

계절성 임베딩을 고려한 STL-Attention 기반 트래픽 예측

염성웅, 최철웅, 콜레카르 시바니 산제이, 김경백
전남대학교 인공지능융합학과

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

STL-Attention based Traffic Prediction with Seasonality Embedding

Sungwoong Yeom, Chulwoong Choi, Shivani Sanjay Kolekar, Kyungbaek Kim
Dept. of Artificial Intelligence Convergence, Chonnam National University

요 약

최근 비정상적인 네트워크 활동 감지 및 네트워크 서비스 프로비저닝과 같은 다양한 분야에서 응용되는 네트워크 트래픽 예측 기술이 네트워크 통신 문제에 의한 트래픽의 결측 및 네트워크 유저의 불규칙한 활동에 의한 비선형 특성 때문에 발생하는 성능 저하를 극복하기 위해 딥러닝 신경망에 대한 연구가 활성화되고 있다. 이 딥러닝 신경망 중 시계열 딥러닝 신경망은 단기 네트워크 트래픽 볼륨을 예측할 때 낮은 오류율을 보인다. 하지만, 시계열 딥러닝 신경망은 기울기 소멸 및 폭발과 같은 비선형성, 다중 계절성 및 장기적 의존성 문제와 같은 한계를 보여준다. 이 논문에서는 계절성 임베딩을 고려한 주의 신경망 기반 트래픽 예측 기법을 제안한다. 제안하는 기법은 STL 분해 기법을 통해 분해된 트래픽 트렌드, 계절성, 잔차를 이용하여 일별 및 주별 계절성을 임베딩하고 이를 주의 신경망을 기반으로 향후 트래픽을 예측한다.

1. 서론

네트워크 트래픽 예측 기술의 발전은 단기, 중기 및 장기 예측을 통해 정확한 네트워크 수요 계획 및 효율적인 자원 관리함으로써 네트워크 관리에 발생하는 비용을 크게 절감할 수 있다. 전통적인 트래픽 예측 기술은 불안정한 네트워크 통신으로 인해 주기적으로 관찰되는 트래픽에서 결측이 발생함으로써 성능 저하가 발생할 수 있다 [2]. 네트워크 통신 장애로 인한 결측 값에 대한 추정을 위해 STL 분해를 사용한 트래픽 예측 기법이 제안되었다 [7]. 하지만, 통계 기반 트래픽 예측 기법의 성능은 네트워크 유저로부터 관찰되는 비선형적인 행동에 의해 저하될 수 있다 [5].

최근 비선형 시계열 회귀 작업을 위해 시계열 딥러닝 신경망 기반 트래픽 예측 연구가 활성화되고 있다 [8-9]. 이 시계열 딥러닝 기반의 트래픽 예측 기법은 불규칙한 트래픽 패턴을 학습하고 매개 변수 간의 장기적인 종속 관계를 고려하여 예측 정확도를 효과적으로 향상시킬 수 있다. 하지만, 단기 트래픽 예측에서는 효율적이지만 트렌드 및 계절 정보와 같

은 장기적 특성이 드러나는 트래픽에서는 비효율적일 수 있다. 더 나아가 트래픽으로부터 일별 및 주별 계절성이 결합된 다중 계절성 패턴에 의해 트래픽 보다 복잡하게 동작한다면 트래픽 예측 기법의 성능이 더 저하될 수 있다.

트래픽의 장기적 특성과 복잡한 패턴을 고려하기 위해 시계열 딥러닝 모델과 주의 메커니즘을 결합하는 기법이 제안되었다 [11]. 이 기법은 밀접하게 연결된 시계열 딥러닝 모델과 주의 메커니즘 모델은 연속적인 입력 트래픽으로부터 특성이 두드러지는 일부 시간 단계에 집중시킴으로써 성능을 향상시킬 수 있다. 하지만, 시계열 딥러닝 모델을 트래픽 예측에 사용하게 된다면 본질적으로 순차적인 특성은 메모리 제약이 일괄 처리를 제한하기 때문에 더 긴 시퀀스 길이에서 병렬화를 배제하게 된다 [14]. 이 시계열 딥러닝 모델에서 발생하는 반복을 피하고 대신 입력과 출력 사이의 전역 종속성을 끌어내기 위해 시계열 딥러닝 신경망 없이 주의 메커니즘만 사용할 필요가 있다.

