

## Pipe Leak Detection System using Wireless Acoustic Sensor Module and Deep Auto-Encoder

Doyeob Yeo\*, Giyoung Lee\*, Jae-Cheol Lee\*\*

\*Post-Doctorate Researcher, Electronics and Telecommunications Research Institute (ETRI), Daejeon, Korea

\*Senior Researcher, Electronics and Telecommunications Research Institute (ETRI), Daejeon, Korea

\*\*Principal Researcher, Korea Atomic Energy Research Institute (KAERI), Daejeon, Korea

### [Abstract]

In this paper, we propose a pipe leak detection system through data collection using low-power wireless acoustic sensor modules and data analysis using deep auto-encoder. Based on the Fourier transform, we propose a low-power wireless acoustic sensor module that reduces data traffic by reducing the amount of acoustic sensor data to about 1/800, and we design the system that is robust to noise generated in the audible frequency band using only 20kHz~100kHz frequency signals. In addition, the proposed system is designed using a deep auto-encoder to accurately detect pipe leaks even with a reduced amount of data. Numerical experiments show that the proposed pipe leak detection system has a high accuracy of 99.94% and Type-II error of 0% even in the environment where high frequency band noise is mixed.

▶ **Key words:** Wireless, Ultrasonic wave, Low-power, Deep auto-encoder, Pipe leak detection

### [요 약]

본 논문에서는 저전력 무선 음향센서 모듈을 통한 데이터 수집과 딥 오토인코더를 이용한 데이터 분석을 통해 배관의 누출을 탐지하는 시스템을 제안한다. 데이터 통신량을 줄이기 위해서 푸리에 변환을 통해 음향센서 데이터 양을 약 1/800로 감소시키는 저전력 무선 음향센서 모듈을 구성하였고, 20kHz~100kHz 주파수 신호를 이용하여 가청 주파수 대역에서 발생하는 노이즈에 강인한 누출 탐지 시스템을 설계하였다. 또한, 데이터 양의 감소에도 배관 누출을 정확하게 탐지하도록 딥 오토인코더를 이용한 데이터 분석 기법을 설계하였다. 수치적인 실험을 통해, 본 논문에서 제안한 누출 탐지 시스템이 고주파 대역대의 노이즈가 섞인 환경에서도 99.94%의 높은 정확도와 Type-II error 0%의 높은 성능을 보이는 것을 검증하였다.

▶ **주제어:** 무선, 초음파, 저전력, 딥 오토인코더, 배관 누출 탐지

- 
- First Author: Doyeob Yeo, Corresponding Author: Giyoung Lee
  - \*Doyeob Yeo (yeody@etri.re.kr), Electronics and Telecommunications Research Institute (ETRI)
  - \*Giyoung Lee (giyoung@etri.re.kr), Electronics and Telecommunications Research Institute (ETRI)
  - \*\*Jae-Cheol Lee (jcle2@kaeri.re.kr), Korea Atomic Energy Research Institute (KAERI)
  - Received: 2019. 12. 13, Revised: 2020. 01. 06, Accepted: 2020. 01. 17.

## I. Introduction

최근, 발전소 및 플랜트(Plant) 설비들의 노후화가 진행됨에 따라 배관 누출(Leakage) 사례들이 빈번히 발생하고 있다. 이러한 배관 누출은 안전사고 발생 시 인명사고를 야기할 수 있고, 경제적 손실 및 환경오염과 같은 문제들도 함께 발생시킬 수 있다. 따라서, 발전소 및 플랜트 설비의 안정적인 운영 및 사고 방지를 위하여 배관의 상시 누출 감시 및 진단 서비스 개발 요구가 증가하고 있다.

기존에는 유선 음향센서 혹은 유선 진동센서 등을 이용하여 수집된 미가공 데이터(Raw data)에 다양한 신호처리 기법들을 적용하여 배관의 누출을 탐지하는 방법이 제안되었다[1-3]. 하지만, 발전소와 플랜트의 배관 설비는 방대하여 누출 가능성이 높은 곡관 용접부와 이음새 부분이 많으며, 이러한 누출 가능 지점들을 상시 감시하기 위해서는 대량의 누출감지 센서를 활용해야 한다. 그런데, 방대하고 복잡한 배관 시스템에서 수천 개에 달하는 누출감지 센서를 유선 형태로 관리하는 것은 거의 불가능하므로, 무선 센서(Sensor)를 이용하는 것이 이상적이다. 또한, 무선 센서의 최대 취약점 중 하나가 배터리 교체 문제인 것을 감안할 때, 소모되는 전력을 최소화할 수 있는 저전력 센싱 기술개발이 요구된다. 저전력 센서 모듈 개발을 위해서는 모듈 내에서 발생하는 계산량을 줄이는 방법과 통신에 사용되는 데이터의 양을 줄이는 방법이 있다. 본 논문에서는 통신에 사용되는 데이터의 양을 줄이는 방법을 통해 저전력 센서 모듈을 개발하는 방법을 제안한다.

