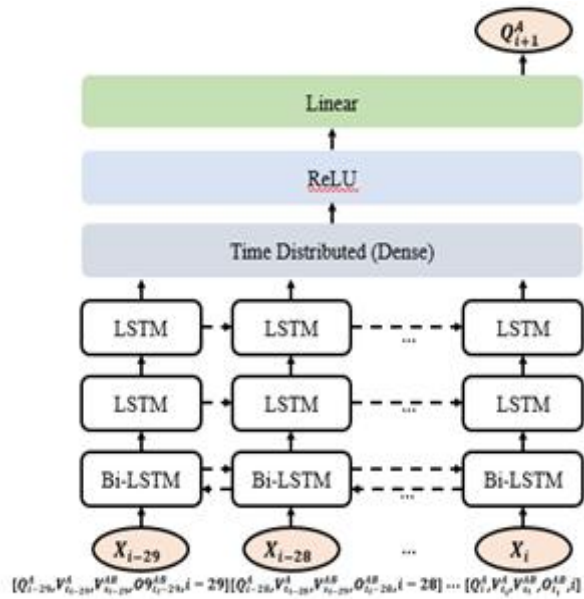


그림 2는 Bi-LSTM 기반 트래픽 흐름 예측 모델 아키텍처이다. 이 Bi-LSTM 모델은 1개의 Bi-LSTM 계층, 2개의 LSTM 계층, 3개의 Dense 계층을 구성한다. 3개의 Dense Layer 중 첫 계층은 Time Distributed, 두 번째 계층은 ReLU, 마지막 계층은 Linear 활성화 함수를 사용한다. 각

레이어는 30개의 노드를 포함한다. 각 노드의 입력을 위해 매 순간 수집되는 트래픽 데이터를 시간 창으로 구성한다. i 번째 시간 창에서 관찰되는 입력벡터 X_i 은 5가지 특징을 사용한다. 1)트래픽 흐름 양 Q_i^A , 2)차량 시간 평균 속도 V_{ii}^A , 3)차량 공간 평균 속도 V_{si}^{AB} , 4)도로 시간 점유율 O_{ii}^{AB} , 5) 타임스탬프 i

제안된 Bi-LSTM 모델은 연속적인 시간대에서 수집된 30개의 입력벡터 $X_{i-29}, X_{i-28}, \dots, X_i$ 을 입력으로 사용하여 다음 시간대의 트래픽 흐름 양을 예측한다. 제안된 Bi-LSTM 모델과 기존의 LSTM 모델의 성능을 비교하기 위해 각 모델의 MSE, MAE, RMSE를 측정하여 비교가 필요하다.

4. 실험교육 및 평가

덴마크의 아르후스 시가 제공하는 차량통행에 대한 449쌍의 교통정보 데이터는 136개의 단일 지점으로 부터 관측치가 수집된다. 이 데이터는 도심 교통관리에 활용 사례를 개발하여 보다 효율적으로 시내 교통을 경로화하기 위해 수집되었다. 아르후스 시의 136개의 교통 지점에서 일부 교통 지점의 트래픽 흐름 예측 결과를 비교한다.

<표 1> 시계열 딥러닝 모델별 회귀 오류 지표

	MSE	MAE	RMSE
LSTM	0.0544	0.1672	0.2331
Bi-LSTM	0.0491	0.1554	0.2215

제안된 Bi-LSTM 모델의 성능을 기존의 LSTM 모델과 비교하기 위해 모델의 Node 수, Layer 수를 변경하면서 성능을 평가하여 각각 최적의 모델을 구성 하였고 모델의 MSE, MAE, RMSE를 비교하였다. 표1은 시계열 딥러닝 모델별 실험 결과이다. Bi-LSTM 모델의 MSE, MAE, RMSE가 LSTM 모델에 비해 전반적으로 더 낮았다. 결과적으로 다변량 시계열 데이터들을 입력으로 사용하는 경우 과거의 특징뿐만 아니라 미래의 특징 모두를 학습하는 Bi-LSTM 모델이 단순 LSTM 모델보다 유효하다.

5. 결론

본 논문에서는 도로 기준점(노드)와 도로 구간(링크) 정보를 활용하여 Bi-LSTM 기반 도시 교통 단기 흐름 예측 기법을 제안한다. 이 기법의 성능을 평가하기 위해 트래픽 흐름 양, 차량 속도, 도로 점유율 등 시공간 트래픽 흐름의 특성을 활용하여 제안된 Bi-LSTM 기반 트래픽 흐름 예측 기법의 성능을 검증하였다. 제안된 기법은 기존의 LSTM 기법보다 전반적으로 낮은 MSE, MAE, RMSE를 보여준다. 향후 수집된 스마트 시내 노드 및 링크 정보를 활용하여 GNN 기반 도시 트래픽 혼잡 예측 기법 연구가 목표이다.

Acknowledgment

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2017R1A2B4012559).

참고 문헌

- [1] Tönjes, Ralf, et al. "Real time iot stream processing and large-scale data analytics for smart city applications." poster session, European Conference on Networks and Communications. sn, 2014.
- [2] Smith, Brian L., Billy M. Williams, and R. Keith Oswald. "Comparison of parametric and nonparametric models for traffic flow forecasting." *Transportation Research Part C: Emerging Technologies* 10.4 (2002): 303-321.
- [3] Bischof, Stefan, et al. "Semantic modelling of smart city data." (2014)
- [4] Huang, Fei-Rong, Cong-Xaiang Wang, and Chih-Min Chao. "Traffic Congestion Level Prediction Based on Recurrent Neural Networks." 2020 International Conference on Artificial Intelligence in Information and Communication (ICAIC). IEEE, 2020.
- [5] Chowdhury, Md Mohiuddin, et al. "A traffic congestion forecasting model using cmtf and

machine learning." 2018 Joint 7th International Conference on Informatics, Electronics & Vision (ICIEV) and 2018 2nd International Conference on Imaging, Vision & Pattern Recognition (icIVPR). IEEE, 2018.

- [6] Li, Jinhong, et al. "Short term traffic flow prediction based on LSTM." 2018 Ninth International Conference on Intelligent Control and Information Processing (ICICIP). IEEE, 2018.
- [7] Jung, H., J. Yoon, and S. Bae. "Traffic Congestion Estimation by Adopting Recurrent Neural Network." *The Journal of The Korea Institute of Intelligent Transport Systems* 16.6 (2017): 67-78.
- [8] Cheng, Tao, James Haworth, and Jiaqiu Wang. "Spatio-temporal autocorrelation of road network data." *Journal of Geographical Systems* 14.4 (2012): 389-413.
- [9] S. Yeom, et al. "Design of Driver Trustiness assessing system with dangerous driving behavior detection" *The Korea Institute of Smart Media (KISM)*, 2019.