

## 딥러닝 알고리즘을 이용한 교통량 예측

# Traffic Volume Prediction Using Deep Learning Algorithms

정도영<sup>1</sup>, 한대철<sup>2\*</sup>

Doyoung Jung<sup>1</sup>, DaeCheol Han<sup>2\*</sup>

### 요약

이 연구는 딥러닝 기반의 다양한 알고리즘을 활용하여 교통량 예측 모델을 제안하고, 전통적인 예측 모델과의 성능 비교를 통해 딥러닝의 우수성을 입증하고자 하였다. 결과적으로, LSTM(Long Short-Term Memory) 모형이 가장 높은 예측 성능을 나타냈으며, 이는 기존 통계적 방법보다 더 정교한 예측이 가능함을 보여준다. 딥러닝 모델은 교통량 데이터를 효과적으로 분석할 수 있는 장점을 가지고 있으며, Spatio-Temporal Neural Networks와 같은 최신 기술이 교통량 예측에서의 가능성을 보여 주었다. 기존 통계적 방법은 교통 데이터의 비선형성과 복잡성을 충분히 설명하지 못했지만, 딥러닝 기법들은 이를 효과적으로 해결하여 예측 정확도를 높였다. 본 연구는 교통 관리 및 도시 계획에 기초 자료를 제공하며, 향후 외부 요인(예: 날씨, 이벤트 등)을 반영한 연구가 필요하다. 이러한 연구는 딥러닝 기반의 교통량 예측 모델이 실시간 교통 관리 시스템에 통합되어 교통 흐름을 효율적으로 조절하고 혼잡도를 줄이는 데 기여할 것으로 기대된다. 결론적으로, 본 연구는 딥러닝 기술의 교통량 예측 분야에서의 잠재력을 입증하였으며, 앞으로 다양한 알고리즘과 데이터 통합을 통해 예측 성능을 지속적으로 향상시켜야 한다.

핵심어 : 딥러닝, 교통량, 시계열, LSTM, 통계학습

### Abstract

This study proposes a traffic volume prediction model utilizing various deep learning algorithms and aims to demonstrate the superiority of deep learning through a performance comparison with traditional prediction models. As a result, the LSTM (Long Short-Term Memory) model exhibited the highest predictive performance, showing that it can achieve more refined predictions than existing statistical methods. Deep learning models have the advantage of effectively analyzing traffic volume data, and recent technologies such as Spatio-Temporal Neural Networks have shown promise in traffic volume prediction. While traditional statistical methods were unable to adequately account for the nonlinearity and complexity of traffic data, deep learning techniques effectively addressed these challenges, thereby improving prediction accuracy. This study provides foundational data for traffic management and urban planning, indicating the need for future research that incorporates external factors (e.g., weather, events, etc.). Such research is

1 Department of Highway and Transportation Research, KICT, Gyeonggi-do, Korea [Research Specialist]  
e-mail: jdy@kict.re.kr

2 Department of Highway and Transportation Research, KICT, Gyeonggi-do, Korea [Senior Researcher]  
e-mail: dchan@kict.re.kr(Corresponding author)

\* 본 연구는 국토교통부 한국건설기술연구원 위탁사업으로 수행되었음(과제번호 20240266-004, 2024년 교통량 정보제공시스템(TMS) 운영 업무대행)

Received(October 28, 2024), Review Result(1st: November 16, 2024), Accepted(December 11, 2024), Published(December 31, 2024)



© 2024 The Authors. Published by NCISS.  
This is an open access article licensed under the Creative Commons Attribution-NonCommercial 4.0 International License.  
To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc/4.0/>.

expected to facilitate the integration of deep learning-based traffic volume prediction models into real-time traffic management systems, efficiently regulating traffic flow and reducing congestion. In conclusion, this study demonstrates the potential of deep learning technologies in the field of traffic volume prediction and emphasizes the necessity for continuous improvement in predictive performance through the integration of diverse algorithms and data sources.

