

# 모듈레이션 기법을 이용한 잡음에 강인한 선로 전환기의 이상 상황 탐지

(Noise-Robust Anomaly Detection of Railway Point Machine using Modulation Technique)

이종욱\*, 김아용\*\*, 박대희\*, 정용화\*

Jonguk Lee\*, A-Yong Kim\*\*, Daihee Park\*, and Yongwha Chung\*

## 요약

열차의 방향을 기존 방향에서 다른 방향으로 이동시키기 위한 변환 장치인 선로 전환기의 고장은 열차의 탈선 등을 유발시킬 수 있다. 따라서 열차운행의 안전 측면에서 해당 장비에 대한 모니터링은 필수 요소이다. 본 논문에서는 선로 전환기의 구동 시 발생하는 소리 정보를 기반으로 잡음에도 강인한 선로 전환기의 이상 상황 탐지시스템을 제안한다. 먼저 제안한 시스템은 소리 센서에서 실시간으로 취득하는 소리 신호에 STFT(Short-Time Fourier Transform)를 적용하여 스펙트로그램을 취득한다. 실제 환경에서 발생하는 잡음의 영향에도 강인한 성능을 보장하기 위하여, 해당 스펙트로그램에 대한 전처리 과정을 수행 후 모듈화 한다. 각각의 모듈에서 평균값과 표준편차를 계산 및 조합하여 특징 벡터로 생성한 후 이진 분류에 뛰어난 성능이 확인된 SVM(Support Vector Machine)에 적용하여 이상 상황을 탐지한다. 실제 선로 전환기의 전환 시 발생하는 소리 데이터를 이용하여 모의실험을 수행한 결과, 제안한 시스템은 잡음이 발생하는 상황에서도 효과적으로 이상 상황을 탐지함을 확인하였다.

■ 중심어 : 선로 전환기; 이상 상황 탐지; 모듈레이션; support vector machine;

## Abstract

The railway point machine is an especially important component that changes the traveling direction of a train. Failure of the point machine may cause a serious railway accident. Therefore, early detection of failures is important for the management of railway condition monitoring systems. In this paper, we propose a noise-robust anomaly detection method in railway condition monitoring systems using sound data. First, we extract feature vectors from the spectrogram image of sound signals and convert it into modulation feature to ensure robust performance, and lastly, use the support vector machine (SVM) as an early anomaly detector of railway point machines. By the experimental results, we confirmed that the proposed method could detect the anomaly conditions of railway point machines with acceptable accuracy even under noisy conditions.

■ keywords : railway point machine; anomaly detection; modulation; support vector machine;

## I. 서론

열차의 안전과 신뢰성을 위해서는 철로의 설비 및 시스템들에 대한 지속적인 모니터링 및 이상 상황에 대한 빠른 탐지가 매우 중요하다. 특히, 열차를 한 궤도에서 다른 궤도로 이동시키기 위하여 철도에 설치한 선로 전환기(그림 1 참조)의 이상 상황은 열차의 탈선을 불러 일으켜 심각한 사고를 유발시킬 수 있는 설비이기 때문에 선로 전환기와 관련된 고장 등의 비정상 상황에 대한 조기 탐지는 매우 중요한 문제이다[1-2].

외부 환경에 노출되어 작동하는 선로 전환기의 특성 상, 선로

전환기의 부품들은 외부적인 요소에 의해 이상 상황들이 발생하게 된다. 예를 들면, 선로 전환기의 나사가 풀린다거나 기본 레일(stock rail)과 스위치 블레이드(switch blade) 사이에 자갈 또는 계절적 특성으로 인한 얼음이 끼어 있게 되면 선로 전환기의 작동에 큰 무리가 가게 되며 열차 탈선과 같은 심각한 사고가 발생할 수도 있다. 또한, 최근 10년간의 철도 사고를 살펴보면 선로 전환기의 장애는 전체 철도 신호장치장애의 27%를 차지하며, 철도 시스템의 운영 및 유지보수 측면에서 가장 많은 노동시간을 소모하는 설비로 분류 된다[3-4]. 따라서 선로 전환기의 고장이 발생한 이후 근로자들의 수작업에 의해 처리되는 현재의 수동적인 철도 유지보수 처리 프로세스에서 벗어

\* 정회원, 고려대학교 컴퓨터융합소프트웨어학과

\*\* 정회원, (주)세화 부설연구소 연구개발팀

본 연구는 2015년도 중소기업청 기술혁신개발사업 혁신형기업과제(S2312692)의 지원을 받아 수행된 연구결과임.

접수일자 : 2017년 06월 09일

수정일자 : 2017년 09월 19일

게재확정일 : 2017년 11월 16일

교신저자 : 박대희 e-mail : dhpark@korea.ac.kr

나 실시간으로 선로 전환기의 이상 상황을 탐지하는 지능형 컴퓨터 시스템으로의 전환이 필요하다.

