

긴 시간의 교통 흐름 예측을 위한 컨볼루션 어텐션 모델

최병진*, 이민우*, 정교민^o

Convolution-Attention Model for Long-Term Traffic Forecasting

Byeongjin Choe*, Minwoo Lee*, Kyomin Jung^o

요약

교통 흐름을 예측하는 것은 현대 도시의 중요한 문제 중 하나이며, 이에 교통 흐름의 예측을 위하여 다양한 모델들이 연구되어왔다. 그러나 교통 흐름을 예측하는 문제는 시간적인 특성과 공간적인 특성을 모두 고려해야 하기 때문에 해결하기에 복잡한 문제이다. 최근 들어서는 시계열 구조와 그래프 구조를 같이 활용하는 뉴럴 네트워크 모델들이 새롭게 떠오르고 있다. 그러나 이전의 많은 연구들은 짧은 시간의 예측을 주로 다루었고, 긴 시간의 교통 흐름을 예측하는 데 어려움이 있었다. 이를 개선하여 짧은 시간 뿐만 아니라 긴 시간의 예측 성능을 같이 고려하기 위하여, 본 논문에서는 dilated causal convolution 구조와 attention 구조를 결합한 새로운 모델을 제시한다. 실제 데이터를 이용한 교통 흐름 예측 실험을 통해 본 논문에서 제시한 모델이 이전의 dilated causal convolution-based models 및 attention model과 비교하여 짧은 시간 및 긴 시간의 예측에서 모두 효과적임을 보여준다.

Key Words : Time Series, Traffic forecasting, Neural Networks, Convolutional Neural Networks, Attention model

ABSTRACT

In modern cities, traffic forecasting is one of the important problems, and various models have been studied to predict traffic flow. However, the traffic forecasting problem is a complex problem in that both temporal and spatial properties must be considered. Accordingly, various spatio-temporal neural network models which consider the two properties together are emerging recently. However, many previous studies have difficulty predicting long-term time series traffic flow. To improve predictive performance in the long-term, we build a model based on a dilated causal convolution and an attention model. We show that our model is effective for long-term prediction through experiments on real-world datasets. Experimental results show better performance than previous models such as dilated causal convolution-based models and attention models in long-term traffic forecasting.

1. 서론

차량이 현대사회의 필수품으로 자리잡은 이후로,

교통 데이터를 활용하여 차량의 흐름을 예측하는 교통 흐름 예측 (traffic forecasting) 문제는 항상 중요한 문제로 여겨졌다. 교통 흐름 예측을 위해 활용되는 교

* 본 연구는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2021R1A2C2008855)

• First Author : Seoul National University Department of Electrical and Computer Engineering bjchoe@snu.ac.kr, 학생회원

◦ Corresponding Author : Seoul National University, Department of Electrical and Computer Engineering, ASRI kjung@snu.ac.kr, 정회원

* Seoul National University Department of Electrical and Computer Engineering minwoolee@snu.ac.kr, 학생회원

논문번호 : 202111-324-C-RU, Received November 24, 2021; Revised December 11, 2021; Accepted December 13, 2021

통량 데이터의 중요한 특징 중 하나는 시간에 따라 변하며 과거가 현재에 영향을 끼치는 time series 데이터라는 것이다. 즉, 매시간 교통량이 독립적인 데이터가 아니라, 예를 들어 30분 전의 교통량부터 5분 전까지 교통량 데이터가 증가 추세를 보였다면 일반적으로 현재의 교통량 또한 더욱 증가한 값을 나타내는 등, 과거의 정보와 현재의 정보가 연관관계를 가진다.

이에 따라 어떠한 지점의 과거 교통 정보를 활용하여 미래의 교통 정보를 예측하고자 하는 연구들이 많이 이루어졌다. 그러나 시간적 특성만을 고려한 연구들은 교통량 데이터의 또 다른 주요한 특징인 그래프 구조를 반영하지 못하였다. 교통 정보는 한 지점에 국한되지 않고 여러 지점에서 측정되며, 서로 네트워크의 형태로 연결되어있다. 또한 한 지점의 교통량은 네트워크(도로)로 연결된 다른 지점의 교통량에 영향을 끼친다. 최근에 Graph Neural Network (GNN)가 활발하게 연구되기 시작하면서, 이를 time series 데이터에도 활용하여 그래프 구조를 반영한 교통 흐름 예측 연구들이 나타났다.

