

네트워크 전송 장비를 위한 예지보전 기술에 관한 연구

나지혜, 이은정, 이광국
KT, KAIST

jihye.na@kt.com {jihye121@kaist.ac.kr}, hannah.lee@kt.com, kwangkoog@kt.com

A Study on the Predictive Maintenance Technology for Network Transmission Equipment

Na Ji-Hye, Lee Eun-Jung, Lee Kwang-Koog
KT

요 약

본 논문은 네트워크 전송 장비인 MSPP의 스위칭 부 외 유닛의 예지보전을 위한 실시간 이상 징후 탐지 모델을 제시한다. 모델링에 앞서 MSPP 장비를 예지보전 하기 위한 어려운 점을 나열하고, 이를 해결하기 위해서 장비 수리의 단위를 사전 정의하고, 사용할 수 있는 통계적 방법과 ML, DL 기반의 다양한 비지도 학습 이상 탐지 모델을 제안한다. 또한, 향후 연구에서 추가로 고려할 변수들을 제시하며, 전송 장비에서 다양한 변수를 사용하여 모델링이 가능함을 시사하였다.

I. 서 론

예지보전(Predictive Maintenance)이란 장비에 대한 유지보수의 방법 중 데이터를 분석하여 이상 징후를 사전에 파악하고 조치하는 방법을 의미하며, 최근 들어 스마트 팩토리에서 설비의 과잉 보전을 개선하고 안정성을 증가시키는 목적으로 주목을 받고 있다[1].

예지보전에 관련된 기존 연구는 대부분 베어링, 배터리, 엔진 등과 관련된 데이터 세트를 활용하여 공장 설비에 적합한 형태의 데이터를 다룬 연구들이 주를 이루며, 네트워크 전송 장비에 대한 연구는 부족한 실정이다 [2].

하지만, 안정적인 네트워크 서비스 제공을 위해서는 네트워크 전송 장비 분야에도 사후 처리 방식의 수리에 벗어난 예지보전 형태의 유지보수가 필수적이다.

따라서, 본 연구에서는 네트워크 전송 장비 중 MSPP(Multiservice Provisioning Platform) 장비를 대상으로 예지보전 적용이 가능한 이상 징후 탐지 모델을 제시하고자 한다.

II. 본론

(1) MSPP 장비 대상 예지보전을 위한 정의

MSPP는 통신 사업자의 전용회선 사업 등에 널리 사용되는 광 전송(Optical Transport) 장비로 [3], 그림 1과 같이 스위칭 부 유닛 S와 SDH, PDH, Ethernet 등의 신호를 다루는 스위칭 부 외 유닛 U로 구성된다. 스위칭 부 유닛과 연결된 다른 유닛 간의 버스 상태는 예지보전을 위한 감시의 대상으로, 버스 상태는 크게 다음과 같이 3가지로 구분하여 정의한다. 먼저, S와 U 간 버스 상태를 구분하기 위해 ①스위칭 부 외의 유닛에서 스위칭 부로 가는 버스 상태, ②스위칭 부에서 스위칭 부 외 유닛으로 가는 버스 상태, S 내부 버스 상태 구분을

위해 ③ 스위칭 부 유닛 내의 HO(High order)와 LO(Low order) 사이를 움직이는 버스 상태로 정의한다.

(2) MSPP 장비 대상 예지보전 모델 설계 방향

MSPP 장비를 대상으로 하는 예지보전에는 다음과 같은 어려움이 존재한다. 첫 번째, 고장 데이터 수집이 어렵다. 따라서, 많은 고장 데이터가 필요한 잔여 수명 예측 방법보다는 이상 징후를 포착하여 예지보전을 하는 접근 방법이 필요하다. 두 번째, 버스 상태가 장비 고장 외의 요인에 영향을 받는다. 이를 해결하기 위해서는 클럭원 변화, 연결 장비의 고장 등의 버스 상태에 영향을 주는 요인들을 실험을 통해 포착할 필요가 있다. 세 번째, 장비 및 장비 내의 칩셋 별 특성이 다르다. 예를 들어, 온보드 형식으로 설계된 유닛은 수리의 단위가 레지스터가 아닌 유닛 자체이다. 그러므로 본 연구에서는 수리의 단위를 장비 전체나 개별 레지스터 r 이 아닌 개별 유닛 u 를 단위로 이상 징후를 포착하는 것을 목적으로 하며, 서비스의 안전성을 위해서 이중화 되어있는 스위칭 부 유닛이 아닌, 이중화가 되어있지 않은 스위칭 부 외 유닛 U 를 대상으로 예지보전 기술을 제안한다.




그림 1. MSPP 장비 내의 버스 구조




그림 1. 개별 레지스터 값에 대한 버스 상태 변화

(3) MSPP 장비의 실시간 이상 징후 탐지 모델

실시간으로 스위칭 부 외 유닛 U 에 대한 이상징후를 파악하는 모델을 설계하기 위해 앞서, 실제 사용 환경에 적합한 수집 주기, 윈도우 사이즈 등을 사전에 정의한다. 또한, 장비 고장 외 요인에 의한 버스 상태를 고려하기 위해서 실험을 통해 사전에 해당 값에 대한 분석이 필요하다. 해당 분석은 모델을 통해 나온 결과가 이상 징후인지를 판단하는 사용자 정의 임계값 설정을 위한 기반 지식으로써 사용될 수 있다. 이후, 아래와 같은 3 단계 과정을 거쳐 실시간 이상 탐지가 가능하다.

