

사전 학습된 모델 지식 활용: 코사인 유사성을 이용한

딥러닝 시계열 이상 탐지 방법에 대한 연구

조유철, 김태현, 김대식*

한국과학기술원 (KAIST)

{yc_cho, rlaxogus0814, daeshik}@kaist.ac.kr

요약


시계열 데이터의 이상 탐지는 시스템의 상태 모니터링과 이상 상황의 조기 발견을 위한 중요한 기술로, 로봇 고장 탐지, 제조업의 품질 관리, 금융 거래의 사기 탐지, IT 시스템의 성능 모니터링 등 다양한 산업 분야에서 활용되고 있습니다. 최근 연구에서는 pretrained 모델의 지식을 활용하여 이러한 이상 탐지 성능을 향상시킬 수 있다는 점에 주목하고 있습니다. 따라서 본 연구에서는 pretrained 모델의 출력을 새로운 모델에 distillation 하여 지식을 전달하는 접근 방식을 제안합니다. 이 방법은 pretrained 모델과 새로운 모델 간의 cosine similarity 를 활용하여, pretrained 모델의 풍부한 특성 정보를 새로운 모델에 효과적으로 전달할 수 있습니다. 실험 결과, pretrained 모델의 출력과 새로운 모델의 출력 간의 cosine similarity 를 학습에 반영함으로써 이상 탐지 성능이 유의미하게 개선되었으며, 제안된 방법은 기존의 state-of-the-art 모델보다 우수한 성능을 보였습니다. 본 연구는 pretrained 모델의 지식을 distillation 기법을 통해 새로운 모델에 전달하고, 이로 인해 시계열 데이터에서의 이상 탐지 성능을 향상시킬 수 있음을 보여주며, 향후 연구에서의 활용 가능성을 제시합니다.

I. 서론

최근, 트랜스포머 (Transformer) 기반의 비지도 학습 (unsupervised learning) 기법을 활용한 시간 시계열 이상 탐지 연구들이 활발히 진행되고 있습니다. 트랜스포머(Vaswani et al., 2017 [1])는 자연어 처리, 오디오 처리, 그리고 컴퓨터 비전 등 시퀀스 데이터 처리에 있어 뛰어난 성능을 보여주었습니다. 시간 시계열 분석에서는 자기 주의 메커니즘 (self-attention mechanism)의 장점을 활용하여, 신뢰할 수 있는 장기적인 시간적 의존성 (long-range temporal dependencies)을 발견하는 데 사용되고 있습니다. 특히, 시간 시계열 이상 탐지 분야에서는 Chen et al. (2021)이 제안한 GTA [2]가 여러 IoT 센서 간의 관계를 학습하기 위해 그래프 구조를 활용하며, 트랜스포머를 시간적 모델링과 재구성 기준을 위한 이상 탐지에 사용하고 있습니다. 최근에 연구된 Anomaly Transformer [3]는 기존의 모델과 달리 연관 불일치 (association discrepancy)에 대한 주요 관찰을 바탕으로 자기 주의 메커니즘을 이상 탐지 주의 (Anomaly-Attention)로 혁신적인 시계열 이상탐지 방법을 제시하였습니다.

하지만 기존의 시계열 이상 탐지 방법들은 사전 학습된 모델의 지식을 활용하지 않아, 모델이 학습 과정에서 얻을 수 있는 지식의 양이 제한적입니다. 이로 인해 복잡한 시계열 데이터의 패턴을 효과적으로 학습하는 데 어려움이

있을 수 있습니다. 반면, 사전 학습된 모델의 출력을 활용하면 정답 데이터만 학습하는 것보다 초기 학습 단계에서 올바른 방향성을 설정하는 데 도움이 됩니다.



[그림 1] 사전학습된 모델의 출력과의 코사인 유사도를 이용한 time series anomaly detection 모델 학습 방법

특히, 사전 학습된 모델의 지식을 전수하는 knowledge distillation 기법은 학생 모델이 더 효율적으로 학습할 수 있도록 할 수 있습니다. 그러나 기존 연구들은 주로 출력을 복원하는 데 초점을 맞추며, mean-squared error (MSE) loss 를 사용해 시점 간 오류를 강조합니다. 이 접근법은 시계열 데이터에서 중요한 패턴이나 이상점을 충분히 포착하지 못할 수 있습니다. 이 문제를 해결하기 위해, 본 논문에서는 사전 학습된 모델과 학습 중인 모델 간의 코사인 유사도 (cosine similarity)를 활용한 새로운 knowledge distillation 방법을 제안합니다. 코사인 유사도는 두 벡터 간의 방향성을 측정하여 학생 모델이 사전 학습된 모델의 지식을 더 효과적으로 학습하게 합니다. 이를 통해 모델이 더 풍부한 지식을 활용하여 시계열 이상 탐지 성능을 향상시킬 수 있음을 보이고자 합니다.

