

Stress Detection of Railway Point Machine Using Sound Analysis

Yongju Choi[†] · Jonguk Lee^{**} · Daihee Park^{***} · Jonghyun Lee^{****} ·
Yongwha Chung^{*****} · Hee-Young Kim^{*****} · Sukhan Yoon^{*****}

ABSTRACT

Railway point machines act as actuators that provide different routes to trains by driving switchblades from the current position to the opposite one. Since point failure can significantly affect railway operations with potentially disastrous consequences, early stress detection of point machine is critical for monitoring and managing the condition of rail infrastructure. In this paper, we propose a stress detection method for point machine in railway condition monitoring systems using sound data. The system enables extracting sound feature vector subset from audio data with reduced feature dimensions using feature subset selection, and employs support vector machines (SVMs) for early detection of stress anomalies. Experimental results show that the system enables cost-effective detection of stress using a low-cost microphone, with accuracy exceeding 98%.

Keywords : Railway Point Machine, Stress Detection, Sound Analysis, SVM

소리 정보를 이용한 철도 선로전환기의 스트레스 탐지

최 용 주[†] · 이 종 욱^{**} · 박 대 희^{***} · 이 종 현^{****} ·
정 용 화^{*****} · 김 희 영^{*****} · 윤 석 한^{*****}

요 약

철도 선로전환기는 열차의 진로를 현재의 궤도에서 다른 궤도로 제어하는 장치이다. 선로전환기의 이상 상황은 탈선 등과 같은 심각한 문제를 발생시킬 수 있기 때문에, 선로전환기의 스트레스를 지속적으로 모니터링 하는 것은 매우 중요하다. 본 논문에서는 선로전환기가 작동할 때 발생하는 소리 정보를 이용하여 선로전환기의 스트레스를 탐지하는 시스템을 제안한다. 제안하는 시스템은 선로전환기의 동작 시 발생하는 소리 데이터로부터 자질 선택방법을 사용하여 스트레스 탐지에 유효한 감소된 차원의 자질 부분집합을 선택한 후, 기계학습의 대표적 모델인 SVM(Support Vector Machine)을 이용하여 선로전환기의 스트레스 상태 여부를 탐지한다. 테스트용 선로전환기를 실제 구동하며 수집한 소리 데이터를 이용하여, 본 논문에서 제안하는 시스템의 성능을 실험적으로 검증한 바 98%를 넘는 정확도를 확인하였다.

키워드 : 철도 선로전환기, 스트레스 탐지, 소리 분석, SVM

1. 서 론

현재의 산업구조에서 철도가 차지하는 비중이 지속적으로 증대됨에 따라 철도의 안정적인 주행이 그 어느 때보다 중요

해지고 있다. 철로를 구성하는 중요한 요소 중 하나인 선로 전환기(Fig. 1 참조)는 열차의 진로를 제어하는 철도 부품 중 하나로, 선로전환기의 결함은 열차의 탈선 및 충돌·추돌을 발생시킬 수 있기 때문에 선로전환기의 이상여부를 조기에 탐지하는 것은 매우 중요한 문제이다[1]. 최근 10년간의 철도 사고를 살펴보면 선로전환기의 장애는 전체 철도 신호장치 장애의 27%를 차지하며, 철도 시스템의 운영 및 유지보수 측면에서 가장 많은 노동시간을 소모하는 설비로 분류된다[2]. 따라서 대부분 근로자의 수작업에 의존하는 현재의 철도 유지보수 시스템에서 선로전환기의 이상여부를 실시간으로 자동 탐지하는 지능형 컴퓨터 시스템으로 전환하려는 노력은 경제적 측면뿐만 아니라 안전에 있어서도 반드시 필요하다.

