

# 설비의 예지 보전을 위한 Transformer 기반의 전력 품질 예측 및 이상 상황 탐지

이 제 혁\*

## Transformer-based Electric Quality Forecasting and Anomaly Detection for Predictive Maintenance

Jehyuk Lee\*

### 요약

최근 본격적으로 스마트팩토리가 도입되면서 설비의 건강 상태를 지속적으로 모니터링하면서 문제가 발생하기 전에 사전에 조치를 수행하는 예지 보전에 대한 중요성이 강조되고 있다. 설비의 건강 상태에 중요한 영향을 끼치는 인자들 중 하나가 설비가 사용하는 전력의 품질이다. 전력의 품질이 좋지 않으면 생산 과정의 중지 및 재가동, 제품 품질 불량 위험 등 불필요한 비용이 발생하고, 이를 사전에 예측하여 줄여야 한다. 본 논문에서는 transformer 기반의 시계열 데이터 장기 예측 모델을 활용하여 전력 품질을 사전에 예측하고 이상 상황을 탐지하는 방법론을 제안한다. 이때, 비정상성, 값이 급격하게 변동하는 데이터의 특성을 고려하여 일반적인 예측 모델과 달리 DILATE 손실함수를 활용하였다. 그 결과, 예측 성능과 이상 탐지 성능이 향상되었다.

### Abstract

With the recent introduction of smart factories in earnest, the importance of predictive maintenance, which continuously monitors the state of health of machinery and takes necessary measures in advance, has been emphasized. The power quality is one of the important factors that affect the health status of facilities. If the quality of power is poor, many unnecessary costs are incurred. Therefore, it is necessary to predict this in advance and reduce the cost. In this paper, we propose a method that predicts the quality-related index value and detects the abnormal situation with the transformer-based long-term time series forecasting model. Here, we utilized DILATE loss function instead of MSE, due to the characteristics of the power quality time series data, the non-stationary, and the rapid change in value. As a result, the performance of both forecasting and detection is improved.

### Keywords

predictive maintenance, transformer, long-term time-series forecasting, anomaly detection

\* 국민대학교 AI빅데이터융합경영학과 교수  
- ORCID: <https://orcid.org/0000-0002-2333-2871>

· Received: Nov. 01, 2023, Revised: Dec. 19, 2023, Accepted: Dec. 22, 2023  
· Corresponding Author: Jehyuk Lee  
Dept. of AI, Big data & Management, Kookmin University  
Tel.: +82-2-910-4537, Email: [jehyuk.lee@kookmin.ac.kr](mailto:jehyuk.lee@kookmin.ac.kr)

## I. 서 론

최근 본격적으로 스마트팩토리가 도입되기 시작하면서 자동 생산에 필수적인 설비의 건강 상태(SOH, State of Health)의 중요성이 강조되고 있고, 이를 위한 설비의 유지 보수에 대한 관심이 높아지고 있다. 유지 보수(Maintenance)는 “필요한 기능을 수행할 수 있는 상태로 유지하거나 복원하려는 것의 수명주기 동안 행하는 모든 기술적, 관리적 조치의 조합”으로 정의된다[1]. 그 중, 제조업에서 설비의 유지 보수는 제품의 품질을 일정하게 유지하기 위해 반드시 필요한 활동이다. 이러한 중요성을 인지하고 설비의 유지 보수를 위해 사후 정비(Reactive maintenance), 계획 정비(Planned maintenance) 등의 활동을 수행해왔다. 사후 정비는 단순히 설비에 문제가 발생하면 보수하는 방법으로, 가장 간단한 방법이지만 이미 생산한 제품의 품질 문제 발생 위험성을 내재하고 있으며, 예기치 못한 생산 중단으로 인한 생산성이 하락할 수 있다는 문제점이 존재한다. 반면, 계획 정비는 미리 계획된 일정에 맞춰서 설비의 부품 등을 교체하여 정비하는 방식으로, 고장 부위 진단을 별도로 하지 않아도 되지만, 정상 부품을 정비하여 불필요한 비용이 발생하는 단점이 존재한다. 이러한 한계들을 극복하고자, 최근에는 설비의 상태를 진단하여 고장 발생 시점을 예측하고 미리 설비를 정비하는데 이를 예지보전(PdM, Predictive Maintenance)이라고 한다[1]. 이를 통해, 불필요한 유지 보수 비용을 최소화하고 생산 제품의 품질을 일정한 수준으로 유지할 수 있다.

예지 보전은 크게 물리적 모델 기반, 데이터 기반, 그리고 혼합 모델 기반 방법으로 분류할 수 있다[2]. 물리적 모델 기반 방법은 설비의 수명 등에 대한 물리적인 모델을 구축하여, 이를 기반으로 하여 설비를 보전하는 방법이다. 반면, 데이터 기반 방법은 설비에서 발생한 과거 데이터를 기반으로 설비의 수명이나 이상 상태가 발생하는 모델을 구축하여, 이를 기반으로 설비를 보전하는 방법이다. 기존에는 통계적 모델을 많이 활용하였으나, 최근에는 딥러닝 기술이 발전함에 따라, 이를 설비의 예지 보전에도 활용하는 연구들이 활발하게 이루어지고

있다[3]-[6].

전력 품질은 설비의 건강 상태에 크게 영향을 주는 중요 인자들 중 하나이다. 다양한 연구에서 전력 품질은 조금씩 다르게 정의되지만, 일반적으로 전압 품질 혹은 전류 품질과 비슷한 의미로 사용되며, 전력 소비자에게는 공급 전력과 전력 소비 기기의 부하가 얼마나 잘 맞는지를 의미한다[7]. 이러한 전력 품질을 나타내는 지표로는 순간 전압 강하와 상승을 의미하는 새그와 스웰, 교류 전류의 3상에서 나타나는 전압, 전류의 불균형, 기본 주파수가 배수로 증가된 상태인 고조파 등이 있다. 전력 품질이 낮으면, 제조업체는 생산 라인의 비정상적인 정지 및 재가동, 설비 운영 수준을 복구하기 위한 비용 발생, 생산성 하락 등으로 인한 경제적 손실이 발생한다[8]. 따라서 이러한 전력 품질을 예측할 수 있다면 설비의 예지 보전에 도움이 될 뿐만 아니라 불필요한 비용도 줄일 수 있을 것이다.