이 논문에서는 네트워크의 일별 및 주별 계절성 임베딩을 고려하여 주의 메커니즘을 기반으로 하는

네트워크 트래픽 예측 기법을 제안한다. 제안하는 기법은 STL 분해를 통해 네트워크 트래픽으로부터 일별 및 주별 계절성을 추출하고 이를 STL-Attention 모델의 입력벡터로 구성한다. 트래픽 예측 결과를 종합적으로 평가하기 위해 예측 결과의 정확도를 측정하는 MAPE(Mean Absolute Percentage Error)를 사용한다.

2. 관련 연구

일반적으로 시계열 예측 기법은 통계적 예측 기법, 머신러닝 기반 예측 기법, 딥러닝 기반 예측 기법으로 나눌 수 있다. 통계적 트래픽 예측 기법은 ARIMA [1], ARFIMA [2] 및 SARIMA [3]를 포함하여 시계열 데이터의 정상 부분을 맞추기 위해 매개변수를 사용한다. 하지만, 이러한 통계적 예측 기법은 결측 발생으로 인한 예측 성능 저하가 발생할 수 있다. 논문 [4]와 논문 [5]는 ARIMA와 Kalman Filter를 결합하여 결측 값을 고려한 시계열 예측을 통해 더 나은 성능을 제공하였다. 또한, 논문 [6]은 결측 값의 격차가 큰 시계열 데이터에 중점으로 누락된 값에 대한 추정을 제공하기 위해 STL 분해 및 다중 분할 간격 반복을 사용하는 반복 프레임워크를 제안하였다. 하지만, 최근 네트워크 유저들의 행동이 불규칙해짐에 따라 트래픽의 비선형적인 특성이 관찰됨에 따라 통계적 예측 기법의 성능이 저하될 수 있다.

이러한 트래픽의 비선형성에 의한 성능 저하를 완화하기 위해 시계열 딥러닝 모델 기반 트래픽 예측 기법 연구가 활성화되고 있다. 논문[7]은 결측값을 대체하기 위해 양방향 RNN기반 시계열 예측 기법을 제안하였다. 논문 [8]는 네트워크 트래픽 폭주와 불확실성에 대처하기 위해 LSTM 기반의 실시간 네트워크 트래픽 예측 모델을 제안하였다. 논문 [9]는 GEANT 백본 네트워크 데이터를 사용하여 LSTM 신경망을 통해 트래픽의 비선형 특성을 학습하고 예측하였다. 더 나아가, 최근 시계열 패턴 중 비선형적 특성이 두드러지는 부분을 더 잘 학습할 수 있는 Attention 메커니즘과 LSTM 모델을 결합한 시계열 예측 모델의 성능이 기존의 LSTM 모델에 비해 성능이 향상되는 것을 확인할 수 있었다 [10]. 논문 [11]는 옛지로부터 수집되는 모바일 트래픽을 주의 학습하는 메커니즘과 함께 LSTM을 기반으로 트래픽 흐름을 예측하는 기법을 제안한다. 이전의 여러 연구에서 시계열 결측과 비선형적 패턴에 대한 시계열 딥러닝 기법의 효과가 입증되었지만 이러한 기법은 주로 트렌드 및 계절 정보와 같은 트래픽의 장기 특성을 고려하지 않고 단기적 관점에서 시간 역학

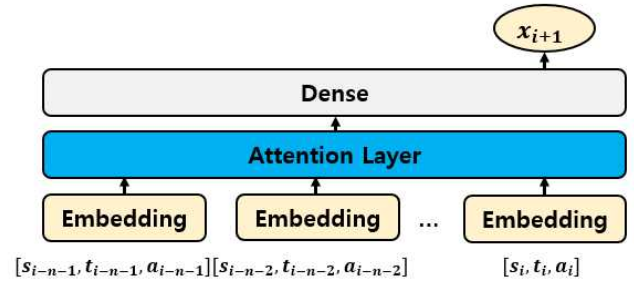


그림 1. STL-Attention 기반 트래픽 예측 모델 아키텍처 모델링에 중점을 둔다.

