

Unsupervised Learning-Based Pipe Leak Detection using Deep Auto-Encoder

Doyeob Yeo*, Ji-Hoon Bae**, Jae-Cheol Lee***

Abstract

In this paper, we propose a deep auto-encoder-based pipe leak detection (PLD) technique from time-series acoustic data collected by microphone sensor nodes. The key idea of the proposed technique is to learn representative features of the leak-free state using leak-free time-series acoustic data and the deep auto-encoder. The proposed technique can be used to create a PLD model that detects leaks in the pipeline in an unsupervised learning manner. This means that we only use leak-free data without labeling while training the deep auto-encoder. In addition, when compared to the previous supervised learning-based PLD method that uses image features, this technique does not require complex preprocessing of time-series acoustic data owing to the unsupervised feature extraction scheme. The experimental results show that the proposed PLD method using the deep auto-encoder can provide reliable PLD accuracy even considering unsupervised learning-based feature extraction.

▶ Keyword: Pipe leak detection, Acoustic signal, Unsupervised learning, Auto-encoder, Deep learning

1. Introduction

현재, 원자력발전소를 포함한 발전 플랜트에서 초기에 설치되었던 배관들의 노후화로 인하여 배관의 부식(Corrosion)이 진행되고 있다. 이로 인해 배관 누출(Leak) 사례들이 빈번히 발생하고 있으며, 이러한 플랜트 설비의 손상 및 결함으로 인한 안전사고 발생 시 대형 인명사고로 이어질 가능성이 높고, 산업의 경제적 손실 및 환경오염 등의 사회적 문제를 야기 시킬 수 있다. 따라서, 이러한 문제점들을 해결하고 발전소의 안정적인 운영 및 유지보수를 위하여 노후화된 배관계의 조기 누출탐지 요구가 증대되고 있다.

기존에는 음향센서 혹은 진동센서 등을 이용하여 수집된 데이터를 시간영역, 주파수영역, 시간-주파수 영역 등에서 다양한 신호처리 기법들을 적용하여 배관의 누출을 탐지하는 방법들이 사용되었다[1]. 이때 사용된 신호처리 기법들은 데이터에 대한 자기상관함수(Auto-correlation function) 및 상호상관함수(Cross-correlation function), 측정 데이터의 시간 및 주파수 패턴 및 크기 등이 있다. 특히, 배관에 누출이 발생할 경우 고주파영역에

서 음향신호가 검출된다는 실험결과를 바탕으로, 비교적 값이 저렴한 음향센서를 이용하여 누출을 판별하는 기기가 상용화 되어 사용되고 있다. 하지만, 플랜트에서 발생하는 다양한 기계잡음이나 소음 환경으로 인하여 기존 신호처리 기반 기법들을 이용하여 미세누출의 발생여부를 판별하는데 있어 어려움이 있으며, 원격의 상시 감시가 불가능하여 조기 누출감지에 한계가 있다.

최근, 빅데이터 시대를 맞이하여 인간의 뇌를 모방한 딥러닝(Deep learning) 기반의 인공지능 기술이 크게 발전함에 따라 다양한 산업 분야에서 경쟁력 향상 및 생산 효율성 증대를 위하여 인공지능 기술을 도입하려는 노력이 한창이다. 특히, 독일, 미국 등 해외 선진국들은 제조업의 생산성 향상 및 품질 향상뿐만 아니라, 설비 유지보수의 효율성 증진 방안으로 딥러닝 기반의 인공지능 기술을 적극적으로 적용 중이다.

본 논문에서는 음향센서로부터 수집된 데이터를 이용한 비지도 학습(Unsupervised learning) 기반의 플랜트 배관계에

• First Author: Doyeob Yeo, Corresponding Author: Ji-Hoon Bae

*Doyeob Yeo (yeody@etri.re.kr), Electronics and Telecommunications Research Institute (ETRI)

**Ji-Hoon Bae (jihbae@cu.ac.kr), Daegu Catholic University

***Jae-Cheol Lee (jlee2@kaeri.re.kr), Korea Atomic Energy Research Institute

• Received: 2019. 08. 14, Revised: 2019. 08. 27, Accepted: 2019. 09. 04.

• This work was supported by a National Research Council of Science & Technology (NST) grant by the Korean government (MSIP) [No. CRC-15-05-ETRI].

대한 미세누출 탐지 방법을 제안하고자 한다.