본 논문에서는 설비의 건강 상태에 중요한 역할을 하는 인자인 설비의 소비 전력 품질 인자의 과거 시계열 값을 활용하여 미래 일정 기간의 값을 예측하고, 이를 활용하여 설비의 건강 상태에 악영향을 줄 수 있는 상황을 사전에 탐지하는 방법론을 제안한다. 이때, 전력 품질의 값을 예측하는 모델로는 여러 종류의 transformer 기반 시계열 예측 모델을 활용하였으며, 일반적으로 예측 모형 학습에 사용하는 MSE 손실함수가 아닌 별도의 손실함수를 사용하였다.

본 논문의 구성은 다음과 같다. 2장에서는 관련 연구로 transformer 기반 시계열 장기간 예측을 소개한다. 또한, 비정상성(Nonstationary) 시계열 예측에 사용할 수 있는 손실함수를 소개한다. 3장에서는 본 논문에서 제안하는 방법을 서술한다. transformer 모델 기반의 전력 품질 시계열 데이터의 장기간 예측과 이를 활용한 설비의 이상 상태 조기 탐지 방법에 대하여 설명한다. 4장에서는 제안한 방법을 검증하기 위해 활용한 데이터, 실험 설정, 평가 방법을 서술하며, 이러한 실험 결과를 5장에서 기술한다. 마지막으로, 6장에서는 본 논문의 결론과 함께 향후 연구에 대하여 제안한다.

## II. 관련 연구

### 2.1 Transformer 기반의 장기 시계열 예측

총  $D$ 개의 변수를 갖는 시계열 데이터  $X = \{\vec{x}_t\}_{t=1}^L$  가 있다고 하자. 이 때,  $t$ 시점의 데이터를 나타내는  $\vec{x}_t = (x_t^1, x_t^2, \dots, x_t^D)$  이고,  $x_t^i$ 는  $t$ 시점에서  $i$ 번째 변수의 값을 의미한다. 시계열 데이터를 예측하는 문제는 시계열  $X$ 가 주어졌을 때, 미래  $T$  시점까지의 시계열 값인  $\hat{X} = \{\vec{x}_t\}_{t=L+1}^T$  를 예측하는 문제이다. 이 때,  $T > 1$ 이면 시계열 데이터의 다단계 예측(Multi-step forecasting)이라 한다. 이를 수행하는 방법으로는 반복적 다단계 예측(IMS, Iterative Multi-Step) 방식과 직접적 다단계 예측(DMS, Direct Multi-Step) 방식이 있다[9]. IMS는 매번  $T=1$ 인 예측을 여러 번 반복하여 수행하는 방식이고, DMS는  $T > 1$ 인 예측을 한 번에 수행하는 방식이다. IMS는 자기 회귀 모형과 유사한 특성이 있는데, 이는 예측 오류가 누적되어 장기간을 예측할 때, 오차가 매우 커질 수 있다는 단점이 존재한다는 것이다.

시계열의 다단계 예측에서  $T$ 가 충분히 커질 경우, 이를 시계열의 장기간 예측(LTSF, Long-time Time Series Forecasting)이라고 한다. 딥러닝을 활용하여 DMS방식의 LTSF를 수행했던 연구는 주로 순환신경망(RNN, Recurrent Neural Network) 기반의 방법이나[10] 시퀀스-투-시퀀스(Sequence-to-sequence) 기반의 방법을 많이 활용하였다[11]. 그러나, 기울기 소실(Vanishing gradient), 어려운 병렬 연산 등 RNN 학습과 관련한 여러 가지 어려움이 존재한다 [12][13]. 최근에는 컴퓨터 비전, 자연어 처리 등 다양한 분야에서 좋은 성능을 보여주는 transformer를 활용한 연구들이 이루어지고 있다[14]-[20].

transformer는 encoder와 decoder로 이루어진 모델로, 각각은 고유한 모듈이 여러 개 반복되어 구성되어 있다[14]. Encoder의 모듈은 multi-head self attention, position-wise feed forward network로 구성되어 있고, decoder의 모듈은 masked multi-head self-attention, encoder 결과 vector와의 multi-head cross-attention module, position-wise feed forward

network로 구성되어 있다. 기존 sequence-to-sequence 모델도 encoder, decoder로 구성되었으나, 입력 데이터의 순서 정보를 보존하기 위해서 RNN계열의 모델을 활용하였다. 그러나, transformer는 position encoding 기법을 활용하여 순서 정보를 보존한다. 그림 1은 transformer의 구조를 나타낸다.

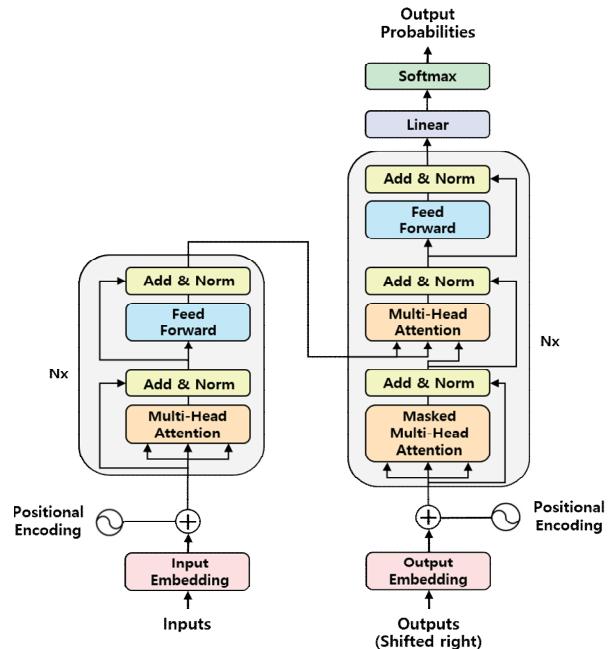


그림 1. Transformer 모델 구조 ([13]에서 인용)

Fig. 1. Model structure of transformer (From [13])

초기에 transformer는 자연어 처리 분야에서 주로 사용되었지만, 최근에는 computer vision[14], 시계열 데이터 처리[16]-[20] 등 다양한 분야에서 활용되고 있다. 그 중, 시계열 데이터의 LTSF를 transformer로 수행하기 위해서는  $O(n^2)$ 에 해당하는 계산 복잡도와 추론 시간이 오래 걸린다는 점, 시계열 데이터의 비정상성에 따른 성능의 한계 등 여러 가지 문제가 있는데, 이를 해결하기 위해 다양한 연구들이 수행되었다[15]-[19].