잡음이 없는 환경에서 수집된 센서 데이터의 경우에는 누출 상태 데이터인지, 정상 상태 데이터인지 육안으로도 구별이 가능하고, 자기상관함수(Auto-correlation), 상호상관함수(Cross-correlation function), 또는 푸리에 변환(Fourier transform) 등과 같은 간단한 신호처리를 통해 높은 정확도로 누출감지 모델을 만들 수 있다. 하지만, 발전소나 플랜트에서는 다양한 기계 잡음이 존재할 수 있기 때문에, 간단한 신호 처리 기술을 이용하여 정확한 누출감지 모델을 만들기는 한계가 있다.

최근, 다층신경망(Multi-layer perceptron: MLP)[4], 컨볼루션 뉴럴 네트워크(Convolutional neural network: CNN)[5-8], 순환신경망(Recurrent neuron network: RNN)[9], 강화학습(Reinforcement learning)[10, 11] 등 딥러닝(Deep learning) 기법들이 크게 발전함에 따라 산업 현장의 데이터를 이용하여 산업 현장에서 발생할 수 있는 문제를 풀고자 하는 노력이 많이 이루어지고 있다. 특히, 딥러닝 기법들을 이용하여 이상 감지(Anomaly detection) 문

제에 활용하고자 하는 연구들이 많이 이루어지고 있고 [12-15], 발전소나 플랜트 배관 누출감지 문제에 딥러닝 기법을 적용하여 해결하려는 연구들도 이루어지고 있다[1-3].

본 연구의 핵심은 두 가지이다. 하나는 저전력 무선 음향센서 모듈의 설계이고, 다른 하나는 딥 오토인코더(Deep auto-encoder)를 이용한 배관 누출 탐지 모델의 설계이다. 본 연구에서는, 저전력 무선 음향센서로부터 수집한 20kHz~100kHz 대역대의 주파수 신호를 딥러닝 기법으로 분석하여, 배관의 누출을 탐지하는 시스템을 제안한다.

본 논문의 구성은 다음과 같다. II장에서는 유선 음향센서 모듈에서 수집된 데이터를 이용한 기존의 배관 누출판별 기법 두 가지를 소개한다. 하나는 영상특징 추출과 지도학습 기반의 CNN을 적용한 방법이고, 다른 하나는 비지도학습 기반의 딥 오토인코더를 적용한 방법이다. III장에서는 본 연구에서 제안하는 저전력 무선 음향센서로부터 수집한 20kHz~100kHz 대역대의 주파수 신호를 이용한 딥러닝 기술 기반의 플랜트 배관 누출 탐지 기법들에 대해 소개한다. 마지막으로, IV장에서는 실제 저전력 무선 음향센서로부터 수집한 주파수 신호를 바탕으로 III에서 소개한 딥러닝 기술 기반의 플랜트 배관 누출 탐지 기법들의 성능에 대해 서술한다.

## II. Preliminaries

### 1. Related Works

기존의 딥러닝 기법을 이용한 배관 누출 탐지 연구들 [1-3]은 음향센서 모듈에 충분한 전력이 공급되는 상황을 가정하였고, 음향 시계열 데이터를 모두 수집 및 전송할 수 있는 상태를 가정하였다. 따라서, 수집된 데이터를 분석하는 데에 있어 많은 양의 정보를 이용할 수 있었으며, 배관 누출 탐지 기법을 설계하는데 있어 다양한 전처리 방법들을 활용할 수 있다.

#### 1.1 Pipe Leak Detection using Image-Based Feature Extraction

여러 딥러닝 기법 중에서 CNN 구조에 관한 연구가 가장 활발하게 진행되었고, GoogleNet[5], VGG[6], 잔여신경망(Residual network: ResNet)[7], 그리고 DenseNet[8] 등과 같이 다양한 CNN 구조들이 연구되었다. [2]에서는 음향 시계열 데이터를 전처리 과정을 통해 2차원의 영상 데이터로 변환한 다음, CNN 구조를 이용하여 배관 누출을 탐지하는 방법을 제안하였다. Fig. 1(a)의 root-mean-square(RMS)

패턴 영상을 이용한 변환과 Fig. 1(b)의 주파수 패턴 영상을 이용한 변환을 새롭게 정의하여 음향 시계열 데이터를 영상 데이터로 변환하는 방법을 제안하였다. Fig. 1은 [2]의 Fig. 7과 Fig. 8에 나타나 있다.