네트워크 트래픽의 단기적 패턴뿐만 아니라 장기적 패턴 또한 고려하기 위해 계절성과 추세를 고려하여 트래픽을 예측할 필요가 있다. 논문 [12]은 소스 측에서 관찰되는 비정기적인 계절적 트래픽에서 고성능을 유지하기 위해 계절성을 임베딩을 고려한 LSTM 기반 트래픽 예측 기법을 제안하였다. 논문 [13]은 STL 분해와 LSTM의 결합을 통해 네트워크 트래픽 예측 기법을 제안하였다. 하지만, 최근 LSTM과 같은 시계열 딥러닝 기법을 사용하지 않고 Attention 메커니즘만 사용한 시계열 예측 기법이 더 나은 성능을 제공하였다. 이 논문에서는 트래픽에서 관찰되는 일별 및 주별 계절성과 같은 다중 계절성을 고려한 주의 신경망 기반 트래픽 예측 기법을 제안한다.

3. 계절성 임베딩을 고려한 STL-Attention 기반 트래픽 예측 기법

네트워크 유저의 일별 및 주별로 일정하게 반복되는 트래픽 요소 추출은 네트워크 트래픽 예측에 중요한 요소이다. 이 논문에서는 트래픽의 일별 및 주별 계절성을 고려하여 주의 신경망 기반 트래픽 예측 모델을 제안한다. 그림 1은 제안하는 주의 신경망 기반 트래픽 예측 모델 아키텍처이다. 이 모델은 1개의 주의(Attention) 레이어와 1개의 텐스(Dense) 레이어로 구성된다. 이 중 마지막 Dense 레이어는 선형 활성화 함수를 사용한다. 각 레이어는 10개의 노드를 포함한다.

네트워크 트래픽은 네트워크 유저의 행동에 영향을 받는다. 트래픽을 딥러닝 신경망의 입력으로 직접적으로 사용한다면 제안된 모델의 예측 어려움이 높아질 수 있다. 제안된 모델의 예측 안정성을 보장하기 위해 STL 분해 기반 계절성 임베딩을 통해 입력 벡터를 생성한다. STL은 로버스트 로컬 가중 회귀를 평활화 기법으로 사용하는 시계열 분해 방법이며 특정 시간 i 의 트래픽 X_i 는 계절 성분 S_i , 추세 성분 T_i 및 잔차 R_i 로 분해되며 수식(1)은 다음과 같이 정의된다.

$$X_i = S_i + T_i + R_i \quad (1)$$

입력 벡터는 i^{th} 번째 시간대에 해당하는 트래픽으로부터 분해된 일별 트래픽 계절성 s_i , 주별 트래픽 추세 t_i , 시간대 인덱스 a_i 세 가지 도메인으로 구성된다. i^{th} 번째 시간 창 의 입력 벡터는 $v_i = (s_i, t_i, a_i)$ 이다. 제안된 주의 신경망 모델은 트래픽을 예측하기 위해 입력 벡터로 학습한다. 제안하는 주의 신경망 모델은 $(i-9)^{th}$ 부터 i^{th} 번째까지의 연속된 입력 벡터 $v_{i-9}, v_{i-8}, \dots, v_i$ 10개를 사용하고 $(i+1)^{th}$ 번째 트래픽 x_i 을 출력한다.

입력 벡터의 첫 번째 도메인은 STL 분해 기법을 통해 i^{th} 번째 트래픽 X_i 으로부터 추출된 일별 계절 성분 S_i 으로 반복되는 트래픽인 일별 계절성 트래픽 s_i 을 나타낸다.

입력 벡터의 두 번째 도메인은 i^{th} 번째 트래픽 X_i 으로부터 계절 성분 S_i 를 제거한 나머지에 LOESS를 적용하여 평활화된 추세 성분 T_i 와 잔차 R_i 를 합친 주별 계절성 트래픽 t_i 을 나타낸다. LOESS는 2차원 산점도 평활화를 위한 일반적인 기법인 국부 다항식 회귀 피팅이다.

입력 벡터의 세 번째 도메인은 시간 창 인덱스 a_i 이다. 시간 창 의 지속시간은 5분으로 설정한다. 시간 창 인덱스 a_i 는 첫 번째 도메인과 두 번째 도메인에서 정의된 일별 트래픽 계절성 s_i 또는 주별 트래픽 계절성 t_i 의 성능을 보정하기 위해 일별 시간 창 인덱스 a_i^d 와 주별 시간 창 인덱스 a_i^w 로 2가지로 나타낼 수 있다. 일별 시간 창 인덱스 a_i^d 의 경우, 길이는 288이고 값은 $\frac{1}{288}$ 에서 1 사이이다. 주별 시간 창 인덱스 a_i^w 의 경우, 길이는 2016이고 값은 $\frac{1}{2016}$ 에서 1 사이이다.