### 2.2 DILATE 손실함수

시계열 데이터를 예측하는 모델을 학습하거나 평가할 때 주로 사용하는 손실함수는 평균제곱오차(MSE, Mean Squared Error)나 평균절대오차(MAE, Mean Absolute Error)이다.

이러한 손실 함수는 정상성(Stationary) 특성을 갖는 데이터 혹은 비정상성 특성이 있더라도 급격하게 값이 변화하지 않는 시계열 데이터에는 적합할 수 있다. 그러나, 순간적으로 값이 큰 폭으로 변화하는 데이터에는 적합한 손실함수가 아니다.

그림 2는 순간적으로 값이 크게 변동하는 시계열 데이터와, 이에 대한 세 가지 모델의 예측값을 나타낸 그림이다.

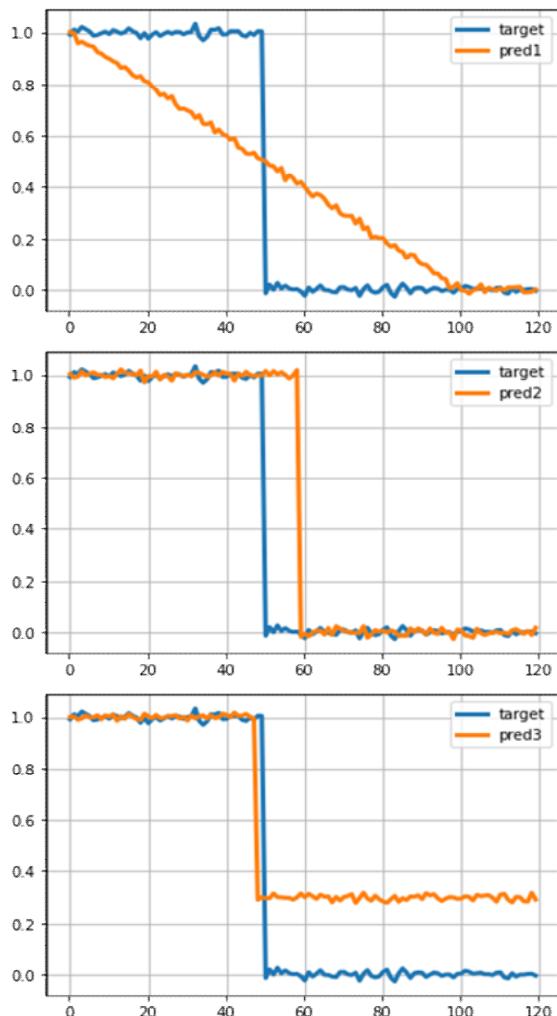


그림 2. 급격한 변화가 있는 시계열 데이터 예측 결과 (위): 시계열 데이터 형태를 제대로 예측하지 못함, (중간): 값의 변화량은 예측, 변화 시점의 오류, (아래): 변화 시점은 예측, 값의 변화량은 오류 ([21]에서 인용)  
Fig. 2. Prediction of rapidly changing time series data  
(upper): Shape of data is not predicted correctly,  
(middle): Correct amount of change, incorrect change point,  
(lower): Correct change point, incorrect amount of change  
(From [21])

각 그림에서 MSE값은 동일하지만, 예측값은 상당히 다른 것을 볼 수 있다. 아래 2개의 그림은 급격한 값의 변화가 생긴 시점 혹은 변화 후 값을 제대로 예측하지 못했으나, 급격한 값의 변화가 발생한다는 것은 예측하였다. 그러나 가장 위의 그림과 같은 결과는 급격한 값의 변화가 발생한다는 것도 제대로 예측하지 못하였다.

값이 급격하게 변화하는 데이터에서 MSE를 손실함수로 RNN 등의 모델을 학습한 뒤, LTSF를 수행하면 가장 위의 결과와 같이 값의 변화를 제대로 예측하지 못하는 결과를 얻게 된다. 이러한 문제점을 해결하기 위해 Guen and Thome[20]은 시계열 예측 결과의 모양(Shape)과 시간 지연(Temporal) 관련 손실함수를 정의하였는데 이를 DILATE (Distortion Loss including shApE and TimE) 손실함수라고 한다. 이 손실함수는 예측 결과의 모양과 지연 관련 손실함수를 각각 정의하고, 이를 각각 가중치  $\alpha$ ,  $(1 - \alpha)$ 를 적용하여 가중합하는 방식으로 산출한다.

$$\mathcal{L}_{DILATE} = \alpha \mathcal{L}_{shape} + (1 - \alpha) \mathcal{L}_{temporal}$$

이를 활용하여 값의 급격한 변화가 존재하는 데이터에 적용하였을 때, 실제값과 더 유사한 형태의 예측을 하는 것을 확인하였다.

## 2.3 전력 품질 이상 탐지

과거와 달리 최근에는 순간적인 전력 품질의 변동에도 민감한 전자기기들의 사용이 증가하였다. 이러한 현상은 기기의 상태에 영향을 미쳐서 문제를 일으키게 된다[22]. 이를 방지하기 위해 전력 품질의 비정상 상태를 탐지하는 연구들이 수행되었다. W. Gu, et al.은 과거 전력 품질 지수들의 시계열 데이터에서 왜도(Skewness), 첨도(Kurtosis) 등의 통계치를 산출하고 이를 활용하여 전력 품질의 이상 탐지를 수행하였다[23]. O. Zyabkina, et al.은 전력 품질의 이상치는 품질 지수의 시계열 데이터에서 중장기적 변화인 추세(Trend)와 계절성(Seasonality) 보다 단기적 변화에 더 관련이 있을 것이라고 가정하여 이를 탐지하는 연구를 수행하였다[24].

