

멀티 스텝 트래픽 예측을 위한 Bi-LSTM 인코더 디코더 모델

염성웅, 최철웅, 홍 남 퀘엣, 김경백

전남대학교

yeomsw0421@gmail.com, sentilemon02@gmail.com, quachhongnam1995@gmail.com,
kyungbaekkim@jnu.ac.kr

Bi-LSTM Encoder Decoder Model for Multi-Step Traffic Prediction

Sungwoong Yeom, Chulwoong Choi, Hong-Nam Quach, Kyungbaek Kim

Dept. Artificial Intelligence Convergence, Chonnam National University.

요약

최근 IoT 기기들의 활성화에 따라 네트워크가 복잡해지고 이를 관리하기 위해 네트워크를 동적으로 변경하는 비용이 높아짐에 따라 네트워크 자원 할당 계획, 제어 및 관리를 위한 단일 단계 트래픽 예측은 한계가 있다. 이를 위해 단일 단계 트래픽 예측 모델의 결과를 입력으로 다시 사용하는 재귀 전략을 적용함으로써 여러 단계를 예측하는 멀티 스텝 트래픽 예측으로 확장되었지만 단계가 진행됨에 따라 예측 성능이 저하되는 단점이 있다. 본 논문에서는 멀티 스텝 트래픽 예측을 위해 다중 출력 전략을 적용한 Bi-LSTM 기반 인코더 디코더 모델을 제안한다. 제안된 기법은 비정상성 트래픽과 정상성 트래픽에 대해 포괄적인 실험을 수행하였고 제안된 기법의 우수한 성능을 확인한다.

I. 서론

최근 IoT 기기들의 활성화로 인해 네트워크에서 관찰되는 트래픽 데이터가 폭발적으로 증가함에 따라 인터넷 서비스 제공업체는 인터넷 운영 효율성을 향상시키기 위해 정확하고 시기적절한 트래픽 흐름 정보를 사용하여 대역폭을 할당하고, 이상을 감지하고, 혼잡을 제어하는 연구가 활성화되고 있다 [1]. 이 트래픽 흐름 정보를 파악하기 위한 모니터링 및 스케줄링을 지원하는 인프라가 적기 때문에 인터넷 관리자는 장단기 트래픽 스케줄링을 수행하기 위해 트래픽에 대한 정확한 예측이 필요하다.

이러한 단기 트래픽 흐름을 예측하기 위해 자기 회귀 통합 이동 평균 (ARIMA) 모델과 같은 통계적 접근 방식을 연구되었다 [2]. 이 기법은 비정상성 또는 정상성과 같은 네트워크 특성에 따라 트래픽의 자기상관을 고려하여 트래픽을 예측한다. 하지만, 이러한 통계적 기법은 급격한 변화가 드러나는 비선형적 특성이 드러나는 네트워크에서는 낮은 성능을 보여준다. 최근 시계열 딥러닝 신경망의 활성화로 인해 시계열 신경망 기반 단기 트래픽 트래픽 볼륨 예측 기법은 낮은 오류율을 보이고 있다 [3]. 하지만, 대역폭, 패킷 소실 및 대기 시간 등과 같은 정보는 네트워크 상태에 따라 원하는 시간에 측정이 불가능할 수 있다. 또한, 고속 네트워크 관리에서는 네트워크의 즉각적인 변경이 비용이 많이 들거나 실행 불가능한 상황이 많다. 예를 들어 광 네트워크에서 파장 (또는 램다)을 설정하는데 필요한 시간은 종종 몇 분 정도이므로 즉시 수행할 수 없다. 이러한 트래픽 성능 측정은 단일 단계를 넘어 향후 단계의 트래픽 적절한 결정을 내릴 수 있는 충분한 시간이 필요하다.