이러한 그래프 구조와 time series 데이터를 결합한 spatio-temporal 데이터에 대한 neural network 모델을 개발하는 많은 연구들은 직후의 교통량이 어떻게 될 것인가에 초점을 맞추었다. 일반적으로 이들 연구의 예측 시간 범위는 한 시간 이내로 국한되어있었다. 그러나 이러한 연구들은 먼 미래를 예측할 경우 예측에 따른 에러가 누적되는 문제가 발생하는 등의 이유로 예측력이 떨어지는 경우가 많았다. 이 문제를 해결하기 위하여, Attention을 활용하는 모델^[1]도 제시되었으나, 반대로 짧은 시간 간격에서 정확성이 상대적으로 떨어졌다.

이에 본 연구에서는 dilated causal convolution과 attention을 같이 활용하여 짧은 시간 (short-term), 긴 시간 (long-term) 모두에서 좋은 성능을 내는 모델을 개발하였다. 본 논문에서 제시하는 convolution-attention model은 입력으로 들어오는 time series data를 dilated causal convolution을 통하여 과거 정보의 인과 관계가 반영된 정보로 바꾸어낸다. 그리고 이를 활용하여 긴 시간을 동시에 예측하기 위해서는 attention 구조를 사용하였다.

실험 결과는 본 논문에서 제시하는 모델이 특히 긴 시간에서 이전의 convolution 기반 모델과 비교해서 교통 정보 예측의 정확성이 향상되었다는 것을 보여 주었다. 이는 예측 범위가 길어질수록 두드러지게 나타났다. 또한, 짧은 시간에서도 attention 기반 모델과 비교하여 향상된 것을 확인할 수 있었다. 본 논문에서

제시한 모델의 각 부분의 역할을 확인하기 위한 ablation study 또한 진행하였다. 실험을 통하여 dilated causal convolution은 짧은 시간의 예측에, attention 구조는 긴 시간의 예측에 큰 영향을 끼친다는 것을 보였다.

본 논문의 구성은 다음과 같다. 2장에서는 time series와 그래프를 다룬 관련 연구를 살펴본다. 3장에서는 본 논문에서 풀고자 하는 문제가 무엇인지에 대하여 설명한다. 4장에서는 본 논문에서 문제를 풀기 위하여 제시하는 convolution-attention 모델과, 그 모델을 구성하는 구조들에 대하여 살펴본다. 5장에서는 제시한 모델을 실제 교통 흐름 데이터에 적용하여 진행한 실험 결과와 이에 대한 분석을 진행하며, 마지막으로 6장에서 결론을 도출한다.

II. 관련 연구

Time series data의 예측을 위하여 전통적으로는 통계학을 기반으로 한 방법들이 많이 연구되어왔다. 대표적으로 autoregressive integrated moving average (ARIMA) 기반 방법^[2]이 있으며, vector autoregressive models (VAR)^[3]이나 support vector machine (SVM)을 이용한 방법^[4]도 제시되었다. Deep learning의 발달과 함께, 예측에 neural net을 사용하는 연구들도 등장하였다. Recurrent neural network (RNN)은 과거의 상태와 현재 입력 정보를 계산하여 새로운 현재의 상태를 계산하고, 이를 반복하여 순환시키는 neural network 구조로, 순차 데이터에 적합한 형태의 구조이다. 이는 순차 데이터를 활용하는 언어 모델^[5] 혹은 음성 모델^[6] 등에 유용하게 사용되었으며, time series data의 예측에도 RNN을 활용한 방법들이 연구되었다.