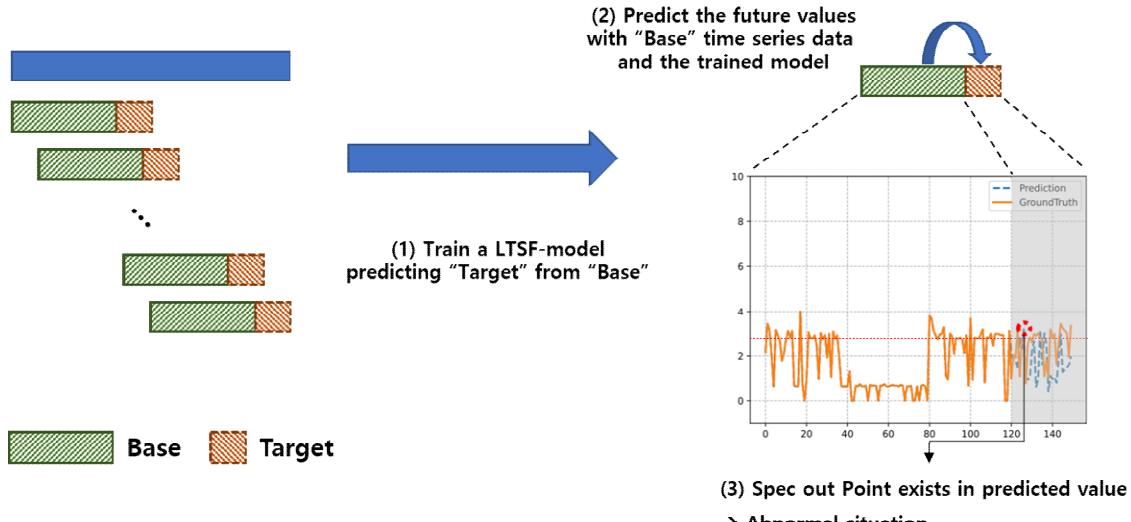


그림 3. LTSF 결과를 활용한 전력 품질 인자의 비정상 상황 사전 탐지 방법론  
Fig. 3. Proposed method for predictive detection of abnormal condition of power quality factors with LTSF

위의 방법들은 시계열 데이터에서 통계적 방법론을 활용하여 이상치를 탐지하는 방법이었다. 최근에는 기계학습 및 딥러닝 방법론을 활용하여 이상치를 탐지하려는 연구도 수행되고 있다. S. H. Ko and C. S. Hong에서는 LSTM 기반의 Variational Autoencoder (LSTM-VAE) 모델을 활용하여 전력 품질을 나타내는 원시데이터에서 이상 상태를 탐지하는 방법론을 제안하였다[25]. M. G. Kim, et al.은 5 가지의 머신러닝 모델을 활용하여 생산라인의 고장을 모니터링하는 애플리케이션을 개발하였다[6].

그러나 지금까지 언급한 연구들은 과거 혹은 현재까지의 데이터를 활용하여 현재 전력 품질에서 비정상적인 상황 발생 여부를 탐지할 수 있다. 그러나, 이를 전력 품질의 미래 상태를 예측하여 이를 사전에 예방할 수 없다는 한계가 존재한다.

### III. 전력 품질 값 LTSF 결과 기반의 비정상 전력 품질 상태 예측

본 연구에서 제안하는 방법은 전력 품질 지수를 나타내는 값을 예측하여 미래 일정 시간 구간 동안 전력 품질 지수에 문제 발생 여부를 미리 탐지하는 것이다. 이는 크게 2가지 단계로 구성된다.

Step 1. 전력 품질지수 예측: 현재 시점을  $t$ , 미래  $T$ 개의 시점의 품질 지수 값을 예측하고자 한다고 하자. 이를 위해, 직전  $L$ 개 과거 시점의 데이터

를 활용한다고 하자. 이를 수식으로 나타내면,  $t-(L-1)$  시점부터  $t$  시점 까지의 과거 측정치  $X_t = \{x_i\}_{i=t-(L-1)}^t$  을 활용하여,  $(t+1)$  시점부터  $(t+T)$  시점 까지의 값  $\hat{X}_t = \{\hat{x}_i\}_{i=t+1}^{t+T}$  을 예측한다.

Step 2. 전력품질 불량 발생 예측: 전력 품질 지수가 규격 상한(USL, Upper Specification Limit), 규격 하한(LSL, Lower Specification Limit)으로 관리된다고 하자. 이때,  $T$ 기간 동안의 예측값들 중에서 규격을 벗어나는 값이 존재하면, 해당 구간은 비정상으로 판단한다. 즉,  $(t+1, t+T)$ 시간 구간에 문제가 발생 여부를 예측한 값  $\hat{y}_t$ 는 다음과 같이 정의된다.

$$\hat{y}_t = \begin{cases} \text{Abnormal}, & \exists \hat{x}_j \in \hat{X}_t = \{\hat{x}_i\}_{i=t+1}^{t+T} \\ & \text{s.t. } \hat{x}_j > USL \text{ or } \hat{x}_j < LSL \\ \text{Normal}, & \text{else} \end{cases}$$

## IV. 실험

### 4.1 사용 데이터

III장에서 제안한 방법을 검증하기 위해 본 연구에서 사용한 데이터는 AI-Hub에서 제공하는 “전력 설비 에너지 패턴 및 고장 분석 센서” 데이터 내의 설비 건강 상태 데이터이다[26].