외부 환경에 노출되어 작동하는 선로전환기의 특성 상, 선

※ 이 논문은 2015년도 중소기업청 기술혁신개발사업 혁신형기업과제 (S2312692)의 지원을 받아 수행된 연구결과임.
† 준 회 원 : 고려대학교 컴퓨터정보학과 학사과정
** 정 회 원 : 고려대학교 컴퓨터정보학과 조빙교수
*** 정 회 원 : 고려대학교 컴퓨터정보학과 교수
**** 비 회 원 : ㈜세화 대표이사
***** 중신회원 : 고려대학교 컴퓨터정보학과 교수
***** 비 회 원 : 고려대학교 응용통계학과 교수
***** 비 회 원 : ㈜세화 부설연구소 연구소장
Manuscript Received : June 29, 2016
First Revision : July 20, 2016
Accepted : July 20, 2016
* Corresponding Author : Daihee Park(dhpark@korea.ac.kr)

로전환기의 부품들은 외부 충격을 자주 받게 된다. 이러한 외부 충격들로 인해 선로전환기는 지속적인 물리적 손상을 받게 되며 이는 선로전환기의 미세한 균열이나 누적 손상을 야기하게 되어 결국 선로전환기의 스트레스로 이어진다[3]. 특히, 선로전환기의 stock rail과 switch blade 사이에 이물질(얼음, 자갈 등)이 끼어서 발생하는 스트레스(Fig. 1 참조)는 선로전환기의 고장에 이르기 전 단계를 의미하므로, 선로전환기의 결함뿐만 아니라 선로전환기의 적절한 교체시기를 예측하기 위해서도 선로전환기가 받는 스트레스 해석은 매우 중요하다고 할 수 있다[4].

본 논문에서는 선로전환기의 실제 작동 소리를 이용하여 열차 운행의 안정성에 중요한 부분을 차지하는 선로전환기의 스트레스를 탐지하는 프로토타입 시스템을 제안한다. 제안된 시스템은 먼저 선로전환기의 구동 시 발생하는 소리 신호의 해석으로부터 해결하고자 하는 문제에 적합한 자질 부분집합을 미리 설정하고, 설정된 자질 부분집합에 해당하는 입력 자질 벡터를 대상으로 선로전환기의 스트레스를 탐지한다. 이때 선로전환기의 스트레스 탐지문제를 이진 분류 문제로 해석하여 이진 분류기의 대표적 모델인 SVM을 탐지기로 설계하였다. SVM기반의 스트레스 탐지기는 정상 작동 소리와 스트레스가 쌓인 선로전환기의 작동소리를 구분하여 미리 학습하고, 스트레스가 쌓인 선로전환기의 작동소리가 실시간으로 입력·탐지될 경우 선로전환기의 관리자에게 알람을 경고한다. 제안된 시스템은 선로전환기의 노후화 여부를 조기 판단하여 선로전환기의 교체시기를 판별함으로써 예정된 사고를 사전에 예방할 수 있는 유용한 정보로 활용될 수 있을 것으로 기대된다.

본 논문의 구성은 다음과 같다. 2장에서는 선로전환기에 관련한 최근 연구방법론의 문헌고찰을 간략하게 소개하고, 3장에서는 본 연구에서 제안하는 소리 기반의 선로전환기 스트레스 탐지 시스템에 대해 상세히 기술한다. 4장에서는 실험 결과 및 성능 분석을, 마지막으로 5장에서는 결론 및 향후 연구과제에 대해 논한다.