선로 전환기에 관한 최근의 학술적 연구들은 대부분 선로 전환기의 모터를 동작시키기 위해 입력되는 전기적 신호를 단순한 임계값 수치로 판단하거나 혹은 이상 상황 탐지를 분류의 문제로 해석하여 기계학습기반의 분류기로 문제를 해결하고 있음을 알 수 있다. 반면, Lee 등[1]은 선로 전환기가 실제 구동 시 발생하는 소리 정보를 이용하여 선로 전환기의 이상 상황을 탐지 및 분류하는 연구결과를 최근 발표하였다. 이는 전기적 신호를 주요 입력으로 하는 선로 전환기의 현재까지의 연구영역에서 소리분석 기반의 연구가 독립적으로 혹은 전기적 신호 시스템에 보조적 역할을 담당할 수 있다는 가능성을 보여준 최초의 연구결과이다. 하지만 해당 연구에서는 실제 선로 전환기가 설치되었을 때 주변에서 발생하는 잡음 등의 영향력은 고려하지 않았다.

본 논문에서는 선로 전환기의 이상 상황을 소리를 기반으로 탐지하는 새로운 방안을 제안하고자 한다. 특히, 잡음의 영향에도 안정적인 성능을 보장하기 위하여, 잡음의 영향력을 감소시키는 모듈레이션(modulation)[5] 기반의 비정상상황 탐지 시스템을 제안한다. 제안하는 시스템은 먼저 소리 센서(마이크로폰)에서 실시간으로 취득되는 소리 정보로부터 STFT를 수행하여 스펙트로그램(spectrogram)을 얻는다. 둘째, 스펙트로그램의 크기 정보를 재조정 및 z-score 변환 방법을 이용하여 스펙트로그램에 대한 표준화를 수행한다. 셋째, 전처리가 수행된 스펙트로그램을 일정 크기의 모듈로 나눈 후, 각각의 모듈에서 평균값과 표준편차를 계산하고 이를 조합하여 특징 벡터를 생성한다. 마지막으로, 이진 분류 문제에 뛰어난 성능을 보이는 SVM을 이용하여 잡음에도 강인한 이상 상황 탐지 성능을 확인한다.

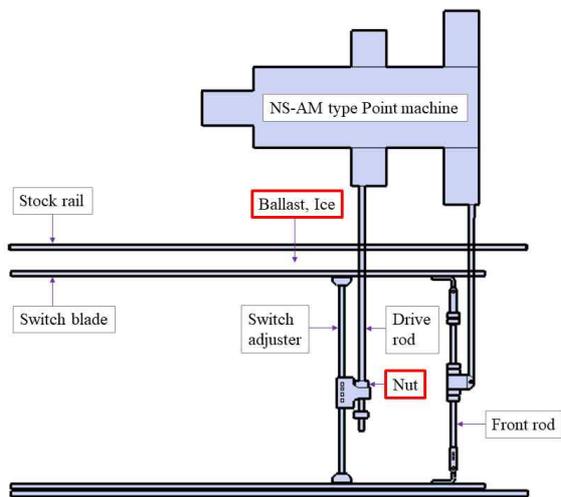


그림 1. NS-AM 형 선로 전환기의 구성 요소

본 논문의 구성은 다음과 같다. 2장에서는 선로 전환기와 관련한 최근의 연구 동향을 간략하게 소개하고, 3장에서는 본 연구에서 제안하는 잡음 환경에도 강인한 소리 기반 선로 전환기의 이상 상황 탐지 시스템에 대해 상세히 기술한다. 4장에서는 실험 결과 및 성능 분석을, 마지막으로 5장에서는 결론 및 향후 연구과제에 대해 논한다.

## II. 관련 연구

선로 전환기와 관련한 최근의 학술적 연구들을 살펴보면, 선로 전환기의 이상 상황을 빠르게 탐지 또는 대처하기 위한 다양한 연구들이 선진국을 중심으로 보고되고 있다[6-10]. Vileiniskis 등[6]은 선로 전환기를 구동시키는 모터에 입력되는 전류(current)값의 변화를 이용하여, 미리 설정해 둔 정상 상황의 전류 값(임계값: threshold)을 초과하게 되면 비정상 상황으로 탐지하였으며, Asada 등[7-8]은 선로 전환기로 유입되는 전류와 전압(voltage)을 이용하여 선로 전환기의 상태를 모니터링 하는 시스템을 제안하였다. Kim 등[9]은 정상시의 전류 값과 이상 상황 시의 전류 정보를 DTW(dynamic time warping) 방법에 적용하여 선로 전환기의 이상 상황을 탐지할 수 있음을 실험적으로 확인하였다. 또한 Eker 등[10]은 모터 전류측정 센서 등을 이용하여 취득한 특징 정보들을 PCA(principal components analysis)와 SVM을 이용하여 전철 막대(drive rod)가 비정상적으로 작동하는 상태인 불일치(out-of adjustment) 상태 여부를 탐지하였다. 반면, Lee 등[1]은 선로 전환기가 실제 구동 시 발생하는 소리 정보를 대상으로, MFCC(mel-frequency cepstrum coefficients)특징 벡터를 추출하고 SVM을 이용하여 선로 전환기의 이상 상황을 탐지 및 분류하는 연구결과를 최근 발표하였다.