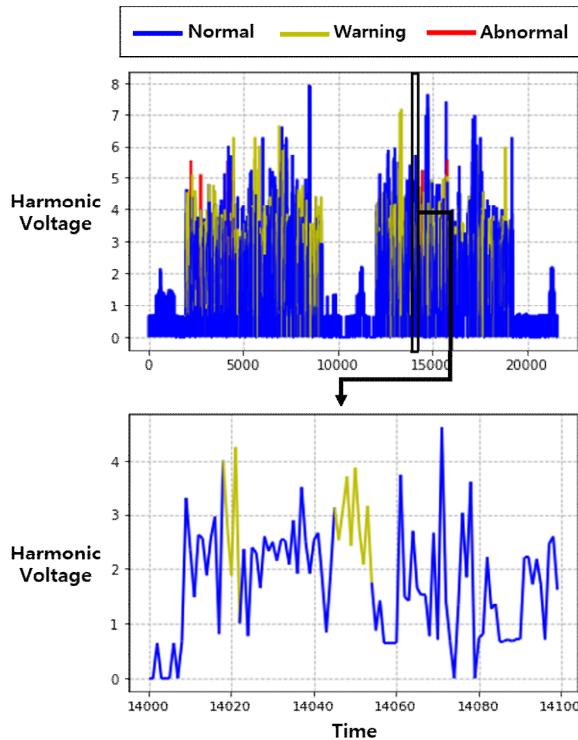


그림 4. 실험 데이터 예시  
Fig. 4. Example of experimental data sets

이 데이터에서는 전력 설비에 공급되는 전력 품질 관련 계측값을 1분 단위로 평균값을 산출하여 제공한다. 측정하는 값으로는 3상 교류의 전압, 전류, 전력, 역률, 고조파 등이 있다. 그리고, 이들의 평균값을 계산한 값도 함께 제공한다. 특정 시점에서 설비의 SOH는 사용하는 전력 품질에 따라 크게 정상, 주의, 경고의 3가지 상태로 관리된다. 그리고, 사용하는 전력 품질 지수에 따라 다른 기준으로 관리된다. 본 실험에서는 전압 고조파 지수를 기준으로 SOH를 관리한다고 가정한다. AI-Hub에서 제공한 관리 매뉴얼에 따르면, 전압 고조파 값이 3% 이하는 ‘정상’, 3~5%는 ‘주의’, 5% 이상은 ‘비정상’으로 분류된다. 그러나, ‘경고’ 상태 데이터가 부족하고 문제를 단순하게 만들기 위하여 ‘주의’와 ‘비정상’을 합하여 ‘비정상’으로 변환하여, 레이블이 2개인 이분류 문제로 변환하였다.

여러 설비 중 2개 설비를 대표로 선정하여 실험을 진행하였다. 이 데이터의 통계량은 표 1과 같다. 또한, 그림 2는 Machine 2의 전압고조파 값을 나타낸 그림이다. 실험에 사용할 데이터는 ‘정상’ 상태가 ‘비정상’ 상태보다 많은 불균형 데이터이며, 설

비가 가동과 정지 상태를 반복하며 값이 급격하게 변하는 특성이 있음을 알 수 있다.

표 1. 실험 데이터 세트

Table 1. Experimental data sets

Attribute \ Data set	Machine 1	Machine 2
Number of total time point	21,600	21,600
Number of normal time point	19,254	19,637
Number of abnormal time point	2,346	1,963

#### 4.2 실험 설정

먼저 전체 시계열 데이터를 6:2:2의 비율로 학습(Train), 검증(Validation), 시험(Test) 데이터로 분리한다. 그리고, 학습 데이터의 통계치를 기반으로 학습, 검증, 시험 데이터를 정규화한다. 이제 학습, 검증, 시험 데이터에서 길이 ( $L + T$ )의 데이터 구간들을 생성한다. 각 데이터 구간의 초기  $L$ 개 시점에 해당하는 데이터를 활용하여, 뒤의  $T$ 개 시점에 해당하는 데이터를 예측하는 모델을 학습한다. 이 실험에서는  $L = 120$ ,  $T = 30$ 으로 설정하였으며, 예측 모델로는 transformer의 변형 모델인 Crossformer[16], FEDformer[17], Informer[15], Non-stationary transformer[18], Pyraformer[19]를 활용하였다. 또한, 손실함수로 MSE와 DILATE[20]를 사용하였을 때의 결과를 확인하였다. DILATE 손실함수에서 필요한 가중치  $\alpha$ 는 0.3으로 설정하였다. 모델에 사용할 나머지 하이퍼파라미터는 검증 데이터에서 손실함수 값이 최소가 되는 조건을 선택하였으며, 총 5번 반복 실험하여 실험 결과를 도출하였다.

#### 4.3 평가 방법

일반적으로 시계열 데이터의 예측 모델을 평가할 때에는 MSE, MAE등의 평가지표를 활용하여 예측의 정확도를 측정한다. 그러나, 본 연구의 목표는 미래 일정 시간 구간에 품질 관련 인자가 spec line을 벗어나는 순간이 존재하는지 예측하는 것으로, 기존의 평가지표를 그대로 사용하는 것은 적합하지 않다.

그 대신, 겹치지 않는 시간 구간에서 실제 전력 품질 문제 발생 여부와 모델의 예측 결과 간의 정확도(Accuracy)와 F1-score로 평가한다.

위 과정을 더 자세히 수식으로 설명하면 다음과 같다. 시험 데이터에는 총  $T_{tst}$  개의 시점이 존재한다고 하자. III장에서 서술했던 바와 같이, 이전  $L$ 개 시점의 값을 활용하여 이후  $T$ 개 시점의 값을 예측하는 모델이 학습된다. 이런 시간 구간이 총  $T_{tst} - L$  개 생성된다.  $(t+1, t+T)$  시간 영역에서 이상 상황이 실제로 발생한 결과를  $y_t$ , 모델이 이상 상황 발생 여부를 예측한 결과를  $\hat{y}_t$ 라고 할 때, 총  $(T_{tst} - L)$  개의  $(y_t, \hat{y}_t)$  쌍이 생성되는데, 이를 중복 구간이 없는(Non-overlapping)  $T$ 개의 집합으로 나눈다.

$$\begin{aligned} S_1 &= \left\{ (y_{L+iT}, \hat{y}_{L+iT}) \right\}_{i=0}^{\lfloor \frac{T_{tst}-L}{T} \rfloor} \\ S_2 &= \left\{ (y_{L+iT+1}, \hat{y}_{L+iT+1}) \right\}_{i=0}^{\lfloor \frac{T_{tst}-L}{T} \rfloor} \\ &\vdots \\ S_T &= \left\{ (y_{L+iT+(T-1)}, \hat{y}_{L+iT+(T-1)}) \right\}_{i=0}^{\lfloor \frac{T_{tst}-L}{T} \rfloor} \end{aligned}$$

각 집합에서 정확도와 F1-score로 평가한  $T$ 개 결과의 평균값을 산출하여 평가한다.

