

CCTV 영상을 이용한 교통 정체 전파 인과 관계 분석

(Causality Analysis for Traffic Congestion Propagation Using CCTV Videos)

박기웅[†] 연한별^{**} 문예완[†] 장윤^{***}
(Giwoong Park) (Hanbyul Yeon) (Yewan Moon) (Yun Jang)

요약 본 논문은 CCTV 영상을 이용해 교통 흐름 데이터를 추출하고 정체 간 인과 관계를 분석하는 프레임워크를 제안한다. 또한 CCTV 영상에서 차량을 추적해 교통 흐름 데이터를 추출하고 CCTV 카메라가 없기 때문에 생기는 교통 흐름 데이터의 결손은 GPS 데이터를 이용해 보간하는 방법을 소개한다. 추출된 교통 흐름 데이터와 도로망 정보를 결합하여 교통 네트워크를 모델링한다. 생성된 교통 네트워크 모델과 granger 인과 관계 테스트를 이용해 발생한 정체 사이의 전파 인과 관계를 계산한다. 우리가 제안한 프레임워크를 이용해 실제 교통 상황의 분석이 가능한지 실험한다.

키워드: 도시 교통 분석, 교통 정체 전파, 시공간 교통 네트워크 모델링, 정체 전파 인과 관계, 다중 CCTV 비디오

Abstract In this paper, we propose a framework for detecting traffic flow data from CCTV video and analyzing causality between traffic congestion. We track vehicles from CCTV video to detect traffic flow. The loss data which is occurring because of by the lack of CCTV cameras is supplemented from GPS average speed data. We model the traffic network by detected traffic flow data and road network information. We calculate causality between congestions with traffic network model and the Granger causality test.

Keywords: urban traffic analysis, traffic congestion propagation, traffic spatiotemporal network modeling, congestion propagation causality, multiple CCTV videos

· 이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (과제번호 2021-0-02076, 빅데이터 인과 분석을 위한 복잡계 기반 추론 인공지능(REX) 개발 및 실증), (No. 2021-0-00469, 이종 융합 데이터 탐지 및 추적 기술 개발)
· 이 논문은 2021 한국컴퓨터종합학술대회에서 'CCTV 영상을 이용한 교통 정체 전파 인과 관계 분석'의 제목으로 발표된 논문을 확장한 것임

논문접수 : 2021년 10월 6일
(Received 6 October 2021)
논문수정 : 2022년 1월 5일
(Revised 5 January 2022)
심사완료 : 2022년 2월 9일
(Accepted 9 February 2022)

[†] 학생회원 : 세종대학교 컴퓨터공학과 학생
rct3232@gmail.com
mool1997@naver.com

^{**} 비회원 : 세종대학교 컴퓨터공학과 연구원
hbyeon109@gmail.com

^{***} 종신회원 : 세종대학교 컴퓨터공학과 교수(Sejong Univ.)
jangy@sejong.edu
(Corresponding author임)

Copyright©2022 한국정보과학회 : 개인 목적이거나 교육 목적인 경우, 이 저작물의 전체 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다.
정보과학회 컴퓨팅의 실제 논문지 제28권 제4호(2022. 4)

1. 서론

많은 도시 지역에서 사람들은 통근하거나 여가 시간을 즐기 위해 차량을 이용한다. 사람들의 목적지는 도시 곳곳에 흩어져 있어 도로 위 차량 흐름을 얻히게 한다. 따라서 차량 이동이 많은 도심 지역에서는 교통 혼잡이 불가피하다. 교통 혼잡 인식[1], 원인 분석[2] 및 신호 최적화[3]와 같은 교통 혼잡과 관련된 연구는 혼잡 지역을 발견하고 해결하는 것을 돕는다. 그러나 지속적으로 움직이는 차량은 정체를 한 지역에서 머물게 하지 않고 계속 전파시킨다. 따라서 교통 혼잡 전파에 관한 연구[4,5]는 교통 분석가들이 교통 혼잡 상태를 조사하고 필요한 조치를 취하는 데 유용하다. 이에 따라 교통 흐름이 만들어낸 혼잡 패턴 간의 인과 관계를 분석하고 어디서 정체가 전파되었는지를 파악하기 위한 연구가 수행되었다.