본 논문의 구성은 다음과 같다. II장에서는 지도학습(Supervised learning) 기반으로 영상특징 추출과 컨볼루션 뉴럴 네트워크(Convolutional neural network: CNN)를 적용한 기존 누출판별 기법을 소개하고, 비지도학습 방법으로, 딥 뉴럴 네트워크(Deep neural network) 구조를 가지고 있는 딥 오토인코더(Deep auto-encoder)의 구성요소 및 특징들을 살펴본다. 다음으로, III장에서는 음향 센서에서 수집한 시계열 음향 데이터를 이용한 오토인코더 기반의 플랜트 배관 누출탐지 방법에 대해 소개한다. 마지막으로, IV장에서는 실제 공장 설비에서 수집한 음향 센서 데이터를 바탕으로, II장에서 소개한 지도학습 기반의 기존 누출판별 기법과 본 논문에서 제안한 누출탐지 방법의 성능을 서로 비교하고자 한다.

II. Preliminaries

1. Related works

1.1 Image feature extraction for pipe leak detection

[2]에서는 음향센서를 이용하여 수집한 시계열 음향 데이터를 전처리 과정을 통해 2차원 영상 특징으로 변환한 다음, 컨볼루션 뉴럴 네트워크를 이용하여 누출과 정상상태를 구분하였다. [2]에서는 누출 및 정상상태에 대한 레이블(Label)이 있는 데이터들로부터 누출 및 정상상태를 분류하는 지도학습 기반의 배관 누출탐지 방법을 제안하였다. 특히, 시계열 음향 데이터를 영상 특징으로 변환하기 위하여, root-mean-square(RMS) 패턴 영상 특징과 주파수 패턴 영상 특징을 새롭게 정의하였다. Fig. 1은 수집된 시계열 음향 데이터를 두 가지 영상특징들로 변환한 결과들을 보여준다.

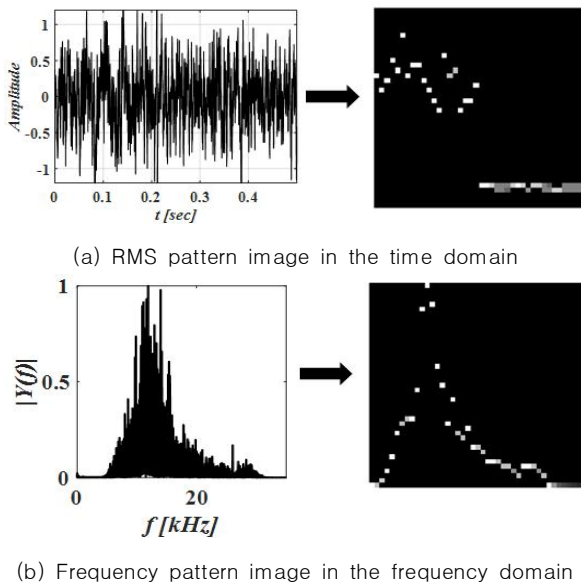


Fig. 1. Image feature extraction for pipe leak detection[2]

[2]의 결과에 따르면, 시계열 음향 데이터와 순환신경망(Recurrent neural network: RNN)을 이용하여 누출 및 정상상태를 분류하였을 때에는 84.53%의 분류 정확도를 나타내었으나, [2]에서 제안한 방법을 이용하면, 기계적 잡음이 있는 환경에서도 99.97%의 분류 정확도를 얻을 수 있다.

2. Deep auto-encoder

오토인코더는 [3]에서 처음으로 소개된 것으로, 레이블이 없는 데이터에서 데이터의 패턴 특징을 학습하기 위한 비지도학습 방법 중 하나이다. 오토인코더의 구성은 Fig. 2와 같이 크게 인코더(Encoder, E)와 디코더(Decoder, D)로 이루어져 있으며, 일반적으로 인코더를 통하여 입력 데이터를 압축하고 디코더를 통하여 압축된 데이터를 복원한다.

인코더와 디코더의 구조가 딥 뉴럴 네트워크 구조를 가지고 있는 것을 딥 오토인코더로 정의하며, 다층신경망(Multi-layer perceptron)[4-5], 컨볼루션 뉴럴 네트워크[6-9], 순환신경망 구조[10-11] 등과 같은 딥 뉴럴 네트워크 구조들을 이용할 수 있다. 다층신경망이나 컨볼루션 뉴럴 네트워크를 이용하는 경우, Fig. 2의 구조에서와 같이, 인코더에서 입력 데이터의 압축을 수행하기 위하여 인코더의 은닉층(Hidden layer)이 깊어질수록 네트워크가 점점 좁아지도록 설계한다. 이때, 네트워크가 좁아진다는 의미는 노드의 수나 특징맵(Feature map)의 개수를 줄여나가는 것을 뜻한다. 이와 반대로, 디코더에서 압축된 데이터를 복원하기 위해서는 디코더의 은닉층이 깊어질수록 네트워크가 점점 넓어지도록 설계한다.