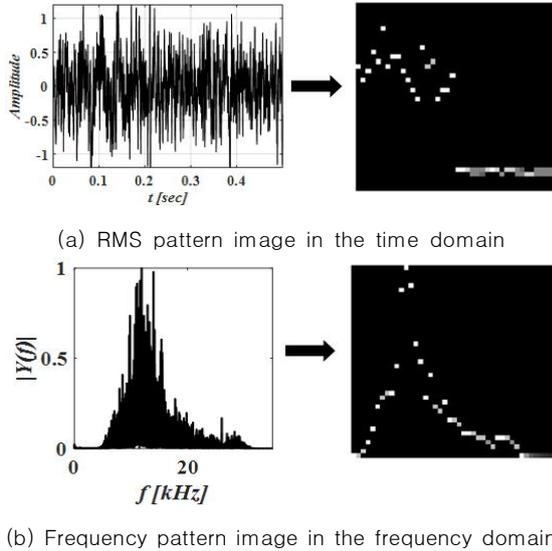


Fig. 1. Image feature extraction for pipe leak detection[2]

[2]에서는 Fig. 1과 같이 음향 시계열 데이터를 전처리한 다음, ResNet 구조의 딥러닝 네트워크를 이용하여 정상 상태인지 누출 상태인지 판별하는 방법을 제안하였다. 이 때, 정상 상태 데이터와 누출 상태 데이터를 모두 학습시켜 두 가지 상태를 판별하게 하는 지도학습 기반의 딥러닝 모델을 이용하였다. [2]에서 제안한 패턴 영상 변환을 이용하면, 기계적 잡음이 있는 환경에서도 99.97%의 분류 정확도를 얻을 수가 있다.

### 1.2 Pipe Leak Detection using Deep Auto-Encoder

실제 현장에서는 배관의 누출이 없는 정상 상태 데이터는 많이 얻을 수 있지만 누출이 있는 상태의 데이터를 확보하기 어려우므로, [3]에서는 비지도학습 기반의 딥 오토인코더를 이용한 배관 누출 탐지 기법에 대해 제안하였다. [3]에서는 [2]에서 사용되었던 음향센서 데이터와 동일한 데이터를 이용하였다.

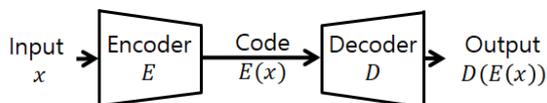


Fig. 2. Basic architecture of the auto-encoder[3]

Fig. 2는 [3]의 Fig. 2에 나타난 오토인코더 구조로, 일반적인 오토인코더는 Fig. 2와 같은 기본 구조를 가지고 있으며, 이상감지를 위한 구조로서 다양한 분야에서 연구되고 있다[3][13-15]. 오토인코더 중에서 인코더(Encoder)와 디코더(Decoder)에 딥 뉴럴네트워크(Dep-neural network) 구조를 이용한 것을 딥 오토인코더라 부르며, [3]에서는 MLP 구조 기반의 딥 오토인코더를 이용하였다. [3]에서 제안한 딥 오토인코더 기반의 배관 누출 탐지 방법을 이용하면, 간단한 전처리 기법과 10개의 누출 상태의 음향데이터만을 이용하여 98.62%의 분류 정확도를 도출한다는 것을 검증하였다.

### 1.3 International Standard for Pipe Leak Detection

배관 누출감지 센서 모듈 성능에 대한 국제 기준은 Table 1과 같다. 이 기준은 간헐적 검사에 사용되는 누출 진단 모듈에 대한 내용으로, 충분한 전력을 상시 공급받으며 누출감지를 수행하는 모듈에 대한 표준이다.

Table 1. International standard for pipe leak detection

Standard	Class	Condition	
ASTM E 1002-11 (USA) [16]	Class I	Orifice diameter	0.2mm
		Distance	10m
		Pressure difference	0.7atm
		Frequency	20kHz~100kHz
	Leak rate	0.024gpm	
	Class II	Distance: 5m Others: Same as Class I	
NDIS 3420:2000 (Japan) [17]		Orifice diameter	0.2mm
		Distance	50mm
		Pressure difference	0.1atm
		Frequency	20kHz~100kHz
		Leak rate	0.00156gpm

## III. The Proposed Scheme

본 장에서는 저전력 무선 음향센서 모듈과 딥러닝 기술을 이용한 배관 누출 탐지 시스템에 대하여 서술한다.

기존의 딥러닝 기술 기반의 배관 누출 탐지 기법에 관련된 연구들[1-3]은 전력이 상시 공급되는 상황을 가정하였기에, 데이터 양이 큰 미가공 음향센서 데이터를 그대로 전송할 수 있었다. 하지만, 본 연구에서 제안하는 저전력 무선 음향센서 모듈은 전송하는 데이터 양을 최소화하여 사용하는 전력을 줄인다. 또한, 기존 연구들[1-3]은 가청

주파수 대역대(20kHz 이하)의 음향 신호를 주로 사용하여 배관의 누출을 탐지하는 기법을 제안하였는데, 발전소와 플랜트에서는 가청 주파수 대역대에서 상당히 큰 잡음(Noise)이 발생하기 때문에 이를 이용하여 배관의 누출 신호를 판별하는 것은 매우 어려운 일이다. 따라서, 본 논문에서는 Table 2의 배관 누출 기법에 대한 국제 표준 규격에 따라 20kHz~100kHz 대역대의 신호를 이용하여 배관의 누출을 감지하는 기법을 제안한다.