## V. 실험 결과

### 5.1 LTSF 결과

그림 5는 동일한 모델을 사용했을 때, 사용한 손실함수의 종류에 따른 예측 결과를 나타낸 것이다. MSE 손실함수를 기준으로 학습한 모델은 LTSF 결과가 거의 일정하게 나오는 것을 볼 수 있다. 그러나, DILATE 손실함수를 기준으로 학습한 모델은 상대적으로 값의 변동을 잘 예측하는 것을 볼 수 있다.

### 5.2 설비의 비정상 상태 탐지 결과

표 2는 LTSF 결과를 활용하여 설비의 비정상 상태를 탐지한 결과를 나타낸다. 모델의 종류에 무관하게 F1-score가 거의 0에 가까운 결과가 나타난 것을 알 수 있다.

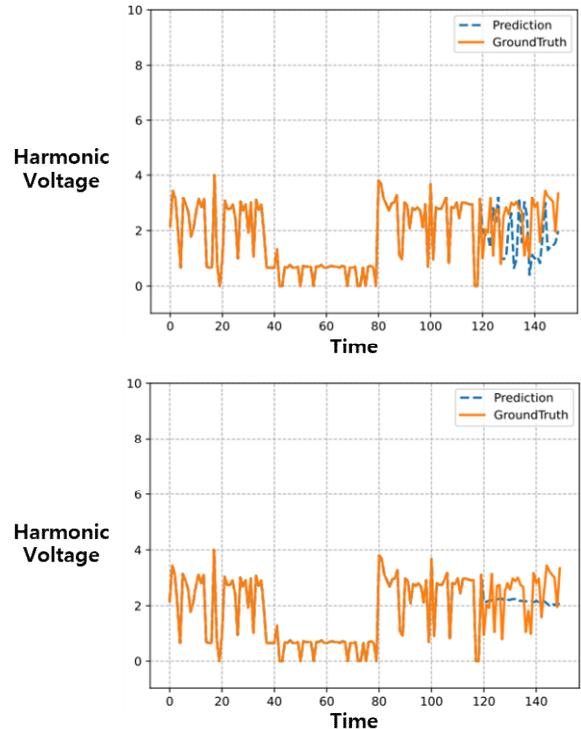


그림 5. LTSF 결과 예시 (위): DILATE 손실함수로 학습한 모델, (아래): MSE 손실함수로 학습한 모델

Fig. 5. Example of LTSF result  
(upper): Model with DILATE loss function,  
(lower): Model with MSE loss function

표 2. 설비의 비정상 상태 탐지 결과

Table 2. Experimental results of abnormal state detection

Data	Model	F1-score (Accuracy)	
		DILATE	MSE
Machine 1	NST	0.609 (0.796)	0.000 (0.616)
	Cross	0.738 (0.845)	0.000 (0.616)
	FED	0.665 (0.807)	0.077 (0.630)
	Info	0.722 (0.829)	0.000 (0.616)
	Pyra	<b>0.755</b> (0.848)	0.000 (0.616)
Machine 2	NST	0.571 (0.771)	0.000 (0.646)
	Cross	0.640 (0.806)	0.000 (0.646)
	FED	0.633 (0.786)	0.051 (0.654)
	Info	0.674 (0.804)	0.000 (0.646)
	Pyra	<b>0.757</b> (0.849)	0.000 (0.646)

이는 MSE 손실함수를 활용하여 학습한 LTSF 모델은 5.1 절에서 살펴본 바와 같이 거의 일정한 수준의 값을 예측하기 때문이다. 또한, DILATE 손실함수를 사용하여 학습한 각 모델을 비교하였을 때 Pyraformer가 가장 좋은 성능을 나타내는 것을 알 수 있다.

### 5.3 DILATE 손실함수 파라미터 $\alpha$ 와 예측 기간 변화에 따른 비정상 상태 탐지 결과

2.2절에서 언급했던 바와 같이 DILATE 손실함수는 예측 결과의 모양과 지연 관련한 손실함수를 별도로 정의하고 이를 가중합하는 방식으로 계산한다. 이 절에서는 이 가중치  $\alpha$ 값에 따른 비정상 상태 탐지 결과의 변화를 기술한다. 그림 6은 두 개의 데이터에 대해서 모델별로  $\alpha$ 값에 따라 비정상 상태 탐지를 수행한 F1-score 결과의 변화를 나타낸 그림이다. 모델에 따라서 결과가 크게 변동이 있는 경우도 존재하지만, 대체로  $\alpha$ 의 값에 따라 값의 큰 변동은 없다. 이는  $\alpha$ 값이 크면 데이터의 급격한 변동을 잘 예측하는 것에 더 많은 가중치를 두기 때문에 설비의 비정상 상태 탐지 성능이 향상되지만, 급격한 변동이 발생한다고 예측하는 시점이 실제 시점보다 지연되기 때문에 탐지 성능이 하락하는 효과로 상쇄되는 것으로 보인다.

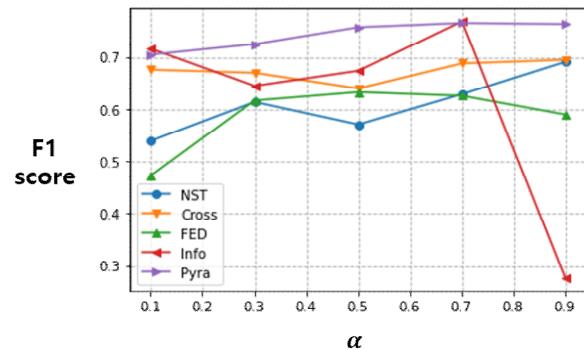


그림 6. 가중치에 따른 비정상 상태 탐지 결과  
( $\alpha = 0.1, 0.3, 0.5, 0.7, 0.9$ )

Fig. 6. Change of abnormal state detection result with respect to  $\alpha$  ( $\alpha = 0.1, 0.3, 0.5, 0.7, 0.9$ )