Keyword : Deep Learning, Traffic Volume, Time Series, Long Short-Term Memory, Statistical Learning

## 1. 서론

교통량 예측은 도시 교통 시스템의 효율성을 높이고, 교통 혼잡을 줄이며, 환경 오염과 에너지 소비를 감소시키기 위한 중요한 과제로, 특히 급속히 도시화되는 현대 사회에서 그 중요성이 더욱 부각되고 있다. 과거에는 회귀분석, ARIMA 모델, Markov 체인 등 전통적인 통계 기법과 시간 시계열 모델이 주로 사용되었으나, 이러한 방법들은 교통 데이터의 비선형적 특성과 다양한 외부 요인에 의해 영향을 받는 복잡한 패턴을 충분히 설명하지 못하는 한계가 있다.

이러한 문제를 해결하기 위해 딥러닝이 강력한 도구로 떠오르고 있으며, CNN, RNN, LSTM, GRU와 같은 네트워크 구조는 대량의 복잡한 데이터에서 비선형적 관계를 자동으로 학습하고, 공간적 및 시간적 패턴을 동시에 분석하는 능력을 가지고 있다. 특히, Spatio-Temporal Neural Networks는 교통 네트워크의 교차로와 도로 간의 상호작용을 반영하고, 시간에 따른 교통 흐름 변화를 학습하여 기존의 통계적 방법보다 더 높은 예측 성능을 보여준다.

또한, 외부 요인(예: 날씨, 공휴일, 이벤트 등)을 고려할 수 있는 딥러닝 모델들이 개발되면서 교통량 예측의 정확도와 실용성이 지속적으로 향상되고 있다. 본 연구에서는 다양한 딥러닝 기반 알고리즘을 활용하여 교통량을 예측하는 모델을 제안하고, 전통적인 모델과의 성능 비교를 통해 딥러닝 알고리즘의 우수성을 입증할 예정이다. 이러한 연구 결과는 도시 교통 문제 해결뿐만 아니라, 교통 계획, 물류 최적화, 대중교통 개선 등 다양한 응용 분야에서 실질적인 혜택을 제공할 것으로 기대된다.

## 2. 선행 연구고찰

### 2.1 통계학습을 활용한 교통량 예측

B. M. Williams & L. A. Hoel (2003)는 계절적 ARIMA(Autoregressive Integrated Moving Average) 모델을 사용하여 교통량 데이터를 예측하는 방법론을 제안하고, 시간적 패턴을 잘 반영하는 시계열 분석 방법으로, 계절성과 비선형적 변동성을 고려하여 교통량을 예측하였다 [1]. B. L. Smith & M. J. Demetsky (1994)는 단기 교통 흐름 예측에 사용되는 여러 통계적 예측 방법을 비교 분석한 연구로, 다양한 통계 모델의 성능을 평가하여 단기 교통 흐름 예측에서 각 모델이 얼마나 효과적

인지를 분석하였다 [2]. M. S. Ahmed & A. R. Cook (1979)은 Box-Jenkins 기법(ARIMA 모델)을 사용하여 고속도로 교통 시계열 데이터를 분석하였으며, 시계열 분석을 통해 고속도로 교통량 데이터를 모델링하고, 단기 교통 흐름을 예측하는 방법을 연구하였다. 이 연구는 교통 관리와 계획 수립에서 시계열 모델의 유용성을 강조했고, 특히 교통량의 시간적 패턴을 분석하는 데 있어 ARIMA 모델이 유효함을 제시하였다 [3]. R. Chrobok, O. Kaumann, J. Wahle & M. Schreckenber (2004)은 실제 교통 데이터를 기반으로 다양한 교통 예측 방법을 비교하고 분석한 연구로, 단기 교통 예측을 위한 여러 방법론의 성능을 평가하고, 각 방법이 교통 예측 문제에서 어떻게 작동하는지를 실험적으로 제시하였다. 주요 예측 방법으로는 통계적 모델, 기계 학습 기법, 그리고 하이브리드 모델이 포함되어 있으며, 교통 데이터의 특성과 각 모델의 적용 가능성, 예측 성능을 상세히 다루고 있다 [4].