한편, 소리 연구 분야에서 대표적으로 가장 많이 사용하는 MFCC를 이용한 특징 정보가 잡음이 상대적으로 적은 실험실 환경이 아닌 다양한 잡음들이 존재하는 실제 환경에서 시스템 성능저하의 주요 원인이라는 다수의 학술적 연구들이 보고되었다. 예를 들면, Sharan 등[5]은 전통적인 MFCC 특징 정보가 실생활의 잡음 환경에서 상대적으로 취약한 성능을 보이는 문제점을 지적하면서, 소리 시그널의 스펙트로그램 이미지로부터 특징벡터를 추출하는 새로운 기법을 제안하였다. Hsiesh 등[11]은 잡음 환경에서도 강인한 음성인식을 수행하기 위하여 스펙트로그램 기반의 특징을 이용하는 것이 MFCC 기반의 특징을 이용하는 것보다 상대적으로 성능이 좋음을 실험적으로 확인하였다. Khunarsal 등[12]은 외부의 위험상황을 탐지하기 위하여 스펙트로그램 기반의 특징을 신경망 및 k-NN(k-nearest neighbor) 분류기에 적용하여 다양한 상황의 소리들을 분류하였으며, 해당 논문에서도 MFCC특징 보다는 스펙트로그램 기

반의 특징이 잡음의 영향에 보다 강인함을 보고하였다. 또한 Schröder 등[13]은 음향 이벤트를 탐지하기 위하여, GFB(gabor filterbank)라는 특징을 제안하였으며, 잡음 상황에서 MFCC 특징 정보 보다 약 26%의 성능이 향상되었음을 발표하였다.

### III. 소리 기반 선로 전환기의 이상 상황 탐지 시스템

본 논문에서 제안하는 잡음에 강인한 선로 전환기의 이상 상황 탐지 시스템의 구조는 그림 2와 같으며 크게 3개의 모듈로 구성된다: 1) 센서로부터 소리를 취득하는 소리 수집 모듈(sound acquisition module), 2) 취득한 소리 데이터에서 특징 벡터를 추출하는 특징 추출 모듈(feature extraction module), 3) 미리 훈련된 SVM을 기반으로 이상 상황을 탐지하는 선로 전환기의 이상 상황 탐지 모듈(anomaly detection module).

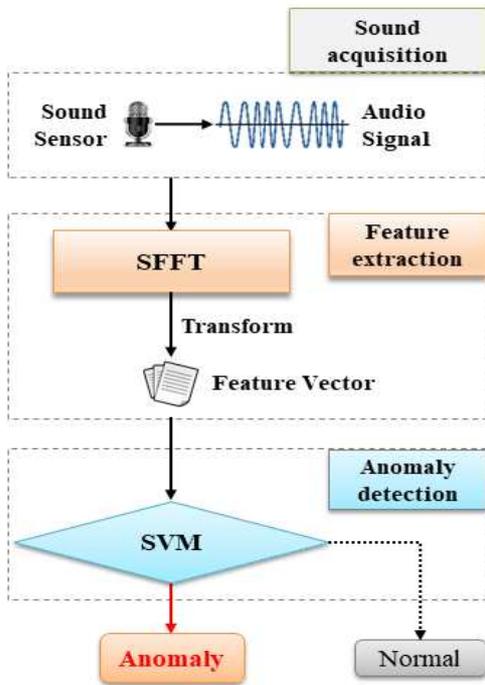


그림 2. 선로 전환기의 이상 상황 탐지시스템

#### 1. 소리 수집 모듈

소리 기반 선로 전환기의 이상 상황을 탐지하기 위해서는 가장 먼저 선로 전환기의 동작 시 발생하는 소리 신호를 소리 센서(마이크로폰)로부터 수집한다.

#### 2. 특징 추출 모듈

본 연구에서 사용하는 소리 특징은 Sharan 등[5]이 제안한 특징 벡터 추출 방법을 차용하였다. Sharan 등은 소리 신호에서 추출한 스펙트로그램 특징을 모듈화한 소리 특징 벡터와 ZCR(zero-crossing rate), STE(short-time energy), SBE(sub-band energy)를 모듈화 특징에 추가한 특징 벡터를 사용하였다. 제안한 두 가지 소리 특징 벡터 모두, 전통적인 소리 특징인 MFCC와 비교하여 잡음 상황에서도 강인한 소리 식별 능력이 있음을 실험적으로 검증하였다[5]. 본 연구에서는 스펙트로그램 정보를 모듈레이션한 특징 벡터를 사용하고자 한다.

다음은 소리 신호로부터 모듈레이션 특징을 추출하는 방법에 대한 설명이다. 소리 센서에서 실시간으로 취득되는 소리 신호로부터 첫째, 소리 신호를 STFT를 이용하여 스펙트로그램 반 주파수 영역의 그레이스케일( grayscale)의 스펙트로그램 특징정보를 추출한다. 둘째, 해당 2차원의 스펙트로그램 정보를 일정한 모듈(module) 또는 블록(block)으로 분할한다(그림 3.a 참조). 셋째,  $n \times n$  크기의 모듈들로 분할된 2차원 스펙트로그램의 개별 모듈에서 평균( $\mu$ )과 표준편차( $\sigma$ )를 계산한다(그림 3.b 참조). 마지막으로, 해당 모듈들의 평균과 표준편차들을 조합하여 특징 벡터를 생성한다(그림 3.c 참조).

실제, 특징 벡터 추출 단계를 보다 자세하게 설명하자면 다음과 같다(그림 4 참조). 먼저 소리 신호에서 STFT를 이용하여 각 프레임에 따른 주파수 에너지 정보인 스펙트로그램을 얻는다. 소리 길이에 따라서 크기가 달라지는 스펙트로그램 정보를 일정한 크기로 표준화하기 위하여, 스펙트로그램의 크기를 재조정(resize) 한 후, 잡음에 강인한 특징을 생성하기 위하여 특징 값을 추출한다. 마지막으로, z-score 표준화를 수행하여 최종 특징 벡터를 생성한다.