그리드 형태의 데이터에 특화된 컨볼루션 연산과 이로 이루어진 CNN 레이어를 활용하여 인접한 다른 지점의 정보를 활용하는 방법도 연구되었다^[7]. 그러나, 이러한 방법은 그래프 형태의 연결 정보를 표현하는데 한계가 있다. 따라서 그래프 구조 위에서 정보를 처리할 수 있는 GNN이 제시됐다. 대표적으로 Graph Convolution Network (GCN)^[8,9]는 그래프를 이루는 노드 정보가 고차원 embedding으로 주어졌을 때, 각 노드마다 그래프 위에서 옛지로 연결된 다른 인접 노드들의 embedding을 모으는 message 함수와, 모아진 정보를 통해 새로운 embedding을 출력하는 update 함수를 통해 입력 그래프 데이터를 처리한다. GCN의 연산 과정에서 노드 정보가 연결된 그래프 구조에 따

라 흐르기 때문에 그래프 구조가 자연스럽게 출력값에 부호화되는 특징을 가진다. 따라서 교통 정보 예측과 같이 주어진 데이터 속 그래프의 구조가 예측에 중요한 정보를 담고 있는 문제에서 GCN을 비롯한 그래프 인공지능망 모델이 활발히 활용되고 있다.

GNN에 시간적인 정보를 결합하여 교통 정보와 같은 time series 데이터에 대한 예측을 수행하는 연구들은 DCRNN^[10] 이래로 연구되기 시작하였다. DCRNN에서는 diffusion convolution과 RNN을 같이 사용하여 지역적인 그래프 정보와 시간적인 정보를 같이 다룰 수 있도록 하였다. DCRNN 이후로 STGCN, STDN^[11,12] 등의 연구들 또한 graph convolution을 활용하여 그래프 구조를 다루는 time series 연구를 진행하였다. Graph Wavenet^[13]에서는 dilated causal convolution을 time series를 다루는 데 활용하여 spatial-temporal 데이터를 다루고자 하였다.

III. 문 제

교통 흐름 데이터는 여러 곳의 관측 지점으로부터 측정되는 일정 시간 간격의 교통 정보를 의미한다. 교통 정보는 평균 차량 속도, 통과한 차량 대수 등의 정보를 포함한다.

교통 데이터를 수집하는 관측 지점들은 특정 장소에 위치하는 것으로, 이들 간에는 물리적인 연관관계가 존재한다. 이 연관관계는 도로 교통망 혹은 물리적인 거리 등으로 생각할 수 있다.

이 관측 지점들과 이들의 지리적 연관관계는 각각 노드와 엣지로 보아 그래프 $G=(V,E,A)$ 로 나타낼 수 있다. 여기서 노드의 개수, 즉 관측 지점의 개수 $|V|=N$ 이다. 이 그래프 구조는 시간에 따라 변하는 구조가 아닌 공간적인 고정된 구조이다.

여기서 각각의 관측 지점이 수집하는 교통 흐름 정보는 시간에 따라 변하는 하나의 time series 데이터이다. 따라서 전체 교통 흐름 정보 데이터는 N 개의 병렬적인 time series라고 할 수 있으며, C 가 각 지점에서 수집되는 교통 정보의 종류 개수라고 할 때, 시간 t 에서의 교통 흐름 정보는 $X^t \in \mathbb{R}^{N \times C}$ 로 표현할 수 있다.

본 논문에서 풀고자 하는 문제는 관측 지점의 공간적 정보인 그래프 G 와 시간적 정보인 이전의 P 시간 스텝의 교통 흐름 정보인 $(X^{t-P+1}, X^{t-P+2}, \dots, X^t)$ 가 주어졌을 때, 아직 일어나지 않은 Q 시간 스텝의 교통 정보 $(X^{t+1}, X^{t+2}, \dots, X^{t+Q})$ 를 예측하는 문제이다.