CCTV 영상은 관측된 모든 차량의 속도, 교통량, 방향 등을 제공하며, 모든 차량 종류를 관찰할 수 있어 교통 흐름을 완전하게 대변한다. 게다가 교통사고나 혼잡과 같은 실시간 교통 상황을 감시하기도 쉽다. CCTV 영상은 장점이 많지만, 과거 연구는 단일 CCTV로 터널 [6], 교차로[7], 고속도로[8] 등 특정 장소에서의 교통 흐름 모니터링에 대해서만 이뤄졌다. 도시의 모든 교차로에 CCTV가 설치되어 있으면 CCTV 영상만 활용해 교통 네트워크를 모델링 할 수 있다. 하지만 CCTV 영상으로 관측되지 않는 교차로가 일부 있어 데이터에 결손이 생긴다. 이 문제를 극복하기 위해 GPS 데이터에서 얻은 평균 속도 정보의 누락된 부분에 해당하는 값으로 결손 데이터를 보간한다.

혼잡 전파 패턴의 발견에 대한 기존 연구[4,9]는 평균 이동 속도가 특정 임계값 미만인 도로의 순서로 전파 트리를 구성할 것을 제안했다. 이 접근법은 고속도로와 같이 이동 경로의 경우의 수가 거의 없는 폐쇄된 도로 상황에 유용하다. 하지만, 교차로를 통해 많은 도로가 연결되는 도시 지역에서는 차량 이동 경로의 경우의 수

가 많아 기존 연구를 적용하기 쉽지 않다. 본 논문에서는 이를 해결하기 위해 granger 인과 관계를 적용해 정체 전파 패턴을 추출한다.

본 논문에서는 교통 혼잡 전파 분석을 지원하는 프레임워크를 제안한다. 프레임워크는 그림 1과 같은 절차로 교통 흐름을 추출하고, 정체 전파간 인과 관계를 계산한다. CCTV 영상에서 차량을 추적하여 속도, 교통량, 이동 방향과 같은 교통 흐름 데이터를 추출한다. CCTV 카메라로 관찰되지 않는 지역으로 인해 생기는 교통 흐름 데이터의 결손은 GPS 데이터의 평균 속도로 보간한다. 추출된 교통 흐름 데이터와 도로망 정보를 결합하여 교통 네트워크를 모델링한다. 생성된 교통 네트워크 모델에 granger 인과 관계 테스트를 적용하여 발생한 정체 간 전파 인과 관계를 분석한다.

2. 프레임워크 구성

이 장에서 프레임워크를 구성하는 기능인 교통 흐름 데이터 추출, 교통 네트워크 모델링, 교통 정체 전파 인과 관계 분석에 관해 기술한다.

2.1 흐름 추출

흐름 추출은 그림 1의 (a)에 해당하는 절차로, 스트리밍 CCTV 비디오를 이용하여 차량 흐름 데이터를 추출하기 위해 YOLOv3(You Only Look Once)[10]를 사용한다. 차량 흐름 데이터는 CCTV 비디오에서 관측 가능한 도로를 사용하는 차량들의 속도, 통행량, 통행 방향을 포함한다. YOLOv3는 비디오 프레임마다 2D 좌표로 차량 위치를 제공하는 최첨단 객체 인식 알고리즘이다. 2D 차량 좌표와 SORT(Simple Online and Realtime Tracking)[11] 모델을 결합하여 비디오에서 차량 이동 경로를 추적한다. SORT 모델은 실시간 애플리케이션을 위한 다중 객체 추적 모델이다.