이러한 상황에서 사전 예방적 관리에 충분한 시간을 제공하기 위해 멀티 스텝 트래픽 예측 기법이 연구되었다 [4]. 멀티 스텝 시계열 예측을 위한 두 가지 일반적인 전략은 직접 (또는 병렬) 예측 기법과 반복 (또는 순진한) 예측 기법이다. 직접적인 접근 방식에서는 서로 다른 모델이 병렬로 학습되어 미리 한 단계 앞서 예측한다. 반면에 반복적 접근 방식에서는 연속적인 단계의 출력이 다음 예측 단계의 입력으로 사용되는 반복적인 한 단계 앞서 예측을 수행하여 멀티 스텝 시계열 예측을 수행한다. 재귀적으

로 한 단계 앞선 예측은 필요한 시간 범위까지 반복할 수 있으며 단일 예측 모델만 사용된다. 하지만, 이러한 재귀 기법은 이전 단계의 예측 오류 누적은 예측 범위가 증가함에 따라 증가한다.

본 논문에서는 인코더 디코더 구조의 Bi-LSTM을 기반으로한 멀티 스텝 트래픽 예측 모델을 제안한다. 이 모델은 트래픽 데이터를 활용하여 단일 단계의 트래픽뿐만 아니라 멀티 스텝 트래픽을 예측할 수 있다. 제안된 기법은 유효성을 검증하기 위해 비정상성 트래픽과 정상성 트래픽이 관찰되는 실제 DNS 요청을 기반으로 히스토리 상관관계를 고려하여 실험을 수행하여 MAPE를 평가한다.

II. 관련 연구

트래픽 예측의 중요성으로 인해 지난 수십 년 동안 많은 트래픽 예측 기법이 제안되었다. 이 트래픽 예측 기법은 트래픽 특성에 따라 성능이 달라질 수 있다. 이 트래픽 특성은 크게 정상성과 비정상성으로 구분할 수 있다. 정상성은 시계열의 확률적인 성질들이 시간에 상관없이 변하지 않는 특성을 가지고 있으며, 비정상성은 반대로 시간에 따라 통계적 특성이 변하는 특성을 가지고 있다. 이러한 정상성과 비정상성을 고려한 접근법으로 추세와 계절성을 기반한 지수 평활 [6], 자기상관을 표현하는데 목적이 있는 ARIMA 모델 [5] 등이 포함된다. 그 중 ARIMA 모델은 트래픽 예측 모델을 구축하기 위한 프레임워크로 널리 알려져 있다 [7]. 이후, 계절적 ARIMA [8] 모델과 같은 일부 개선된 방법도 단기 트래픽 예측에 사용되었다. 하지만, 네트워크 유저의 수가 증가함에 따라 네트워크 트래픽 흐름이 무작위 및 비선형으로 인해 많은 전통적인 방법이 불충분한 것으로 나타났다 [9]. 논문 [10]은 노드 간 트래픽 양을 예측하고 실제 데이터를 사용하여 모델을 학습시키기 위해 SDN에 모델을 배포하여 대용량 트래픽 예측을 위한 LSTM 기반 모델을 제시했다. 논문 [11]은 소스 측에서 관찰된 트래픽 계절성을 학습하여 LSTM 기반 네트워크 트래픽 볼륨 추정 방법을 제안했다. 논문 [12]은 네트워크 트래픽 폭주와 불확실성에 대처하기 위해 LSTM 기반의 실시간 네트워크 트래픽 예측 모델을 제안했다. 논문

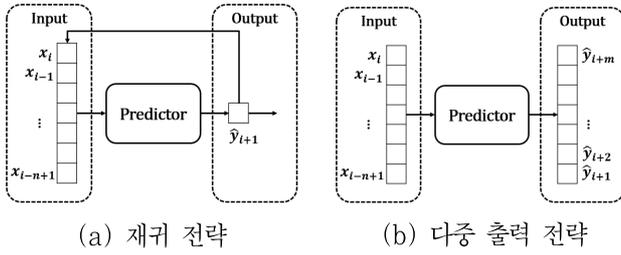


그림 1. 멀티 스텝 예측 모델 구조

[13]는 GEANT 백본 네트워크 데이터를 사용하여 LSTM 신경망을 통해 트래픽의 비선형 특성을 학습하고 예측했다.