위 가정을 검증하기 위하여  $\alpha = 0.5$ ,  $\alpha = 0.9$ 일 때, 예측 시간 범위를 다르게 하면서 비정상 상태 탐지 결과를 확인하였고, 그 결과를 그림 7에 표기하였다.  $\alpha$ 가 크면 극단적인 변화를 잘 예측하기 때문에 탐지 결과가 더 좋아야 하지만, 단기 예측에서는  $\alpha$ 가 작을 때 오히려 탐지 결과가 더 좋을 것을 알 수 있다. 이는 극단적인 변화 예측 결과가 설정한 시간 범위를 넘어서 예측되기 때문에 비정상 상태를 잘 탐지하지 못함을 알 수 있다. 또한, 예측하는 기간이 길어지면서,  $\alpha = 0.9$ 일 때가 성능이 더

좋아지는 것을 볼 수 있다. 이러한 실험 결과로부터  $\alpha$ 값이 크면 극단적인 값을 잘 예측하지만 예측하는 시점이 늦어지기 때문에 탐지 성능이 떨어질 위험성이 있으므로, 예측하려는 시간 구간에 따라  $\alpha$ 값을 잘 설정해야 한다는 것을 알 수 있다.

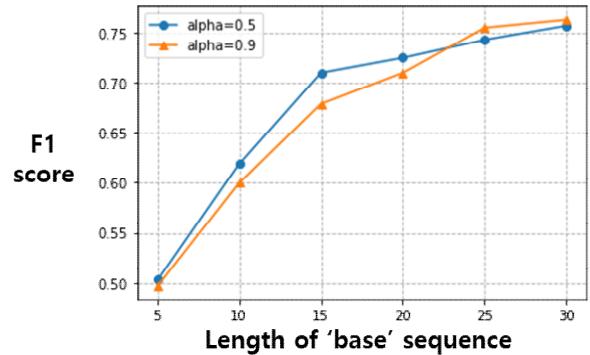


그림 7. 가중치  $\alpha$ 와 예측 기간의 관계  
Fig. 7. Relationship between the prediction range and the hyper-parameter  $\alpha$

## VI. 결론 및 향후 과제

최근 스마트팩토리가 본격적으로 도입되기 시작하면서, 설비의 건강 상태를 지속적으로 모니터링하며 설비에 문제가 발생하기 전에 미리 예지 보수에 대한 필요성이 대두되고 있다. 설비의 건강 상태에 영향을 미치는 인자들 중 하나는 전력 품질이다. 낮은 품질의 전력을 사용하게 되면 설비에 문제가 발생하게 되고, 이로 인해 생산라인의 비정상적인 정지 및 재가동, 제품의 품질 위험성 등 불필요한 비용이 발생하게 된다. 따라서, 이를 낮은 품질의 전력이 공급되는 시점을 사전에 예측할 수 있다면, 이러한 불필요한 비용을 절감할 수 있을 것이다.

본 논문에서는 transformer 기반의 모델들을 활용하여 비정상적인 전력이 공급되는 상황을 사전에 탐지하는 방법론을 제안하였다. 이를 위해, 먼저 transformer 기반의 모델들을 활용하여 일정 시간 구간의 전력 품질 인자의 값을 예측한다. 이 때, 단순히 기존 모델들을 그대로 활용한다면 비정상성, 값의 변동이 크다는 특징이 있는 전력 품질 인자의 시계열 데이터는 제대로 예측하지 못한다. 따라서, 비정상성 시계열 데이터를 예측하기 위한 DILATE 손실함수를 활용하여 LTSF를 수행한다.

그 후, 해당 인자가 관리 범위를 넘어서는 시점이 존재한다면, 해당 구간은 비정상적인 상태라고 판단한다. 이를 실제 데이터에 적용하여 실험한 결과 비정상 상태를 잘 탐지함을 보였다. 특히, MSE 손실 함수를 활용하여 학습하면 거의 탐지하지 못하던 이상 상황을 DILATE 손실함수를 활용했을 때 이상 상황 탐지 성능이 크게 향상되었음을 확인하였다.

본 논문에서는 LTSF를 수행하는 transformer 기반 모델에 DILATE 손실함수를 적용하여 설비의 전력 품질 인자 값을 예측하고, 미리 이상 상황을 탐지할 수 있음을 보였다는 것에서 연구의 의의를 찾을 수 있다. 그러나, 더 다양한 형태의 시계열 데이터에 대해 해당 방법을 적용하여 추가 검증이 필요하다. 또한, 본 연구는 단일 품질 인자에 대해서 실험을 진행하였지만, 전력 품질과 관련된 인자는 여러 개 존재한다. 따라서, 이러한 인자들을 모두 고려한 이상 상황 탐지 방법론 연구가 필요하다.