교통량은 SORT 모델에서 획득한 차량 이동 경로의 수를 계산하여 추정한다. 그러나 속도를 추정하려면 비

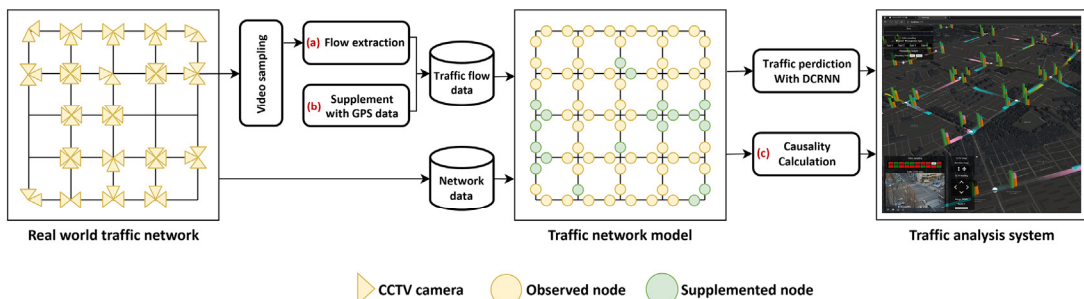


그림 1 CCTV 영상으로 교통 흐름을 추출하고 교통 네트워크를 모델링하여 교통 정체 인과 관계를 분석하는 프레임워크
 Fig. 1 Our framework extracts traffic flow from CCTV videos and models traffic network to analyze congestion causality

디오 프레임의 2D 좌표를 실제 도로의 2D 좌표로 변환해야 한다. 따라서, Stein 외 연구진 등이 제안한 대로 고정 지상 좌표와 좌표 사이의 실제 거리가 필요한 호모그래피[12] 변환을 사용한다. 한국도로교통공단에 따르면 모든 도로의 노면 표식은 동일하다. 특히 모든 점선은 길이와 간격이 동일하다. 따라서 점선을 참조하여 호모그래피 변환을 사용해 경로의 길이를 계산한다. 서울에 설치된 CCTV 영상은 초당 프레임 수는 15개로, 프레임당 0.06초로 변환된다. 이 정보들을 사용하여 차량의 이동 거리와 속도를 계산한다. 차량 방향을 파악하기 위해 스트리밍 영상에서 Pi 외 연구진[2]이 제시한 실제 북쪽을 지정하고 차량 궤적을 도로의 좌표와 비교하는 방법으로 이동 방향을 추정한다.

2.2 네트워크 모델링

CCTV 영상에서 추출한 차량 흐름 데이터는 모든 도로에 CCTV 영상이 설치되어 있지 않기 때문에 도심 내 모든 도로의 교통 정보를 나타내지 않는다. 이를 해결하기 위해 그림 1의 (b)에 해당하는 과정을 통해 CCTV 영상으로 관찰되지 않는 도로의 교통 흐름 데이터를 추정하고 이를 이용하여 도시 교통 네트워크를 형성한다.

도시 교통 네트워크를 모델링하기 위해 CCTV 카메라(노드)와 도로(엣지)를 포함하는 CCTV 네트워크를 구축한다. 이후 차량 흐름 데이터와 CCTV 네트워크를 결합해 교통 네트워크를 구축한다. 이 네트워크에서 각 노드는 교차로에 연결된 도로를 나타내고, 각 엣지는 인접한 두 노드 사이의 연결을 나타낸다. YOLOv3 및 SORT에 의해 추정된 교통 흐름 데이터는 노드 데이터로 활용된다. 그러나 일부 CCTV는 모든 교차로를 관찰하지 않기 때문에 일부 노드의 교통 흐름 데이터 결손이 발생한다.

CCTV 영상으로 추출한 교통 흐름 데이터로 교통 네트워크의 모든 노드를 채울 수 없을 경우 GPS 경로 데이터에서 생성된 각 노드의 평균 속도 데이터로 보완한다. TOPIS[13]는 GPS 데이터로부터 계산된 서울 시내 각 도로의 평균 속도를 5분, 10분, 15분, 1시간 간격으로 구성한 데이터를 제공한다. 불완전한 교통 네트워크의 보완 작업 순서는 다음과 같다. 누락된 흐름 데이터의 시간대를 확인한 뒤에 적합한 시간 단위의 데이터 세트를 선택한다. 이후 누락된 흐름 데이터를 해당 시간대의 평균 속도로 채워 완전한 교통 흐름 데이터를 완성하고 이용해 교통 네트워크를 생성한다.