이 딥러닝 기반 트래픽 예측 기법은 다른 방법에 비해 장점을 보여주었다. 앞서 언급한 접근 방식은 단기 시퀀스를 정확하게 예측할 수 있지만 장기 예측 성능에서보다 빠르게 감소되기 때문에 효과적인 예측이 어려워진다. 이를 위해 자연어 처리 분야에서 자주 사용되는 심층 신경망을 사용하여 모델 입력을 고정 벡터로 인코딩한 다음 다른 심층 신경망을 사용하여 예측을 위해 고정 벡터에서 출력 시퀀스를 디코딩하는 시퀀스 대 시퀀스 모델 구조를 트래픽 예측 분야에서 활용할 필요가 있다 [14]. 이 논문에서는 고전적인 통계 및 기계 학습 방법과는 달리 시퀀스 대 시퀀스 학습 구조를 통해 멀티 스텝 예측 모델을 제안한다.

III. Bi-LSTM 기반 멀티 스텝 트래픽 예측 기법

1. 멀티 스텝 트래픽 예측 방법론

멀티 스텝 모델의 트래픽 입력 창 슬라이드 X_i 와 그라운드 트루스 Y_i 는 i 번째 시간 창에서 n, m 차원으로 구성되어 과거와 미래에 대한 이해를 돕는다. X_i 와 Y_i 는 수식 (1)과 (2) 같이 표현한다.

$$X_i = [x_{i-n+1}, x_{i-n+2}, \dots, x_i] \quad (1)$$

$$Y_i = [y_{i+1}, y_{i+2}, \dots, y_{i+m}] \quad (2)$$

n 개의 과거 단계를 걸쳐 m 개의 미래 단계에 대한 정확한 트래픽 추정을 목표로 하는 멀티 스텝 트래픽 예측 함수 $f(\cdot)$ 는 전략에 따라 다르게 공식화할 수 있다. 일반적으로 멀티 스텝 예측을 위한 두 가지 효과적인 상태는 재귀 전략과 다중 출력 전략이다.

재귀 전략은 그림 1 (a)와 같다. 재귀 전략은 단일 단계 예측 모델에서 i 번째 트래픽 창 슬라이드 X_i 를 입력하여 $i+1$ 번째 트래픽 \hat{y}_{i+1} 을 출력한다. 트래픽 \hat{y}_{i+1} 에 대한 추정치는 수식 (3)과 같이 표현한다.

$$\hat{y}_{i+1} = f(X_i) = f(x_{i-n+1}, x_{i-n+2}, \dots, x_i) \quad (3)$$

예측된 트래픽 \hat{y}_{i+1} 은 다음 예측을 위한 입력으로 구성되며, 이를 m 번 반복한다. 이 전략은 트래픽의 동적 특성을 고려한다. 그러나 예측된 결과가 입력으로 사용되기 때문에 예측을 반복할수록 오류가 축적된다. 즉, 모델의 예측 성능은 단계 수가 증가함에 따라 저하되고 예측은 실제 관찰에서 조금씩 벗어나게 된다.

다중 출력 전략은 그림 1 (b)와 같다. 다중 출력 모델에서 i 번째 트래픽 창 슬라이드 X_i 를 입력하여 i 번째부터 $i+m$ 번째까지의 트래픽으로

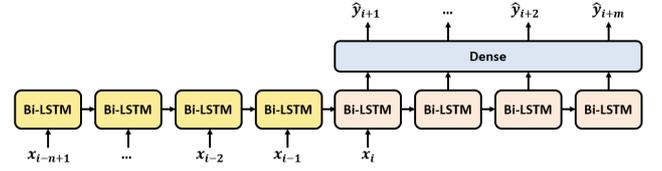


그림 2. Bi-LSTM 기반 인코더 디코더 트래픽 예측 모델
구성된 트래픽 창 슬라이드 \hat{Y}_i 를 출력함으로써 멀티 스텝 예측을 달성한다. 트래픽 출력 창 슬라이드 \hat{Y}_i 에 대한 추정치는 수식 (4)와 (5) 같이 표현한다.

