

GATSBY: Graph Attention with Seasonality and Behavioral Yield

Hoyoung Yoon, U Kang

Seoul National University

crazy8597@snu.ac.kr, ukang@snu.ac.kr

GATSBY: 시계열 그래프에서의 주기성 보존을 위한 그래프 어텐션 기법

윤호영, 강 유
서울대학교

Abstract

시계열 그래프 학습(Temporal Graph Learning)에서 주기성(seasonality) 정보를 어떻게 효과적으로 반영할 수 있을까? 이 질문은 시계열 그래프 내에서 반복적으로 발생하는 패턴을 정확히 포착하여 예측 성능을 향상시키는 데 핵심적인 질문이다. 그러나 기존의 대표적 접근 방식인 Graph Convolutional Recurrent Network (GCRN)[1]은 시간적 연속성을 모델링하는 데에는 효과적이나, 주기적 시간 패턴을 명시적으로 반영하지 못하는 한계를 지닌다.

본 논문에서는 이러한 한계를 극복하기 위해 **GATSBY**(Graph Attention with Seasonality and Behavioral Yield)를 제안한다. **GATSBY**는 기존 GCRN의 LSTM을 Attention LSTM으로 대체하고, attention 계산 과정에 seasonality term을 가중합 형태로 통합함으로써 시점 간의 주기적 유사성을 반영할 수 있도록 한다.

실험 결과, **GATSBY**는 주기성이 존재하는 시계열 데이터셋에서 기존 GCRN 대비 일관된 성능 향상을 보였으며, 이는 주기성을 내재화한 attention 구조가 시계열 그래프의 시간 문맥을 보다 정밀하게 반영할 수 있음을 시사한다.

I . Introduction

시계열 그래프 학습에서 주기성을 어떻게 효과적으로 모델링할 수 있을까?

이 질문은 시간에 따라 동적으로 변화하는 노드 및 엣지 간의 관계를 정확하게 학습하고자 하는 최근의 연구 흐름에서 중요한 이슈로 떠오르고 있다. 시계열 그래프는 구조적 변화와 시간 흐름을 동시에 고려해야 하며, 특히 실제 데이터에는 특정 주기로 반복되는 상호작용 패턴이 자주 나타난다. 예를 들어 현실 세계의 시계열 그래프는 일일 교통량이나 주간 행동과 같은 주기적인 상호작용 패턴을 자주 포함한다.

기존의 temporal graph learning 접근법, 예컨대 GCRN[1], TGAP[2] 등은 순차적 정보는 잘 반영하지만, 주기적 패턴은 학습 구조 내에 명시적으로 반영되어

있지 않다. 이로 인해, 주기성이 중요한 역할을 하는 도메인에서는 모델 성능에 제약이 발생할 수 있다.

이에 본 논문에서는 주기성을 내재화한 attention 기반 시계열 모델인 **GATSBY** 프레임워크를 제안한다. **GATSBY**는 attention 계산 과정에 주기성 정보를 포함시켜, 동일한 시간 간격이라 하더라도 그 의미가 관계의 반복성에 따라 다르게 해석되도록 유도한다. 본 연구는 다음 세 가지 질문에 답하고자 한다:

1. 시계열 그래프에서 주기성을 구조적으로 반영할 수 있는가?
2. attention 기반 구조 내에서 seasonality 정보를 효과적으로 통합할 수 있는가?
3. 주기성 반영이 실제 예측 성능 향상으로 이어지는가?

II. Method

GATSBY 는 GCRN 의 구조를 기반으로 하되, 시간 정보를 처리하는 recurrent unit 을 Attention LSTM 으로 대체한다. 그리고 attention 연산 내에 seasonality 정보를 반영한 term 을 포함시켜 시점 간 유사성을 주기성 기반으로 재조정한다. 결과적으로, 동일한 시간 차이를 가진 노드 간 상호작용이라 하더라도, 주기적 맥락에 따라 서로 다른 attention score 가 할당된다.