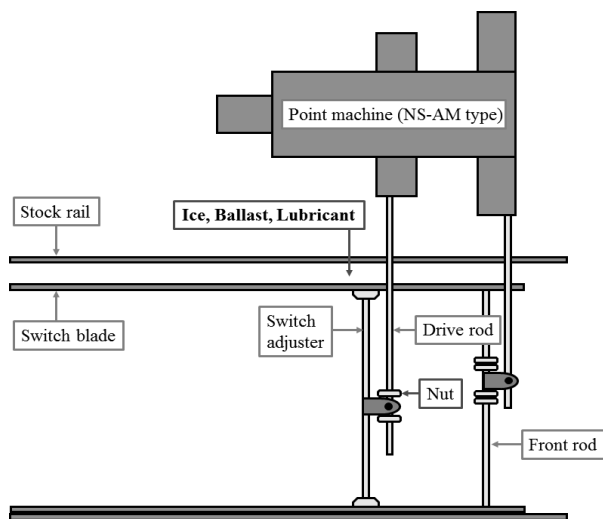


Fig. 1. Schematic for railway point machine

2. 관련 연구

선로전환기에 관한 최근의 연구동향을 살펴보면, 선로전환기의 결함을 조기에 탐지하고자 하는 많은 노력들이 철도 선진국을 중심으로 진행되고 있음을 알 수 있다. 예를 들면, Vileiniskis 등[5]은 선로전환기를 구동시키는 모터의 전류값의 변화를 이용하여, 미리 설정해 둔 임계값을 벗어나는지의 여부를 근거로 선로전환기의 이상상황을 판단하였다. Eker 등[6]은 모터 전류측정 센서 등을 이용하여 취득한 자질 정보들을 PCA(Principal Components Analysis)와 SVM을 이용하여 drive rod가 비정상적으로 작동하는 상태인 불일치(out-of adjustment) 상태 여부를 탐지하였다. 또한 Asada 등[7, 8]은 선로전환기로 유입되는 전기적 신호(전류와 전압)를 이용하여 선로 전환기의 상태를 모니터링 하는 시스템을 제안하였다. 이상에서 살펴본 바와 같이, 최근 선로전환기에 관한 연구들은 대부분 선로전환기의 모터를 동작시키기 위해 입력되는 전기적 신호를 단순한 임계값 수치로 판단하거나 혹은 이상상황 탐지를 분류의 문제로 해석하여 기계학습 기반의 분류기로 문제를 해결하고자함을 알 수 있다. 반면, Lee 등[9]은 선로전환기가 실제 구동 시 발생하는 소리 정보를 대상으로, MFCC (Mel-Frequency Cepstrum Coefficients) 자질 벡터를 추출하고 SVM을 이용하여 선로전환기의 이상상황을 탐지 및 분류하는 혁신적인 연구결과를 최근 발표하였다. 이는 전기적 신호를 주요 입력으로 하는 선로전환기의 현재까지의 연구영역에서 소리분석 기반의 연구가 독립적으로 혹은 전기적 신호 시스템에 보조적 역할을 담당할 수 있다는 가능성을 보여준 최초의 연구결과이다.

본 연구는 Lee 등[9]의 소리분석 기반 연구의 연장선으로, 선로전환기의 이상상황 및 노후화로 인한 교체 시기 등을 판단하는데 있어서 중요한 역할을 하는 선로 전환기의 스트레스를 탐지하기 위하여, 전통적인 전기적 신호를 이용하는 방법이 아닌 이미 그 효과가 검증된 선로 전환기의 작동소리 정보를 이용하여 선로전환기의 스트레스를 탐지하는 시스템을 제안한다.

3. 소리 기반의 선로전환기 스트레스 탐지 시스템

본 논문에서 제안하는 소리 기반의 선로전환기 스트레스 탐지 시스템의 구조는 다음의 Fig. 2와 같다. 제안하는 시스템은 크게 소리 수집(sound acquisition) 모듈, 자질 추출(feature extractor) 모듈, 스트레스 탐지(stress detector) 모듈로 구성된다.

3.1 소리 수집 모듈

먼저 소리 수집 모듈에서는 센서(마이크)로부터 선로전환기 동작의 시작과 완료 사이에 발생하는 입력 소리를 수집한다.