4. 성능 평가

제안된 계절성을 고려한 주의 기반 트래픽 예측 기법(STL-Attention)을 평가하기 위해 비선형성이 관찰되는 트래픽에서 제안하는 기법의 성능을 기존의 LSTM 기반 트래픽 예측 기법들[11],[13]과 비교한다. 먼저 딥러닝 기법들의 성능 비교하기 위해서 Attention, LSTM, Att-LSTM 모델들의 성능을 비교한다. 이후, STL 분해 기반 계절성 임베딩 기법 적용 유무에 따른 성능 비교를 위해 STL-Attention, Attention 모델들의 성능을 비교한다. 마지막으로 입력 벡터의 시간 창 인덱스의 종류

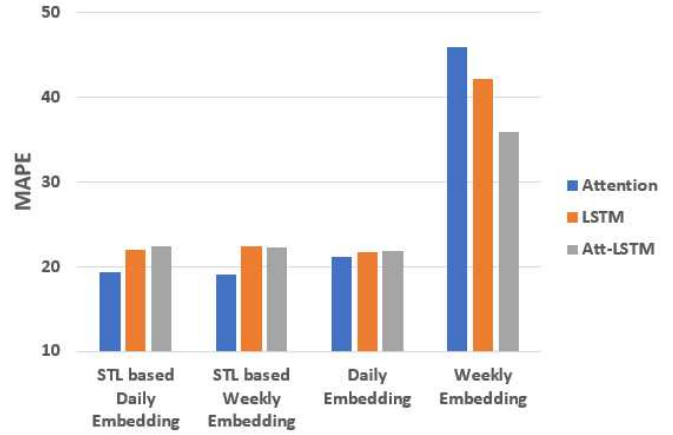


그림 2. 임베딩 기법에 따른 트래픽 예측 모델 성능 비교에 따른 모델들의 성능을 비교한다.

ICANN(Internet Corporation for Assigned Names and Numbers)에서 운영하는 DNS-STAT:Hedgehog의 리우데자네이루에서 한달(2020년 9월 1일 - 2020 9월 30일) 동안 수집된 실제 DNS 요청 트래픽으로 제안하는 기법을 평가했다. 각 데이터 세트의 처음 24일간의 트래픽은 제안된 기법과 다른 모델들을 학습하는데 사용하고 각 데이터 세트의 다음 6일은 각 트래픽을 얼마나 효과적으로 예측하는지 평가하기 위한 테스트 세트로 사용된다. 각 기법을 평가하기 위해 MAPE를 사용하며 기법의 성능이 좋을수록 MAPE는 낮다.

그림 6은 임베딩 기법에 따른 트래픽 예측 모델의 성능을 비교한다. 먼저, 딥러닝 모델의 구성에 따른 영향 평가를 위해 Attention(D), LSTM(D), Att-LSTM(D)을 비교할시 시계열 딥러닝 모델 없이 단독으로 어텐션 레이어만 사용한 Attention(D)가 LSTM(D) 및 Att-LSTM(D)에 비해 MAPE가 약 2% 더 낮다. LSTM(D) 및 Att-LSTM(D)은 두드러지지 않는 특징까지 구조 때문에 예측 성능이 저하되는 반면 Attention(D)는 특징이 두드러지는 일부 시간 단계에 집중하여 예측 성능이 향상된다.

이후, 계절성 임베딩에 대한 영향 평가를 위해 STL-Attention(D)과 Attention(D)를 비교할시 STL 임베딩을 적용한 STL-Attention(D)이 일반 Attention(D)에 비해 MAPE가 약 4% 정도 낮다. Attention(D)은 다중 계절성을 인지하지 못하는 반면에 STL-Attention(D)은 STL 분해 기법을 기준으로 다중 계절성을 분해 후 이를 입력 벡터의 특징으로 사용하기 때문에 성능이 더 좋다.

