

# Subset 샘플링 검증 기법을 활용한 MSCRED 모델 기반 발전소 진동 데이터의 이상 진단

홍수웅<sup>1</sup>, 권장우<sup>2\*</sup>

<sup>1</sup>인하대학교 컴퓨터공학과 학생, <sup>2</sup>인하대학교 컴퓨터공학과 교수

## Anomaly Detection In Real Power Plant Vibration Data by MSCRED Base Model Improved By Subset Sampling Validation

Su-Woong Hong<sup>1</sup>, Jang-Woo Kwon<sup>2\*</sup>

<sup>1</sup>Student, Department of Computer-Engineering, Inha University

<sup>2</sup>Professor, Department of Computer-Engineering, Inha University

**요약** 본 논문은 전문가 독립적 비지도 신경망 학습 기반 다변량 시계열 데이터 분석 모델인 MSCRED(Multi-Scale Convolutional Recurrent Encoder-Decoder)의 실제 현장에서의 적용과 Auto-encoder 기반인 MSCRED 모델의 한계인, 학습 데이터가 오염되지 않아야 된다는 점을 극복하기 위한 학습 데이터 샘플링 기법인 Subset Sampling Validation을 제시한다. 라벨 분류가 되어있는 발전소 장비의 진동 데이터를 이용하여 1) 학습 데이터에 비정상 데이터가 섞여 있는 상황을 재현하고, 이를 학습한 경우 2) 1과 같은 상황에서 Subset Sampling Validation 기법을 통해 학습 데이터에서 비정상 데이터를 제거한 경우의 Anomaly Score를 비교하여 MSCRED와 Subset Sampling Validation 기법을 유효성을 평가한다. 이를 통해 본 논문은 전문가 독립적이며 오류 데이터에 강한 이상 진단 프레임워크를 제시해, 다양한 다변량 시계열 데이터 분야에서의 간결하고 정확한 해결 방법을 제시한다.

**주제어** : 전문가 독립적 특징, 오류 데이터 검출기법, 다변량 시계열 데이터, 진동 이상 진단, Auto-encoder모델

**Abstract** This paper applies an expert independent unsupervised neural network learning-based multivariate time series data analysis model, MSCRED(Multi-Scale Convolutional Recurrent Encoder-Decoder), and to overcome the limitation, because the MCRED is based on Auto-encoder model, that train data must not to be contaminated, by using learning data sampling technique, called Subset Sampling Validation. By using the vibration data of power plant equipment that has been labeled, the classification performance of MSCRED is evaluated with the Anomaly Score in many cases, 1) the abnormal data is mixed with the training data 2) when the abnormal data is removed from the training data in case 1. Through this, this paper presents an expert-independent anomaly diagnosis framework that is strong against error data, and presents a concise and accurate solution in various fields of multivariate time series data.

**Key Words** : Expert independent feature extraction, Error data detection method, Multivariate time series data anomaly detection, Vibration anomaly diagnosis, Auto-encoder model

\*This article was supported in part by the Korea Hydro & Nuclear Power Co., Ltd., Republic of Korea(No. L18-S065-0000)

\*This article was supported in part of smart factory technology development project(Cloud-based data platform) by the Ministry of SMEs and Startups

\*Corresponding Author : Jang-Woo Kwon(jwkwon@inha.ac.kr)

Received November 20, 2021

Revised December 20, 2021

Accepted January 20, 2022

Published January 28, 2022

### 1. 서론

최근 스마트 팩토리를 필두로 한 산업 IOT 분야에서 AI 모델을 활용한 자동 진단 기술들이 주목받고 있다. 이 중, 자동 이상 진단 분야에서는 AI 기술이 공장 설비의 진단, 배출되는 오염물질 감시까지 폭넓은 분야에서 활용되고 있다.

이러한 이상 진단 분야에선 연속적인 시간에 따른 측정값인 시계열 데이터의 분석이 요구된다. 고전적인 시계열 데이터의 이상 진단 과정은 센서로 측정된 raw data를 해당 데이터의 종류에 따라 분야의 전문가가 정의한 통계/확률 기반의 특징들로 가공하는 과정이 필요했다. 그러나 전문가에 의존하는 특징 추출 과정은 모델의 성능이 전문가의 역량에 의존되고, 데이터 분석에 인적/물적 자원이 크게 소모되는 문제점이 있었다.