II. 본론

	Model	P	R	F1
MSL	LSTM	85.45	82.50	83.95
	OmniAnomaly	89.02	86.37	87.67
	THOC	88.45	90.97	89.69
	Anomaly Transformer	91.75	93.90	92.81
	Ours	92.14	97.93	94.94
PSM	LSTM	76.93	89.64	82.80
	OmniAnomaly	88.39	74.46	80.83
	THOC	88.14	90.99	89.54
	Anomaly Transformer	97.24	97.86	97.55
	Ours	97.34	98.79	98.06
SMD	LSTM	78.55	85.28	81.78
	OmniAnomaly	83.68	86.82	85.22
	THOC	79.76	90.95	84.99
	Anomaly Transformer	88.65	91.15	89.88
	Ours	89.10	94.85	91.89

[표 1] 세 개의 실제 데이터셋에 대한 우리 모델 (ours) 의 정량적 결과입니다. P, R, F1 은 각각 정확도, 재현율, F1 점수(%)를 나타내며, F1 점수는 정확도와 재현율의 조화 평균입니다. 이 세 가지 지표에서 값이 클수록 성능이 더 우수함을 의미합니다.

본 논문에서는 사전학습된 모델 (reconstruction model)의 output 과 학습하고자 하는 모델의 output 간의 코사인 유사도를 계산하여, 이를 학습에 반영하고자 합니다. 사전학습된 모델과 학습 모델은 서로 다른 output 을 출력하게 되며, 일반적인 학습의 경우, 신경망은 오로지 input data 를 reconstruction 을 잘 하는 방향으로만 학습하는 경우가 많습니다. 하지만 [그림 1]에서 볼 수 있는 것처럼, 본 논문에서 제안하는 방법의 경우, 사전학습된 모델과 학습하고자 하는

모델 간의 코사인 유사도를 계산하여 이를 학습에 반영합니다. 자세한 loss function 은 아래와 같습니다:

$$L_{\cos} = \text{CosineSimilarity} (O_{\text{pretrained}}, O_{\text{training}}),$$

여기서 L 은 손실함수, O 는 output 을 의미합니다.

이를 학습에 반영하면, 초기 학습부터 사전학습된 모델의 output 의 형태를 배움으로써 학습이 더욱 용이하게 하며, 코사인 유사도를 통하여 학습하고자 하는 방향성을 더 수월하게 파악할 수 있습니다. 결과적으로, [표 1]에서 보이는 것처럼, 우리가 제안하는 방법의 경우, 3 가지 dataset 에 대하여 precision (P), recall (R) 및 F1-score (F1) 등의 여러 가지 metric 에서 가장 좋은 성능을 보여줍니다.

III. 결론

본 논문에서는 사전학습된 모델의 출력과 학습 중인 모델의 출력을 비교하여 코사인 유사도를 계산하고 이를 학습 과정에 반영하는 새로운 방법을 제안했습니다. 기존의 방법이 입력 데이터를 단순히 복원하는 데 중점을 두었다면, 제안된 방법은 초기 학습 단계에서부터 사전학습된 모델의 지식을 활용하여 학습 방향을 보다 효율적으로 설정할 수 있도록 했습니다. 이 방법을 적용한 결과, 세 가지 데이터셋에서 precision, recall, F1-score 등 다양한 성능 지표에서 기존 방법들보다 우수한 성과를 달성했습니다. 따라서 본 연구는 시계열 이상 탐지 분야에서 사전학습된 모델의 지식을 효과적으로 활용하는 방법의 가능성을 제시하며, 향후 연구에 유용한 기초 자료를 제공할 수 있을 것입니다.

ACKNOWLEDGMENT

This work was supported by the Technology Innovation Program (20015802, 22 kW class high power 10 kHz high speed processing predictive maintenance based OLED mask transfer robot controller servo motor and drive development) funded by Ministry of Trade, Industry & Energy (MOTIE, Korea)

참 고 문 헌

- [1] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. Advances in neural information processing systems, 30.
- [2] Chen, Z., Chen, D., Zhang, X., Yuan, Z., & Cheng, X. (2021). Learning graph structures with transformer for multivariate time-series anomaly detection in IoT. IEEE Internet of Things Journal, 9(12), 9179-9189.
- [3] Xu, J., Wu, H., Wang, J., & Long, M. (2021). Anomaly transformer: Time series anomaly detection with association discrepancy. arXiv preprint arXiv:2110.02642.