본 논문에서는 이산 푸리에 변환을 이용하여 데이터 양을 줄이는 방법을 통해 센서 모듈을 설계하고, 이를 딥 오토인코더를 이용하여 분석하는 방법을 통해 배관 누출 탐지 시스템을 설계하였다.

### 1. Low-Power Wireless Acoustic Sensor Module

저전력 무선 센싱을 위해서는 저전력 음향센서를 사용함으로써 발생하는 음향 신호 센싱 능력 저하 문제와 무선 통신에 따른 전력소모 문제를 해결해야 한다. 본 논문에서는 신호 증폭을 이용하여 능력 저하 문제를 개선하고, 신호를 푸리에 변환의 스펙트럼으로 변환함으로써 이 신호의 특성을 최소량의 데이터로 표현하여 무선통신 데이터 양을 획기적으로 줄이고자 하였다.

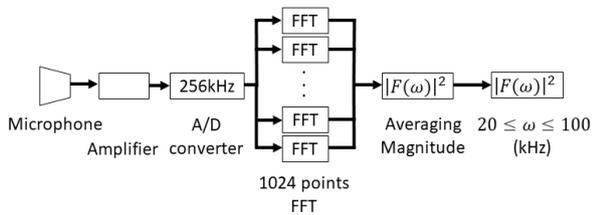


Fig. 3. A low-power acoustic sensor module

본 논문에서 음향 신호 수집에 사용된 저전력 센서 모듈은 Fig. 3과 같다. 우선, 마이크로폰(Microphone)으로부터 수집된 아날로그 음향 신호를 증폭한 다음, 아날로그-디지털 변환회로(A/D converter)를 통하여 디지털 신호로 변환한다. 이 때, 수집하는 초당 샘플수는 256kHz를 이용하였다. 샘플링된 디지털 신호는 1차원 이산 푸리에 변환(Discrete Fourier transform)을 통해 주파수 영역 데이터로 변환된다.

이산 함수  $f(x)$ ,  $x = 0, 1, 2, \dots, N-1$ 에 대한 1차원 이산 푸리에 변환은 수식 (1)과 같이 주어진다.

$$f(x) = \sum_{\omega=0}^{N-1} F(\omega) e^{j2\pi\omega x/N}, \quad x = 0, 1, \dots, N-1 \quad (1)$$

여기서  $F(\omega)$ 는 수식 (2)와 같이 주어진다.

$$F(\omega) = \sum_{x=0}^{N-1} \frac{f(x)}{N} e^{-j2\pi\omega x/N}, \quad \omega = 0, 1, \dots, N-1 \quad (2)$$

수식 (1)과 (2)에서  $j$ 는 허수(imaginary number) 단위를 나타내는 기호로,  $j = \sqrt{-1}$ 를 의미한다. 또한,  $e^{jx}$ 는 오일러 공식을 의미하며,  $e^{jx} = \cos x + j \sin x$ 로 정의된다.

본 논문에서는 256kHz의 초당 샘플수로 수집된 디지털 신호를 1/250초 단위로 나누어, 1024개의 샘플을 이용하여 1차원 이산 푸리에 변환을 적용하였다. 즉, 수식 (1)과 (2)에  $N = 1024$ 를 적용하였다. 그런 다음, 각각의  $F(\omega)$ 에 대한 크기를 구하여 16개의 구간 데이터들을 평균값을 취하였다.  $F(\omega)$ 의 크기인  $|F(\omega)|$ 는 푸리에 변환의 스펙트럼(Spectrum) 또는 크기(Magnitude)라고 부른다. 이 방법을 이용하면 0~128kHz의 주파수 대역대의 평균 스펙트럼 값을 0.25kHz(=256kHz/1,024) 간격으로 얻을 수 있는데, 본 논문에서는 [16, 17]의 표준 기준에 의거하여 가청 주파수 대역대의 정보와 고주파 대역대의 정보를 제외한 20kHz~100kHz 주파수 대역대의 평균 스펙트럼만을 출력하였다. 따라서, 최종적으로 Fig. 3의 저전력 음향 센서 모듈을 통해 얻어지는 데이터는 0.25kHz 간격의 20kHz~100kHz 주파수 대역대 푸리에 변환의 평균 스펙트럼 값으로, 총 320개이다.

추가적으로, 데이터의 용량을 줄이기 위하여 푸리에 변환의 평균 스펙트럼 값을 하나의 주파수 당 4bytes 용량으로 초당 한 번씩 전송하는 방식을 택하였다. 결과적으로, 음향센서 모듈 하나당 전송되는 데이터의 양은 초당  $320 \times 4 = 1,280$  bytes가 된다.