IV. 모 델

그림 1은 본 논문에서 제시하는 모델인 convolution-attention model의 구조를 나타낸다. Convolution-attention model은 크게 convolution 부분과 attention 부분, 두 부분으로 나누어 짧은 시간과 긴 시간의 교통 정보 예측을 모두 효과적으로 수행할 수 있도록 한다. 윗 부분에 해당하는 transform attention 및 decoder attention 부분에서는 시간적인 정보를 다룰 때, 먼 과거의 정보까지도 한번에 attention하며, 긴 기간을 동시에 예측함으로써 긴 시간의 교통 정보 예측을 효과적으로 수행할 수 있다. 긴 시간을 효과적으로 고려하는 Attention 구조에서 오히려 소홀해질 수 있는 짧은 시간의 시간적 의존 관계는 attention을 수행하기 전에 dilated causal convolution 구조를 통해 사전에 인코딩하여 다룬다. Dilated causal convolution 구조 부분에서는 현재의 정보 뿐만이 아니라 일정 거리만큼 떨어진 과거의 정보를 같이 고려하여 교통 정보 time series 데이터를

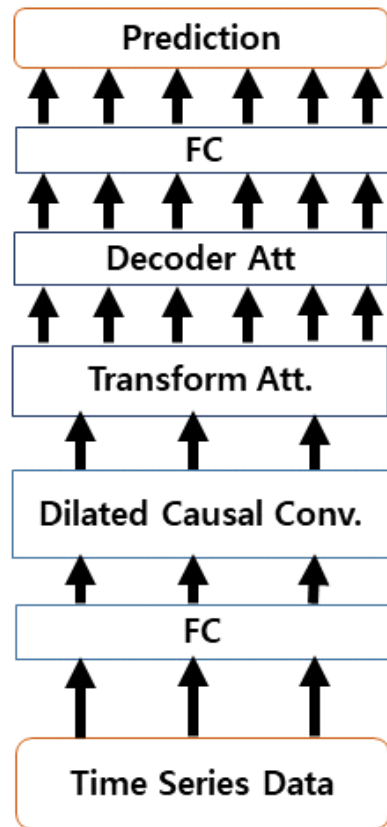


그림 1. 모델 구조
Fig. 1. Model architecture

인코딩함으로써 시간적인 의존 관계, 특히 짧은 시간 사이의 관계를 파악하여 반영한다. 4.1과 4.2에서는 짧은 시간과 긴 시간의 예측 모두를 고려하기 위해 사용한 두 부분에 대하여 자세한 설명을 제시한다.

4.1 Dilated Causal Convolutions

Dilated causal convolution은 음성 생성 모델인 wavenet^[14]에 사용되었던 구조로, time series의 형태로 이루어진 데이터에서 시간적인 의존 관계(temporal dependency)를 효과적으로 잡아내기 위한 convolution 구조의 한 형태이다.

Convolution 구조는 특정 위치의 출력 값을 얻기 위하여 넓은 범위의 convolution filter를 사용하여 주변 변의 정보를 종합한다. 기본적인 convolution 구조를 time series 데이터에 적용하면 시간 t 에 대한 출력 값을 얻기 위하여 시간 스텝 $t-w$ 부터 $t+w$ 까지의 입력 정보를 활용하여 convolution filter를 적용하는 구조이다. 그러나 이러한 구조는 시간 t 로부터 미래의 시간 정보까지 활용하는 구조로, 본 논문에서 풀고자 하는 문제와 같이 미래의 정보가 주어지지 않은 상황에서 시간적인 의존 관계를 활용하여 미래의 결과를 예측하는 문제에서는 활용하기 부적합한 구조이다. Causal convolution 구조는 이러한 문제를 해결하기 위한 구조로, 그림 2와 같이 시간 t 에 대한 출력값을 얻기 위하여 시간 t 이후의 시간에 대한 입력 정보를 활용하지 않고, 시간 t 와 그 이전 시간들의 입력 정보만 활용한다. 즉, convolution filter의 크기가 w 일 경우 시간 $t-w+1$ 부터 t 까지의 정보를 활용한다. 계




그림 2. 인과 컨볼루션 구조
Fig. 2. Causal Convolution




그림 3. 확장 인과 컨볼루션 구조
Fig. 3. Dilated Causal Convolution

층이 2개일 경우, 2번째 계층에서 입력받는 $t-w+1$ 의 값은 1번째 계층에서 시간 $(t-w+1)-(w+1)$ 부터 $t-w+1$ 까지의 정보를 활용해 얻어진 출력값이 되어 계층이 1개일 때보다 더 과거의 정보를 활용할 수 있게 된다.