## 2.2 딥러닝을 활용한 교통량 예측

Y. Li, R. Yu, C. Shahabi & Y. Liu (2018)는 딥러닝 기반의 교통량 예측에 있어 Spatio-Temporal 모델을 다루었으며, CNN과 RNN을 결합한 모델을 제안하여 교통량 예측 성능을 향상시키는 방법을 연구하였다 [5]. J. Zhang, Y. Zheng & D. Qi (2017)는 잔차 네트워크를 기반으로 한 딥러닝 모델을 사용하여 도시 전역의 군중 흐름과 교통 예측에 대한 새로운 방법론을 제시하였으며, 공간적 시간적 상호작용을 효과적으로 처리하는 방법을 제시하였다 [6]. B. Yu, H. Yin & Z. Zhu (2018)는 그래프 컨볼루션 네트워크(GCN)를 사용하여 교통 데이터의 공간적 관계를 반영하고, 이를 시계열 모델과 결합하여 교통량 예측 성능을 극대화하는 방법을 제안하였다 [7]. X. Ma, Z. Tao, Y. Wang, H. Yu & Y. Wang (2015)는 LSTM을 사용하여 시간에 따른 교통 속도 예측을 연구하였으며, 딥러닝을 통해 교통 데이터의 비선형적 패턴을 학습하는 방법을 제안하였다 [8]. E. I. Vlahogianni, M. G. Karlaftis & J. C. Golias (2014)는 교통량 예측의 전반적인 개요를 제공하고, 전통적인 모델부터 딥러닝 모델까지 다양한 방법론을 비교하여 딥러닝 모델의 장점을 제시하였다 [9].

## 3. 딥러닝 시계열 분석 설정


### 3.1 모형 초기 설정(관측 및 예측 기준 설정)

본 연구에서는 LSTM RNN 모델을 사용하여 시계열 예측을 수행하였으며, 최근의  $p$ 값을 입력으로 받고  $q$ 의 미래값들을 출력으로 설정하였다.  $p$ 와  $q$ 는 각각 'lookback'과 'lookahead'로 정의되며, 네트워크는 여러 은닉층과 출력층으로 구성된다. 과적합 방지를 위해 'dropout' 기법을 적용하고, 출력층은 선형 활성화 함수를 사용하여 평균제곱오차(MSE)를 손실 함수로 설정하였다. 주요 실험

은 여러 시간 단계를 예측하여 LSTM의 성능을 검증하고, 예를 들어 5분 단위의 데이터를 사용해 6개의 시간 단계를 예측함으로써 다음 30분 동안의 시계열 동작에 대한 통찰을 제공한다. 그러나 실제 입력값이 사용될 때만 이상치 탐지가 가능하며, 여러 시간 단계를 예측할 경우 정확도가 떨어질 수 있다. 따라서 연구에서는 예측 정확도가 수용 가능한 수준일 때만 'lookahead' 값을 1보다 크게 설정하였고, 실제 lookahead 값은 연구자가 임의로 지정하였다. 이러한 접근은 LSTM 모델의 시계열 예측 능력을 평가하고 이상치 탐지 가능성을 높이는 데 기여하고자 하였다.

### 3.2 시계열 특성

본 연구에서는 시간당 교통량 통계 자료를 활용하여 데이터 전처리를 진행하였으며, 이 데이터는 시간에 따른 주기성을 가지고 있지만 활용에 한계가 있다. 이를 개선하기 위해 '하루 중 시간'과 '연중 시간'으로 변환하여 중요한 시간 단위에 접근할 수 있도록 하였다. 시계열 분석 방법론을 채택한 이유는 타임스탬프를 통해 시간 단위별 특징을 추정할 수 있기 때문이다. 교통량 데이터는 사람의 행동과 밀접한 관련이 있어, 이를 통해 교통량에 따른 행동 패턴을 추정할 수 있다. [그림 1]은 주기성 추출의 시계열 특성을 시각적으로 나타내며, Sine 함수와 Cosine 함수의 조합이 복잡한 시계열 데이터 내의 숨겨진 주기적 패턴을 드러내는 데 중요함을 강조한다.



