

# 시계열 교통량 정보의 2차원 이미지화를 통한 저복잡도 CNN 기반 예측 모델

변정훈, 조오현

충북대학교

JHByun@chungbuk.ac.kr, ohyunjo@chungbuk.ac.kr

## Low Complexity CNN Model by Using 2D Imaging of Time Series Traffic Data

Jung Hun Byun, Ohyun Jo

Chungbuk National University

### 요약

본 논문에서는 학습 모델의 복잡도와 연산량 감소를 위해 시계열 교통량 정보를 2차원 이미지로 변환하여 CNN(Convolutional Neural Network) 기술에 적용한다. CNN은 2차원 이미지 데이터에 대하여 적은 자원으로 데이터의 특징을 찾아내는 유용한 방법이다. 방대한 시계열 데이터를 축적한 현대에 같은 양의 데이터를 적은 자원으로 학습하면서 정확한 예측을 위한 모델이 필요하다. 교통량 예측 모델은 예측하고자 하는 구간으로 들어가는 다른 모든 구간의 시계열 데이터를 모아서 2차원 이미지로 변환하고, 학습한다. 제안하는 예측 모델은 특정 위치에서의 평균 이동 속도를 예측하며 5km/h 이내의 오차로 차량의 이동 속도를 예측할 수 있는 정확도는 50.6%이며, 평균 예측 오차는 6.6km/h 정도로 매우 높은 정확도를 나타낸다.

### I. 서론

최신 다양한 ICT 기술의 융합과 접목을 통한 도로 교통량의 정확한 예측은 더 나은 차량 동선을 선택할 수 있게 해주고 교통 혼잡, 배기가스 배출, 이동시간 등을 줄이는 데 큰 도움이 된다.[1] 이미 시계열 교통량 정보를 학습하기 위해 머신러닝을 적용한 다양한 연구가 진행되고 있고, 그 중 RNN(Recurrent Neural Network), LSTM(Long Short-Term Memory models)은 대표적인 시계열 학습 머신러닝과 더불어 인공신경망(Artificial Neural Network, ANN), ARIMA 등의 다양한 시계열 자료 예측 기법도 교통량 예측에 이용되고 있다[2,3]. 지능형 교통 체계(Intelligent Transportation Systems, ITS)가 적용됨으로써 많은 양의 교통자료를 쉽게 획득하여 머신러닝 기술 적용 연구가 활발히 진행되고 있다.

CNN(Convolutional Neural Network)은 2차원 데이터에서 특징을 찾아내며 적은 매개변수로 학습될 뿐만 아니라 그 성능도 우수함이 입증되었다. 본 논문에서는 이러한 CNN 모델의 우수한 성능을 사용하기 위해 시계열 교통량 정보를 2차원으로 이미지화한 뒤 교통량을 예측하는 방법을 제안한다. 도로의 교통량을 예측하기 위해서 연결된 다른 도로들의 시계열 교통량 정보가 사용된다.

### II. 본론

#### A. 데이터 전처리

교통량 예측 모델의 학습에는 공공데이터 포털의 부산광역시 지능형 교통정보가 사용되었다. 데이터는 부산광역시 교통정보서비스센터에서 운영 중인 DSRC(Dedicated Short Range Communications) 기반의 교통 정보 수집 장치를 통해 수집되었고, 구간별로 5분마다 속도를 제공한다.

교통량 예측은 일반적으로, 특정 시간대( $t$ )까지의 데이터를 이용해서 미래( $t+m$ )의 교통량을 추정한다. CNN 모델에 시계열 데이터를 적용하기 위해서는 데이터의 전처리 과정이 필요하다. 학습을 위한 시계열 데이터 2차원 이미지화에는 예측하고자 하는 구간과 연결된 다른 모든 구간의 시계열 데이터를 전부 사용한다. 다른 구간들의 시계열 데이터는 시간대( $t-n$ )에서 시간대( $t$ )까지의 데이터를 하나의 이미지로 픽셀화 하여 처리한다. 시계열 데이터의 2차원 이미지화는 그림 1과 같다.




그림 1. 시계열 교통량 정보의 2차원 이미지화

그림 1에서 한 이미지의 x축은 시계열 데이터의 길이( $n$ )이고, 다른 구간의 개수는 y축이 된다. 또한, 각 이미지의 라벨은 예측하고자 하는 구간 시계열 데이터 중에서 시간대( $t+m$ )에 해당하는 값을 정규화하여 사용한다. 학습에 사용된 데이터는 구간별 5분 평균속도를 총 6가지로 분류하였

고, 더 나은 학습을 위해 학습 데이터와 검증 데이터는 라벨이 골고루 분배될 수 있도록 8:2의 비율로 나누어 사용한다.