$$\hat{Y}_i = f(X_i) = f(x_{i-n+1}, x_{i-n+2}, \dots, x_i) \quad (4)$$

$$\hat{Y}_i = [\hat{y}_{i+1}, \hat{y}_{i+2}, \dots, \hat{y}_{i+m}] \quad (5)$$

이 전략은 오류 누적을 다소 피할 수 있지만 데이터의 동적 특성을 무시하고 시계열 프로브를 정적 문제로 취급하여 예측의 정확도를 떨어뜨릴 수 있다.

2. 제안된 다중 출력 트래픽 예측 기법

제안된 접근 방식은 네트워크 트래픽을 $i+1$ 번째 시간 창부터 $i+m$ 번째 시간 창까지 비교적 정확하게 단계적으로 추정하는 기법이며, 이 추정을 위해 시계열 신경망인 Bi-LSTM을 인코더 디코더 형태로 사용한다. 그림 2는 제안된 LSTM 기반 인코더 디코더 트래픽 예측 모델을 보여준다. 이 모델은 1개의 Bi-LSTM 레이어로 구성된 인코더와 디코더와 1개의 Dense 레이어로 구성된다. 이 Dense 레이어의 활성화 함수는 선형 함수를 사용한다. 인코더와 디코더는 각각 10개의 노드가 포함된다.

제안된 Bi-LSTM 기반 인코더 디코더 모델의 입력벡터는 관찰된 트래픽 볼륨 s_i 와 시간 창 인덱스 t_i 로 구성된다. i 번째 시간 창에서 구성된 입력벡터는 $x_i = (s_i, t_i)$ 로 표현한다. 제안된 모델의 학습은 $i-9$ 번째 시간 창부터 i 번째 시간 창까지의 입력 벡터 $x_{i-n+1}, \dots, x_{i-1}, x_i$ 와 $i+1$ 번째 시간 창부터 $i+10$ 번째 시간 창까지의 그라운드 트루스 $y_{i+1}, y_{i+2}, \dots, y_{i+10}$ 을 사용한다. 제안된 모델의 예측은 $i-9$ 번째 시간 창부터 i 번째 시간 창까지의 입력 벡터 $x_{i-n+1}, \dots, x_{i-1}, x_i$ 를 입력으로 사용하여 연속적인 트래픽 $\hat{y}_{i+1}, \hat{y}_{i+2}, \dots, \hat{y}_{i+10}$ 을 예측한다.

제안된 모델은 정상성 트래픽과 비정상성 트래픽에 의해 영향을 받을 수 있다. 입력 벡터의 첫 번째 도메인은 트래픽 볼륨으로 정상성과 비정상성을 고려하여 두 가지 전처리를 적용할 수 있다. 첫 번째 전처리 방식은 계절성과 같은 비정상성 트래픽을 고려한 정규화이며, 이는 Bi-LSTM에서 기울기 폭발 또는 손실이 발생하지 않도록 한다. 두 번째 전처리 방식은 편차가 거의 없는 정상성 트래픽을 고려한 트래픽 볼륨을 트래픽 변화율로 바꾸는 것이다. 입력 벡터의 두 번째 도메인은 트래픽 볼륨에 대한 시간 창 인덱스이다. 이 논문에서는 i 번째 시간 창에서 관찰된 트래픽과 $i-1$ 번째 시간 창 사이 간격을 5분으로 설정하며, 하루동안 관찰된 트래픽의 시간 창 인덱스의 최대 길이를 288로 설정한다. 따라서 시간 창 인덱스 t_i 의 값은 1부터 288가 된다. 이 시간 창 인덱스 또한 Bi-LSTM에서 기울기 폭발 또는 손실이 발생하지 않도록 하기 위해 정규화를 적용한다.