2.3 교통 정체 전파 인과 관계 계산

Granger 테스트는 두 독립 시계열 변수 사이의 상호 영향을 검증하는 방법이다. 이 영향은 한 변수의 변화로 인해 어떤 시차에서 다른 변수가 변화됨을 의미한다. 두 시계열 변수 X와 Y의 인과 관계를 다음 식으로 검증한다.

$$Y_t = \alpha_0 + \sum_{n=1}^N \alpha_n X_{t-n} + \sum_{m=1}^M \beta_m Y_{t-m} + \epsilon_t$$

위의 식에서 귀무 가설은 변수 X의 변화가 변수 Y의 변화의 원인이 아니라는 것이다. 귀무 가설이 기각되면 변수 X가 변수 Y의 원인이 된다. F-검정을 적용하여 granger 인과 관계 귀무 가설을 검증한다.

그림 1의 (c)에 해당하는 과정인 정체 전파 패턴 추출을 진행하기 위해 특정 시간 단위의 각 도로 평균 차량 속도를 계산한다. 그런 뒤 선택된 정체가 발생하는 도로를 기반으로 다른 도로와 granger 테스트를 수행한다. 테스트에서 시차 단위는 데이터의 시간 단위로 설정한다. 그러나 granger 테스트에서 인과 변수와 출력 변수 사이의 적절한 시차를 선택해야 한다. 짧은 시차는 auto-correlated 오류를 유발할 수 있으며, 긴 간격의 시차는 검증 결과를 약화시킬 수 있다. 또한 정체 전파 패턴을 추출할 영역을 지정해야 한다. 예를 들어, 너무 많은 엣지를 포함하는 큰 영역이 지정되었다고 가정할 때, 특정 시간에 정기적으로 발생하는 교통 흐름 패턴으로 인해 관련 없는 엣지 간의 영향이 존재할 수 있다.

granger 인과 관계에 의해 계산되는 엣지의 혼잡 전파 영향의 유무는 사전에 설정한 범위 내의 엣지로 구성된 트리에 매핑된다. 트리는 사전에 설정한 시차에 대해 구축되며, 각 트리는 정체 전파 분석을 위해 선택한 엣지로부터 순차적으로 도달할 수 있는 엣지로 구성된다. 그 후, 특정 시차에서 어떤 엣지가 영향을 받지 않는다고 판단되면, 하위 노드는 우연에 의해 계산되는 인과 관계를 피하고자 제거된다. 완성된 트리가 엣지 및 시간에 대한 2차원 행렬로 변환되면 선택한 엣지에 영향을 주었거나, 영향을 받은 정체 전파 인과 관계 시계열 데이터가 완성된다.

3. 실험

이 장에서 실제 데이터를 사용해 교통 흐름 전파의 인과 관계를 계산하고, 시각화하는 과정을 통해 이 논문이 제한하는 프레임워크가 실제 교통 상황을 분석할 수 있는지 확인한다.

그림 2는 2020년 10월 5일 오전 6시와 7시의 이른 아침 교통 상황을 각각 (a)와 (b)로 나타낸다. (a)와 비교했을 때 (b)의 교통상황은 모든 도로의 교통흐름이 느려졌고, 색상, 선 두께로 표현되는 대로 교통량이 증가했음을 보여준다. 그림 2(c)와 (d)의 1번 교차로에서 2번 교차로까지의 도로 2.5D 막대 도표를 보면 오전 6시 교통상황에 비해 교통흐름이 약 2배, 교통량이 약 1.5배 증가했으며, 혼잡유형은 오전 7시 교통신호가 되었다.