기존 attention[3]은 query-key 내적에 softmax 를 적용한 형태로 계산되지만, **GATSBY** 에서는 여기에 seasonality term 을 추가한다:

$$a_{t,i} = \text{softmax}\left(\frac{q_t^T k_i}{\sqrt{d_k}} + \lambda \cdot s_{t,i}\right)$$

여기서 q_t, k_i 는 t 시점의 query 와 이웃 i 의 키, $s_{t,i}$ 는 시점간 주기적 유사성을 계산한 seasonality term, λ 는 조절 계수이다.

GATSBY 는 attention 계산 시 시점 간 주기적 유사성을 반영하기 위해 Fourier 변환 기반의 seasonality term 을 도입한다. 입력 행렬 $F \in \mathbb{R}^{N \times T}$ 의 시간 축에 대해 FFT 를 수행한 뒤, 상위 K 개의 dominant frequency 를 선택하여 각 주기를 P_k 로 추정한다. 이후 각 시점 쌍 (t, i) 에 대해 $s_{t,i} = \sum_{k=1}^K \cos\left(\frac{2\pi(t-i)}{P_k}\right)$ 로 정의된 주기 유사도를 계산하고, attention score 에 가중합 형태로 추가한다. 이를 통해 모델은 반복되는 시간 구조를 반영한 attention 을 학습할 수 있다.

III. Experiments

실험에는 도시 교통량의 시간적 패턴을 담고 있는 METR-LA 시계열 데이터셋을 사용하였다. 각 교통 센서는 그래프의 노드로 간주되며, 센서 간 도로 연결 정보를 바탕으로 그래프 구조를 구성하였다. 시간에 따른 각 노드의 연속 관측값을 시계열 입력으로 활용하고, 이를 기반으로 다음 시점의 노드 값을 예측하는 temporal graph forecasting 문제로 정식화하였다.

비교 대상 모델로는 기존의 GCRN 을 선정하였다.

GCRN 은 그래프 구조를 갖는 시계열 데이터를 처리하기 위한 대표적인 베이스라인 모델로,

시점마다 노드 간의 spatial dependency 를 GCN(Graph Convolutional Network)을 통해 학습하고, 시간 축의 dependency 는 LSTM 구조를 통해 처리한다.

모델 성능 평가는 MAE (Mean Absolute Error) 및 RMSE 를 기준으로 수행하였다.

Data	Methods	MAE	RMSE
METR-LA	GCRN	12.415	17.692
	GATSBY(ours)	8.528	13.561

실험 결과, **GATSBY** 는 baseline 모델들에 비해 모든 지표에서 우수한 성능을 나타냈으며, 특히 주기적 구조가 뚜렷한 구간에서 더 큰 성능 차이를 보였다. 이는 seasonality-aware attention 구조가 시계열 그래프 내 시간 문맥을 보다 정밀하게 해석함을 의미한다.

III. Conclusion

본 논문에서는 시계열 그래프 학습에서 주기성을 구조 내에 명시적으로 반영하기 위한 **GATSBY** 프레임워크를 제안하였다. **GATSBY** 는 attention 계산에 seasonality term 을 통합함으로써, 주기적 시간 패턴을 고려한 정보 선택이 가능하며, 실제 예측 성능 향상으로 이어짐을 실험을 통해 확인하였다. 본 연구는 향후 반복적 행동 패턴이 중요한 다양한 temporal graph 분석 문제에 폭넓게 활용될 수 있을 것으로 기대된다.

ACKNOWLEDGMENT

이 논문은 2025년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 [NO.RS-2021-II211343, 인공지능대학원지원원(서울대학교)]

REFERENCES

- [1] Seo, Y., Defferrard, M., Vandergheynst, P., & Bresson, X. (2016). Structured Sequence Modeling with Graph Convolutional Recurrent Networks. *arXiv*
- [2] Jung, J., Jung, J., & Kang, U. (2021). Learning to Walk across Time for Interpretable Temporal Knowledge Graph Completion. *KDD*.
- [3] Vaswani, A., et al. (2017). *Attention is All You Need*. *NeurIPS*.