dilated causal convolution은 그림 3과 같은 모양의 구조로, causal convolution과 같은 계산량으로 더 넓은 범위의 시간 정보를 활용할 수 있도록 한다. 이를 위하여 계층의 높이가 높아질수록 입력받는 데이터의 시간 간격을 늘린다. 1번째 계층의 입력의 시간 스텝 간격은 $d^{(l-1)}$ 로 주어지며, 본 논문에서는 $d=2$ 이다.

4.2 Attention

미래의 정보를 예측함에 있어서 바로 다음 시간 스텝의 값을 예측하는 구조를 사용할 경우, 먼 시간의 결과를 예측하기 위해서는 이전 시간의 예측값 또한 입력으로 사용하여 예측을 수행하여야 한다. 이러한 경우, 점점 더 먼 시간의 결과를 예측할수록 이전 시간의 예측 결과의 오차가 누적되어 오차가 더욱 커지는 현상이 발생한다. Transform attention 및 spatio-temporal attention은 이를 해결하기 위하여 GMAN^[1]에서 제시된 Q 개의 시간 스텝을 동시에 계산하는 attention 기반으로 하는 구조이다.

Transform Attention에서는 그림 4와 같이 Dilated causal convolution에서 인코딩된 시간 스텝 P 개의 결과를 한 번에 활용하여 Q 개의 시간 스텝의 결과로 변환한다. Spatio-temporal attention (ST Attention)은 그림 4와 같이 transform attention에서 Q 개의 시간 스텝으로 변환된 결과를 활용하여 시계열과 그래프




그림 4. 변환 어텐션 구조와 공간적-시간적 어텐션 구조
Fig. 4. Transform Attention and Spatio-temporal Attention

구조를 같이 고려하여 길이 Q 의 예측 결과를 얻어낸다. ST Attention 구조는 spatial attention, temporal attention, 그리고 둘을 병합하는 gated fusion으로 구분된다. Spatial attention에서는 동일 시간의 그래프의 인접한 다른 노드의 값을 활용하여 attention 결과를 얻으며, temporal attention에서는 동일 노드의 과거 시간의 값들을 활용하여 attention 결과를 얻는다.

앞의 두 attention에서는 원래의 입력 값들 뿐만 아니라 spatial embedding과 temporal embedding을 합친 형태인 spatio-temporal embedding 또한 추가로 활용한다. 그래프 구조에서 노드들의 embedding을 spatial embedding은 node2vec^[15]을 기반으로 하여 노드들의 embedding을 얻어내며, temporal embedding은 요일 및 시간 정보를 one-hot encoding의 형태로 변환하여 이를 fully-connected neural network를 통하여 벡터 형태의 embedding을 얻어낸다.

V. 실험

5.1 데이터셋

본 논문에서는 실제 환경에서 수집된 교통 흐름에 대한 데이터셋인 METR-LA 데이터셋^[16]을 활용하여 실험을 진행하였다. 이 데이터셋은 로스앤젤레스 고속도로의 207개 센서에서 얻어진 데이터셋으로, 일정 기간의 교통 흐름 정보와 207개 관측 지점들의 지리적 정보를 포함하고 있다. 사용한 데이터셋은 2012년 3월부터 6월까지의 4개월간의 데이터를 포함하고 있으며, 측정 기간 동안 교통 정보의 측정 간격은 5분 간격으로 이루어졌다.

실험에서는 이 데이터셋을 시간 스텝을 기준으로 7:1:2의 비율로 분할하여 각각 train set, validation set, test set으로 사용하였다.