그림 3은 그림 2의 시간대에 관측된 혼잡 전파 패턴을 보여준다. 그림 2에 나타난 정체 현상의 인과 관계를

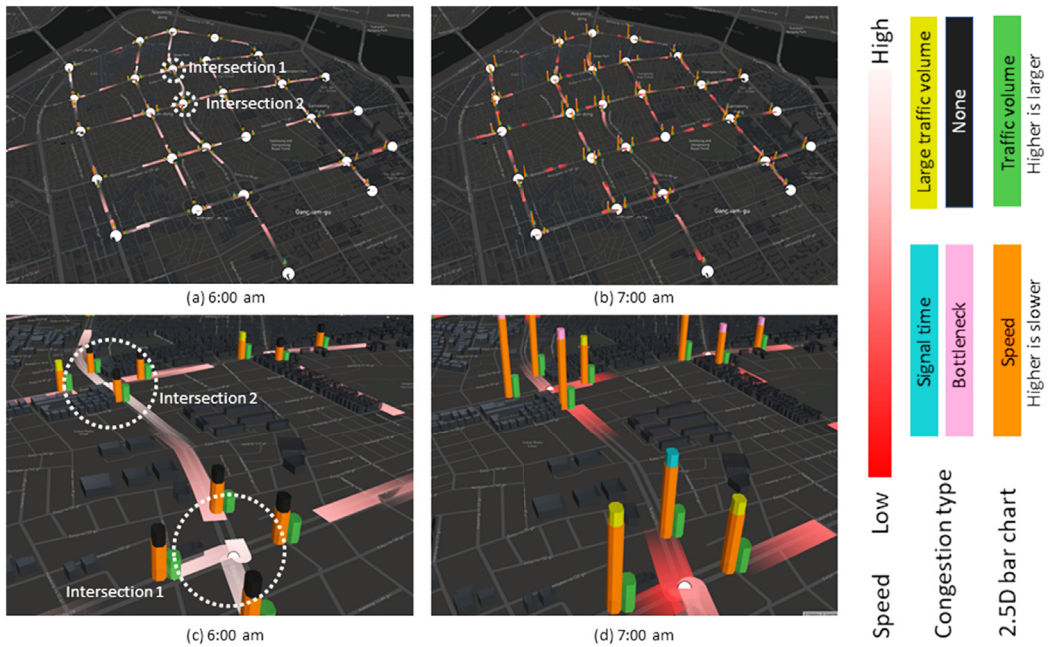


그림 2 2020년 10월 5일 새벽 6시에서 7시 사이의 교통 상황 시각화
 Fig. 2 Traffic state visualization between 6 am and 7 am on October 5, 2020

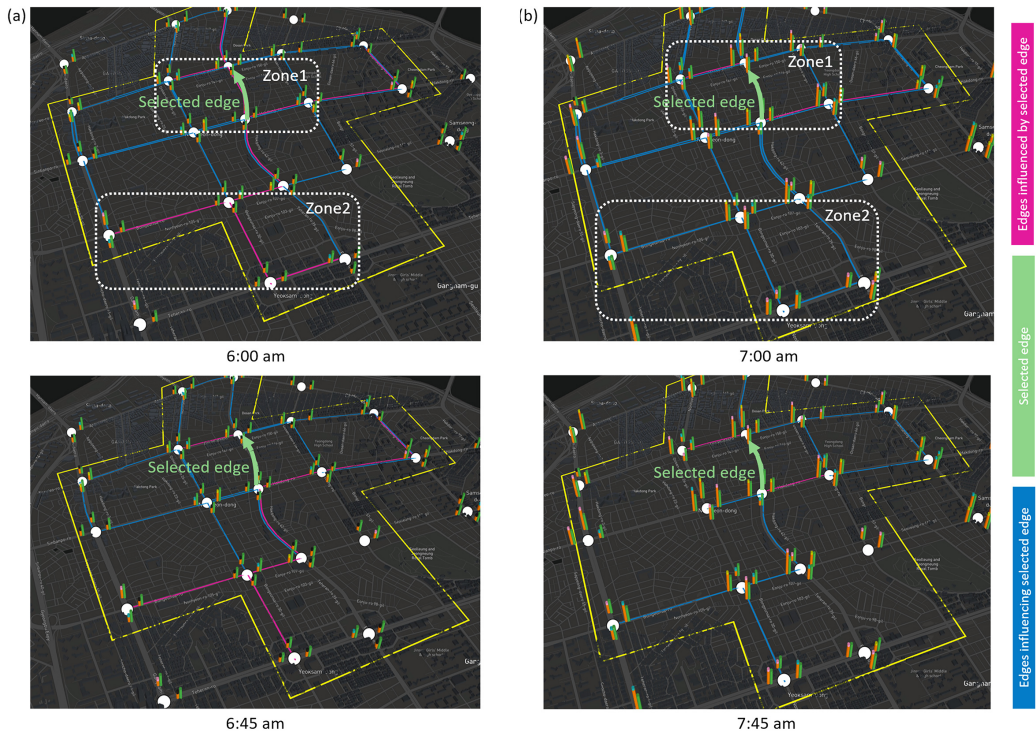


그림 3 2020년 10월 5일 새벽 6시에서 7시 사이의 교통 정체 인과 관계 시각화
 Fig. 3 Traffic congestion causality visualization between 6 am and 7 am on October 5, 2020