### B. 학습 모델




그림 2. 2차원 이미지화 된 시계열 교통량 정보를 학습하기 위한 CNN 모델 구조

교통량 예측 모델에서 사용하는 CNN 모델은 그림 2와 같이 하나의 Convolutional 계층과 하나의 Max pooling 계층으로 구성되어있다. Pooling size는 2\*2 크기로 함으로써 전체 데이터의 양을 1/4로 줄여준다. 그리고 학습 최적화를 위해 2차원 이미지의 x축 길이(n)와 라벨로 사용되는 시간대(t+m)의 가까운 미래(m)의 값을 각각 25분~100분, 5분~50분의 범위에서 변화를 준다.

### III. 성능 평가




그림 3. CNN 모델 시뮬레이션 결과(정확도).

CNN 모델의 성능 평가를 위한 시뮬레이션은 많이 알려진 파이썬 머신러닝 라이브러리 Keras를 사용하였다. 학습 결과는 그림 3과 같다. n 값은 2차원 이미지를 만들 때 시간대(t)부터 과거의 데이터를 얼마나 사용할지 결정한다. 그리고 m 값은 시간대(t)로부터 얼마나 먼 미래를 예측할지 결정한다. 시뮬레이션에서 가장 높은 정확도는 5km/h 이내의 오차 범위 내

에서 50.6%가 나왔으며 이것은 시간대(t)를 기준으로 과거 55분까지의 데이터를 사용해 학습한 모델이 미래 30분 후를 예측한 경우 가장 정확한 예측을 한다는 의미이다.

또한 예측 모델의 성능은 평균 예측 오차값으로 평가가 가능한데, 이는 예측값( $P_i$ )과 실제값( $R_i$ ) 사이의 차이로 구할 수 있다. 예측 모델이 예측한 횟수를  $N$ 이라고 했을 때  $i$ 는 몇 번째의 예측인지를 알려준다.  $R_i$ 는  $i$ 번째 샘플 데이터의 실제값이고,  $P_i$ 는  $i$ 번째 샘플에 대한 예측값이다.  $P_i$ 와  $R_i$ 는 속도를 10으로 나눈 몫이기 때문에  $R_i$ 와  $P_i$ 의 차이는 1당 10km/h의 오차를 의미한다.  $R_i$ 와  $P_i$ 의 차이에 10을 곱하면  $i$ 번째 예측의 오차를 알 수 있다. 예측 모델의 평균 예측 오차는  $N$ 번의 모든 오차를 더한 뒤  $N$ 으로 나누면 구할 수 있다. 평균 예측 오차율은 식 1과 같이 구해진다.

$$\frac{\sum_{i=1}^N |P_i - R_i| * 10}{N} \quad (1)$$

제안하는 방법은 평균 예측 오차가 6.6km/h 로 매우 높은 정확도를 나타내었다. 또한, 예측 결과가 실제 속도와 10km/h 내의 차이를 보일 확률이 90% 이상으로 나타났으며 실시간 학습과 예측이 가능하도록 복잡도가 낮은 모델을 적용하였음에도 불구하고 매우 우수한 성능을 나타내었다. 제안하는 CNN 예측 모델은 2차원 이미지화를 할 때의 정렬 방법에 다양한 알고리즘을 적용함으로써 더 좋은 결과를 기대할 수 있다.

### III. 결론

본 논문에서는 시계열 교통량 데이터를 2차원 이미지로 변환하고, CNN 모델에 학습시킴으로써 다른 시계열 머신러닝 기술보다 자원을 아끼며 우수한 성능을 보이는 교통량 예측 모델을 제안한다. CNN 모델의 Max pooling 계층을 한번 사용함으로써 사용되는 파라미터를 1/4로 줄여 학습할 수 있고, 5km/h 오차 기준 예측 정확도는 50.6%이다. 또한, 모델의 평균 예측 오차는 6.6km/h 로 측정되었다.

### ACKNOWLEDGMENT

이 논문은 2020년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. 2020R1A6A1A12047945)

### 참 고 문 헌

- [1] Lv, Yisheng, et al. "Traffic flow prediction with big data: a deep learning approach." IEEE Transactions on Intelligent Transportation Systems 16.2 (2014): 865-873.
- [2] Stathopoulos, Anthony, and Matthew G. Karlaftis. "A multivariate state space approach for urban traffic flow modeling and prediction." Transportation Research Part C: Emerging Technologies 11.2 (2003): 121-135.
- [3] Vlahogianni, Eleni I., Matthew G. Karlaftis, and John C. Golias. "Optimized and meta-optimized neural networks for short-term traffic flow prediction: A genetic approach." Transportation Research Part C: Emerging Technologies 13.3 (2005): 211-234.