Fig. 2. Basic architecture of the auto-encoder

이러한 오토인코더 구조는 비지도학습의 이상탐지(Anomaly detection) 모델을 만드는데 주로 활용될 수 있다. 이상탐지 문제의 경우, 정상상태가 아닌 비정상의 이상상태 데이터를 학습에 필요할 만큼 충분히 얻을 수 없는 경우가 대부분이고, 극단적으로는 이상상태의 데이터를 전혀 얻을 수 없는 경우도 발생할 수 있다. 또한, 여러 종류의 이상상태가 존재할 수도 있기 때문에, 모든 종류의 이상상태에 대해 학습하는 것은 불가능하다. 이러한 이유들 때문에, 오토인코더와 정상상태 데이터를 이용하여 정상상태에 대한 특징들을 추출한 다음, 이러한 특징들을 이용하여 이상탐지를 수행하는 많은 방법들이 연구되고 있다 [12-14]. 이상탐지에 이용하는 오토인코더의 경우, 오토인코더를 통해 입력 데이터가 그대로 디코더의 출력으로 나오는 것이 목적이기 때문에, 입력 데이터와 출력 데이터 사이의 차이를 줄이는 방법을 이용하여 오토인코더를 학습한다.

III. The Proposed Scheme

본 장에서는 음향 센서에서 수집한 시계열 음향 데이터들을 이용한 오토인코더 기반의 플랜트 배관 누출탐지 방법을 소개하고자 한다.

II.1절에서 소개한 방법은 지도학습을 이용하는 방법으로, 99.97%의 높은 분류 정확도로 배관 누출탐지를 수행할 수 있다. 하지만, 실제 상황에서 누출상태의 음향 데이터 수집을 위해 실제 공장의 배관에서 누출을 발생시키는 것은 매우 위험하기 때문에, 정상상태의 음향 데이터 수집만 가능한 경우가 대부분이다. 따라서 II.1절에서 소개한 지도학습 기반의 배관 누출탐지 대신, 누출상태의 데이터 없이도 정상상태의 데이터만을 이용하여 학습이 가능한 비지도학습 기반의 배관 누출탐지 모델이 필요하다. 또한, 음향신호의 특성상 여러 종류의 잡음(Noise)이 발생할 수 있기 때문에, 음향신호 데이터를 효과적으로 학습시키기 위해서는 간단한 선형 모델이 아닌 딥 뉴럴 네트워크 구조의 인코더와 디코더가 필요하다. 이러한 이유 때문에 본 연구에서는 딥 오토인코더 기반의 비지도학습을 이용한 배관 누출탐지 방법을 소개하고자 한다.

1. Design of deep auto-encoder architecture

II.2절에서 기술한 바와 같이, 딥 오토인코더에서 인코더와 디코더를 설계하는데 사용할 수 있는 딥 뉴럴 네트워크 구조로는 다층신경망, 컨볼루션 뉴럴 네트워크, 순환신경망 등이 있다. 플랜트 배관의 누출 상황의 경우, 선행 시간대의 데이터 특성이 현재 시간대의 데이터 특성에 크게 영향을 미치지 못한다고 가정하였다. 본 논문에서는 정상상태가 유지되다가 사전 징후 없이 갑작스런 균열이 발생하는 경우도 다루기 위하여, 인코더 및 디코더 구조 중에서 순환신경망 구조를 배제하였다. 또한, 사용하고자 하는 데이터 형태가 시계열 데이터이기 때문에, 본 연구에서는 인코더 및 디코더 구조로써 컨볼루션 뉴럴 네트워크가 아닌 다층신경망 구조를 적용하였다.

본 논문에서 이용한 딥 오토인코더는, 인코더를 이용하여 입력 데이터에 대한 압축을 수행하기 위해, 은닉층이 깊어짐에 따라 다층신경망의 노드 수를 줄이고, 디코더를 이용하여 압축된 데이터의 복원을 수행하기 위해, 은닉층이 깊어짐에 따라 다층신경망의 노드를 늘리는 방식으로 설계하였다. 또한, 입력과 출력을 직접 비교하기 위하여 입력 데이터의 차원과 출력의 차원이 같아지도록 딥 오토인코더를 설계하였다. 시계열 음향신호를 이용하여 배관 누출탐지 문제에 적용한 딥 오토인코더의 상세구조는 다음의 IV장에서 자세히 다루고자 한다.

2. Loss function for deep auto-encoder

Fig. 2에서, 딥 오토인코더의 입력 데이터인 시계열 음향신호를 $x \in R^n$ 라고 하면, 디코더에서의 출력은 $D(E(x))$ 가 된다. 입력과 출력의 직접 비교를 위해 III.1 절에서 언급한 바와 같이 디코더 출력 데이터의 차원 또한 $D(E(x)) \in R^n$ 이 되

도록 딥 오토인코더를 설계하여야 한다.