256kHz로 샘플링하여 정제하지 않고, 16진수로 변환하여 전송한다면, 데이터의 양은 초당  $256,000 \times 4$  bytes = 1,000kbytes가 된다. 따라서, 본 논문에서 제안한 음향센서 모듈을 이용하면, 데이터를 정제하지 않고 전송하는 것에 비하여 전송되는 데이터의 양을 1/800로 감소시킬 수 있다.

### 2. Pipe Leak Detection Model using Deep Auto-Encoder

III. 1의 저전력 음향센서 모듈을 통해 한 번에 얻어지는 신호  $x$ 는  $x \in \mathbb{R}^{320}$ 인 벡터(Vector)이다. 여기서  $\mathbb{R}$ 은 실수 집합을 의미한다. 따라서, 본 논문에서는 데이터를 분석하는데 있어 딥러닝 구조 중 벡터 데이터를 분석하는데 가장 일반적으로 사용되는 MLP 구조를 이용하였다.

본 절에서는 MLP 구조를 이용한 딥 오토인코더를 통해

푸리에 변환의 스펙트럼 데이터로부터 정상 상태 데이터의 패턴을 학습하여 정상 상태와 누출 상태를 구분하는데 이용하고자 한다.

## 2.1 Architecture of Deep Auto-Encoder

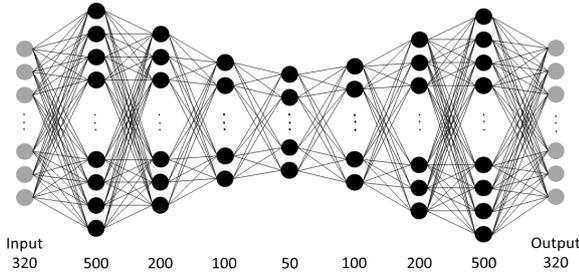


Fig. 4. Architecture of deep auto-encoder for pipe leak detection using data from low-power acoustic sensors

본 절에서 제안하는 딥 오토인코더의 기본 구조는 Fig. 2와 같고, 딥 오토인코더의 상세 구조는 Fig. 4와 같다. 딥 오토인코더의 인코더는 총 4층의 은닉층(Hidden layer)을 갖도록 설계되었으며, 디코더는 인코더 구조의 역으로 설계되었다. 인코더층과 디코더층은 Fig. 4에서 검정색 동그라미로 표시되어 있다. 입력층(Input layer)과 출력층(Output layer)은 Fig. 4에 회색 동그라미로 표시되어 있으며, 왼쪽에 나타나 있는 것이 입력층, 오른쪽에 나타나 있는 것이 출력층이다. III. 1의 저전력 음향센서 모듈을 통해 전달되는 신호  $x$ 가 입력층의 입력으로 사용되기 때문에 입력층의 노드(Node)는 320개로 구성된다. 또한, 신호  $x$ 가 딥 오토인코더를 거쳐 최종적으로 출력되는 값과 입력 신호  $x$ 의 직접적인 비교를 위하여 출력층의 노드 수는 입력층의 노드 수와 같게 구성된다. 최종적으로, 딥 오토인코더의 노드 수는 {320(입력), 500, 200, 100, 50, 50, 100, 200, 500, 320(출력)}으로 구성된다.

또한, MLP 구조에서 비선형성(Non-linearity)을 부여하기 위하여, 각각의 은닉층에서 ReLU(Rectified Linear Units) 함수를 활성화 함수(Activation function)로 이용하였다.

## 2.2 Pipe Leak Detection Model using Deep Auto-Encoder

딥 오토인코더를 통한 정상 및 누출 상태를 구분하는 모델은 다음과 같이 구성된다. 먼저, 정상 상태 데이터만을 이용하여 딥 오토인코더를 학습시킨다. 이 때, 학습 기법은 레이블(Label) 정보 없이 학습이 진행되는 비지도학습이다.

딥 오토인코더가 정상적으로 학습이 되었다면, 학습된

딥 오토인코더는 정상 상태 데이터에 대한 패턴을 학습하여, 정상 상태 데이터와 비슷하게 복원된 값을 출력한다. 따라서, 학습된 딥 오토인코더의 입력값으로 정상 상태 데이터를 주는 경우, 출력값은 입력값과 유사하다. 하지만, 누출 상태 데이터는 딥 오토인코더가 학습하지 않은 데이터이기 때문에, 누출 상태 데이터를 입력값으로 주는 경우, 출력값은 입력값과 차이가 나게 된다.