MSCRED(Multi-Scale Convolutional Recurrent Encoder-Decoder)[1]는 전문가 독립적 특징 기반 비지도 이상 진단 프레임워크이다. MSCRED는 전문가에 의존해야되는 기존의 전문가 의존적 특징을 다변량 시계열 데이터 간의 상관관계로 대체하는 특징 추출 과정을 제시했다. MSCRED의 모델은 학습에 정상 데이터만이 사용된다는 전제를 갖는 Auto-encoder의 비지도 학습 기법을 따른다. Fig. 1은 MSCRED Framework의

대략적인 개요를 나타낸다.

그러나 실제 현장 데이터는 훈련 데이터가 정상/비정상이 분류되어 있지 않은 경우가 많아 훈련 데이터가 정상 데이터만으로 이루어졌는지를 파악하기 어려우며, 검증을 위해 전문가에 의존하게 된다면 MSCRED의 전문가 독립적인 비지도 학습이라는 강점을 잃게 된다.

통상적인 오염데이터를 찾는 방식에는 주로 cross-validation 기법이 활용된다[2]. 하지만 cross-validation 기법은, 학습 데이터를 학습과 검증 데이터 셋으로 나누는 데에 있어, 적은 양의 데이터에서 성능이 좋지 않다. 검증 데이터의 양이 늘어나면 학습의 질은 보장되나 데이터의 양이 줄어들어 제대로 학습되지 않고, 검증 데이터의 양이 줄어들면 제대로 검증이 이루어지지 않는다.

본 논문에선 위와 같은 훈련 데이터 오염에 관한 문제를 극복하기 위해, 실제 발전소의 진동 데이터 설비를 이용하여 MSCRED의 성능을 1) 훈련 데이터에 비정상 데이터가 혼합된 경우 2) Subset Sampling Validation 기법을 활용해 1의 데이터에서 비정상 데이터를 제거한 경우로 나누어 평가하여 MSCRED의 성능 검증과 학습의 성능을 저하하는 오류 데이터의 처리 기법인 Subset Sampling Validation을 제시한다.