5.2 비교 모델 및 지표

본 논문에서는 비교를 위하여 널리 알려진 spatio-temporal 데이터를 다루는 모델인 Graph Wavenet 모델^[13]과 GMAN^[11]과 비교실험을 진행하였다. GMAN은 Attention에 기반한 딥러닝 모델로, Spatio-temporal Encoder, Transform attention, Decoder의 형태로 이루어져있다. Graph Wavenet은 graph convolution과 dilated causal convolution을 결합한 형태의 모델이다. 각 모델 연구에서는 1시간의 교통 정보 예측 결과를 사용하였지만, 본 논문의 실험에선 더 긴 시간의 예측 결과를 얻어내기 위하여 2시간 및 4시간 교통 정보 예측 결과를 사용하였다.

비교를 위한 평가 지표로는 평균 절대 오차 (MAE)와 평균 제곱근 오차 (RMSE)를 사용하였다. 예측된 속도에 대한 오차가 얼마나 되는지 확인하기 위한 가장 직관적인 지표인 평균 절대 오차와, 큰 오차에 가중치를 부여하는 평균 제곱근 오차를 같이 사용함으로써 오차의 평균과 분산 모두를 살펴볼 수 있도록 하였다.

5.3 실험 결과

표 1은 과거 1시간의 교통량 데이터를 바탕으로 앞으로의 2시간 교통량을 예측한 결과의 MAE와 RMSE를 담은 표로, 본 논문에서 제시하는 모델과 타 모델을 비교하였다. 데이터의 측정 간격이 5분 간격이므로, 관측한 시간 스텝 개수 $P=12$, 예측하는 시간 스텝 개수 $Q=24$ 이다. 모든 모델에서 기본적으로 더 먼 시간의 교통 정보를 예측하려고 할 때 오차가 더

표 1. 2시간 교통 정보 예측 결과 성능 비교
Table 1. 2 hours traffic forecasting results comparison

	Time (min)	Our	GMAN	Graph Wavenet
	MAE	15	2.96	3.06
30		3.24	3.30	3.12
60		3.56	3.56	3.54
90		3.71	3.71	3.78
120		3.82	3.81	3.96
RMSE	Time (min)	Our	GMAN	Graph Wavenet
	15	5.84	6.24	5.25
	30	6.64	6.89	6.28
	60	7.50	7.59	7.35
	90	7.88	7.94	7.94
120	8.09	8.14	8.32	

커지는 것을 확인할 수 있다.

실험 결과, 제시하는 모델은 GMAN과 비교하여 긴 시간인 120분에서의 오차는 비슷하며, 짧은 시간에서의 예측 오차를 줄인 것을 확인할 수 있었다. 또한, Graph Wavenet과 비교하면, 예측하려는 시간이 점점 더 멀어짐에 따른 성능 하락 폭이 작아 멀리 있는 시간의 예측 성능에서 우위에 있다는 것을 보여준다.

표 2는 예측 길이를 더욱 확장한 4시간($Q=48$)의 교통 정보를 예측하여 long-term 예측의 중요성을 높인 실험의 결과이다. 실험 결과, 모든 시간에서 GMAN과 비교하여 성능적 우위를 유지하는 것을 확인할 수 있다. 또한, Graph Wavenet과 비교하면 2시간 예측 실험보다 더 멀리 있는 시간에서 예측 오차가 더욱 확연히 줄어드는 것을 확인할 수 있다. 표 1과 2를 통하여 예측 길이가 확장될수록 본 연구의 모델의 긴 시간에서 성능적 우위가 뚜렷하게 나타나며, 짧은 시간에서의 예측 성능 또한 이전의 긴 시간을 고려한 모델보다 향상됨을 확인할 수 있다.