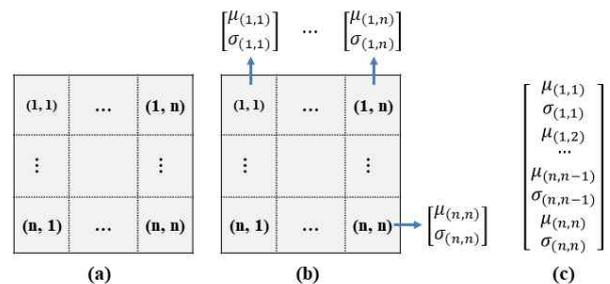


그림 3. 모듈레이션 기법

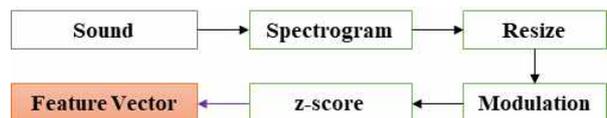


그림 4. 특징 벡터 추출 과정

### 3. 이상 상황 탐지 모듈

이상 상황 탐지 모듈에서는 선로 전환기의 이상 상황 탐지를 위해 미리 훈련을 마친 SVM을 기반으로, 실시간으로 유입되는 소리 신호의 이상 상황 여부를 탐지한다. 이진 분류 문제에서 최근 많이 활용되는 SVM은 구조적 위험 최소화 개념에 기반을 둔 최적의 선형 결정 평면을 찾음으로써 두 개의 클래스를 분류하는 방법이다[14-16]. 이때 결정 평면은 학습 원소들의 가중화된 조합이며, 이러한 학습 원소들을 서포트 벡터(support vector)라 부르며 이들은 두 클래스간의 경계면에 존재한다. 예를 들면, 선형 분리가 가능한 데이터를 가정할 때 최대 여백 분류의 목표는 서포트 벡터들의 거리가 최대화되는 초평면(hyperplane)에 의해 두 개의 클래스를 분리하는 것이다. 이러한 초평면은 최적 경계 초평면(optimal separating hyperplane)이라고 불리며, 2차 프로그래밍(quadratic programming)문제의 해를 구함으로써 서포트 벡터를 구한다(그림 5 참조). 또한 선형 분리가 불가능한 데이터인 경우에는, 입력 벡터를 선형 초평면이 발견되는 고차원의 특징 공간으로 비선형 매핑한다. 이때 목표 함수와 결정 함수가 벡터의 내적으로 표현됨에 따라, 계산적으로 복잡한 매핑을 명시적으로 계산할 필요가 없어진다. 즉, Mercer 조건을 만족하는 커널 함수는 벡터의 내적을 치환한다. 본 논문에서는 커널 함수로 방사 기저 함수(Radial Basis Function: RBF)를 가정한다.

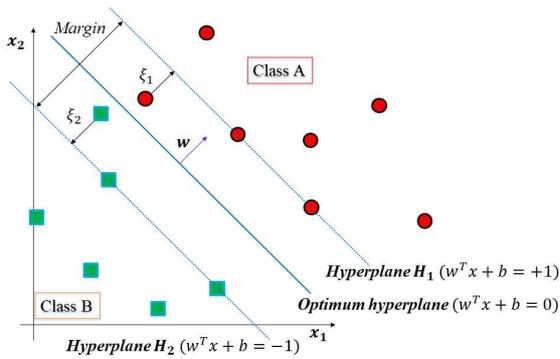


그림 5. SVM의 최적 경계 초평면 예시(선형 분리가 가능한 예)

## IV. 실험 및 결과 분석

### 1. 실험 데이터 취득

선로 전환기의 이상 상황을 탐지하는 실험을 위해 2016년 1월 1일 대전광역시 유성구에 위치한 (주)세화 연구소에서 실험환경을 구축하고 선로 전환기의 작동 시 발생하는 소리를 수집하였다(그림 6 참조). 선로 전환기에서 약 1m 떨어진 정중앙에서

마이크(Shure SM137)를 이용하여 소리 데이터를 수집하였으며, 이때의 기상상황은 약한 바람이 부는 0~6℃의 환경이었다.



그림 6. 선로 전환기의 소리 데이터 수집

본 실험에서는 Asada 등[5]이 정리한 선로 전환기의 어골도(fishbone diagram)에 기초하여 다음과 같이 이상 상황을 수집하였다: 기본 레일과 스위치 블레이드 사이에 얼음 또는 자갈이 낀 상황과 전철 막대의 나사가 풀어진 경우를 이상 상황이라고 정의하였다. 다음의 그림들은 데이터를 수집한 실제 모습을 촬영한 것이다: 얼음이 선로에 낀 상황(그림 7), 자갈이 낀 상황(그림 8), 전철 막대의 나사가 풀어진 상황(그림 9). 물론 공정성 확보를 위하여, 선로 전환기의 유지보수 작업을 수행한 후, 소리 데이터를 수집하였다.