그림 4 2020년 10월 2일 자정의 교통상황과 실시간 CCTV 이미지 및 교통 정체 인과관계 시각화
 Fig. 4 Traffic state visualization and real-time CCTV video between 0 am on October 2, 2020

분석하기 위해 그림 2(c)와 그림 2(d)에 나타난 도로를 선택하여 granger test를 진행했다. 그림 3에서 오전 6시와 7시에 도로에 표기된 색상이 다른 것을 확인할 수 있다. 오전 6시의 혼잡 전파 패턴에서 선택된 도로는 Zone1과 Zone2에 영향을 주었다. Zone2는 선택된 도로로부터 탈출한 차들이 몰려 정체가 일어났음을 나타내며, Zone1은 선택된 도로로 향하는 차들이 계속해서 쌓이는 것을 나타낸다. 시간이 지남에 따라 해당 도로는 Zone2에 더 이상 영향을 주지 않지만, Zone1에는 지속적으로 영향을 주고 있다. 오전 7시의 혼잡 전파 패턴은 오전 6시의 혼잡 전파 패턴과 매우 유사하다. 하지만 Zone2는 선택된 도로에 영향을 받는 것이 아니라 영향을 주고 있다. 오전 6시에 영향을 받은 Zone2가 정체됨에 따라 선택된 도로는 오전 7시에 Zone2에 의해 영향을 받고 있다. Zone1은 오전 7시에도 선택된 도로의 정체 상황이 지속함에 따라 계속해서 영향을 받고 있다.

그림 4는 2020년 10월 2일 오전 0시의 교통 상황을 나타낸다. 이 시간대의 모든 도로는 교통량이 많지 않아 혼잡하지 않고, 원인 분석 결과도 나오지 않을 것으로 예상된다. 그러나 Zone3의 도로는 주변 도로보다 교통량이 많고 속도가 느린 것으로 관측되었다. 정보가 없는 상황에서 Zone3 안의 도로가 주변 도로에 어떤 영향을 미치는지 살펴보기 위해 혼잡전파 패턴 분석을 진행했다. 그림 3의 혼잡 전파 패턴은 Zone3가 주변 도로와 주고받는 영향을 나타낸다. Zone3의 도로는 이 도로로 접근하는 모든 도로에 영향을 미치고 있다. 이를 통해 Zone3의 도로 수용량을 초과하는 차량들이 Zone3으로 모이는 것을 유추할 수 있다. 이후 CCTV 스트리밍 영상을 통해 Zone3의 도로 수용량을 초과한 이유를 확인했다. 그림 4의 CCTV 스트리밍 영상에는 도로 중앙의 차선을 막고 진행중인 공사와 노면 상태가 열악한 Zone3가 나타나 있다. 이러한 이유로 Zone3에는 차량이

자유롭게 통과할 수 없었다. 위 과정을 통해 Zone3의 교통 체증의 원인을 병목 현상으로 규정할 수 있었다.