따라서, 정상 상태 데이터를 이용하여 학습된 딥 오토인코더는 다음과 같이 배관의 누출 탐지 모델로 사용된다.

$$l(x) = \|x - D(E(x))\|_2 \quad (3)$$

식 (3)에서  $E$ 와  $D$ 는 각각 인코더와 디코더를 의미하며,  $x$ 는 입력 데이터를 의미한다. 어떤 입력  $x$ 에 대하여 식 (3)의 값이 임계치  $T$ (Threshold) 보다 작으면  $x$ 는 정상 상태 데이터, 임계치  $T$ 보다 크면  $x$ 는 누출 상태 데이터라 판단한다. 본 논문에서 임계치  $T$ 는 실험적으로 결정하였다.

## IV. Experimental Results

본 연구에서는 충분한 전력을 사용할 수 없는 저전력 음향센서를 통한 저전력 무선 센싱 상황을 가정하였으므로, Table 1의 국제 기준보다 다소 완화된 환경을 고려한다. 본장에서 진행된 실험에서는 3m 거리에서 1기압 압력 차로 0.1mm 직경의 누출 구멍에서 발생하는 누출 음향을 저전력 음향센서로 수집한 데이터를 이용하였다. 또한, 고주파 대역대의 잡음을 인위적으로 추가하여 데이터를 생성하였다.

### 1. Data from a Low-Power Wireless Acoustic Sensor

III. 1에서 기술한 저전력 센서 모듈을 통하여 수집되는 음향 신호의 푸리에 변환의 평균 스펙트럼 데이터는 Fig. 5와 같다. Fig. 5에서 검정색 실선은 누출 상태 데이터의 스펙트럼, 회색 점선은 정상 상태 데이터의 스펙트럼을 나타낸다. 또한, Fig. 5(a)는 인위적으로 발생시킨 잡음이 없는 환경에서 수집한 데이터이고, Fig. 5(b)는 인위적으로 고주파 대역대의 잡음을 발생시킨 환경에서 수집한 데이터이다.

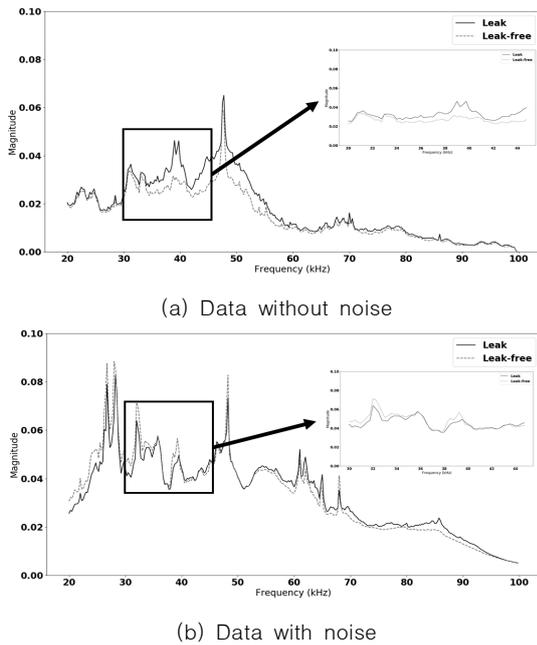


Fig. 5. Data from low-power acoustic sensor modules

[18]의 실험 결과에서 볼 수 있듯이 정상 상태와 누출 상태의 푸리에 변환의 스펙트럼 값의 차이는 약 40kHz 대역대에서 가장 크게 나타난다. Fig. 5(a)를 관찰해보면, 약 40kHz 대역대에서 누출 상태 데이터의 스펙트럼이 정상 상태 스펙트럼과 차이가 큰 것을 볼 수 있다. 따라서, Fig. 5(a)에서의 결과는 본 논문의 저전력 센서 모듈이 정상적으로 동작한다는 것을 실험적으로 검증한다.

## 2. Pipe Leak Detection Results using Deep Auto-Encoder

[18]과 같은 실험 결과로부터, 대부분의 배관 누출 탐지 장비들은 40kHz 근방의 주파수 신호를 누출 탐지에 이용한다. 하지만, Fig. 5(b)에서처럼 고주파 대역대의 잡음이 섞이게 되는 경우, 40kHz 근방의 주파수 대역에서 정상 상태 데이터의 스펙트럼이 누출 상태 데이터의 스펙트럼보다 더 크게 나타나는 것을 확인할 수 있다. 이 때문에 기존의 배관 누출감지 방법들은 누출 상태를 정확히 판단하지 못하게 된다. 따라서, 본 절에서는 저전력 음향센서를 통해 수집된 데이터를 딥 오토인코더를 이용하여 분석한 결과에 대해 기술한다.

### 2.1 Classification Results using Deep Auto-Encoder

오토인코더 기반의 분류문제를 풀기 위하여, 정상 상태 데이터 10,757개만을 오토인코더 학습에 이용하였다. 또한, 검증을 위해 정상 상태 데이터 2,656개, 누출 상태 데이터 2,464개를 사용하였다. 오토인코더를 학습한 다음, 정상 상태와 누출 상태를 구별하기 위한 수식 (3)의 임계치값은 0.02로 설정하였다. 오토인코더를 이용한 배관 누

출 탐지 모델의 정확도는 99.94%로 나타나며, Confusion matrix는 Table 2와 같다.