표 3은 제시한 모델에서 일부분을 제거하였을 때 어떻게 성능이 변하는가 비교한 내용을 담은 표이다. 이 실험 결과는 본 논문에서 제시하는 모델에서 어느 부분이 어느 시간 스텝의 예측 성능의 향상에 도움을 주는지 보여준다. 실험 결과, dilated causal convolution 부분을 제거하였을 경우, 상대적으로 긴

표 3. 2시간 교통 정보 예측 결과 모듈별 제거 비교
Table 3. 2 hours traffic forecasting ablation study

	Time (min)	Full	No Dilated	No
			Conv.	Decoder
MAE	15	2.96	3.03	2.98
	30	3.24	3.29	3.26
	60	3.56	3.57	3.57
	90	3.71	3.73	3.76
	120	3.82	3.84	3.91
RMSE	Time (min)	Full	No Dilated Conv.	No Decoder
	15	5.84	6.14	5.93
	30	6.64	6.84	6.73
	60	7.50	7.60	7.54
	90	7.88	7.98	7.98
	120	8.09	8.19	8.28

시간의 성능은 거의 차이가 나타나지 않지만, 15분 후, 30분 후 등 짧은 시간 후의 예측 결과의 성능이 하락하는 것으로 나타난다. 그리고, spatio-temporal decoder 부분을 제거하였을 경우 반대로, 짧은 시간 후의 예측의 평균 절대 오차는 0.02 이하로 적게 나타났지만, 예측하려는 시간이 120분으로 가장 길어진 경우, 예측의 MAE가 0.1로 커지는 것으로 나타난다. RMSE 또한 짧은 15분 예측에서는 dilated causal convolution을 제거하였을 때 성능이 더 크게 떨어지고, 120분 예측에서는 decoder 부분을 제거하였을 때 성능이 더 크게 떨어지는 것을 확인할 수 있다. 즉, convolution-attention 모델에서 convolution 부분은 짧은 시간, attention 부분은 긴 시간의 예측 정확성 향상에 크게 기여하고 있다. 따라서 본 연구에서 제시하는 모델은 attention 모델의 장점과 convolution 모델의 장점을 통합한 모델을 제시하였다고 할 수 있다.

표 2. 4시간 교통 정보 예측 결과 성능 비교
Table 2. 4 hours traffic forecasting results comparison

	Time (min)	Our	GMAN	Graph Wavenet
MAE	15	3.22	3.32	2.98
	30	3.43	3.50	3.40
	60	3.68	3.76	3.85
	90	3.8	3.89	4.10
	120	3.87	3.98	4.29
	180	3.94	4.08	4.52
	240	3.98	4.11	4.73
RMSE	Time (min)	Our	GMAN	Graph Wavenet
	15	6.55	7.01	5.70
	30	7.10	7.50	6.69
	60	7.74	8.14	7.60
	90	8.05	8.46	8.11
	120	8.21	8.66	8.47
	180	8.35	8.89	8.98
	240	8.41	8.94	9.34

VI. 결 론

본 논문에서는 시간적 정보와 공간적 정보를 모두 포함하는 데이터인 교통 흐름 데이터의 예측 성능을 향상시키는 딥러닝 모델을 개발하였다. 개발된 모델은 dilated causal convolution과 attention을 기반으로 하여 긴 시간의 예측에서 효과적일 수 있도록 설계하였다. 실험 결과는 개발된 모델이 실제 교통 흐름 데이터에서 효과적임을 보였다. 또한, 모델의 convolution 부분이 가까운 미래의 예측 성능 향상에 큰 영향을 주며, attention 부분이 먼 미래의 예측 성능에 영향을 더

많이 끼친다는 것을 보였다.