[그림 1] sin, cos 함수 활용의 주기성 추출

[Fig. 1] Extraction of periodicity using sine and cosine functions

sin, cos 작업을 통해 어떤 시간이 중요한지에 대해 파악할 수 있으며, 이 경우 어떤 시간 단위가 중요한지 미리 알 수 있다. 본 연구는 CNN 및 RNN 등 다양한 방식의 모델을 사용하며, 단일 타임스탬프 및 다중 타임스탬프를 통해 예측 하는 것으로 방향성을 설정하였다. 따라서 해당 작업을 위해 데이터의 일련의 작업 진행이 모든 모델에 재사용할 수 있도록 data windowing(데이터 창

작업)을 실시하였다.

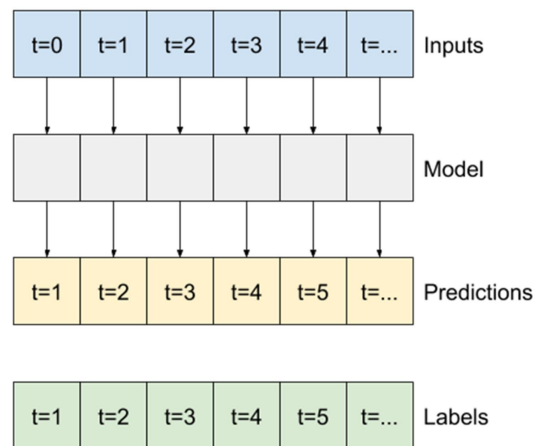
### 3.3 딥러닝 과적합 검증

본 연구에서는 데이터 세트를 훈련(70%), 검증(20%), 테스트(10%)로 나누어 모델의 학습 과정을 검증하고 과적합과 편향을 방지하였다. 검증 및 테스트 데이터는 모델 훈련 후 평가에 사용되며, 데이터 분할은 현실성을 높이기 위해 필수적이다. 데이터 분할 후에는 정규화 작업이 수행되며, 이는 신경망의 자율성과 범용성을 높이고 출력값의 오류를 줄이는 데 중요하다. 또한, nan 값이 포함된 데이터는 오류를 유발할 수 있으므로, 본 연구에서는 실제값이 있는 데이터를 사용하여 선 보정 없이 데이터를 잘라내어 예측력을 검증하였다. 이를 통해 데이터의 질을 유지하면서 효율적인 분석을 수행할 수 있었다.

## 4. 딥러닝 분석 예측 결과

### 4.1 단일 스텝 선형 결합 모형(baseline 모형)

단일 스텝 선형 결합 모형은 CNN, LSTM, 자기회귀 LSTM 모형과의 절대적인 비교를 위한 baseline 모형으로, 본 연구에서 개발된 딥러닝 기반 모형들의 예측력을 비교하는 데 활용되었다. 이 모형은 가장 간단한 구조의 다계층 기계식 네트워크로, 단일 window(예: 1시간 후)의 short-term 타임스탬프를 예측한다. [그림 2]는 단일 스텝 모형의 입출력 전달 방식을 시각화하여 시스템의 입력과 출력 간의 관계 및 각 요소의 상호작용을 명확히 보여준다.