그림 7. 얼음이 선로에 낀 상황

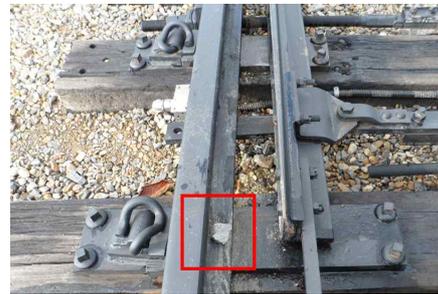


그림 8. 자갈이 선로에 낀 상황

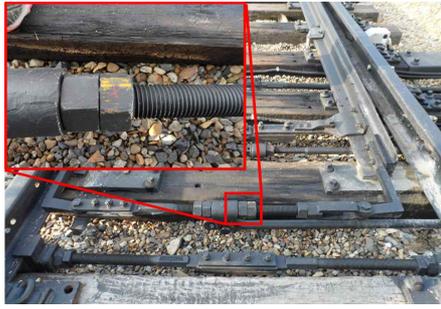


그림 9. 전철 막대의 나사가 풀어진 상황

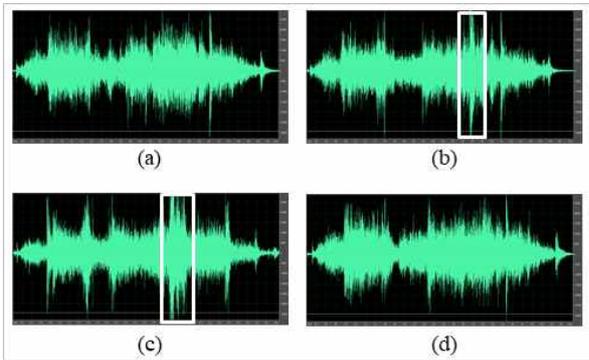


그림 10. 선로 전환기의 전환 시 소리 파형: (a) 정상, (b) 얼음이 낀 상황, (c) 자갈이 낀 상황, (d) 전철 막대의 나사가 풀린 상황.

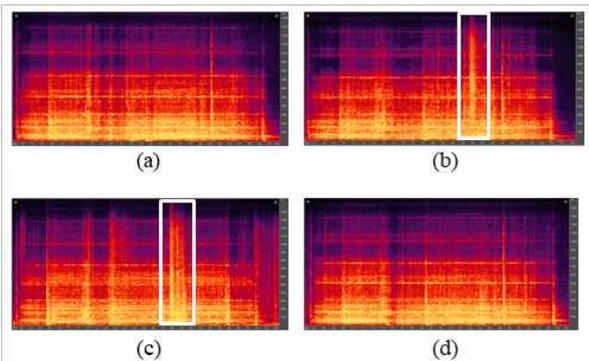


그림 11. 선로 전환기의 전환 시 소리의 스펙트로그램: (a) 정상, (b) 얼음이 낀 상황, (c) 자갈이 낀 상황, (d) 전철 막대의 나사가 풀린 상황.

선로 전환기의 이상 상황을 탐지하기 위해 수집한 소리 데이터는 소리 신호의 파형과 스펙트로그램을 확인한 후 수동으로 선로 전환 시 발생하는 소리 영역을 편집하였다(그림 10 참조). 해당 신호의 스펙트로그램은 그림 11과 같다. 그림 10의 소리 시그널과 그림 11의 스펙트로그램을 확인 해 보면 자갈 또는 얼음이 깨지는 시간 영역에서(흰색 사각형) 소리 시그널의 파형 및 주파수 영역의 에너지가 강하게 나타나는 것을 확인할 수 있

다.

본 실험에서는 제안한 시스템이 잡음 상황에서도 선로 전환기의 이상 상황을 강인하게 탐지하는지의 여부를 확인하기 위하여, 정상 소리 신호에 백색 가우시안 잡음인 SNR(Signal to Noise Ratio) 값을 다양하게(3, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 18, 21) 합성하여 실험하였다. 여기서 SNR의 수치는 낮아질수록 잡음이 강하게 합성됨을 의미한다. 또한, 소리를 녹음하는 마이크로폰에 녹음되는 소리의 강도(Intensity)가 낮아질 때의 이상 상황 탐지율의 변화를 확인하기 위하여, 정상 소리 원본에서 소리 강도를 80%, 90%로 축소 조정한 Intensity 1, Intensity 2라는 이름의 데이터도 추가하였다.

그림 12는 정상 소리와 SNR 잡음(3, 12, 21)이 합성된 소리의 파형을 보여주며, SNR의 수치가 작아질수록 아날로그 파형의 왜곡이 상당히 커짐을 확인할 수 있다. 또한, SNR 합성에 따른 스펙트로그램의 변화를 확인할 수 있는 그림 13을 보면, 정상 파형에 비해 SNR 3의 경우는 주파수 전역에서 에너지의 변화가 매우 강하게 나타남이 확인된다.

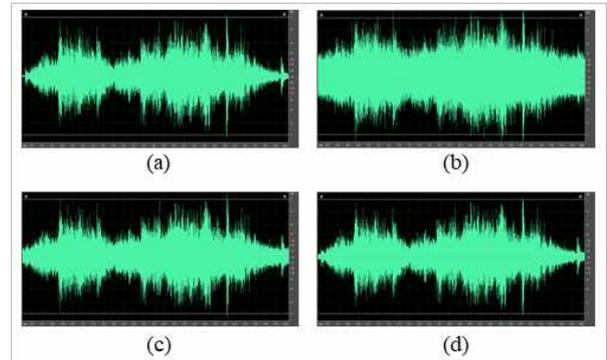


그림 12. SNR 합성에 따른 소리의 파형 변화: (a) 정상 소리, (b) SNR 3 합성, (c) SNR 12 합성, (d) SNR 21 합성