이와 같이 다중 출력 전략을 고려한 제안된 Bi-LSTM 기반 인코더 디코더 모델은 멀티 스텝 트래픽 예측의 전반적인 성능을 향상시킬 수 있다.

IV. 실험 및 검증

제안된 Bi-LSTM 기반 인코더 디코더 모델 (Bi-LSTM_S2S)을 평가하기 위해 LSTM 기반 인코더 디코더 모델 (LSTM_S2S), Bi-LSTM 기반 회귀 모델 (Bi-LSTM_RE) 그리고 LSTM 기반 회귀 모델 (LSTM_RE) 와 비교한다. 제안된 기법을 평가하기 위해 ICANN에서 운영하는 DNS-STAT: Hedgehog의 데이터 셋 중 중국 상하이에서 한 달 (2020년 9월 01일 - 2020년 9월 31일) 동안 수집된 실제 DNS 요청 트래픽을 사용한다. 데이터 세트의 첫 20일에 대한 트래픽은 시계열 딥러닝 모델의 학습에 사용하며, 데이터 세트의 다음 10일은 테스트에 사용한다. 제안된 기법은 예측값에 대한 오차율을 측정하기 위해 가장 보편적으로 사용되는 MAPE를 사용한다.

이 멀티 스텝 트래픽 기법은 트래픽에서 관찰되는 정상성이나 비정상성과 같은 특성에 의해 영향을 받을 수 있다. 또한, 트래픽 시간 창 사이의 상관관계에 따라 성능이 영향을 받을 수 있다. 이를 위해 비정상성이 관찰되는 상하이 DNS 요청 트래픽을 전처리하고, 정상성 트래픽과 비정상성 트래픽에 대해 트래픽 시간 창 간의 상관관계를 히트맵을 사용하여 시각화할 필요가 있다. 첫 번째 전처리는 비정상성 트래픽을 그대로 사용하기 위한 정규화이고, 이 전처리를 사용하는 기법은 M1으로 표현한다. 두 번째 전처리는 비정상성 트래픽을 정상성화하기 위해 트래픽을 변화율로 변환하고, 이 전처리를 사용하는 기법은 M2로 표현한다. 우리는 각각의 전처리에 따라 멀티 스텝 트래픽 예측 기법들의 성능을 비교할 필요가 있다.

그림 3은 정규화를 통해 전처리된 비정상성 트래픽 시간 창 간의 상관관계를 히트맵으로 시각화하였다. 히트맵의 색상이 어두울수록 해당 기간 동안 상관 계수가 높아진다. 이 비정상성 트래픽에서는 시간 창 사이의 스텝 간격이 좁아질수록 양의 상관계수의 값이 상승하는 것을 확인할 수 있다. 이에 따라, 멀티 스텝 트래픽 기법은 다음 단계의 예측을 위해 이전 단계의 출력이 모델의 입력으로 사용하기 때문에 이전 단계의 결과에 영향을 받을 수 있다. 하지만, 이전 단계의 결과에 대한 오류가 섞여 입력으로 다시 사용된다면 단계가 진행됨에 따라 오류는 점점 더 쌓이게 되어 성능이 점점 낮아질 수 있다.

그림 4는 트래픽에서 비정상성이 관찰될 때 재귀 기법과 다중 출력 기법이 각 단계의 예측한 결과에 대한 MAPE를 보여준다. 제안된 Bi-LSTM_S2S_M1 모델은 Bi-LSTM_RE_M1 모델에 비해 모든 단계에서 MAPE가 약 3% 낮다. 다수의 결과를 한꺼번에 출력하는 인코더 디코더 모델은 기존의 재귀적 단일 스텝 예측 모듈에 비해 장기적 특징을 학습하기 때문에 전반적으로 낮은 에러율을 보여준다.

그림 5는 트래픽 변화를 변환을 통해 전처리된 정상성 트래픽 시간 창 간의 상관관계를 히트맵으로 시각화하였다. 이 정상성 트래픽에서는 전반적으로 변화가 두드러지지 않아 어떤 사이 간격의 시간 창에서도 상관계수가 낮다. 단계가 진행됨에 따라 오류가 쌓임에도 불구하고 많은 영향을 받지 않을 수 있다.