마지막으로, 일별 그리고 주별 시간창 인덱스에 따른 성능 비교를 위해 STL-Attention(D)와 STL-Attention(W)을 비교할 때 STL-Attention(W)

가 STL-Attention(D)에 비해 MAPE가 약 1% 더 낮다. 입력 벡터의 두 번째 도메인인 주별 계절성 트래픽이 STL 분해 기법을 통해 추출된 추세와 잔차의 합으로 추출된 계절성에 비해 불규칙적이다. 이를 주별 시간 창 인덱스를 통해 주별 계절성 트래픽의 불규칙적인 패턴을 보정하기 때문에 성능이 더 좋다.

5. 결론

이 논문에서는 네트워크 트래픽 계절성 임베딩을 고려한 STL-Attention 기반 트래픽 예측 기법을 제안한다. 제안하는 기법은 네트워크 트래픽과 같이 다중 계절성이 관찰되는 데이터로부터 STL 분해 기법을 통해 일별 계절성 트래픽과 주별 계절성 트래픽을 추출하고 이를 시간 창 인덱스와 함께 입력 벡터로 구성한다. 제안하는 기법은 실험을 통해 기존의 기법에 비해 약 4% 더 낮은 MAPE를 보여주었다. 차후에, 우리는 글로벌 환경에서 제안하는 트래픽 예측 모델을 도입하기 위한 프레임워크를 설계할 예정이다.

Acknowledgement

"본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터육성지원사업의 연구결과로 수행되었음" (IITP-2021-2016-0-00314)

참고문헌

- [1] Moayedi, H. Zare, and M. A. Masnadi-Shirazi. "Arima model for network traffic prediction and anomaly detection." 2008 International Symposium on Information Technology. Vol. 4. IEEE, 2008.
- [2] Andrysiak, Tomasz, et al. "Network traffic prediction and anomaly detection based on ARFIMA model." International Joint Conference SOCO'14-CISIS'14-ICEUTE'14. Springer, Cham, 2014.
- [3] Kumar, S. Vasantha, and Lelitha Vanajakshi. "Short-term traffic flow prediction using seasonal ARIMA model with limited input data." European Transport Research Review 7.3 (2015): 1-9.
- [4] D. S. Fung, "Methods for the estimation of missing values in time series," M.S. thesis, Edith Cowan Univ., Joondalup, WA, Australia, 2006.
- [5] E. Afrifa-Yamoah, U. A. Mueller, S. M. Taylor, and A. J. Fisher, "Missing data imputation of high-resolution temporal climate time series data," Meteorol. Appl., vol. 27, no. 1, p. e1873, Jan. 2020.
- [6] Y. Liu, T. Dillon, W. Yu, W. Rahayu, and F. Mostafa, "Missing value imputation for industrial IoT sensor data with large gaps," IEEE Internet Things J., vol. 7, no. 8, pp. 6855 - 6867, Aug. 2020.
- [7] J. Yoon, W. R. Zame, and M. van der Schaar, "Multi-directional recurrent neural networks: A novel method for estimating missing data," in Proc. Time Workshop Int. Conf. Mach. Learn., 2017, pp. 1 - 5.
- [8] 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.
- [9] 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.
- [10] G. Buroni, B. Lebichot and G. Bontempi, "AST-MTL: An Attention-Based Multi-Task Learning Strategy for Traffic Forecasting," in IEEE Access, vol. 9, pp. 77359-77370, 2021, doi: 10.1109/ACCESS.2021.3083412.
- [11] M. Chen, Y. Miao, H. Gharavi, L. Hu and I. Humar, "Intelligent Traffic Adaptive Resource Allocation for Edge Computing-Based 5G Networks," in IEEE Transactions on Cognitive Communications and Networking, vol. 6, no. 2, pp. 499-508, June 2020, doi: 10.1109/TCCN.2019.2953061.
- [12] Yeom, Sungwoong, Chulwoong Choi, and Kyungbaek Kim. "Source-side DoS attack detection with LSTM and seasonality embedding." Proceedings of the 36th Annual ACM Symposium on Applied Computing. 2021.
- [13] Y. Huo, Y. Yan, D. Du, Z. Wang, Y. Zhang, and Y. Yang, "Long-term span traffic prediction model based on STL decomposition and LSTM," in Proc. 20th Asia - Pacific Netw. Oper. Manage. Symp. (APNOMS), Sep. 2019, pp. 1 - 4.
- [14] Vaswani, Ashish, et al. "Attention is all you need." Advances in neural information processing systems. 2017.