[그림 2] 단일 스텝 모형의 입출력 전달 방식

[Fig. 2] Input-output transmission method of the single-step model

단일 스텝 선형 결합 모형은 입력과 출력이 선형 결합 형태로 구성되어 1시간 단위로 예측을 수행하지만, 장기 시계열 예측 시 추세 반영이 어려워 예측 성능이 저하될 우려가 있다. [그림 3]은 24시간 예측 결과를 보여주며, 입력 교통량은 청색선, 실제 교통량은 녹색 원형, 모델의 예측 교통량은 적색 도형으로 나타난다. 입력 데이터는 min-max 스케일링을 통해 변환되며, 시간대, 요일, 월 등의 요인도 예측 변수로 활용된다.

단일 스텝 선형 결합 모형의 예측 정확도가 시점별로 상이한 이유는 두 가지이다. 첫째, 비선형은닉층이 없어 구조적 한계로 인해 예측 성능이 저하될 수 있다. 둘째, 이 모형은 직전 타임스텝의 값과 특성에만 의존하여 예측하므로 장기 추세를 반영하지 못하는 문제가 발생한다. 이러한 한계로 인해 예측 정확도가 떨어질 수 있다.

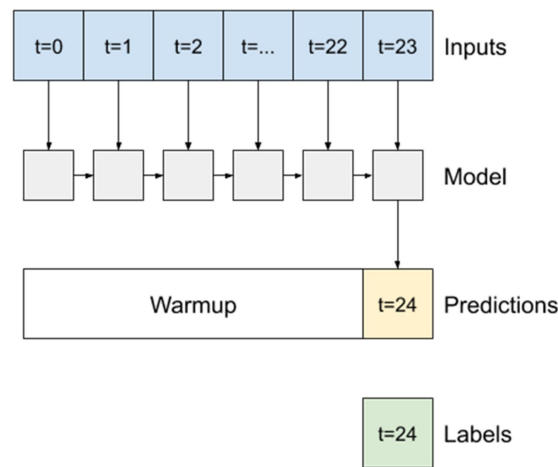


[그림 3] 단일 스텝 선형 결합 모형 예측 결과 예시(24시간)

[Fig. 3] Example of prediction results from the single-step linear combination model (24 hours)

## 4.2 망각 게이트 기반 LSTM 모형

RNN의 경우 장시간의 타임스텝을 가진 데이터를 처리할 때, 연산 비용이 기하급수적으로 증가하기 때문에 이를 해소하기 위해 기억 중단형 통시적 역전파(Truncated Back propagation Through time)를 활용하게 되고, 이로 인해 단기 기억 정보만을 처리하게 된다. 하지만 이 경우에는 gradient vanishing 문제로 인해 모형 예측 성능에 한계가 존재하게 된다. LSTM은 장·단기 기억 장치(Long Short-Term Memory)라는 은닉층을 통해 단순 RNN의 장기 의존성 문제를 해결하고, 동시에 예측 성능을 향상시키는 구조를 가지는 모형이다. [그림 4]는 LSTM(Long Short-Term Memory) 모형의 입출력 전달 방식을 세련되게 시각화한 것이다. 이 모형은 순환 신경망(RNN)의 한 형태로, 시계열 데이터나 순차적 정보를 효과적으로 처리하는 데 특화되어 있다.




[그림 4] LSTM 모형의 입출력 전달 방식

[Fig. 4] Input-output transmission method of the LSTM model

본 연구는 실제 시스템에 적용 가능한 교통량 보정 및 예측 시스템 개발을 위해 LSTM의 상태 불안정을 해소하는 것이 중요하다고 판단하였다. 장시간의 타임스텝을 가진 데이터 처리 시 LSTM의 연산 비용이 증가하여 네트워크가 불안정해질 수 있는 문제를 해결하기 위해, 메모리 셀의 내용을 재설정하는 방법을 적용하였다. 특히, 활성화 망각 게이트를 활용하여 과거 학습에 중요했던 특성만 기억하도록 하여 학습의 불안정성을 방지하고자 하였다.