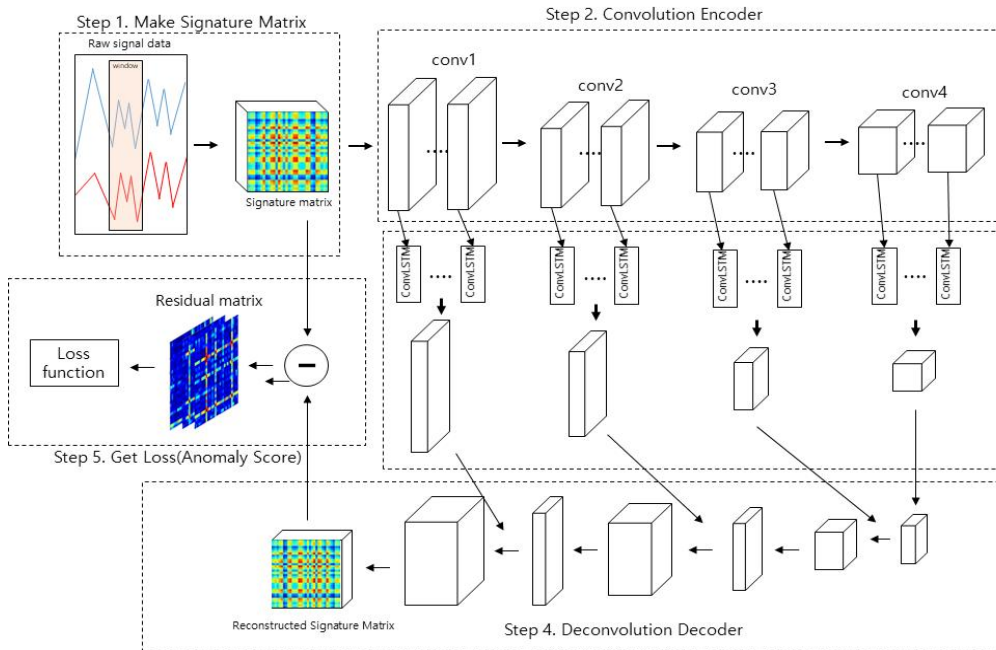


Fig. 1. MSCRED Framework

## 2. 선행 연구

### 2.1 MSCRED Framework

#### 2.1.1 Signature Matrix

MSCRED는 pattern 유사도를 활용해 정상/비정상을 파악하는 것을 목적으로 Signature Matrix를 만들어 데이터 특징을 추출한다. Signature Matrix는 측정된 raw data를 토대로 다변수 간의 상관관계와 시간 흐름을 표현한 특징이다. Fig. 2는 Signature Matrix를 구하는 과정을 표현한 그림이다.




Fig. 2. Making Signature Matrix process

Signature Matrix를 구하기 위해 먼저 시계열 데이터의 다양한 크기의 윈도우로 측정 데이터들을 나누고, 같은 윈도우 내의 다변수(센서)들의 correlation matrix를 구해, 변수간 상관관계를 표현한다. 이 서로 다른 시계열 쌍의 상관관계가 현재 시스템의 상태 특징을 표현하는 데에 중요한 역할을 한다[3]. 식 (1)은 시점  $t$ 의 크기가  $w$ 인 윈도우에서, 서로 다른 두 변수(센서)  $(i, j)$ 의 correlation matrix  $m_{ij}^t$ 를 수식으로 표현한 것이다. 식에서  $(x_i^t, x_i^{t+1}, \dots, x_i^{t+w})$ ,  $(x_j^t, x_j^{t+1}, \dots, x_j^{t+w})$ 는 시간  $(t, t+w)$ 사이의 측정값을 나타내며,  $k$ 는 scaler factor로 윈도우 크기  $w$ 와 같다.

$$m_{ij}^t = \frac{\sum_{\delta=0}^w x_i^{t-\delta} x_j^{t-\delta}}{k} \quad (1)$$

MSCRED는 위의 과정을 거쳐 모든 윈도우에서 correlation matrix를 구한 뒤, 이들을 병합하여 Signature matrix로 만들어 데이터로 사용한다.

#### 2.1.2 Convolutional Encoder

MSCRED는 입력의 spatial pattern을 추출하기 위해 4개의 convolution layer로 구성된 fully convolutional encoder[4]를 사용한다.

식 (2)와 식 (3)은 Fully convolutional encoder에서

사용되는 활성화 함수인 SELU(Scaled Exponential Linear Unit)[5]와 시점  $t$ 의  $I$ 번째 Feature Map인  $X^{t,I}$ 을 도출해내는 과정을 수식으로 표현한 것이다. Eq 2의 식에서  $\alpha$ 는 scale을 의미하며 Eq 3의 식에서  $f(\dots)$ 는 활성화 함수인 SELU를 뜻하고,  $W^I$ 는  $I$ 번째의 kernel을 의미하며,  $*$ 은 convolution 연산을,  $b^I$ 는 편향을 의미한다.

$$f(\alpha, x) = \begin{cases} x & (x > 0) \\ \alpha(e^x - 1) & (x \leq 0) \end{cases} \quad (2)$$