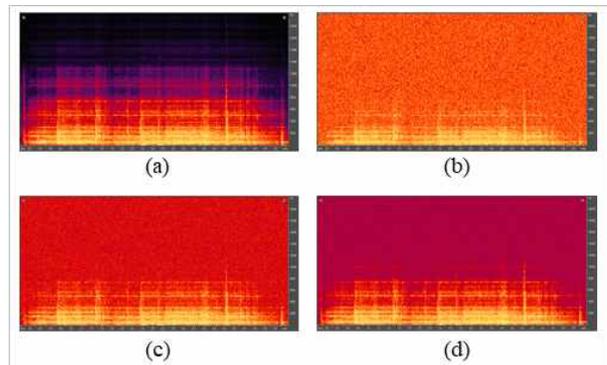


그림 13. SNR 합성에 따른 소리의 스펙트로그램 변화: (a) 정상 소리, (b) SNR 3 합성, (c) SNR 12 합성, (d) SNR 21 합성

## 2. 소리 특징 추출

16 bits, 44,100 Hz의 샘플 레이트(sample rate)로 녹음된 소리 데이터로부터 모듈레이션 기반의 특징 벡터를 생성하였다. 먼저 Matlab을 이용하여 주파수 1,024Hz 마다 (샘플레이트 × 소리길이)를 기준으로 Overlap(512) 크기 단위로 스펙트로그램을 추출하였다. 그 결과 행은 512로 고정이지만 열의 크기가 소리의 길이에 따라 달라지는 2차원의 스펙트로그램을 취득하였다. 특징 벡터의 차원을 일치시키기 위하여 해당 스펙트로그램의 크기를 200 × 200로 조정하였으며, 모듈의 크기는 5 × 5로 설정하였다. 모듈화를 수행하고 각각의 블록에서 평균과 표준편차를 구한 후 이를 z-score 표준화를 거친 3,200 차원(40 × 40 × 2)의 최종 특징 벡터를 얻었다.

## 3. 이상 상황 탐지

본 연구에서 제안한 시스템의 성능 평가를 위하여, 정상적인 데이터 140개, 비정상 데이터 420개(나사가 풀어진 경우: 140, 자갈이 있는 경우: 140, 얼음 조각이 있는 경우: 140), 총 560개의 데이터로 선로 전환기의 이상 상황 탐지 실험을 수행하였다. 실험에서, 프로그램 R의 SVM 패키지인 'e1071'[17]을 이용하였으며, 전체 데이터 셋의 70%를 랜덤으로 선택하여 SVM의 학습 데이터로 사용하고, 나머지 30%를 SVM의 테스트 데이터로 이용하였다. SVM의 상대적 중요성을 조정하는 상수(trade-off constant) C 값과 RBF kernel 계수 값인 gamma는 실험에서 가장 좋은 결과를 보인 12.7과  $0.33 \times 10^{-5}$ 로 설정하였다.

실험 성능 측정을 위한 지표로는 정확도(accuracy)와 F-measure를 사용하였고, 각각의 수식은 다음과 같다.

$$\bullet \text{ Accuracy} = \frac{TP + TN}{P + N} \quad (1)$$

$$\bullet \text{ Precision} = \frac{FP}{TP + FP} \quad \bullet \text{ Recall} = \frac{TP}{P} \quad (2)$$

$$\bullet \text{ F-measure} = 2 \times \frac{\text{Precision} \times \text{recall}}{\text{Precision} + \text{recall}} \quad (3)$$

위 식들에서 P는 이상 상황 데이터의 개수, TP는 이상 상황을 이상 상황으로 올바르게 탐지한 데이터의 개수, N은 정상 데이터의 개수, FP는 정상 데이터를 이상 상황으로 잘못 탐지한 데이터의 개수, TN는 정상을 정상 상황으로 맞게 판단한 데이터의 개수를 의미한다.

본 논문에서 제안한 선로 전환기의 이상 상황 탐지 시스템의 성능 실험 결과는 표 1과 같으며, 잡음을 고려하지 않은 실험

(Clean이라는 이름으로 명시)에서는 선로 전환기의 정확도가 100%라는 매우 우수한 성능결과를 확인하였다. 실험결과를 보다 자세히 분석해보면 다음과 같다. 원본 소리 신호의 강도가 80%, 90%(Intensity 1 and 2)로 감소하여도 제안한 시스템의 이상 상황 탐지율의 성능변화는 없었다. 즉, 일정량의 소리 강도의 저하는 이상 상황 탐지에 큰 영향을 미치지 않는 것으로 판단된다. 또한 소리 잡음의 다양한 강도에 따른 시스템의 성능 평가를 수행한 실험 결과에서는 잡음의 강도가 비교적 약한 SNR 21~9까지는 안정적인 성능, 잡음의 강도가 매우 강한 SNR 8~3구간에서는 시스템의 성능이 급격하게 저하되는 것을 확인하였다. 결국, 본 논문에서 제안한 모듈레이션 기반의 SVM은 다양한 잡음 환경에서도 안정적인 선로 전환기의 이상 상황 탐지 성능을 보임을 확인하였다.