예측 성능 비교를 위해 단일 스텝 선형 결합 모형 외에도 다중선형결합모형과 CNN을 분석하였다. CNN은 횡단면 데이터 예측에 주로 사용되지만, 본 연구에서는 특성 공학을 통해 과거 시점을 요인으로 간주하여 시계열 예측에도 활용하였다. [그림 5]는 다양한 딥러닝 모형과 망각 게이트 기

반 LSTM 모형의 성능을 비교한 자료로, LSTM 모형의 우수성을 보여준다.



[그림 5] 망각 게이트 기반 LSTM 모형 성능 비교

[Fig. 5] Performance comparison of the forget gate-based LSTM model


[표 1]과 같이 각 모델별 예측 성능 비교 결과 Baseline(MAE - 0.1288), 다중선형결합(MAE - 0.0944), CNN(MAE - 0.0769), LSTM(MAE - 0.0733) 순으로 성능이 우수한 것으로 나타났으며, LSTM이 가장 우수한 예측 성능을 보여주고 있음을 확인할 수 있었다.

[표 1] 망각 게이트 기반 LSTM 모형의 예측 성능 검증 결과

[Table 1] Prediction performance validation results of the forget gate-based LSTM model

모형	Baseline	Linear	CNN	LSTM
평가척도(MAE)	0.1288	0.0944	0.0769	0.0733

[그림 6]은 무작위 지점 및 시점에 대한 24시간 동안의 교통량을 LSTM을 활용하여 예측한 예시를 나타내는 그림이다. 앞 절에 언급된 그림들과 동일하게 inputs(청색선)는 각 타임스텝의 입력 교통량을 의미하고, Labels(녹색 원형)는 모형이 목표로 하는 예측 시간과 실제 교통량(ground truth)을 나타내며, 이 레이블에 표시된 시간의 교통량을 예측, Predictions(적색 도형)는 각 출력 타임스텝에 대한 모형의 예측 교통량을 의미한다. [그림 3]의 Baseline 모형 결과와 비교해보면 대부분의 지점 및 시점에서 정확한 장래 예측이 이루어지는 것을 확인할 수 있다.

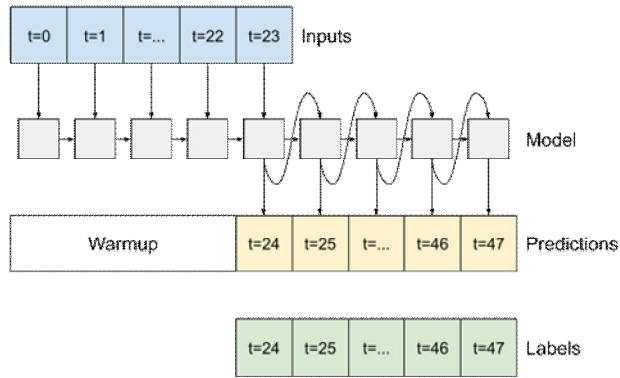


[그림 6] 망각게이트 기반 LSTM 모형 예측 결과 예시(24시간)

[Fig. 6] Example of prediction results using the forget gate-based LSTM model (24 hours)


### 4.3 자기회귀 LSTM(Autoregressive LSTM) 기반 multi-step 예측

자기회귀 LSTM은 LSTM 모형에 자기 회귀 루프를 적용하여 장기 추세성 패턴 인식 능력을 향상시키는 것을 목표로 한다. 이는 기존 자기회귀 모형과 비선형 은닉 레이어를 결합한 형태로, 본 연구에서는 심각한 장기 결측 문제에 적용 가능한 모형을 개발하고 그 활용성을 검증하고자 하였다. 장기 결측의 경우 이전 타임 스텝의 데이터를 직접 활용할 수 없지만, 자기회귀 모형을 통해 장기 계절성과 패턴을 반영하여 장래 시계열 예측에 유용하다. [그림 7]은 자기회귀 LSTM 모형의 입출력 전달 방식을 시각적으로 표현하여 LSTM의 구조와 데이터 흐름을 설명한다.