$$X^{t,I} = f(W^I * X^{t,I-1} + b^I) \quad (3)$$

#### 2.1.3 Attention-based ConvLSTM

기존 시계열 데이터의 학습에는 시간 정보를 분석하는 ConvLSTM[6]이 사용되었다. 하지만 ConvLSTM은 Sequence 길이가 길어질수록 성능이 저하되는 문제를 가지고 있었는데, MSCRED는 Attention 기법[7]을 적용하여 이러한 단점을 개선한 모델인 Attention-based ConvLSTM을 제시했다. MSCRED는 Attention 가중치를 구하기 위해 이전 단계의 Convolutional encoder에서 도출된  $h$ 개의 feature map을 ConvLSTM의 input으로 넣어  $h$ 개의 hidden state를 추출했다. 이때  $h$ 개의 hidden state의 attention 가중치는 last hidden state와의 유사도를 기반으로 도출하게 되며, 최종적으로 가중 합을 활용하여 최종 Feature Map을 구하게 된다. 식 (4)는 attention 가중치를 구하는 과정을 식으로 표현한 것이며,  $H^{t,I}$ 은  $t$ 시점의  $I$ 번째 hidden state를 의미하고,  $k$ 는  $k$ 단계의 attention 가중치를 의미한다.

$$\alpha^k = \frac{\exp \frac{(\overrightarrow{H^{t,I}})^T (\overrightarrow{H^{k,I}})}{x}}{\sum_{k \in (t-h, t)} \exp \frac{(\overrightarrow{H^{t,I}})^T (\overrightarrow{H^{k,I}})}{x}} \quad (4)$$

#### 2.1.4 Convolutional Decoder

MSCRED는 Encoding 과정에서 압축된 Signature Matrix를 복원하여 위해 4개의 Deconvolutional layer로 구성된 Convolutional Decoder를 사용한다. 식 (5)는 복원된 시점  $t$ 의  $I-1$ 번째 Signature Matrix인  $\hat{X}^{t,I}$ 를 식으로 표현한 것이다. 식에서  $f(\dots)$ 는 활성화 함수인 SELU를 뜻하고,  $\hat{W}^I$ 는  $I$ 번째의 kernel을 의미하며,  $\oplus$ 은 레이어간 병합을,  $\otimes$  Deconvolution 연

산을,  $\hat{b}^I$ 는 편향을 의미한다.

$$\hat{X}^{t,I-1} = \begin{cases} f(\hat{W}^{t,I} \otimes \hat{H}^{t,I} + \hat{b}^{t,I}) & \dots (I=4) \\ f(\hat{W}^{t,I}[\hat{H}^{t,I} \oplus \hat{X}^{t,I}] + \hat{b}^{t,I}) & \dots (I=3, 2, 1) \end{cases} \quad (5)$$

### 2.1.5 Loss Function

이러한 MSCRED의 Encoder-Decoder 모델이 정상 데이터로 잘 학습되었다면, 입력이 정상 데이터라면 Decoder의 재구성된 Signature Matrix가 높은 복원율을 보일 것이다. 이러한 점을 활용해 MSCRED는 Encoder 이전의 Signature Matrix와 Decoder의 재구성된 Signature Matrix의 차이인 Residual Matrix를 활용해 Loss를 계산한다. 식 (6)은 MSCRED에서 사용하는 Loss Function을 식으로 표현한 것이며 식에서  $X^t$ 는 원본 Signature Matrix를,  $\hat{X}^t$ 는 복원된 Signature Matrix를 의미한다. MSCRED는 mini-batch stochastic gradient descent와 Adam optimizer[8]를 조합한 방식으로 loss를 최소화 하게 학습한다.

$$Loss_{mscRed} = \sum \sum \|X^t - \hat{X}^t\| \quad (6)$$

## 3. 연구방법

### 3.1 연구 대상

MSCRED Framework의 학습 방식은 훈련 데이터로 정상 데이터만을 사용했을 때 성능이 보장되는 단점이 있다. 이러한 한계를 극복하고자 본 논문은 학습 데이터 적합도 판정 기법인 Subset Sampling Validation 기법을 제시한다. 실제 발전소 데이터를 활용하여 정상/비정상 혼합 데이터 상황에서의 MSCRED의 성능과 Subset Sampling Validation 기법의 성능을 평가한다.

### 3.2 데이터 셋 수집 방법

본 연구는 한국수력원자력의 자동 이상 예측 진단 프로젝트의 지원으로 진행되어 한국수력원자력이 보유한 원전의 실제 데이터를 이용하여 진행되었다. 한국수력 원자력 산하의 실제 원자력 설비 중, 이상이 발생한 진동 설비에 대해, 전문가 라벨 분류가 끝난 설비를 대상으로 가능한 모든 측정 데이터를 수집하였다.