배치(Batch) 단위의 학습을 위해 크기가 m 인 시계열 음향신호 배치 데이터 집합을 $X = \{x_1, x_2, \dots, x_m\}$ 이라고 하자. 여기서, $\{x_i\}_{i=1}^m$ 은 각각 시계열 음향신호를 의미한다. 배치 단위의 딥 오토인코더의 비지도학습을 위한 손실함수(loss function)는 다음과 같이 정의된다.

$$l(X) = \frac{1}{m} \sum_{i=1}^m \|x_i - D(E(x_i))\|_2^2 \quad (1)$$

여기서 $\|\cdot\|_2$ 은 n 차원 공간에서의 유클리드안 놈(Euclidean norm)을 나타낸다. 따라서, 수식 (1)의 손실함수가 최소가 되도록 딥 오토인코더를 학습하며, 인코더에서는 시계열 음향신호에 대한 특징을 비지도학습 방법을 통해 추출한다.

3. Learning procedure of deep auto-encoder

3.1 Preprocessing

[2]에서는 배관의 누출 및 정상상태 분류 문제를 해결하기 위해, 두 가지 영상 기반의 특징 추출을 이용하여 시계열 음향신호를 영상 특징으로 변환하였다. 이를 위해서는 잡음 음향신호 및 누출 음향신호에 대한 도메인 지식이 필요할 수 있으며, 신호처리에 대한 지식이 수반되어야 한다. 또한, 배관의 모양이나 크기, 배관이 위치한 곳의 상태 등에 따라 영상 기반의 특징 추출을 위한 인자(Parameter)들이 수정되어야 할 필요성이 있을 수 있다.

딥 오토인코더의 경우, 입력 데이터가 인코더를 통해 압축되는 과정에서 입력 데이터를 대표할 수 있는 특징들이 추출된다. 따라서, 자료에 대한 복잡한 특징 추출과정 없이 음향신호 데이터를 간단한 전처리 과정만으로 딥 오토인코더를 학습시킬 수 있다.

입력 음향신호의 경우, 복수의 센서들로부터 수집한 각 데이터마다 최대 및 최소값이 다르기 때문에, 딥 오토인코더를 학습시키기 위해서는 입력 데이터에 대한 정규화(Normalization) 과정이 필요하다. 따라서, 본 논문에서는 딥 오토인코더를 학습하기 위해, 수집된 음향신호 신호 크기 범위를 $[-1, 1]$ 사이로 정규화 하여 모델의 입력 데이터로 이용한다. 또한, 입력 음향신호에는 수집 센서의 동작 환경 문제나 잡음 때문에 발생하는 이상치(Outlier)들이 포함될 수 있다. 이러한 이상치들은 6시그마 방법(6시그마는 ETRI KSB융합연구단에서 구현한 전처리 라이브러리의 함수를 이용)을 이용하여 모델 입력 전에 제거하였다.

3.2 Deep auto-encoder design without Batch-normalization

[15]에서는 딥 뉴럴 네트워크를 학습시키는데 있어서 발생하는 내부적인 공변량 변화(Internal covariant shift) 현상의 정도를 줄이기 위하여 배치정규화를 제안하였다. 이는, 특히 큰 규모의 딥 뉴럴 네트워크를 보다 안정적이고 빠르게 학습할 수 있도록 한다. 최근에는 딥 뉴럴 네트워크 구조를 설계하는데 있

어서 배치정규화 과정을 필수적인 요소로 간주하고 있다.

딥 뉴럴 네트워크 구조에 배치정규화를 적용하게 되면, 최종 결과 값이 배치에 영향을 받게 된다. 훈련 과정에서 랜덤 셔플(random shuffle) 과정이 들어가게 된다면 배치에 있는 데이터들이 바뀌게 될 것이고, 은닉층들의 변수 값이 다 같은 경우에도 배치에 따라 출력 결과 값이 달라질 수 있다. 분류 문제의 경우에는 출력 결과에서 최댓값을 주는 요소가 있는 위치가 중요하기 때문에, 잘 학습된 딥 뉴럴 네트워크의 경우, 출력 결과 값이 변하더라도 최댓값을 주는 요소의 위치에는 크게 영향을 미치지 않는다.

한편, 본 논문에서 제안하는 방법에서는 다층신경망을 이용한 딥 오토인코더를 이용한 모델을 제안하였는데, 수식 (1)에서 정의된 손실함수를 줄이는 방향으로 학습이 진행이 되어야 한다. 하지만, 딥 오토인코더에 배치정규화를 적용하게 되면 배치가 바뀌에 따라 $D(E(x_i))$ 결과 또한 바뀌게 되어 오히려 학습에 부정적인 영향을 미칠 수 있다. 게다가, 딥 오토인코더 학습 시 손실함수가 0에 가깝게 학습이 되었다 하더라도 검증 시 배치가 바뀌게 된다면, 정확한 결과를 주지 못하는 경우가 발생할 수 있다. 따라서, 본 논문의 딥 오토인코더 구조에서는 배치정규화 과정이 없는 인코더 및 디코더 구조 설계를 고려하였다.