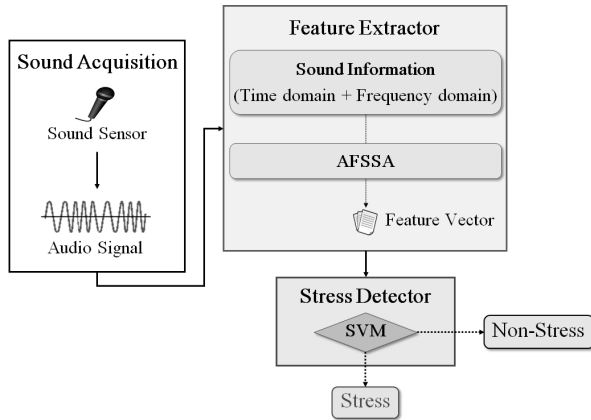


Fig. 2. Overall structure of stress detection for railway point machine using sound analysis

3.2 자질 추출 모듈

자질 추출 모듈은 선로전환기의 스트레스 탐지를 위하여 time domain과 frequency domain에서의 소리 자질들을 추출한다. 취득한 자질들은 자질 선택 방법인 AFSSA (Acoustic Feature Subset Selection Algorithm)[10] 방법을 이용하여 중요한 자질들로 구성되는 최종 소리 자질 벡터를 생성한다. 본 논문에서 사용한 time domain과 frequency domain에서 각각 추출한 소리 자질 매개변수들[11]은 다음과 같다.

• Time domain features

- i) RMS(Root Mean Square): Gaussian random process에 의해 계산되는 진폭 값.
- ii) Power: 단위시간당 소리신호의 energy 값.
- iii) Energy: 시간에 대한 소리신호 진폭의 제곱의 적분 값.
- iv) Absolute extremum: 소리신호의 최대 진폭의 절댓값.
- v) Intensity: 단위면적당 소리신호의 energy 값.
- vi) Shimmer: 진폭변동률이라고도 하며, 연속 시간에서의 진폭의 average absolute difference를 평균 진폭으로 나눈 값.
- vii) Jitter: 주파수 변동률이라고도 하며, 연속 시간에서의 average absolute difference를 평균 시간으로 나눈 값.
- viii) HNR(Harmonics to Noise Ratio): 조화음 대 소음비.

• Frequency domain features

- i) Formant, F1~F9: 음성 신호의 공명 특성을 보여주는 개체로써 공명 주파수는 0~10,000Hz 사이에서 추출.
- ii) PSD(Power Spectral Density), PSD1~PSD39: 주파수에 대한 스펙트럼의 변화율을 뜻하며, 단위는 단위 주파수당 power값을 의미함. 본 실험에서는 39개의 PSD를 사용하였고, 100~4,000Hz구간에서 100Hz마다 추출.

주어진 문제를 풀기위해 사용되는 자질 집합의 최적 선택 문제는 시스템이 실제 동작하기 전에 결정해야만 하는 패턴

인식 분야의 중요한 주제 중 하나이다[12]. 이는 시스템의 성능을 계속 유지하거나 최소한의 성능 저하만을 허락하는 입장에서, 자질 집합에 존재하는 변수들 중, 정보가 비교적 적게 반영된 변수들과 중복된 성질을 갖는 자질 매개변수들을 제거함으로써 자질 집합의 차원을 축소하는 방법이다[12, 13]. 본 논문에서는 선로전환기의 주요한 소리 자질들을 선택하는 방법으로 Lee 등[10]이 제안한 AFSSA를 사용하였다.

Pseudocode of AFSSA[10]

Definition:

sound data set $A = \alpha \cup \beta$,

α : stress sound, β : non-stress sound.

universal sound features set = $\{F_1, F_2, \dots, F_k\}$, where k is the number of features that can be extracted from A .

Input: universal feature set A .

1. compute t -test and obtain the first candidate set F' :
 - if p-value of $F_i \geq 0.05$ then remove F_i in F' .
2. compute the information gain of each formant in F' .
3. apply correlation analysis to F' using information gain and obtain the second candidate set F'' :
 - if |correlation value| $\geq threshold$ then select the highest ranked sound feature.
4. apply Sequential Forward Search(SFS) to F'' with Between Class Distance(BCD) as an evaluation function and obtain the final feature subset F''' .

Output: an optimal sound feature subset F''' .