연구에 활용된 진동 설비는 인보드, 아웃보드에 각각 수직 수평 센서가 설치되어 있으며, 총 4개의 센서에서

진동 데이터가 측정된다. Table 1은 수집한 데이터 셋의 정보이다.

Table 1. Dataset before preprocessing

Dataset Information	
Total Data	(149 date) x (4 sensor) files
Sensor	Inboard Vertical, Inboard Horizontal, Outboard Vertical, Outboard Horizontal
Anomaly Type	Rotor Rub
Length	3.3s / 3.8s
date	2008.08-2020.10
Labeled/ Unlabeled data	23 date x 4 sensor / 126 date x 4 sensor

### 3.3 데이터 셋 정제

데이터 간의 이상치가 측정 방식에 따라 다르게 나타나는 것을 방지하기 위해 측정 방식이 변경된 2017년 이전의 데이터는 모두 데이터에서 제외하였다. 또한, 측정 길이가 3.8s인 데이터 역시 오류 데이터일 가능성이 있지만, 이것이 진짜로 오류 데이터인지 잘 측정된 데이터인지 알 방법이 없는, 제어할 수 없는 데이터기에 제외하였다. 마지막으로 검증을 위해서 라벨 분류가 되지 않은 126 x 4개의 측정 데이터를 제외하였다.

Table 2는 선택된 데이터 셋에 대한 정보이다. 하나의 날짜에는 총 4096번의 진동 값이 측정되어있으며 4개의 센서에서 총 18일 동안 측정된 데이터를 사용하였다.

Table 2. Selected Dataset

Total Dataset			
Sample per data	Total	Normal	Rotor Rub
4096	18 date x 4 sensor	16 date x 4 sensor	2 date x 4 sensor

### 3.4 훈련/테스트 데이터 셋 구성

MSCRED의 훈련 데이터에 비정상 데이터가 혼합되는 경우의 성능을 평가하기 위해 정상과 비정상이 혼합된 데이터 셋을 구성하였다.

Table 3은 훈련/테스트 데이터 셋이 어떻게 구성되어 있는지를 보여준다.

Table 3. Dataset split

Complex data use to train				
	Sample per data	Total	Normal	Rotor Rub
Train	4096	8 date x 4 sensor	7 date x 4 sensor	1 date x 4 sensor
Test	4096	10 date x 4 sensor	9 date x 4 sensor	1 date x 4 sensor