## References

- [1] O. Serradilla, E. Zugasti, J. Rodriguez, and U. Zurutuza, "Deep learning models for predictive maintenance: a survey, comparison, challenges and prospects", *Applied Intelligence*, Vol. 52, No. 10, pp. 10934-10964, Jan. 2022. <https://doi.org/10.1007/s10489-021-03004-y>.
- [2] L. Liao and F. Kottig, "A hybrid framework combining data-driven and model-based methods for system remaining useful life prediction", *Applied Soft Computing*, Vol. 44, pp. 191-199, Jul. 2016. <https://doi.org/10.1016/j.asoc.2016.03.013>.
- [3] O. Aydin and S. Guldamlasioglu, "Using LSTM networks to predict engine condition on large scale data processing framework", 2017 4th International Conference on Electrical and Electronic Engineering (ICEEE), Ankara, Turkey, pp. 281-285, Apr. 2017. <https://doi.org/10.1109/ICEEE2.2017.7935834>.
- [4] D. Bruneo and F. D. Vita, "On the Use of LSTM Networks for Predictive Maintenance in Smart Industries", 2019 IEEE International Conference on Smart Computing (SMARTCOMP), Washington DC, USA, pp. 241-248, Jun. 2019. <https://doi.org/10.1109/SMARTCOMP.2019.00059>.
- [5] J. Yuan, Y. Wang, and K. Wang, "LSTM Based Prediction and Time-Temperature Varying Rate Fusion for Hydropower Plant Anomaly Detection: A Case Study", *Advanced Manufacturing and Automation VIII*, pp. 86-94, Dec. 2018. [https://doi.org/10.1007/978-981-13-2375-1\\_13](https://doi.org/10.1007/978-981-13-2375-1_13).
- [6] M. G. Kim, W. S. Jeon, and S. Y. Rhee, "Artificial Intelligence-based Monitoring Application for Production Line Failure/Predictive Maintenance", *Journal of KIIT*, Vol. 21, No. 10, pp. 147-158, Oct. 2023. <https://doi.org/10.14801/jkiit.2023.21.10.147>.
- [7] V. Meier, "Electric power systems: a conceptual introduction", John Wiley & Sons, Jun. 2006.
- [8] G. J. Lee and G. T. Heydt, "An interactive--dynamic mechanism conceptualizing the cost and benefit of electric power quality", *Electric Power Systems Research*, Vol. 69, No. 1, pp. 69-75, Apr. 2004. <https://doi.org/10.1016/j.epsr.2003.07.011>.
- [9] G. Chevillon, "Direct multi-step estimation and forecasting", *Journal of Economic Surveys*, Vol. 24, No. 4, pp. 746-785, Jul. 2007. <https://doi.org/10.1111/j.1467-6419.2007.00518.x>.
- [10] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors", *nature*, Vol. 323, No. 6088, pp. 533-536, Oct. 1986. <https://doi.org/10.1038/323533a0>.
- [11] I. Sutskever, O. Vinyals, and Q. V. Le, "Sequence to sequence learning with neural networks", *Advances in neural information processing systems*, Vol. 27, 2014.
- [12] S. Hochreiter and J. Schmidhuber, "Long short-term memory", *Neural computation*, Vol. 9, No. 8, pp. 1735-1780, Nov. 1997.

- [13] S. Hochreiter, Y. Bengio, P. Frasconi, and J. Schmidhuber, "Gradient flow in recurrent nets: the difficulty of learning long-term dependencies", A Field Guide to Dynamical Recurrent Neural Networks, 2001. <https://doi.org/10.1109/9780470544037.ch14>.
- [14] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, T. Kaiser, and I. Polosukhin, "Attention is All you Need", Advances in Neural Information Processing Systems, Vol. 30, 2017.
- [15] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, M. Dehghani, M. Minderer, G. Heigold, S. Gelly, J. Uszkoreit, and N. Houlsby, "An Image is Worth 16x16 Words: transformers for Image Recognition at Scale", International Conference on Learning Representations, 2021.
- [16] H. Zhou, S. Zhang, J. Peng, S. Zhang, J. Li, H. Xiong, and W. Zhang, "Informer: Beyond efficient transformer for long sequence time-series forecasting", Proceedings of the AAAI conference on artificial intelligence, Vol. 35, No. 12, pp. 11106-11115, May 2021. <https://doi.org/10.1609/aaai.v35i12.17325>.
- [17] Y. Zhang and J. Yan, "Crossformer: transformer utilizing cross-dimension dependency for multivariate time series forecasting", The Eleventh International Conference on Learning Representations, Sep. 2022.
- [18] T. Zhou, Z. Ma, Q. Wen, X. Wang, L. Sun, and R. Jin, "Fedformer: Frequency enhanced decomposed transformer for long-term series forecasting", International Conference on Machine Learning, pp. 27268-27286, Jun. 2022.
- [19] Y. Liu, H. Wu, J. Wang, and M. Long, "Non-stationary transformers: Exploring the stationarity in time series forecasting", Advances in Neural Information Processing Systems, Vol. 35, pp. 9881-9893, 2022.
- [20] S. Liu, H. Yu, C. Liao, J. Li, W. Lin, A. X. Liu, and S. Dustdar, "Pyraformer: Low-complexity pyramidal attention for long-range time series modeling and forecasting", International conference on learning representations, 2021.
- [21] V. L. Guen and N. Thome, "Shape and Time Distortion Loss for Training Deep Time Series Forecasting Models", Advances in Neural Information Processing Systems, pp. 4191-4203, 2019.
- [22] A. Sannino, J. Svensson, and T. Larsson, "Power-electronic solutions to power quality problems", Electric Power Systems Research, Vol. 66, No. 1, pp. 71-82, Jul. 2003. [https://doi.org/10.1016/S0378-7796\(03\)00073-7](https://doi.org/10.1016/S0378-7796(03)00073-7).
- [23] W. Gu, J. Bai, X. Yuan, S. Zhang, and Y. Wang, "Power quality early warning based on anomaly detection", Journal of Electrical Engineering & Technology, Vol. 9, No. 4, pp. 1171-1181, Jul. 2014. <https://doi.org/10.5370/JEET.2014.9.4.1171>.
- [24] O. Zyabkina, M. Domagk, J. Meyer, and P. Schegner, "Classification and identification of anomalies in time series of power quality measurements", In 2016 IEEE PES Innovative Smart Grid Technologies Conference Europe, Ljubljana, Slovenia, pp. 1-6, Oct. 2016. <https://doi.org/10.1109/ISGTEurope.2016.7856290>.
- [25] S. H. Ko and C. S. Hong, "Anomaly Detection in Power Quality using LSTM-based Variational Autoencoder", In Korea Computer Congress 2021, pp. 1016-1018, Jun. 2021.
- [26] AI-Hub dataset, <https://aihub.or.kr/aihubdata/data/view.do?currMenu=115&topMenu=100&aihubDataSe=realm&dataSetSn=239> [accessed: Mar. 27, 2023]

## 저자소개

이제혁 (Jehyuk Lee)



2012년 2월 : 한국과학기술원  
산업및시스템공학과(공학사)  
2014년 2월 : 한국과학기술원  
산업및시스템공학과(공학석사)  
2020년 8월 : 서울대학교  
산업공학과(공학박사)  
2020년 9월 ~ 2022년 8월 :

삼성전자 메모리사업부 Staff Engineer  
2022년 9월 ~ 현재 : 국민대학교 AI빅데이터융합경영학과  
조교수  
관심분야 : Data mining, Machine Learning, Industrial AI