3.3 스트레스 탐지 모듈

스트레스 탐지 모듈에서는 선로전환기의 스트레스 탐지를 위해 미리 훈련을 마친 SVM을 기반으로, 실시간으로 유입되는 소리 신호의 스트레스 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[13, 14]. 이때 결정 평면은 학습 원소들의 가중화된 조합이며, 이러한 학습 원소들을 support vector라 부르며 이들은 두 클래스간의 경계면에 존재한다. 예를 들면, 선형 분리가 가능한 데이터를 가정할 때 최대 여백 분류의 목표는 support vector들의 거리가 최대화되는 초월면(hyperplane)에 의해 두 개의 클래스를 분리하는 것이다. 이러한 초월면은 최적 경계 초월면(optimal separating hyperplane)이라고 불리며, 2차 프로그래밍(quadratic programming) 문제의 해를 구함으로써 support vector를 구한다(Fig. 3 참조). 또한 선형 분리가 불가능한 데이터인 경우에는, 입력 벡터를 선형 초월면이 발견되는 고차원의 자질 공

간으로 비선형 매핑한다(Fig. 4 참조). 이때 목표 함수와 결정 함수가 벡터의 내적으로 표현됨에 따라, 계산적으로 복잡한 매핑을 명시적으로 계산할 필요가 없어진다. 즉, Mercer 조건을 만족하는 커널 함수는 데이터 벡터 대신에 사용되는 매핑 함수로 치환할 수 있다. 본 논문에서는 커널 함수로 Radial Basis Function(RBF)을 가정한다.




Fig. 3. Main concept of SVM in a linearly separable case




Fig. 4. Graphical view of the SVM in the non-linearly separable case

4. 실험 및 결과 분석

4.1 실험 데이터 획득

선로전환기의 스트레스를 탐지하는 실험을 위해 2016년 1월 1일 대전광역시 유성구에 위치한 ㈜세화 연구소에서 실험환경을 구축하고 선로전환기의 작동 시 발생하는 소리를 수집하였다(Fig. 5 참조). 선로전환기에서 약 1m 떨어진 정중앙에서 마이크(Shure SM137)를 이용하여 소리 데이터를 수집하였으며, 이때의 기상상황은 약한 바람이 부는 0~6°C의 환경이었다.



Fig. 5. Data collection from railway point machine

본 실험에서는 스트레스가 없는 상황(non-stress)과 스트레스(stress)가 쌓인 상황을 Asada 등[7, 8]이 정리한 선로전환기의 fishbone diagram에 기초하여 다음과 같이 설정하였다: stock rail과 switch blade 사이에 얼음 또는 자갈이 낀 상황과 drive rod의 나사가 풀어진 경우를 스트레스가 쌓인 상황이라고 정의하였으며, 이물질이 없고 윤활유를 칠한 상황을 스트레스가 없는 상황이라고 정의하였다. 다음의 그림들은 데이터를 수집한 실제 모습을 촬영한 것이다: 얼음이 선로에 낀 상황(Fig. 6), 자갈이 낀 상황(Fig. 7), drive rod의 나사가 풀어진 상황(Fig. 8), 그리고 윤활유를 선로에 바른 후의 상황(Fig. 9). 물론 공정성 확보를 위하여, 선로전환기의 유지보수 작업을 수행한 후, 소리 데이터를 수집하였다.



Fig. 6. Stress condition(ice obstruction)



Fig. 7. Stress condition(gravel obstruction)




Fig. 8. Stress condition(slackened nut)




Fig. 9. Non-stress condition(lubrication)

선로전환기의 스트레스 탐지를 실험하기 위한 소리 데이터는 소리 신호의 파형과 스펙트로그램을 확인한 후 수동으로 선로 전환 시 발생하는 소리 영역을 편집하였다(Fig. 10A·B, 11A·B 참조). 이때, Fig. 10B와 Fig. 11B를 비교해보면 스트레스가 없는 소리 신호(Fig. 10B)에 비해서 스트레스가 발생한 소리(Fig. 11B)의 스펙트로그램은 자갈이 깨지는 시간 영역에서(빨간색 사각형) 주파수 영역의 에너지가 강하게 나타나는 것을 확인할 수 있다. 소리 데이터는 대략 4.5~5.5초의 길이를 가지며 실험에 사용한 데이터의 구성은 Table 1과 같다.