Table 2. Confusion matrix for pipe leak detection using proposed deep auto-encoder

		Predicted	
		Normal	Leak
Actual	Normal	2653	3
	Leak	0	2464

미가공 음향센서 데이터를 이용한 배관 누출 탐지 모델의 방법들에서, [2]의 경우 99.97%의 분류 정확도, [3]의 경우 최대 99.17%의 분류 정확도가 나왔던 실험 결과들과 비교하였을 때 성능이 저하되지 않는 것을 확인할 수 있다. 미가공 음향센서 데이터를 사용한 데 비해 데이터의 양은 1/800 감소하였으나, [2]에 비해 단지 0.03%p의 성능 저하만 관찰되었고, [3]에 비해서는 오히려 성능이 향상된 것을 관찰할 수 있다.

또한, Table 2에서 볼 수 있듯이 실제로 누출 상태일 때 정상 상태로 판단한 경우는 없음을 볼 수 있다. 이러한 에러(Error)를 Type II Error라고 하며, 배관의 누출 탐지 모델 설계 시, 정확도가 높은 모델을 만드는 것도 중요하지만, Type II Error를 0%로 만드는 것 또한 매우 중요하다. 이러한 사실로부터 본 논문에서 제안한 딥 오토인코더를 이용한 배관 누출 탐지 모델은 정확도와 Type II Error 두 가지 측면에서 모두 성능이 좋은 모델이라 판단된다.

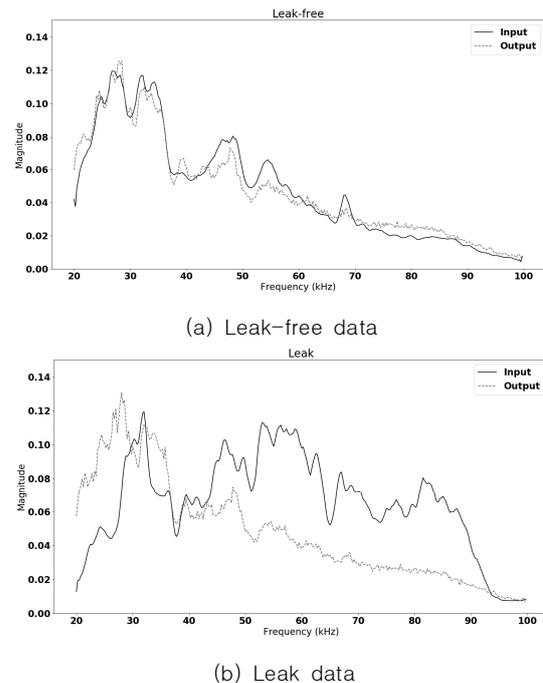


Fig. 6. Reconstruction results of proposed deep auto-encoder model

Fig. 6은 딥 오토인코더의 입력과 출력 데이터를 나타낸 것이다. 검정색 실선은 입력, 회색 점선은 출력 데이터를 나타낸다. 또한, Fig. 6(a)는 정상 상태 데이터를 입력으로 사용한 결과이고, Fig. 6(b)는 누출 상태 데이터를 입력으로 사용한 결과이다. 학습한 딥 오토인코더가 정상 상태 데이터의 특징 및 패턴을 잘 학습하여 복원한 반면, 누출 상태 데이터는 제대로 복원하지 않음을 확인할 수 있다.

본 논문에서 제안한 배관 누출 탐지 모델은 딥 오토인코더를 이용한 비지도학습 방법이므로, 정상 상태의 데이터만으로도 모델을 학습하여 누출 상태를 찾아낼 수 있다. 따라서, 현장에서는 누출 상태 데이터 확보에 어려움이 있다는 점을 감안할 때, [2]에서 제안한 누출 탐지 모델보다 본 논문에서 제안한 모델이 현장 적용에 유리하다.

## 2.2 Comparison Results with Pipe Leak Detection Model using MLP

본 논문에서 설계한 딥 오토인코더 기반의 배관 누출 탐지 모델의 성능을 검증하기 위하여, 지도학습 기반의 MLP 구조를 통한 배관 누출 탐지 모델과 비교하였다. MLP 구조는 Fig. 4에서의 인코더 구조와 동일한 구조를 사용하였으며, 출력층은 정상 및 누출 상태, 두 가지 범주(Category)를 구분하기 위하여 2개의 노드로 구성하였다.