선행 연구와의 비교 실험을 위해서 Lee 등[1]이 제안한 MFCC 기반의 SVM 연구 방법론을 선택하였다. 실험에서, MFCC는 소리의 길이에 상관없이 60 프레임으로 나눈 후, 각 각에서 12개의 cepstral coefficient 값을 추출하였다. 그 결과 MFCC 특징 벡터는 720 크기의 특징 차원을 가진다. 전 실험과 동일하게, 전체 데이터 셋의 70%를 랜덤으로 선택하여 SVM의 학습 데이터로 사용하였고, 나머지 30%를 SVM의 테스트 데이터로 이용하였다. 이때, 실험에 의해 가장 좋은 결과를 보인 C(3.9)와 gamma 값( $0.41 \times 10^{-4}$ )을 설정하였다.

표 1. 모듈레이션 특징 벡터와 MFCC 특징 벡터의 이상 상황 탐지율 비교 (단위: %)

	MFCC+SVM		Modulation+SVM	
	정확도	F-meas.	정확도	F-meas.
Clean	100	100	100	100
Intensity 1	100	100	100	100
Intensity 2	100	100	100	100
SNR 21	99.4	99.6	99.4	99.6
SNR 18	99.4	99.6	99.4	99.6
SNR 15	96.4	97.7	100	100
SNR 14	89.9	93.7	100	100
SNR 13	81.5	89.1	100	100
SNR 12	78	87.2	95.2	96.9
SNR 11	76.2	86.3	87.5	92.3
SNR 10	75	85.7	86.9	92
SNR 9	75	85.7	85.7	91.3
SNR 8	75	85.7	77.4	86.9
SNR 7	75	85.7	75	85.7
SNR 6	75	85.7	75	85.7
SNR 3	75	85.7	75	85.7

실험결과를 정리한 표 1을 살펴보면, 원본 신호의 강도가 80%, 90% (Intensity 1 and 2)로 감소하여도 MFCC와 모듈레이션 기반의 특징을 이용한 두 경우 모두 이상 상황 탐지율에는 변화가 없었다. 다만 소리 잡음의 강도가 강한 SNR 3과 SNR 6 뿐만이 아니라 SNR 7~13에서는 MFCC 특징을 이용한 경우의 성능은 매우 낮으며, 또한, 잡음이 상대적으로 적게 합성된 SNR 15의 경우에서도 모듈레이션 특징을 이용한 경우보다 상대적으로 낮은 성능을 확인하였다(그림 14 참조).

참고로, 이상 상황 탐지율을 정리한 표 1을 살펴보면 유독 정확도는 75%, F-measure는 85.7%를 기록한 경우가 많다. 이는 표 2의 혼동행렬(confusion matrix)처럼 실제 정상 데이터가 이상 상황으로 잘못 예측이 되고, 이상 상황을 모두 이상 상황으로 예측한 결과에 의한 것이다.

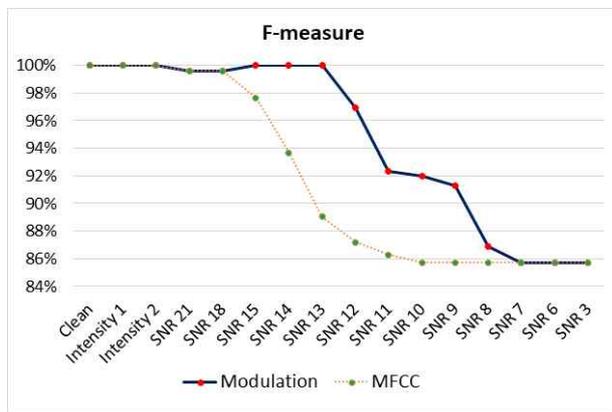


그림 14. 모듈레이션 및 MFCC 특징 벡터의 이상 상황 탐지 성능 비교 그래프

표 2. 이상 상황 탐지의 혼동행렬 (정확도 75%, F-measure 85.7%의 경우)

	정상으로 예측	이상 상황으로 예측
실제 정상 데이터	0	42
실제 이상 상황	0	126

## V. 결론

본 논문에서는 선로전환 시 발생하는 소리 정보를 이용하여 선로 전환기의 이상 상황을 탐지하는 프로토타입 시스템을 제안하였다. 제안된 시스템은 먼저 실시간으로 유입되는 소리 정보로부터 주파수 공간의 특징인 스펙트로그램을 추출한 후 이를 모듈화 기법을 이용하여 특징 벡터를 생성하였다. 이후, 생성된 모듈레이션 특징 벡터는 기계학습의 대표적인 이진 분류 모델인 SVM에 적용되어 선로 전환기의 비정상 상황을 탐지하였다. 실제 선로 전환기의 전환 시 발생하는 소리 시그널에 잡음 정보를 추가로 합성한 후 실험한 결과, 제안한 시스템의 성능이

안정적임을 실험적으로 검증하였다. 본 논문에서 제안한 시스템은 설치 가격이 경제적일 뿐만 아니라 선로 전환기의 전기적 신호를 기반으로 한 비정상 상황 탐지 시스템의 부가적인 모듈 또는 단독으로 사용될 수 있다.

향후 연구 과제로는 제안된 프로토타입의 시스템을 실세계에서 구현 및 운용하기 위한 구체적인 후속 연구들이 요구되며, 기존의 연구에서 활발히 연구된 전기적 신호와의 멀티모달 기반의 융합 연구가 기대된다.