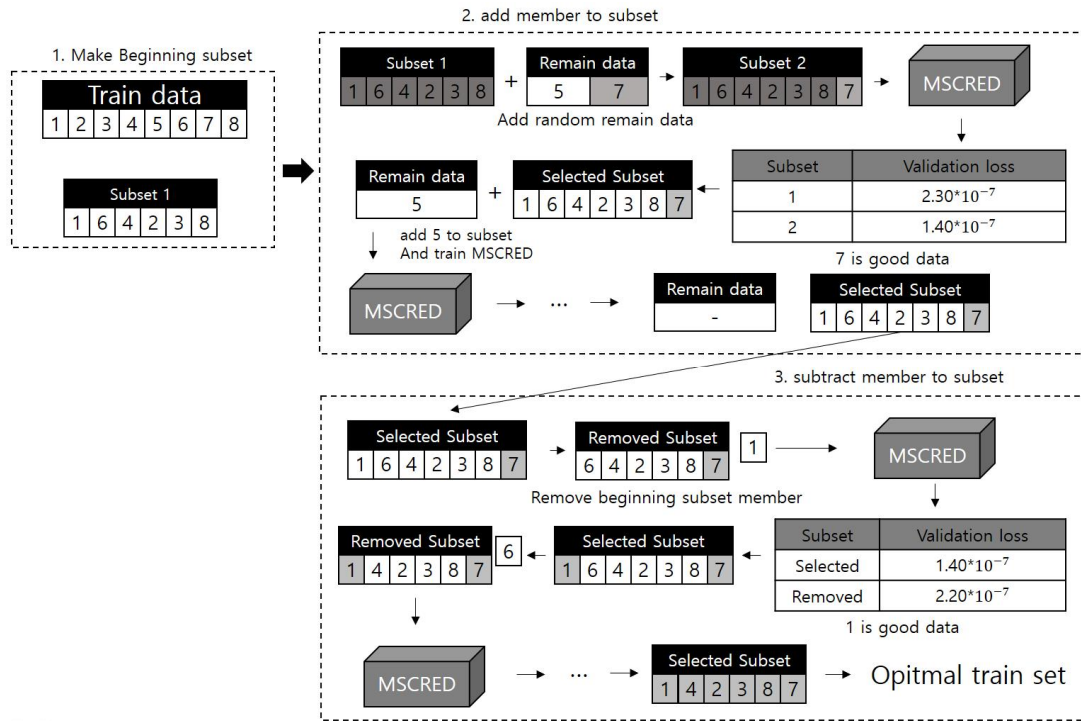


Fig. 3. Subset Sampling Validation

### 3.5 Subset Sampling Validation

본 논문은 비정상 데이터가 혼합된 훈련 데이터를 여러 subset으로 나누어 최적의 훈련 데이터 셋을 찾는 Subset Sampling Validation 기법을 제안한다.

#### 3.5.1 Brute force Subset Sampling과 Auto encoder에서의 Subset Sampling 아이디어

n개의 train data set에서 최적의 train subset을 찾는 방법은, 평균 지표인 subset validation score를 정하는 방식과 subset을 구성하는 방식에 따라 차이가 존재한다. 가장 쉽고 성능을 보장할 방법은 가능한 모든 subset을 cross validation 기법으로 validation score를 분석하는 Brute Force 방식이다. 이 방법은 모든 subset을 검증한다는 점에서 성능을 보장하지만 모든 subset을 상대로 cross validation을 진행한다는 것은 현실적이지 못한 시간과 리소스가 소모되기에 부적절한 방식이다.

최적의 train subset을 좋은 방법은 어떠한 데이터가 좋지 못한 데이터라는 힌트를 얻어 그 데이터를 제거하며 검증하는 방법이다. Auto-encoder 모델에서

학습은 압축과 재구성을 거친 데이터 흐름의 차이를 통해, 이들의 유사성을 기준으로 진행된다. 그로 인해 Auto-encoder 모델은 적어도 '입력값'에 대해서는 복원을 보장해주는 성격을 지니게 된다. 본 논문에선 Auto-encoder의 이런 성격을 이용하여, 정상 데이터가 train data에서 많은 수를 차지한다는 전제하에 최적 train subset을 구한다.

#### 3.5.2 Subset Sampling Validation

먼저 초기의 Subset을 train data의 크기에 비례하게 임의로 구한 뒤, 학습을 진행한다. 이때 subset의 크기가 학습에 사용될 수 있게 충분히 크게 한다. Subset Sampling Validation의 설계상 많은 양의 학습이 요구되므로, max epoch과 early stopping 기법을 활용하여 최대한 학습 시간을 단축했다. 최초로 진행된 학습에서 k-fold cross validation 기법으로 loss를 구하고, Subset의 구성원을 추가한다. 구성원은 뽑히지 않은 train data에서 임의로 추가하며, 다시 학습을 진행하여 얻은 validation loss가 개선되었는지를 확인한다. 만약 validation loss가 개선되었다면, 새로 추가된 데이터가

기존의 train data와 특징이 비슷하다는 것을 의미한다. 이때의 subset을 selected subset으로 생각하고 다음 구성원을 추가한다. 만약 개선되지 않았다면, 이것은 기존의 train data와 성격이 맞지 않음을 의미한다. 따라서 train에서 제외하고 이전의 subset을 selected subset으로 두고 다음 구성원을 추가한다. 이 구성원을 추가하는 과정은 초기 subset의 구성원이 아닌 모든 train data를 구성원에 걸맞는지 판정하며 진행한다.