그림 6은 정상성 트래픽을 재귀 기법과 다중 출력 기법이 각 단계의 예측한 결과에 대한 MAPE를 보여준다. 제안된 Bi-LSTM_S2S_M2 모델은 LSTM_RE_M2 모델을 제외한 나머지 모델과 비슷한 성능을 보여준다.

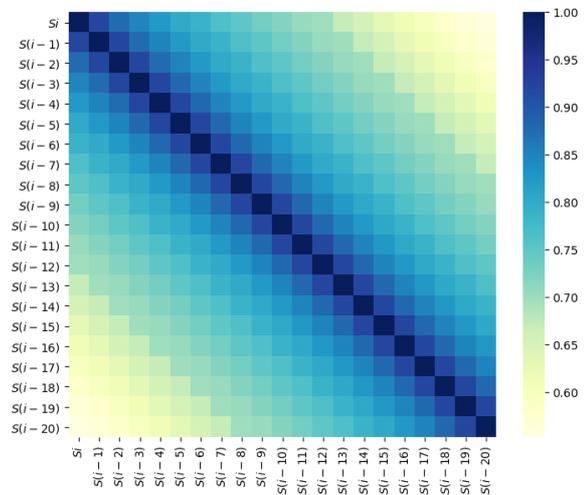


그림 3. 비정상성 트래픽 시간 창 간의 상관관계에 대한 히트맵 시각화

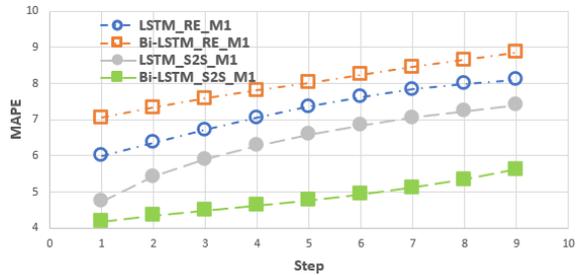


그림 4. 비정상성 트래픽에 대한 10 단계 앞선 예측

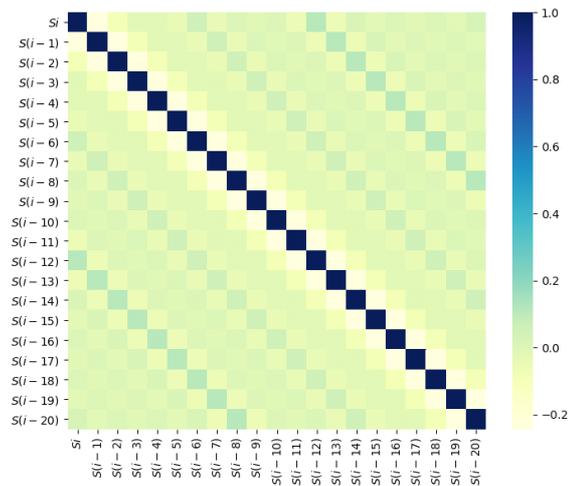


그림 5. 정상성 트래픽 시간 창 간의 상관관계에 대한 히트맵 시각화

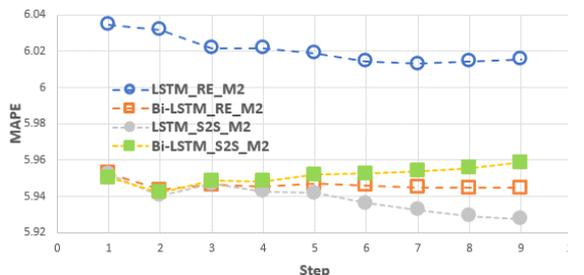


그림 6. 정상성 트래픽에 대한 10 단계 앞선 예측

LSTM_RE_M2은 높은 에러율의 첫 스텝 결과를 회귀하여서 이후 스텝의 에러율은 비교적 높은 에러율을 보여준다.