4. 데이터 보간 성능 평가

이 장은 GPS 데이터로 데이터 보완 알고리즘의 성능을 검증한다. 2.2장에서 GPS 데이터로 CCTV가 관찰하지 않는 노드 데이터를 완성하는 알고리즘을 소개했다. 대부분의 연구는 속도 예측에 적용된 알고리즘을 평가하기 위해 METR-LA 및 PEMSBAAY와 같은 VD(Vehicle Detector) 공용 데이터 세트를 활용한다. 하지만 VD는 대부분 고속도로에 설치되어 있으며, 이 논문에서는 도시 교통망에 대해 다루기 때문에 네트워크 모델링에 VD를 사용하지 않고 도심지역 CCTV 카메라 20대에서 수집한 스트리밍 영상 데이터를 활용한다. 따라서 이 논문에서 사용한 기법을 평가하기 위해 공개적으로 사용 가능한 데이터 집합을 얻기는 쉽지 않다. 스트리밍 CCTV 비디오는 2.1장에서 설명한 차량 흐름 추출 기법을 사용하여 각 교차로 노드의 트래픽 데이터로 변환된다. 본 논문에서는 서울 교통망을 모델링 하기 위해 62개의 교차로 노드를 선택하고 5분마다 데이터를 수집했다. 보충을 위한 GPS 데이터는 TOPIS [13]에서 제공하는 택시 GPS 센서의 평균 속도 데이터이다. 이 데이터는 5분마다 서울의 모든 도로의 평균 속도를 담고 있다. 본 논문에서는 보완 성능을 측정하기 위해 점차적으로 특정 비율의 노드 트래픽 흐름 데이터를 제거하고, 이 부분을 해당 시간의 GPS 평균 속도로 대체한다. 노드의 데이터 삭제 비율은 0%에서 90%까지 10% 단위로 증가시켜 실험을 진행한다. 보완된 데이터의 신뢰성을 평가하기 위해 DCRNN(Diffusion Convolutional Recurrent Neural Network) [14]을 적용하여 향후 트래픽 흐름 예측의 정확성을 검증했다. DCRNN은 시공간 그래프 데이터의 확산을 이용해 교통 예측이 가능한 딥러닝 모델이다. 본 논문에서는 제거한 노드의

표 1 보간된 노드에 대한 예측 정확도

Table 1 Prediction error comparison as the supplemented node ratio

ratio(%)	0	10	20	30	40
MAPE	11.47%	11.1%	11.76%	10.98%	11.18%
RMSE	3.54	3.33	3.36	3.4	3.43
ratio(%)	50	60	70	80	90
MAPE	12.53%	10.86%	10.75%	10.91%	12.73%
RMSE	3.74	3.35	3.32	3.36	3.83

교통 흐름 데이터를 GPS 흐름 평균 속도 데이터로 대체하고 이를 학습한 DCRNN 모델의 예측 정확도를 제거된 노드의 비율별로 비교했다. RMSE(Root Mean Square Error) 및 MAPE(Mean Absolute Percentage Error)를 사용하여 예측 정확도를 측정한다.

표 1에서 0%에 대한 MAPE 값과 RMSE 값은 GPS 데이터로 보완하지 않을 때 DCRNN 트래픽 흐름 예측의 정확도를 의미한다. CCTV 스트리밍 비디오에서 추출된 트래픽 흐름 데이터를 이용한 트래픽 네트워크의 DCRNN 예측은 11.47% MAPE와 3.54 RMSE를 가지고 있다.

CCTV 영상의 정확한 속도가 아닌 평균 속도로 보완 되었음에도 불구하고 모든 정확도가 노드 데이터를 제거하지 않았을 때와 크게 다르지 않음을 알 수 있다. 표 1에서 50%, 90%의 RMSE와 MAPE는 0%보다 높다. 대부분의 경우 오차는 0%보다 낮다. 50%와 90%의 오차는 다른 경우보다 높게 나타난다. 그러나 이러한 값 간의 차이는 다른 경우에 나타나는 차이는 유의하지 않다. 불충분한 CCTV 영상으로 인한 흐름 데이터 누락이 GPS나 VD 데이터 등 보조 데이터로 보완되더라도 예측 DCRNN에서는 성능 저하가 없음을 알 수 있다.

5. 결론

본 논문에서는 CCTV 영상을 이용해 교통 흐름을 추출하고, 이를 사용해 교통 네트워크를 모델링했다. CCTV로부터 교통 흐름을 추출하기 위해 YOLOv3와 SORT 모델을 사용했으며, 추출된 교통 흐름 데이터와 도로망 데이터를 사용해 교통 네트워크 모델을 완성했다. 교통 네트워크 모델에 granger 테스트를 시행해 정체 간 전과 인과 관계를 분석했다. CCTV 스트리밍 영상이 준비되지 않았을 때 GPS를 활용한 평균 속도 데이터로 결측 데이터를 보간했으며, DCRNN을 활용해 이 작업이 교통량 예측 및 인과 관계 분석에 유의미한 영향을 끼치지 않는 것을 확인했다.