4. Classification using trained deep auto-encoder

누출이 없는 배관의 정상상태에서의 음향센서 데이터를 이용하여 딥 오토인코더를 학습하게 되면, 이를 이용하여 누출 및 정상상태에 대한 판단을 수행하여야 한다. 본 연구의 딥 오토인코더는 정상상태의 음향신호만을 이용하여 학습을 수행하기 때문에, 검증 시에 정상상태의 음향센서 데이터를 딥 오토인코더 모델에 입력할 경우 수식 (1)의 값이 작게 나오고, 누출상태의 음향센서 데이터를 입력할 경우 수식 (1)의 값이 크게 나온다고 가정한다.

누출상태의 음향 데이터가 소수 개라도 있는 경우, 정상상태의 음향 데이터를 이용하여 수식 (1)을 계산한 결과 값과 누출상태의 음향 데이터를 이용하여 수식 (1)을 계산한 결과 값 사이에 위치한 값을 누출판별을 위한 임계치(Threshold, T)로 정할 수 있다. 다음으로, 임의의 입력 데이터에 대하여 수식 (1)의 값이 T 보다 큰 경우에는 누출상태로 판단하고, 수식 (1)의 값이 T 보다 작은 경우에는 정상상태로 판단한다. 본 논문에서는 임계치 설정 및 결과 검증을 위하여 누출상태의 음향 데이터가 있다고 가정한다.

누출상태의 음향 데이터와 정상상태의 음향 데이터의 수식 (1)의 값에 대한 집합을 각각 L 과 B 이라 하자. 또한, L 과 B 에서의 표본 평균과 표본 분산을 각각 (μ_L, S_L^2) , (μ_B, S_B^2) 라고 정의하자. 본 논문에서는 계산의 편의를 위하여, L 과 B 가 정규 분포를 이루고, 각각의 집합이 표본 평균과 표본 분산을 정규 분포의 평균과 분산으로 갖고 있다고 가정한다. 즉, $L \sim N(\mu_L, S_L^2)$, $B \sim N(\mu_B, S_B^2)$ 이라 하면, 잘 학습된 딥 오토인코더는 $\mu_L > \mu_B$ 가 될 것이다.

표본 분산 값이 크다면 데이터들의 분포 폭이 크고, 표본 분산 값이 작다면 데이터들의 분포 폭이 작음을 의미한다. 따라서, 본 연구에서는 Fig. 3에서와 같이 임계치 T 의 값을 μ_B 와 μ_L 을 $S_B : S_L$ 의 비로 내분하는 점으로 정하도록 한다.




Fig. 3. Threshold T for pipe leak detection using the deep auto-encoder

간단한 계산 과정을 거치면, $T = \frac{S_B \mu_L + S_L \mu_B}{S_B + S_L}$ 가 된다. 본 논문에서는 정상상태의 음향 데이터만을 이용하여 딥 오토인코더를 학습시켰기 때문에, 정상상태 데이터의 수식 (1)의 손실함수 값은 μ_B 에 가까운 값들로 분포된다. 따라서 잘 학습된 딥 오토인코더의 경우에는 $S_B \ll S_L$ 인 경향을 보이게 된다.

위와 같은 이유에서, S_B 에 가중치를 줄 필요가 있다. 본 논문에서는 $S_B^{\alpha} = \alpha S_B$ 로 정의하고, 임계치 T_{α} 를 $T_{\alpha} = \frac{S_B^{\alpha} \mu_L + S_L \mu_B}{S_B^{\alpha} + S_L}$

과 같이 정의한다. α 값은 실험적으로 결정을 하며, 학습에 사용된 정상상태의 데이터와 임계치를 정하기 위해 사용되는 누출상태의 데이터를 사용하여 분류 정확도를 계산하고, T_{α} 중에 가장 높은 분류 정확도를 주는 값을 임계치 T 로 설정하였다.

만약, 누출상태의 음향 데이터가 없는 경우에는 딥 오토인코더 학습에 이용한 정상상태의 음향 자료만을 이용하여 T 값을 정해야 한다. 이때, 정상상태 음향 데이터를 이용하여 계산한 수식 (1) 값의 분포를 관찰하여 T 값을 결정하여야 한다.