V. 결론

본 논문에서는 멀티 스텝 트래픽 예측을 위해 다중 출력 전략을 적용한 Bi-LSTM 기반 인코더 디코더 모델을 제안한다. 실제 DNS 네트워크 트래픽 기반 평가를 통해 제안된 기법이 비정상성 관찰되는 트래픽에 대해 성능을 향상시키는데 효과적이다. 또한, 제안된 기법은 정상성이 관찰되는 트래픽에서 이전의 접근 방식과 유사한 성능을 달성하였다. 차후에 우리는 전반적인 네트워크 트래픽 흐름을 파악하기 위해 그래프 신경망을 네트워크 트래픽 예측 모델에 적용할 계획이다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터육성지원사업의 연구결과로 수행되었음 (IITP-2021-2016-0 - 00314*). 본 논문은 2021년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과입니다.

참고 문헌

- [1] Bhuyan, Monowar H., Dhruva Kumar Bhattacharyya, and Jugal K. Kalita. "Network anomaly detection: methods, systems and tools." *Ieee communications surveys & tutorials* 16.1 (2013): 303-336.
- [2] T. Alghamdi, K. Elgazzar, M. Bayoumi, T. Sharaf and S. Shah, "Forecasting Traffic Congestion Using ARIMA Modeling," 2019 15th International Wireless Communications & Mobile Computing Conference (IWCMC), Tangier, Morocco, 2019, pp. 1227-1232, doi: 10.1109/IWCMC.2019.8766698.
- [3] R Vinayakumar, KP Soman, and Prabaharan Poornachandran. 2017. Applying deep learning approaches for network traffic prediction. In 2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI). IEEE, 2353 - 2358.
- [4] Zang, Chuanyun. "Deep Learning in Multiple Multistep Time Series Prediction." arXiv preprint arXiv:1710.04373 (2017).
- [5] Haviluddin, Haviluddin, and Rayner Alfred. "Forecasting network activities using ARIMA method." (2014).
- [6] Chan, Kit Yan, et al. "Traffic flow forecasting neural networks based on exponential smoothing method." 2011 6th IEEE Conference on Industrial Electronics and Applications. IEEE, 2011.
- [7] Rutka, G. "Network traffic prediction using ARIMA and neural networks models." *Elektronika ir Elektrotechnika* 84.4 (2008): 53-58.
- [8] Shu, Yantai, et al. "Wireless traffic modeling and prediction using seasonal ARIMA models." *IEICE transactions on communications* 88.10 (2005): 3992-3999.
- [9] Somenath Mukherjee, Rajdeep Ray, Rajkumar Samanta, Mofazzal H Khondekar, and Goutam Sanyal. 2017. Nonlinearity and chaos in wireless network traffic. *Chaos, Solitons & Fractals* 96 (2017), 23 - 29.
- [10] A. Azzouni and G. Pujolle. 2018. NeuTM: A neural network-based framework for traffic matrix prediction in SDN. In *NOMS 2018 - 2018 IEEE/IFIP Network Operations and Management Symposium*. 1 - 5.
- [11] Giang-Truong Nguyen, Van-Quyet Nguyen, Huu-Duy Nguyen, and Kyungbaek Kim. 2018. LSTM based Network Traffic Volume Prediction. In *Proceedings of 2018 KIPS Spring Conference*.
- [12] H. Lu and F. Yang. 2018. Research on Network Traffic Prediction Based on Long Short-Term Memory Neural Network. In *2018 IEEE 4th International Conference on Computer and Communications (ICCC)*. 1109 - 1113.
- [13] R Vinayakumar, KP Soman, and Prabaharan Poornachandran. 2017. Applying deep learning approaches for network traffic prediction. In *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*. IEEE, 2353 - 2358.
- [14] Sutskever, Ilya, Oriol Vinyals, and Quoc V. Le. "Sequence to sequence learning with neural networks." arXiv preprint arXiv:1409.3215 (2014).