References

[1] Z. Wang, M. Lu, X. Yuan, J. Zhang, and H. Van De Wetering, Visual traffic jam analysis based on

trajectory data, *IEEE transactions on visualization and computer graphics*, 19(12):2159–2168, 2013.

[2] M. Pi, H. Yeon, H. Son, and Y. Jang, Visual cause analytics for traffic congestion, To appear in *IEEE Transactions on Visualization and Computer Graphics*, 2019.

[3] K. Wada, K. Usui, T. Takigawa, and M. Kuwahara, An optimization modeling of coordinated traffic signal control based on the variational theory and its stochastic extension, *Transportation Research Procedia*, 23:624–644, 2017.

[4] X. Di, Y. Xiao, C. Zhu, Y. Deng, Q. Zhao, and W. Rao, Traffic congestion prediction by spatiotemporal propagation patterns, *2019 20th IEEE International Conference on Mobile Data Management (MDM)*, pp. 298–303, IEEE, 2019.

[5] Z. Shan, Z. Pan, F. Li, and H. Xu, Visual analytics of traffic congestion propagation path with large scale camera data, *Chinese Journal of Electronics*, 27(5):934–941, 2018.

[6] H. Piringer, M. Buchetics, and R. Benedik, Alvis: Situation awareness in the surveillance of road tunnels, *2012 IEEE Conference on Visual Analytics Science and Technology (VAST)*, pp. 153–162, IEEE, 2012.

[7] L. Xin, D. Yang, Y. Chen, and Z. Li, Traffic flow characteristic analysis at intersections from multi-layer spectral clustering of motion patterns using raw vehicle trajectory, *2011 14th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, pp. 513–519, IEEE, 2011.

[8] C. Liu, D. Q. Huynh, Y. Sun, M. Reynolds, and S. Atkinson, A vision based pipeline for vehicle counting, speed estimation, and classification, *IEEE Transactions on Intelligent Transportation Systems*, 2020.

[9] Y. Liang, Z. Jiang, and Y. Zheng, Inferring traffic cascading patterns, *Proc. of the 25th acm sigspatial international conference on advances in geographic information systems*, pp. 1–10, 2017.

[10] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, You only look once: Unified, real-time object detection, *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 779–788, 2016.

[11] A. Bewley, Z. Ge, L. Ott, F. Ramos, and B. Uppcroft, Simple online and realtime tracking, *2016 IEEE International Conference on Image Processing (ICIP)*, pp. 3464–3468, 2016.

[12] M. Stein, H. Janetzko, A. Lamprecht, T. Breitkreutz, P. Zimmermann, B. Goldlucke, T. Schreck, G. Andrienko, M. Grossniklaus, and D. A. Keim, Bring it to the pitch: Combining video and movement data to enhance team sport analysis, *IEEE transactions on visualization and computer graphics*, 24(1):13–22, 2017.

- [13] Seoul Transport Operation and Information Service, Seoul traffic cameras. <https://topis.seoul.go.kr/>. Accessed: 2021-03-31.
- [14] Li, Yaguang and Yu, Rose and Shahabi, Cyrus and Liu, Yan, Diffusion Convolutional Recurrent Neural Network: Data-Driven Traffic Forecasting, International Conference on Learning Representations, 2018.



박 기 응

2021년 세종대학교 컴퓨터공학과 졸업(학사). 2021년~현재 세종대학교 석사과정
관심분야는 기계학습, 데이터시각화




연 한 별

2012년, 2014년, 2019년 세종대학교 컴퓨터공학과 졸업(학사, 석사, 박사). 관심분야는 기계학습, Visual Analytics, 데이터시각화



문 예 완

2017년~현재 세종대학교 컴퓨터공학과 학사과정. 관심분야는 기계학습, 데이터시각화



장 윤

2000년 서울대학교 전기공학부 졸업(학사)
2002년, 2007년 미국 Purdue University ECE 졸업(석사, 박사). 2007년~2009년 Swiss National Supercomputing Center 박사 후 연구원. 2009년~2011년 Swiss ETH Zurich 박사 후 연구원. 2012년~현재 세종대학교 컴퓨터공학과 교수. 관심분야는 데이터 시각화, Visual Analytics, 빅데이터 분석 및 시각화, 컴퓨터 그래픽스