이후 초기 subset의 검증을 진행하는데, 구성원을 추가하는 단계가 모두 마무리된 selected subset에서 시작하여, 임의로 구성원을 하나씩 빼며 validation loss가 개선되는지를 파악한다. 이 과정은 모든 초기 subset의 검증이 끝날 때까지 진행하며 이 과정이 끝난 뒤 남은 subset의 구성원들이 최종 optimal train list가 된다.

Fig. 2는 논문이 제시하는 Subset Sampling Validation의 과정을 그림으로 표현한 것이다.

#### 4. 연구결과

Table 4는 실험에 사용된 테스트 데이터들의 날짜별 정보이다.

Table 4. Information of test data

Test data Information		
	date	label
1	2017/11/14	Rotor Rub
2	2017/12/19	Normal
3	2018/04/03	Normal
4	2018/05/29	Normal
5	2018/07/23	Normal
6	2019/01/23	Normal
7	2019/05/13	Normal
8	2019/07/25	Normal
9	2019/08/16	Normal
10	2019/11/07	Normal

식 (7)은 MSCRED 모델의 테스트 결과, 비정상 데이터의 분류에 사용되는 Anomaly Score를 수식으로 표현한 것으로 Residual Matrix의 MSE(Mean Squared Error)이다.

$$Anomaly\ Score = \frac{X_{pred}^t - X_{true}^t}{size\ of\ pred} \quad (7)$$

또한, 테스트 데이터의 정상/이상 판정을 위해, Anomaly score의 Threshold를 Youden's J

statisic을 사용하여 구하였다.[9] 식 (8)은 실험에 사용된 Threshold를 공식으로 표현한 것이다.

$$Threshold = \frac{TP}{TP+FN} + \frac{TN}{TN+FP} - 1 \quad (8)$$

모델의 성능 평가는 accuracy, f1 score, precision score, recall score의 4가지 측면에서 평가하였다.

Table 5는 Subset Sampling Validation의 결과, train data들의 실제 라벨과 최적 train subset에 선택된 여부를 나타낸 표이다. 실험은 1~8을 모두 포함한 original train data와 1~7 데이터를 포함한 optimal train subset data로 별개의 MSCRED모델을 학습하며 진행하였다.

Table 5. Information of train data

Test data Information			
	date	label	optimal subset
1	2017/01/13	Normal	O
2	2017/02/07	Normal	O
3	2017/04/05	Normal	O
4	2017/05/10	Normal	O
5	2017/08/22	Normal	O
6	2017/09/05	Normal	O
7	2017/09/27	Normal	O
8	2017/10/26	Rotor Rub	X

#### 4.1 Anomaly Score

Fig. 4는 정상/비정상 혼합 데이터를 별다른 기법 없이 학습에 사용했을 때와(test 4.1) subset Sampling validation 기법을 활용하여 만든 optimal train subset을 학습한 MSCRED 모델(test 4.2)이 갖는 Anomaly Score의 날짜별 그래프이다. 또한, Table 6은 Fig. 4를 정상 데이터의 Anomaly Score range, 비정상 데이터의 Anomaly Score range, Threshold의 위치를 이용하여 정리한 표이다. Subset Sampling Validation 기법을 활용했을 때, 정상 데이터의 anomaly range의 min-max 범위가 더 낮고, Threshold로 구분되는 data의 양이 더 많은 것을 볼 수 있다.

Table 6. Anomaly score analysis in test 4.1 & 4.2

	Normal data Anomaly range	Abnormal data Anomaly range	Threshold
4.1	(0.0058, 0.0062)	(0.0059, 0.0063)	0.00599
4.2	(0.0036, 0.00385)	(0.0037, 0.00418)	0.00382

\*4.1 result of none additional validation  
\*4.1 result of SubsetSampling Validation




Fig. 4 Anomaly Score in test 4.1 and test 4.2

#### 4.2 분류 성능 평가

Table 7은 두 실험의 모델을 f1 score, precision score, recall score, accuracy score에서 평가한 표이다.