IV. Experimental Results

본 장에서는 음향 센서를 통해 수집한 시계열 음향 데이터를 이용하여 누출과 정상상태를 구분하는 딥 오토인코더에 대한 실험 결과에 대해 분석할 것이다. 본 논문에서 기술한 배관 누출탐지를 위한 딥 오토인코더 구현 시, 전 세계적으로 널리 활용되고 있는 딥러닝 프레임워크 중의 하나인 텐서플로우(Tensorflow)를 사용하였다.

1. Experimental settings

1.1 Time-series acoustic data for experiments

본 논문에서 제안한 딥 오토인코더를 이용한 배관 누출 방법에 대한 실험을 위하여, Fig. 4에서와 같은 공장 설비에 음향 센서를 설치하여 시계열 음향 데이터를 수집하였다.




Fig. 4. Laboratory facility environment for pipe leak detection [2]

[2]에서와 같이, 누출상태의 음향 데이터는 100군데의 누출 지점으로부터 수집하였다. 또한, 각각의 누출 지점에 대하여 5종의 누출 구멍 직경들과 5종의 누출 압력들에 대해 총 25종의 조합을 만들어 4개의 음향 센서에서 누출상태의 음향 데이터를 수집하였다. 따라서, 누출상태 데이터는 총 $100 \times 5 \times 5 \times 4 = 10,000$ 개를 수집하였고, 마찬가지로 정상상태 데이터도 총 10,000개를 수집하였다. 이때, 정상 및 누출 데이터 모두 0.5초 동안 음향 센서로부터 $150kHz$ 샘플링 (Sampling)으로 수집하여 크기가 $10,000 \times 75,000$ 인 행렬 데이터로 구성하였다. 또한, 0.5초동안 수집된 신호를 0.1초 단위로 나누어 길이가 75,000인 음향 데이터를 길이가 15,000인 데이터 5개로 구성하여 실험에 이용하였다. 결과적으로, 본 논문의 실험에서는 누출상태 데이터와 정상상태 데이터는 크기가 $50,000 \times 15,000$ 인 행렬 데이터를 사용하였다.

Table 1. Experimental conditions for leak hole diameter (mm)

H_1	H_2	H_3	H_4	H_5
0.5	1.0	1.5	2.0	2.5

Table 2. Experimental conditions for escaping air pressure (bar)

P_1	P_2	P_3	P_4	P_5
1.0	2.0	3.0	4.0	5.0

실험에 사용된 누출 구멍 직경들과 누출 압력들은 각각 Table 1 및 Table 2와 같이 주어진다. $H_i P_j$ ($i, j = 1, 2, \dots, 5$)는 H_i 와 P_j 의 조합으로 수집된 누출상태의 음향 데이터를 의미한다. 예를 들어, $H_1 P_1$ 은 누출 구멍 직경 0.5mm, 누출 압력 1.0bar에서 수집된 누출상태의 음향 데이터를 나타낸다.

정상상태의 음향 데이터는 무작위로 추출하여 60%는 딥 오토인코더를 학습하는데 이용하였고, 40%는 딥 오토인코더의 성능을 검증하는데 이용하였다. 또한, 누출 음향 자료 중에서 $\{H_i P_1\}_{i=1}^5$, $\{H_i P_3\}_{i=1}^5$, $\{H_i P_5\}_{i=1}^5$ 는 누출상태와 정상상태를

구분하는 임계치를 결정하는데 사용하였고, $\{H_i P_2\}_{i=1}^5$ 와 $\{H_i P_4\}_{i=1}^5$ 는 딥 오토인코더의 성능을 검증하는데 이용하였다.


1.2 Architecture of deep auto-encoder

딥 오토인코더는 III.2 절에서 설명한 것과 같이 인코더와 디코더로 구성되어 있으며, 인코더는 은닉층이 깊어짐에 따라 노드의 수가 줄어든다. 반대로 디코더는 은닉층이 깊어짐에 따라 노드의 수가 늘어나게 되고, 마지막 노드의 개수는 입력 데이터 하나의 길이와 같도록 구성한다.


본 논문의 실험에서 사용한 입력 자료 하나의 길이는 15,000이고, 딥 오토인코더는 총 6개의 은닉층을 가진 다층신경망 구조의 인코더와 디코더로 구성하였다. 인코더의 노드 개수는 $\{7500, 5000, 2500, 2500, 1250, 1250\}$ 과 같이 구성하였으며, 디코더의 노드 개수는 $\{1250, 2500, 2500, 5000, 7500, 15000\}$ 와 같이 구성하였다. 본 논문에서 인코더 및 디코더의 구조는 실험적인 검증을 통하여 설계하였다.

2. Experimental results

본 논문에서 제안한 딥 오토인코더를 학습시킨 후, 정상상태 음향신호 및 누출상태 음향신호를 각각 재구성(Reconstruction)한 결과는 Fig. 5와 같이 주어진다.