Fig. 10A. Waveform of non-stress(lubrication) sound sample




Fig. 10B. Spectrogram of non-stress(lubrication) sound sample




Fig. 11A. Waveform of stress(gravel) sound sample




Fig. 11B. Spectrogram of stress(gravel) sound sample

Table 1. Sound dataset

Class	Number of dataset	Note
Non-stress	300	Lubrication
Stress	141	Ice obstruction
	147	Gravel obstruction
	155	Slackened nut

4.2 자질 추출 및 자질 선택

취득한 선로전환기의 작동 소리에서 소리 자질을 추출하기 위해 Praat 6.0.05를 사용하여 time domain에서 16개, frequency domain에서 48개, 총 64개의 자질을 추출했다.

• Time domain(16개)

{RMS, Power, Energy, Absolute extremum, Intensity, HNR, Shimmer(local), Shimmer(apq3), Shimmer(apq5), Shimmer(ddp), Shimmer(dB), Jitter(local), Jitter(rap), Jitter(ppq5), Jitter(ddp), Jitter(absolute)}

• **Frequency domain(48개)**

{Formant F1~F9, PSD 1~39}

총 64개의 자질 파라미터 집합에서 AFSSA를 사용하여 최적의 자질 부분 집합을 선택하였다. 그 결과 데이터 셋의 차원은 약 15.62%로 축소되었으며, 선택된 자질 부분집합은 다음과 같다:

- AFSSA를 사용하여 선택된 F' 자질들(43개) : 1단계 {F3~F8, RMS, Power, Energy, Absolute extremum, Intensity, Shimmer(apq5), Jitter(abs), HNR, PSD5, PSD7, PSD8, PSD9, PSD10, PSD11, PSD12, PSD13, PSD14, PSD15, PSD16, PSD17, PSD19, PSD21, PSD22, PSD23, PSD24, PSD25, PSD26, PSD27, PSD29, PSD30, PSD31, PSD32, PSD35, PSD36, PSD37, PSD38, PSD39}
- AFSSA를 사용하여 선택된 F'' 자질들(25개) : 2, 3단계 {F5, F8, Energy, Absolute extremum, Shimmer(apq5), HNR, PSD5, PSD11, PSD12, PSD13, PSD14, PSD15, PSD16, PSD17, PSD21, PSD23, PSD25, PSD26, PSD29, PSD32, PSD35, PSD36, PSD37, PSD38, PSD39}
- AFSSA를 사용하여 최종적으로 선택된 자질들(10개) {Energy, Absolute extremum, Shimmer(apq5), HNR, F5, F8, PSD12, PSD23, PSD25, PSD26}

선택된 소리 자질 집합 중 일부의 변수에 관한 자질값의 변화 추세를 살펴보면, time domain과 frequency domain에서 모두 스트레스가 증가함에 따라 자질값이 독립적으로 단조 증가(monotonic increasing)함을 확인할 수 있다(Fig. 12, 13 참조). 위 예비 실험 결과로부터 소리 정보를 통해 스트레스에 따른 선로전환기의 소리 분류의 가능성을 확인할 수 있다.




Fig. 12A. Transition graph of energy in time domain




Fig. 12B. Transition graph of absolute extremum in time domain




Fig. 13A. Transition graph of formant 5 in frequency domain




Fig. 13B. Transition graph of formant 8 in frequency domain

4.3 소리 자질을 이용한 선로전환기의 스트레스 탐지

소리 자질을 이용한 선로전환기의 스트레스 탐지 실험은 Table 1에서 명시한 바와 같이, 스트레스가 없을 때의 소리 300개와 스트레스가 쌓였을 때의 소리 443개를 대상으로 Weka 3.8.0 버전을 이용하여 SVM 실험을 수행하였다. 전체 데이터 셋의 50%를 랜덤으로 선택한 데이터로부터 Weka에

서 제공하는 grid search 방법을 이용하여, SVM의 상대적 중요성을 조정하는 상수(trade-off constant) C 값은 6.95, 그리고 RBF kernel의 계수 값인 gamma는 1.9로 설정하였다. grid search에 참여하지 않은 나머지 50%의 데이터 셋에 대해서 10 fold-cross validation으로 스트레스 탐지의 성능실험을 수행하였다.