References

- [1] C. Zheng, X. Fan, C. Wang, and J. Qi, "Gman: A graph multi-attention network for traffic prediction," *AAAI Conf. Artificial Intell.*, pp.1234-1241, New York, USA, February 2020.
- [2] B. M. Williams and L. A. Hoel, "Modeling and forecasting vehicular traffic flow as a seasonal arima process: Theoretical basis and empirical results," *J. Transport. Eng.*, vol. 129, no. 6, pp. 664-672, 2003.
- [3] E. Zivot and J. Wang, "Vector autoregressive models for multivariate time series," *Modeling Financial Time Series with SPLUS*, pp. 385-429, 2006.
- [4] Y. Jeong, Y. Byon, M. M. Castro-Neto, and S. M. Easa, "Supervised weighting-online learning algorithm for shortterm traffic flow prediction," *IEEE Trans. Intell. Transport. Syst.*, vol. 14, no. 4, pp. 1700-1707, 2013.
- [5] T. Mikolov, M. Karafiat, L. Burget, J. Cernocky, and S. Khudanpur, "Recurrent neural network based language model," in *Proc. Annu. Conf. Int. Speech Commun. Assoc.*, pp. 1045-1048, 2010.
- [6] A. Graves, A. Mohamed, and G. Hinton, "Speech recognition with deep recurrent neural networks," in *Proc. IEEE Int. Conf. Acoustics, Speech, and Sign. Process.*, pp. 6645-6649, Vancouver, Canada, May 2013.
- [7] J. H. Byun and O. Jo, "Low complexity CNN model by using 2D imaging od time series traffic data," in *Proc. KICS Summer Conf.*, pp. 98-99, 2020.
- [8] M. Defferrard, X. Bresson, and P. Vandergheynst, "Convolutional neural networks on graphs with fast localized spectral filtering," in *Proc. Neural Inf. Process. Syst.*, pp. 3844-3852, Barcelona, Spain, December 2016.
- [9] T. N. Kipf and M. Welling, "Semi-supervised classification with graph convolutional networks," in *Proc. ICLR*, Toulon, France, April 2017.
- [10] Y. Li, R. Yu, C. Shahabi, and Y. Liu, "Diffusion convolutional recurrent neural network: Data-driven traffic forecasting," in *Proc. ICLR*, Vancouver, Canada, May 2018.
- [11] B. Yu, H. Yin, and Z. Zhu, "Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting," in *Proc. Int. Joint Conf. Artificial Intell.*, pp. 3634-3640, Stockholm, Sweden, July 2018.
- [12] H. Yao, X. Tang, H. Wei, G. Zheng, and Z. Li, "Revisiting spatial-temporal similarity: A deep learning framework for traffic prediction," in *Proc. AAAI Conf. Artificial Intell.*, pp. 5668-5675, Honolulu, USA, January 2019.
- [13] Z. Wu, S. Pan, G. Long, J. Jiang, and C. Zhang, "Graph wavenet for deep spatial-temporal graph modeling," in *Proc. Int. Joint Conf. Artificial Intell.*, pp. 1907-1913, Macao, China, August 2019.
- [14] A. van den Oord, S. Dieleman, H. Zen, K. Simonyan, O. Vinyals, A. Graves, N. Kalchbrenner, A. Senior, and K. Kavukcuoglu, "Wavenet: A generative model for raw audio," arXiv preprint arXiv:1609.03499, 2016.
- [15] A. Grover and J. Leskovec, "Node2vec: scalable feature learning for networks," in *Proc. 22th ACM SIGKDD Conf. Knowledge Discovery & Data Mining*, pp. 855-864, San Francisco, USA, August 2016.
- [16] H. V. Jagadish, J. Gehrke, A. Labrinidis, Y. Papakonstantinou, J. M. Patel, R. Ramakrishnan, and C. Shahabi, "Big data and its technical challenges," *Commun. ACM*, vol. 57, no. 7, pp. 86-94, 2014.

최 병 진 (Byeongjin Choe)



2014년 2월 : KAIST 전자공학과 졸업

2014년 3월~현재 : 서울대학교 전기정보공학부 석박통합과정

<관심분야> 머신러닝, 시계열 예측, 네트워크 분석

[ORCID:0000-0002-8357-7555]

정 교 민 (Kyomin Jung)



2003년 8월 : 서울대학교 수학과 졸업

2009년 6월 : Massachusetts Institute of Technology 수학과 박사

2009년~2013년 : KAIST 전산학과 교수

2013년~현재 : 서울대학교 전기정보공학부 교수

<관심분야> 머신러닝, 네트워크 분석, 자연어 처리

[ORCID:0000-0003-2547-7051]

이 민 우 (Minwoo Lee)



2018년 2월 : 연세대학교 글로벌융합공학부 졸업

2018년 3월~현재 : 서울대학교 전기정보공학부 석박통합과정

<관심분야> 머신러닝, 자연어 처리

[ORCID:0000-0002-6354-9311]