[그림 7] 자기회귀 LSTM 모형의 입출력 전달 방식

[Fig. 7] Input-output transmission method of the autoregressive LSTM model



[그림 8] 자기회귀 LSTM 모형 예측 결과 예시 (24시간)

[Fig. 8] Example of prediction results from the autoregressive LSTM model (24 hours)


[그림 8은]은 무작위 지점 및 시점에 대한 24시간 동안의 교통량을 자기회귀 LSTM 모델을 활용하여 예측한 예시를 나타내는 그림이다. 자기회귀 LSTM 모델의 결과에서 확인할 수 있듯이 장기 추세 및 특성에 영향을 많이 받는 시점의 경우 예측 성능이 매우 우수한 반면, 시간대별 교통량의 변동이 높은 시간대나 구간에서는 예측의 정확성이 떨어지는 것을 확인할 수 있다. 이는 은닉층에서 이전 단계의 모델 결과가 다음 단계의 예측에 활용되는 자기회귀 방식을 가지게 되므로 장기 추세에 영향을 크게 받기 때문이다.

자기회귀 LSTM(AR-LSTM)을 추가하여 다중 스텝 예측 시 절대적 예측 성능 비교 수행하였다. 다중 스텝 예측을 위해 Baseline 모델의 예측 방식을 미래의 단일 시점에 대한 출력 대신에 다중 시점을 예측하는 형태로 변환하였다.

[표 2] AR-LSTM을 추가한 절대적 예측 성능 검증 결과

[Table 2] Verification results of absolute prediction performance with the addition of AR-LSTM

모델	Last	Repeat	Linear Network	Dense NN	CNN	LSTM	AR-LSTM
평가척도(MAE)	0.5242	0.2517	0.0558	0.0691	0.0474	0.0393	0.0528



[그림 9] 자기회귀 LSTM 모델 예측 결과 예시 (24시간)

[Fig. 9] Comparison of absolute prediction performance with the addition of AR-LSTM

단일 직전 스텝 활용 모델(LAST), 다중 반복 스텝 활용 모델(Repeat), 선형 결합(Linear), 다중밀집(Dense), CNN, LSTM, AR LSTM에 대해 예측 성능을 검증하였다. [표 2]와 같이 각 모델별 예측 성능 비교 결과 LAST(MAE - 0.5242), Repeat(MAE - 0.2517), Dense NN(MAE - 0.0691), Linear Network(MAE - 0.0558), AR-LSTM(MAE - 0.0528), CNN(MAE - 0.0474), LSTM(MAE - 0.0393) 순으로 나타났으며, 예측 성능 결과 망각게이트를 활용한 LSTM이 가장 우수한 예측 성능을 보여주고

있음을 확인하였다. [표 2]는 AR-LSTM(Autoregressive Long Short-Term Memory) 모델을 포함한 다양한 딥러닝 모델의 절대적 예측 성능을 비교 분석한 결과이다. 이 표는 각 모델이 시계열 데이터에 대해 얼마나 효과적으로 예측을 수행하는지를 정량적으로 평가한 것이다.

[그림 9]에서 제시된 분석 결과에 따르면, 자기회귀 LSTM(AR-LSTM) 모델을 추가하여 여러 모델을 비교한 결과, 전통적인 LSTM 모델이 AR-LSTM 모델에 비해 현저히 우수한 예측 성능을 보이는 것으로 나타났다. 이러한 결과는 LSTM 모델이 시계열 데이터의 복잡한 패턴을 효과적으로 학습하고, 장기 의존성을 잘 포착할 수 있는 능력을 갖추고 있음을 시사한다. 반면, AR-LSTM 모델은 자기회귀 특성으로 인해 데이터의 과거 값에 의존하는 경향이 강해, 예측의 정확성이 상대적으로 떨어지는 것으로 분석되었다.

## 5. 결론

본 연구는 딥러닝 기반의 다양한 알고리즘을 활용하여 교통량을 예측하는 모델을 제안하고, 전통적인 통계적 예측 방법과 비교하여 딥러닝 모델의 성능 우수성을 입증하였다. 연구 결과, CNN, LSTM 및 그 조합으로 구성된 모델들은 교통량 예측에서 높은 정확도를 기록하며, 기존의 통계적 모델들이 가진 한계를 극복할 수 있는 가능성을 보여주었다.