(a) Reconstruction of leak signal



(b) Reconstruction of leak-free signal

Fig. 5. Acoustic data reconstruction using the trained deep auto-encoder

Fig. 5에서 빨간색 선은 원래 수집된 음향신호를 의미하고, 파란색 선은 딥 오토인코더를 이용해 복원된 신호를 각각 의미한다. Fig. 5(a) 결과에서와 같이 누출상태 음향신호는 원래 신호와 차이 나게 복원되는 반면, Fig. 5(b)에서 정상상태 음향신

호는 원래 신호와 유사하게 복원되는 것을 관찰할 수 있다.

본 논문에서 제안한 배관 누출판별 실험 결과는 Table 3과 Table 4에 나타나 있다. 본 논문에서는 정상상태의 음향 데이터만을 이용하여 딥 오토인코더를 학습하였고, 정상과 누출상태를 구분하는 임계치 T 를 정하는데 있어서는 정상 및 누출상태의 음향 데이터를 이용하였다. 임계치를 정할 때, 딥 오토인코더를 학습하는데 이용한 정상상태의 데이터 모두를 이용하였으며, Table 3에서는 누출상태의 음향신호 $\{H_i P_1\}_{i=1}^5$, $\{H_i P_5\}_{i=1}^5$, $\{H_i P_3\}_{i=1}^5$ 중에서 20%, 40%, 60%, 80%, 100%를 이용하였다.

Table 3의 결과에서와 같이, 본 논문에서 제안한 방법을 적용한 배관의 누출판별 정확도는 99.00%로 도출되었다. 이 수치는 5번의 실험을 통해 구한 정확도들의 평균값이다. 이는 [2]에서 제안한 지도학습 기반의 배관 누출판별 방법에 비하여 약 1% 낮은 수치이다. 하지만, 본 논문에서 제안한 방법은 별도의 복잡한 전처리 과정이 필요하지 않고, 정상상태의 데이터만을 이용한 비지도학습 기반의 방법이라는 점에서 실제 산업 현장 상황에 쉽게 적용 가능하다는 장점이 있다.

Table 3. Classification accuracy [%] for pipe leak detection

Method	Classification accuracy(%)
Existing method[2]	99.97
Proposed method	99.00

Table 4의 결과에서 관찰할 수 있는 것과 같이, 본 논문에서 고려한 배관 누출 음향 데이터를 이용한 실험에서는 임계치 T 를 정하는데 사용된 누출상태 데이터의 양과 분류 정확도는 크게 상관이 없다. 이는 오토인코더가 정상상태의 음향 데이터의 특징을 효과적으로 추출하도록 학습이 잘 되었음을 의미한다.

Table 4. Classification accuracy [%] versus the number of leak data to determine the threshold T

The number of leak data	Threshold (T)	Classification accuracy(%)
10 (0.033%)	0.01180	98.62
6,000 (20%)	0.01562	99.08
12,000 (40%)	0.01633	99.17
18,000 (60%)	0.01428	98.91
24,000 (80%)	0.01428	98.91
30,000 (100%)	0.01428	98.91

V. Conclusions

본 논문에서는 비지도학습 기반의 딥 오토인코더를 이용한 배관 누출탐지 방법에 대해 제안하였다. 음향 센서로부터 수집

된 시계열 음향 데이터를 이용하였으며, 정상상태의 음향 데이터만 이용하여 딥 오토인코더를 학습한 후 누출상태인지 정상상태인지 구분하였다. 또한, 본 논문에서는 임계치 T 값을 정하기 위하여 통계적인 방법 및 실험적인 방법을 이용하여 T 를 정하는 방법에 대해 제안하였다. 실험 결과에서는 기존의 지도학습 기반의 배관 누출판별 방법에 비해 약 1% 정도 성능은 떨어지지만, 제안한 방법을 이용하면 복잡한 전처리 과정 없이, 누출상태의 음향 데이터가 단 10개만 있어도 98.62%의 분류 정확도를 도출하는 것을 실험적으로 검증하였다.

본 연구에서는 누출상태와 정상상태를 구분하기 위하여 통계적인 방법을 이용하여 수동으로 임계치 T 값을 정하였다. 또한, T 보다 높은 결과값을 나타낼 경우에 누출이라 판단하고, T 보다 낮은 결과값을 나타낼 경우에 정상이라 판단하였다. 본 연구에서처럼 임계치를 이용하여 상태를 구분하는 접근 방법은 결과값의 선형이진 분류에만 적용 가능하다. 따라서, 향후에는 일반적인 분류를 위하여, 인코더에서 압축된 결과와 분류기 (Classifier)를 이용한 배관 누출판별에 대해 연구할 예정이다.