## REFERENCES

- [1] J. Lee, H. Choi, D. Park, Y. Chung, H.-Y. Kim, and S. Yoon, "Fault Detection and Diagnosis of Railway Point Machines by Sound Analysis," *Sensors*, vol. 16, no. 4, pp. 549, 2016.
- [2] 이종현, 김용규, "센서를 활용한 전기선로전환기의 전환력 측정에 대한 연구," *한국철도학회논문지*, 제18권, 제4호, 335-343쪽, 2015년 8월
- [3] 이종현, 김용규, 박재영, "센서를 이용한 선로전환기 전환력 측정의 현장 적용성 연구," *전기학회논문지*, 제64권, 제7호, 1130-1136쪽, 2015년 6월
- [4] 유광균, 노성찬, "분기기 고장 시 열차사고방지를 위한 안전시스템 모델링," *한국철도학회 2011년 추계학술대회*, 724-730쪽, 2011년 10월
- [5] R. Sharan and T. Moir, "Noise Robust Audio Surveillance using Reduced Spectrogram Image Feature and One-Against-All SVM," *Neurocomputing*, vol. 158, pp. 90-99, 2015.
- [6] M. Vileiniskis, R. Remenyte-PreScott, and D. Rama, "A Fault Detection Method for Railway Point Systems," *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, vol. 230, no. 3, pp. 1-14, 2015.
- [7] T. Asada, C. Roberts, and T. Koseki, "An Algorithm for Improved Performance of Railway Condition Monitoring Equipment: Alternating-Current Point Machine Case Study," *Transportation Research Part C: Emerging Technologies*, vol. 30, pp. 81-92, 2013.
- [8] T. Asada and C. Roberts, "Improving the Dependability of DC Point Machines with a Novel Condition Monitoring System," *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of rail and rapid transit*, vol. 227, no. 4, pp. 322-332, 2013.
- [9] H. Kim, J. Sa, Y. Chung, D. Park, and S. Yoon,

저 자 소 개

- “Fault Diagnosis of Railway Point Machines using Dynamic Time Warping,” *Electronics Letters*, vol. 52, no. 10, pp. 818-819, 2016.
- [10] O. Eker, F. Camci, and U. Kumar, “SVM based Diagnostics on Railway Turnouts,” *International Journal of Performability Engineering*, vol. 8, no. 3, pp. 289-398, 2012.
- [11] H. J. Hsieh, B. Chen, and J. W. Hung, “Enhancing the Complex-Valued Acoustic Spectrograms in Modulation Domain for Creating Noise-Robust Features in Speech Recognition,” *Proc. of Asia-Pacific Signal and Information Processing Association (APSIPA)*, pp. 303-307, Dec. 2015.
- [12] P. Khunarsal, C. Lursinsap, C., and T. Raicharoen, “Very Short Time Environmental Sound Classification based on Spectrogram Pattern Matching,” *Information Sciences*, vol. 243, pp. 57-74, 2013.
- [13] J. Schröder, S. Goetze, and J. Anemüller, “Spectro-Temporal Gabor Filterbank Features for Acoustic Event Detection,” *IEEE/ACM Transactions on Audio, Speech and Language Processing*, vol. 23, no. 12, pp. 2198-2208, 2015.
- [14] J. Han, M. Kamber, and J. Pei, *Data Mining: Concepts and Techniques*, Morgan Kaufmann Publishers, 2012.
- [15] S. T. Trieu and G. S. Lee, “Machine Printed and Handwritten Text Discrimination in Korean Document Images,” *한국스마트미디어학회논문지*, 제5권, 제3호, 30-34쪽, 2016년 9월
- [16] H. Kim, S. Lee, Y. Chung, D. Park, and H. Lee, “Multicore Processor based Parallel SVM for Video Surveillance System,” *Journal of the Korea Institute of Information Security and Cryptology*, vol. 21, no. 6, pp. 161-169, 2011.
- [17] Meyer, D. *Support vector machines: The interface to libsvm in package e1071*, 2014.



이종욱(정회원)

2003년 고려대학교 전산학과 학사 졸업.  
2005년 고려대학교 전산학과 석사 졸업.  
2014년 고려대학교 전산학과 박사 졸업.

2014년~현재 고려대학교 컴퓨터융합 소프트웨어학과 초빙교수

<주관심분야 : 딥러닝, 데이터마이닝, 융합 IT, 음향 분석>



김아용(정회원)

2013년 배재대학교 컴퓨터공학 학사 졸업.  
2015년 배재대학교 컴퓨터공학 석사 졸업.

2016년~현재 세화부설연구소 연구개발팀 재직 중

<주관심분야 : 병렬 처리, 기계학습,

컴퓨터 비전>



박대희(정회원)

1982년 고려대학교 수학과 학사 졸업.  
1984년 고려대학교 수학과 석사 졸업.  
1989년 플로리다 주립대학 전산학과 석사 졸업.  
1992년 플로리다 주립대학 전산학과 박사 졸업.

1993년~현재 고려대학교 컴퓨터융합소프트웨어학과 교수.

<주관심분야 : 빅데이터, 데이터마이닝, 인공지능, 융합 IT>



정용화(정회원)

1984년 한양대학교 전자통신공학과 학사 졸업.

1986년 한양대학교 전자통신공학과 석사 졸업.

1997년 U. of Southern California 박사 졸업.

1986년~2008년 한국전자통신연구원 생체인식기술 연구팀 팀장.

2003년~현재 고려대학교 컴퓨터융합소프트웨어학과 교수.

<주관심분야 : 병렬처리, 영상처리, 융합IT>