특히, Spatio-Temporal Neural Networks와 같은 최신 딥러닝 기법은 교통 네트워크 상의 복잡한 패턴을 효과적으로 학습하고, 시간적 및 공간적 요인을 동시에 고려함으로써 예측 성능을 한층 향상시켰다. 이 모델들은 도로 네트워크의 공간적 상호작용, 날씨, 공휴일, 이벤트 등 다양한 외부 요인을 통합적으로 반영함으로써, 실시간 교통 관리 및 계획 수립에 유용한 인사이트를 제공할 수 있다.

본 연구는 딥러닝 기술이 교통량 예측 분야에 실질적인 기여를 할 수 있음을 입증하였으며, 이러한 결과는 도시 교통 문제 해결뿐만 아니라 물류 최적화 및 대중교통 개선 등 다양한 응용 분야에서 활용될 수 있을 것이다. 앞으로의 연구에서는 더 다양한 데이터 세트를 활용하여 모델의 범위를 확장하고, 예측 정확도를 더욱 높이는 방향으로 나아가야 할 것이다. 이를 통해 현대 도시의 복잡한 교통 상황을 효율적으로 관리하고 개선하는 데 기여할 수 있을 것으로 기대된다.

## References

- [1] B. M. Williams, L. A. Hoel, "Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: Theoretical basis and empirical results", *Journal of Transportation Engineering*, vol. 129, no. 6, November 2003, pp. 664-672, doi: 10.1061/(ASCE)0733-947X(2003)129:6(664).
- [2] B. L. Smith, M. J. Demetsky, "Short-term traffic flow prediction models - A comparison of statistical methods", *Transportation Research Record*, October 2-5, 1994, San Antonio, TX, USA, pp 99-104, doi: 10.1109/ICSMC.1994.400094.
- [3] M. S. Ahmed, A. R. Cook, "Analysis of freeway traffic time-series data by using Box-Jenkins techniques", *Transportation Research Record*, 1979, pp 1-9
- [4] R. Chrobok, O. Kaumann, J. Wahle, M. Schreckenber, "Different methods of traffic forecast based on real data", *European Journal of Operational Research*, vol. 155, no. 3, June 2004, pp. 558-568, doi: 10.1016/j.ejor.2003.08.005.
- [5] Y. Li, R. Yu, C. Shahabi, Y. Liu, "Diffusion convolutional recurrent neural network: Data-driven traffic forecasting", In *Proceedings of the International Conference on Learning Representations (ICLR)*, February 2018, pp. 1-16, doi: 10.48550/arXiv.1707.01926.
- [6] J. Zhang, Y. Zheng, D. Qi, "Deep spatio-temporal residual networks for citywide crowd flows prediction", In *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 31, no. 1, February 2017, pp. 1655-1661, doi: 10.1609/aaai.v31i1.10735.
- [7] B. Yu, H. Yin, Z. Zhu, "Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting", In *Proceedings of the International Joint Conference on Artificial Intelligence(IJCAI)*, July 2018, Pages 3634-3640, doi: 10.48550/arXiv.1709.04875.
- [8] X. Ma, Z. Tao, Y. Wang, H. Yu, Y. Wang, "Long short-term memory neural network for traffic speed prediction using remote microwave sensor data", *Transportation Research Part C: Emerging Technologies*, vol. 54, May 2015, pp. 187-197, doi: 10.1016/j.trc.2015.03.014.
- [9] E. I. Vlahogianni, M. G. Karlaftis, J. C. Golias, "Short-term traffic forecasting: Where we are and where we're going", *Transportation Research Part C: Emerging Technologies*, vol. 43, June 2014, pp. 3-19, doi: 10.1016/j.trc.2014.01.005.