학습에 사용된 데이터 수는 정상 상태 데이터 10,757개와 누출 상태 데이터 20,812개이며, 검증을 위한 데이터는 IV.2.1과 동일한 데이터를 이용하였다. 학습에 사용된 두 범주의 데이터 개수가 많이 차이 나기 때문에, 학습을 위한 배치(Batch)를 구성할 때, 샘플링 확률을 조정하여 정상 상태 데이터와 누출 상태 데이터의 비율을 같게 만들었다. 이를 이용한 배관 누출 탐지 모델의 정확도는 Table 3과 같다.

Table 3. Classification Accuracies (%) for pipe leak detection using MLP

Tri	1	2	3	4	5	Ave.
Acc. (%)	96.41	96.57	96.53	96.41	96.31	96.45

MLP를 이용한 배관 누출 탐지 모델의 정확도는 평균 96.45%로, 본 논문에서 제안한 딥 오토인코더를 이용한 배관 누출 탐지 모델의 성능에 비하여 3%p 가까이 성능이 저하되는 것을 볼 수 있다. 이는 정제되지 않은 음향 신호가 저전력 음향센서 모듈을 통해 푸리에 변환의 스펙트럼 값으로 변환이 되면서 상당히 많은 양의 정보를 잃었기 때문이라 판단된다.

## V. Conclusions

본 논문에서는 무선 저전력 음향센서 모듈과 딥 오토인코더를 이용한 배관 누출 탐지 시스템에 대해 제안하였다. 저전력 음향센서로부터 수집되는 아날로그 신호를 증폭하고, 20kHz~100kHz 사이의 푸리에 변환의 스펙트럼 데이터 320개로 변환하는 방식을 통해, 실제 전송하는 데이터의 양을 1/800로 줄일 수 있었다. 딥 오토인코더는 정상 상태 데이터만을 이용하여 학습한 후, 실험적으로 결정된 임계치값을 통해 정상 상태인지 누출 상태인지 구분하도록 설계하였다. 본 논문에서 설계한 딥 오토인코더를 이용하면 데이터의 양이 감소함에 따라 많은 양의 정보를 잃는 상황임에도 불구하고, 정확도 99.94%, Type II Error가 0%인 배관 누출 탐지 모델을 만들어낼 수 있음을 실험적으로 확인하였다.

## ACKNOWLEDGEMENT

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

## 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. Yeo, J.-H. Bae, and J.-C. Lee, "Unsupervised Learning-Based Pipe Leak Detection using Deep Auto-Encoder," Journal of The Korea Society of Computer and Information, Vol. 24, No. 9, pp. 21-27, September 2019. <https://doi.org/10.9708/jksoci.2019.24.09.021>
- [4] G. Cybenko, "Approximation by superpositions of a sigmoidal function," Mathematics of Control, Signals, and Systems, Vol. 2, No. 4, pp. 303-314, 1989. <https://doi.org/10.1007/BF02551274>
- [5] 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.
- [6] 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.
- [7] 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.
- [8] 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.
- [9] S. Hupchreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, Vol. 9, No. 8, pp. 1735-1780, 1997. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [10] V. Mnih, K. Kavukcuoglu, D. Silver, A. Graves, I. Antonoglou, D. Wierstra, and M. Riedmiller, "Playing atari with deep reinforcement learning," arXiv preprint arXiv:1312.5602, 2013.
- [11] V. Mnih, A. P. Badia, M. Mirza, A. Graves, T. P. Lillicrap, T. Harley, and K. Kavukcuoglu, "Asynchronous Methods for Deep Reinforcement Learning," arXiv preprint arXiv:1602.01783, 2016.
- [12] R. Chalapathy and S. Chawla, "Deep Learning for Anomaly Detection: A survey," arXiv preprint arXiv:1901:03407, 2019.
- [13] 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.
- [14] 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.
- [15] 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.
- [16] ASTM E1002-11(2018), "Standard Practice for Leaks Using Ultrasonics," American Society for Testing and Materials (ASTM) International, West Conshohocken, PA, 2018, <https://doi.org/10.1520/E1002-11R18>, [www.astm.org](http://www.astm.org).
- [17] NDIS 3420-2000: "Methods for Leak Test using Ultrasonics," Non-Destructive Inspection Society.
- [18] Y. Pei, The gas leak locating detection based on the improved ultrasonic transducer array group, Proceedings of the International

Conference on Machinery, Materials Science and Engineering Application (MMSE), pp. 251-255, Wuhan, China, June, 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 Post-Doctorate 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.



Giyoung Lee received the B.S., M.S. and ph.D. degrees in Electronic Engineering from Kyungpook National University, Daegu, Korea, in 2008, 2013, and 2017, respectively. Dr. Lee joined Electronics and Telecommunications

Research Institute (ETRI), Daejeon, Korea in 2017. She is currently a Senior Researcher in the Knowledge-converged Super Brain (KSB) Convergence Research Department of ETRI. She is interested in artificial intelligence, machine learning, neural networks, deep learning and image processing.



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 Principal 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.