REFERENCES

- [1] D.-B. Yoon, S.-S. Moon, and B.-S. Yang, A Study on Acoustic Signal Processing Method for Detecting Small Leak of Piping System, Proceedings of the Domestic conference on the Korean Society for Noise and Vibration Engineering, pp. 139-139, Hoengseong, Korea, Oct. 2016.
- [2] J.-H. Bae, D. Yeo, D.-B. Yoon, S.W. Oh, G.J. Kim, N.S. Kim, and C.S. Pyo, Deep-Learning-Based Pipe Leak Detection Using Image-Based Leak Features, Proceedings of the IEEE International Conference on Image Processing (ICIP), pp. 2361-2365, Athens, Greece, Oct. 2018.
- [3] D.E. Rumelhart, G.E. Hinton, and R.J. Williams, "Parallel Distributed Processing. Vol. 1: Foundations," MIT Press, pp. 318-362, 1986.
- [4] F. Rosenblatt, "Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms," Spartan Books, 1961.
- [5] G. Cybenko, "Approximation by superpositions of a sigmoidal function," Mathematics of Control, Signals, and Systems, Vol. 2, No. 4, pp. 303-314, 1989.
- [6] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, Going Deeper with Convolutions, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1-9, Boston, USA, Jun. 2015.
- [7] K. Simonyan and A. Zisserman, Very Deep Convolutional

- Networks for Large-scale Image Recognition, Proceedings of 5th International Conference on Learning Representations (ICLR), pp. 1-14, San Diego, USA, May 2015.
- [8] K. He, X. Zhang, S. Ren, and J. Sun, Deep Residual Learning for Image Recognition, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1-12, Las Vegas, USA, Jun. 2016.
- [9] G. Huang, Z. Liu, L.V.D. Maaten, and K. Weinberger, Densely Connected Convolutional Networks, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 2261-2269, Hawaii, USA, Jul. 2017.
- [10] S. Hupchreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, Vol. 9, No. 8, pp. 1735-1780, 1997.
- [11] K. Cho, B. Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, "Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation," *arXiv preprint arXiv:1406.1078*, 2014.
- [12] A. Borghesi, A. Bartolini, M. Lombardi, M. Milano, and L. Benini, Anomaly detection using autoencoders in high performance computing systems, Proceedings of the AAAI Conference on Artificial Intelligence, Vol. 33, No. 01, pp. 9428-9433, Hawaii, USA, Jul. 2019.
- [13] T. Luo and S.G. Nagarajan, Distributed Anomaly Detection Using Autoencoder Neural Networks in WSN for IoT, Proceedings of 2018 IEEE International Conference on Communications (ICC), pp. 1-6, Kansas City, USA, May 2018.
- [14] J. Pereira and M. Silveira, Unsupervised Anomaly Detection in Energy Time Series Data using Variational Recurrent Autoencoders with Attention, Proceedings of 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA), pp. 1275-1282, Orlando, USA, Dec. 2018.
- [15] S. Ioffe and C. Szegedy, Batch normalization: accelerating deep network training by reducing internal covariant shift, Proceedings of 32nd International Conference on Machine Learning (ICML), pp. 1-9, Lille, France, Jul. 2015.

Authors



Doyeob Yeo received the B.S., M.S. and Ph.D. degrees in Mathematical Sciences from Korea Advanced Institute of Science and Technology (KAIST), Daejeon, Korea, in 2009, 2012 and 2017, respectively. Dr. Yeo joined Electronics and

Telecommunications Research Institute (ETRI), Daejeon, Korea in 2017. He is currently a Researcher in the Knowledge-converged Super Brain (KSB) Convergence Research Department of ETRI. He is interested in shape prior segmentation, deep learning and transfer learning.



Ji-Hoon Bae received the B.S. degree in electronic engineering from Kyungpook National University, Daegu, Korea, in 2000, and the M.S. and Ph.D. degrees in Electrical Engineering from Pohang University of Science and Technology (POSTECH),

Pohang, Gyeongsangbuk-do, Korea, in 2002 and 2016, respectively. From 2002 to 2019, Dr. Bae was with Electronics and Telecommunications Research Institute (ETRI), Daejeon, Korea, as a principal researcher. He joined the faculty of the Department of AI • Big Data Engineering, Daegu Catholic University, Gyeongsan-si, Gyeongbuk, Korea in 2019. He is interested in deep learning and transfer learning, radar imaging, and optimized techniques.



Jae-Cheol Lee received the B.S. and M.S. degrees in Electronic Engineering from Kyungpook, National University, Daegu, Korea, in 1986 and 1988, respectively. Mr. Lee joined Korea Atomic Energy Research Institute (KAERI), Daejeon, Korea in 1988.

He is currently a Researcher in the Robot laboratory of KAERI. He is interested in signal processing and neural nets application to robotics, diagnostic of mechanical structures, and its hardware realizing.