Table 7. F1, Precision, Recall, Accuracy in test 4.1 & 4.2

	F1	Precision	Recall	Accuracy
4.1	0.7360	0.7169	0.7562	0.9457
4.2	0.8443	0.7674	0.9383	0.9654

\*4.1 result of none additional validation  
 \*4.1 result of SubsetSampling Validation

test 4.1보다 test 4.2의 성능 지표가 더 높은 것을 확인할 수 있다.

### 5. 결론 및 향후 연구 계획

#### 5.1 결론

MSCRED는 전문가 독립적인 특징을 바탕으로 광범위한 시계열 데이터에서 적용 가능한 학습 방식을 제시한다. 그러나 Auto-encoder에서 파생된 학습 방식은, 학습 데이터가 정상 데이터로만 학습되어야 한다는 무

결성을 요구하고[10] 이는 실제 현장에서 보장되지 않을 가능성이 존재한다. 본 논문은 이러한 문제점을 무결한 데이터셋을 찾는 기법인 Subset Sampling Validation 기법을 통해 극복하는 방법을 제시하였다. Subset Sampling Validation 기법은 각각의 학습 데이터가 학습에 적합한지 평가하여 train set의 subset을 만들어 optimal train set을 만들어냈다. 이러한 기법은 기존의 cross-validation 기법과 다르게 적은 학습데이터가 존재하는 환경에서도, 적절한 성능을 보장한다.

## 5.2 향후 연구 계획

본 논문에서 사용된 Subset Sampling Validation 기법은 많은 학습 단계를 요구하여 학습에 많은 리소스가 사용된다. 향후 subset 표본을 추출하는 기법을 연구하여 subset 개수를 줄여, 학습 리소스를 줄이는 연구가 필요하다.

## REFERENCES

- [1] C. Zhang et al. (2019, July). *A deep neural network for unsupervised anomaly detection and diagnosis in multivariate time series data*. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 33, No. 01, pp. 1409-1416).
- [2] M. Ojala & G. C. Garriga. (2010). Permutation tests for studying classifier performance. *Journal of Machine Learning Research*, 11(6).
- [3] D. Hallac, S. Vare, S. Boyd & J. Leskovec. (2017, August). *Toeplitz inverse covariance-based clustering of multivariate time series data*. In Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 215-223).
- [4] J. Long, E. Shelhamer & T. Darrell. (2015). *Fully convolutional networks for semantic segmentation*. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 3431-3440).
- [5] G. Klambauer, T. Unterthiner, A. Mayr & S. Hochreiter. (2017, December). *Self-normalizing neural networks*. In Proceedings of the 31st international conference on neural information processing systems (pp. 972-981).
- [6] S. H. I. Xingjian et al. (2015). *Convolutional LSTM network: A machine learning approach for*

*precipitation nowcasting*. In Advances in neural information processing systems (pp. 802-810).

- [7] D. Bahdanau, K. Cho & Y. Bengio. (2014). Neural machine translation by jointly learning to align and translate. *arXiv preprint, arXiv:1409.0473*.
- [8] D. P. Kingma & J. Ba. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- [9] W. J. Youden. (1950). Index for rating diagnostic tests. *Cancer*, 3(1), 32
- [10] N. Merrill & A. Eskandarian. (2020). Modified autoencoder training and scoring for robust unsupervised anomaly detection in deep learning. *IEEE Access*, 8, 101824-101833.

### 홍수웅(Su-Woong Hong)

[정회원]



- 2020년 2월 : 인하대학교 컴퓨터공학과(이학사)
- 2020년 3월 ~ 현재 : 인하대학교 전기컴퓨터 공학과(공학석사)
- 관심분야 : 이상진단, 심층신경망, 인공지능, 로봇 오퍼레이팅 시스템
- E-Mail : hsw2012s@gmail.com

### 권장우(Jang-Woo Kwon)

[정회원]



- 1996년 8월 : 인하대학교 정보공학과(박사)
- 1998년 3월 : 특허청 사무관
- 2009년 3월 : 동명대학교 부교수
- 2012년 3월 : 경원대학교 부교수
- 2012년 3월 ~ 현재 : 인하대학교 교수
- 관심분야 : HCI, 교통, 인공지능
- E-Mail : jwkwon@inha.ac.kr