실험 성능 측정을 위한 지표로는 SDR(Stress Detection Rate: 스트레스 상황 탐지율), FPR(False Positive Rate: 스트레스가 없는 소리가 스트레스가 있다고 오답지된 비율), FNR(False Negative Rate: 스트레스가 있는 소리가 스트레스가 없는 소리로 오답지된 비율)을 사용하였고, 각각의 수식은 다음과 같다.

$$SDR = \frac{\sum_{i=1}^m T_i}{\sum_{i=1}^n I_i} \quad (1)$$

$$FPR = \frac{\sum_{i=1}^k P_i}{\sum_{i=1}^l N_i} \quad (2)$$

$$FNR = \frac{\sum_{i=1}^{n-m} F_i}{\sum_{i=1}^n I_i} = 1 - \frac{\sum_{i=1}^m T_i}{\sum_{i=1}^n I_i} \quad (3)$$

위 식들에서 I_i 는 스트레스가 있는 데이터의 개수, T_i 는 스트레스가 있는 데이터를 스트레스가 있다고 정상적으로 탐지한 데이터의 개수, N_i 는 스트레스가 없는 데이터의 개수, P_i 는 스트레스가 없는 데이터를 스트레스가 있는 상황으로 잘못 탐지한 데이터의 개수, F_i 는 스트레스가 있는 데이터를 스트레스가 없다고 잘못 판단한 데이터의 개수를 의미한다.

실험 결과는 Table 2와 같으며, 선로전환기의 SDR은 98.19%, FPR과 FNR은 각각 2.00%, 1.81%라는 안정적인 실험결과를 확인하였다.

Table 2. Experimental performance measurement for stress detection

SDR	FPR	FNR
98.19%	2.00%	1.81%

5. 결 론

본 논문에서는 선로전환기의 선로 전환 시 발생하는 작동 소리정보를 이용하여 선로전환기의 스트레스를 탐지하는 프로토타입의 시스템을 제안하였다. 제안된 시스템은 먼저, 선

로전환기 작동 시 발생하는 소리를 취득하였다. 둘째, 취득한 소리정보를 이용하여 time domain과 frequency domain에서 다양한 소리 자질들을 추출한 후 AFSSA를 이용하여 스트레스 탐지에 효과적인 최적의 자질 부분집합을 선택하였다. 마지막으로 선택된 자질 벡터를 이진 분류기인 SVM에 적용하여 선로전환기의 스트레스 유무를 탐지하였다. 실제 테스트를 위해 수집한 소리 데이터 셋을 이용하여, 본 논문에서 제안하는 소리정보 기반의 선로전환기 스트레스 탐지 시스템의 성능을 실험적으로 검증하였다.

향후 연구 과제로는 본 연구에서 제안된 프로토타입의 시스템을 실제 세계에서 구현·운용하기 위한 구체적인 후속 연구들이 요구되고, 소리 데이터뿐만 아니라 전기적 신호 데이터도 동시에 고려하는 멀티모달 기반의 융합 연구가 기대된다.

References

- [1] J. H. Lee and Y. K. Kim, "A study on switching power measurement of an electrical point machine using a sensor," *Journal of the Korean Society for Railway*, Vol.18, No.4, pp.335-343, 2015.
- [2] J. H. Lee, Y. K. Kim, and J. Y. Park, "A study on the field application of switching power measurement by using sensor in electrical point machine," *The Transactions of the Korean Institute of Electrical Engineers*, Vol.64, No.7, pp.1130-1136, 2015.
- [3] C. S. Kim and G. H. Kang, "Fatigue analysis of reduction gears unit in rolling stock considering operating characteristics," *Journal of the Korea Academia Industrial Cooperation Society*, Vol.12, No.3, pp.1085-1090, 2011.
- [4] W. Jin, Z. Shi, D. Siegel, P. Dersin, C. Douzich, M. Pugnalmi, and J. Lee, "Development and evaluation of health monitoring techniques for railway point machines," in *Prognostics and Health Management 2015 IEEE Conference*, pp.1-11, 2015.
- [5] M. Vileiniskis, R. Remenyte-Priscott, and D. Rama, "A fault detection method for railway point systems," in *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, Vol.230, No.3, pp.852-865, 2016.
- [6] 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.
- [7] 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.
- [8] 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.