첫 번째, ‘전처리 단계’에서는 실시간으로 수집된 버스 상태에 관한 데이터를 3 가지로 범주화하고 이 중 스위칭 부 외 유닛 U 에서 스위칭 부 유닛 S 로 가는 그림 1 의 1 번 버스 방향에 대한 버스 상태만을 추출한다. 이후, 개별 레지스터별로 누적된 버스 상태 정보인 히스토리 데이터에 윈도우 내에 발생한 버스 상태의 횟수를 증가시킨다. 두 번째, ‘모델 적용 단계’에서는 이상 징후에 대한 정도 V 가 임계값 이상인지를 판단한다. 이때, 이상 징후 정도 V 는 다양한 기준에 의해서 모델링을 하는 것이 가능하다. 단, 고장 데이터에 대한 수집의 어려움으로 인해서 지도학습을 사용하기에는 어려움이 존재한다. 그러므로 통계치와의 비교 또는 비지도 학습 기반 모델 사용이 필요하다. 세 번째, ‘레지스터 통합 단계’에서는 스위칭 부 외 유닛 내의 레지스터의 버스 상태에서 임계값 이상의 이상징후가 포착되었는지를 로그로써 반환한다. 만약 유닛 내의 적어도 하나의 레지스터가 이상징후가 포착된다면, 이를 로그 저장하고 경보를 울린다.

MSPP 의 유닛이 정상인 경우에 버스 상태가 안정적으로 움직이기에 ‘모델 적용 단계’에서 정상인 경우에 대한 특성을 다양한 방법으로 추출하여 이상 징후를 탐지할 수 있다. 가장 간단한 방법으로는 윈도우 내의 버스 상태의 ‘값’이 정해진 범위를 넘는 (비)연속적인 횟수를 V 로 정의할 수 있다. 하지만, 이 경우 해당 범위 내에서 자주 변동되는 패턴을 잡지 못한다. 따라서, 다른 방법으로써 버스 상태 값의 ‘변동’을 V 로 정의하고 V 가 임계값을 넘는지를 판단 내릴 수 있다. 이때, 윈도우 내의 변동을 정의하기 위해서 분산을 사용하며, 첫 번째 단계에서 수집한 히스토리 데이터를 이용하여 평균을 구하고 이를 기반으로 분산을 계산한다.

예를 들어, 그림 2 와 같이 각 윈도우마다 실시간으로 데이터를 받으면서 해당 윈도우에서 이상 징후가 포착되었는지를 살펴보고 이를 기준으로 수리의 필요성을 장비 관리자에게 알려줄 수 있다. 이때, 그림 2 의 4 번째 윈도우에서 이전 윈도우인 1, 2, 3 번째 윈도우와 버스 상태가 더 많이 변동하는 패턴을 보였고 이러한 이상 징후 포착을 통해서 고장이 발생하는 5 번째 윈도우 이전에 사전 조치할 수 있도록 한다.

이 외에도 ML 기반의 모델인 Isolation Forest 를 사용하여 해당 트리의 깊이를 기준으로 V 를 정의할 수 있다 [4]. 반면, DL 기반의 모델은 AE(AutoEncoder) 기반 모델을 통해서 재구성 에러(Reconstruction

Error)를 얻고, 이를 V 라고 정의한다. 이때, AE 는 CNN 과도 결합할 수 있으며, 시간을 모델링하기 위해서 RNN, LSTM, GRU 와 결합할 수 있다 [1]. 또는 이상 감지 모듈과 시계열 예측 모듈을 결합해서 비지도 학습으로 이상 탐지를 하는 DeepAnT[5]와 같은 모델을 사용할 수도 있다.

III. 결론

본 연구에서는 네트워크 전송 장비인 MSPP 에서 SDH, PDH, Ethernet 등의 신호를 다루는 유닛에 대한 예지보전 방법을 제시한다. 이때, 현실의 제약사항들을 잘 고려한 범용적인 모델 설계를 위해서 수리의 단위를 유닛 단위로 설정한 뒤, 다양한 비지도 학습 기반의 모델을 통해서 이상 징후를 포착할 수 있음을 제안했다. 또한, 장비 고장 외의 요인을 다루기 위한 추가 실험을 기반으로 임계값을 설정할 필요성을 서술하였다.

향후 연구에서는 이상 징후 탐지를 위해서 더 다양한 변수들을 고려할 수 있다. MSPP 간의 토폴로지, 에러 메시지 등은 추가적인 고려 대상이다. 단, 추가 고려 대상 중 일부는 카테고리 변수이므로 연속형 변수와 다른 접근 방법으로 이상을 탐지하고 이를 예지보전에 적용해야 한다 [6].

참 고 문 헌

- [1] Serradilla, O., Zugasti, E., Rodriguez, J., et al. “Deep learning models for predictive maintenance: a survey, comparison, challenges and prospects”, Applied Intelligence 52, pp. 10934-10964, Jan. 2022.
- [2] NASA, “Prognostics Center of Excellence Data Set Repository”, (<https://www.nasa.gov/content/prognostics-center-of-excellence-data-set-repository>)
- [3] 김홍주, 이현재, 유제훈, 고제수, 김태일, 주법순, 이종현, “광-회선-패킷 통합 전달망 기술 동향”, 전자통신동향분석 Vol. 28, no.6. pp.49-62, Dec. 2013.
- [4] Charu C. Aggarwal. “Outlier Analysis”, Springer, 2017.
- [5] M. Munir, S. A. Siddiqui, A. Dengel and S. Ahmed, “DeepAnT: A Deep Learning Approach for Unsupervised Anomaly Detection in Time Series”, IEEE Access Vol. 7, pp. 1991-2005, 2019.
- [6] Taha, Ayman and Hadi, Ali S. “Anomaly Detection Methods for Categorical Data: A Review”, ACM Computing Survey 52, pp. 1-35, Mar. 2020.