- [9] 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.
- [10] J. Lee, L. Jin, D. Park, Y. Chung, and H. Chang, "Acoustic features for pig wasting disease detection," *International Journal of Information Processing and Management*, Vol.6, No.1, pp.37-46, 2015.
- [11] J. Lee, B. Noh, S. Jang, D. Park, Y. Chung, and H.-H. Chang, "Stress detection and classification of laying hens by sound analysis," *Asian-Australasian Journal of Animal Sciences*, Vol.28, No.4, pp.592-598, 2015.
- [12] S. Theodoridis and K. Koutroumbas, "Pattern Recognition," 4th ed, Oxford: Academic Press, 2009.
- [13] J. Han, M. Kamber, and J. Pei, "Data Mining: Concepts and Techniques," 3rd ed, San Francisco: Morgan Kaufmann Publishers, 2012.
- [14] 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.



최 용 주

e-mail : aaa928@korea.ac.kr
 2011년~현 재 고려대학교
 컴퓨터정보학과 학사과정
 관심분야: 빅데이터, 기계학습, 인공지능,
 데이터마이닝



이 종 욱

e-mail : eastwest9@korea.ac.kr
 2002년 고려대학교 전산학과(학사)
 2005년 고려대학교 전산학과(석사)
 2014년 고려대학교 전산학과(박사)
 2014년~현 재 고려대학교
 컴퓨터정보학과 초빙교수

관심분야: 딥러닝, 기계학습, 멀티미디어 마이닝, 융합 IT



박 대 희

e-mail : dhpark@korea.ac.kr
 1982년 고려대학교 수학과(학사)
 1984년 고려대학교 수학과(석사)
 1989년 플로리다 주립대학 전산학과(석사)
 1992년 플로리다 주립대학 전산학과(박사)

1993년~현 재 고려대학교 컴퓨터정보학과 교수

관심분야: 데이터마이닝, 인공지능, 융합 IT



이 종 현

e-mail : 7n87n8ljh@sehwa.biz
 2014년 우송대학교 철도시스템학과(석사)
 2015년~현 재 우송대학교
 철도시스템학과 박사과정
 현 재 ㈜세화 대표이사
 관심분야: 철도 신호, 선로전환기, 열차제어



정 용 화

e-mail : ychungy@korea.ac.kr
 1984년 한양대학교 전자통신공학과(학사)
 1986년 한양대학교 전자통신공학과(석사)
 1997년 U. of Southern California(박사)
 1986년~2003년 한국전자통신연구원
 생체인식기술연구팀(팀장)

2003년~현 재 고려대학교 컴퓨터정보학과 교수

관심분야: 병렬처리, 영상처리, 융합 IT



김 희 영

e-mail : starkim@korea.ac.kr
 1991년 고려대학교 수학과(학사)
 1995년 고려대학교 통계학과(석사)
 2002년 고려대학교 통계학과(박사)
 2013년~현 재 고려대학교 응용통계학과
 부교수

관심분야: Martingales, Queueing theory, Markov process,
 Financial time series analysis



윤 석 한

e-mail : shy5406@sehwa.biz
 1977년 고려대학교 전자공학과(학사)
 1985년 한국과학기술원 전산학과(석사)
 1995년 고려대학교 전자공학과(박사)
 현 재 ㈜세화 부설연구소 연구소장
 관심분야: 철도 신호 시스템, 빅데이터
 시스템, U-컴퓨팅