

소리정보와 DNN을 이용한 선로전환기의 비정상 상황 분류

노병준*, 이종욱*, 박대희†, 정용화*, 김희영**, 윤석한***

*고려대학교 컴퓨터정보학과

**고려대학교 응용통계학과

***(주)세화

e-mail:{powernoh, eastwest9, dhpark, ychungy, starkim}@korea.ac.kr, shy5406@sehwa.biz

Anomaly Classification of Railway Point Machine Using Sound Information and DNN

Byeongjoon Noh*, Jonguk Lee*, Daihee Park*, Yonghwa Chung*,
Heeyoung Kim**, SukHan Yoon***

*Dept. of Computer Information Science, Korea University,

**Dept. of Applied Statistics, Korea University,

***Sehwa Company

요 약

최근 철도 산업의 비중이 증가함에 따라 열차의 안정적인 주행이 그 어느 때보다 중요한 이슈로 부각되고 있다. 특히, 열차의 진로 변경을 위한 핵심 요소인 선로전환기의 결함은 열차의 사고와 직결되는 장비 중 하나로서, 그 이상 여부를 사전에 인지하여 선로전환기의 안정성을 확보하기 위한 유지보수의 지능화 시스템이 필요하다. 본 논문에서는 선로전환기의 작동 시 발생하는 소리정보를 활용하여 선로전환기의 비정상 상황을 분류하는 시스템을 제안한다. 제안하는 시스템은 먼저, 선로전환기의 상황별 소리를 수집하고, 다양한 소리정보를 추출하여 특징 벡터를 생성한다. 다음으로, 딥러닝 모델 중 하나인 DNN(Deep Neural Network)을 이용하여 선로전환기의 비정상 상황을 분류한다. 실제 선로전환기의 전환 시 발생하는 소리 데이터를 기반으로 DNN의 파라미터에 따른 다양한 실험을 수행한 결과, 약 93.10%의 정확도를 갖는 안정적인 DNN 모델을 설계하였다.

1. 서론

최근 철도 산업의 비중이 증가함에 따라 열차의 안정적 주행이 그 어느 때보다 중요한 이슈로 부각되고 있다[1]. 2011년 중국에서 열차의 탈선·추락으로 약 100여명의 사상자가 발생하였고, 2013년 산티아고에서 열차의 탈선으로 막대한 피해가 발생하는 등 열차의 사고는 막대한 경제적 피해와 인명피해를 야기함에 따라 열차의 안정성이 더욱 강조되고 있다[2]. 특히, 열차의 진로를 변경하는 핵심 장치인 선로전환기의 결함은 열차의 탈선 및 충돌과 직결되는 요소들 중 하나로서, 철도시스템 가운데 안전상 가장 유의해야하는 설비 중 하나이다[3]. 따라서 열차의 안정적인 주행을 위하여 선로전환기의 이상 여부를 사전에 인지함으로써 선로전환기의 안정성을 확보하기 위한 유지보수의 지능화 시스템이 필요하다.

이에 따라, 선로전환기의 결함을 조기에 탐지하고자 하는 연구가 철도 선진국을 중심으로 활발하게 진행되고 있다. 그 예로써, Eker 등[4]은 선로전환기를 구동시키는 모터의 전류측정 센서 데이터로부터 특징정보들을 취득하고, PCA(Principal Components Analysis)와 SVM(Support Vector Machine) 기계학습 방법을 활용하여 선로전환기의

이상 여부를 탐지하였다. 또한, Asada 등[5]은 선로전환기의 전기적 신호를 이용하여 선로전환기의 모니터링 시스템을 제안하였다. 이상에서 살펴본 바와 같이, 선로전환기에 관련된 최근의 연구들은 대부분 선로전환기의 전기적 신호를 기계학습 기반의 방법론을 활용하여 문제를 해결하고자 함을 알 수 있다. 반면, Lee 등[6]은 선로전환기의 실제 구동 시 발생하는 소리로부터 MFCC(Mel-Frequency Cepstrum Coefficients) 소리 정보 추출하고, SVM을 이용하여 선로전환기의 이상 상황을 탐지하는 연구를 진행하였다. 이는 전기적 신호를 주요 입력으로 하는 선로전환기의 현재까지의 연구영역에서 소리분석을 활용한 연구의 가능성을 보여준 매우 참신한 연구결과이다.

본 논문에서는 최근 음성인식과 영상인식을 비롯한 다양한 패턴인식 분야의 성능 향상을 이끄는 중요한 인공지능 기술 중 하나인 딥러닝의 DNN(Deep Neural Network) 모델[7, 8]을 활용하여 선로전환기의 작동 시 발생하는 소리 정보로부터 선로전환기의 비정상 상황을 분류하는 시스템을 제안한다. 제안하는 시스템은 먼저, 선로전환기의 작동 시 발생하는 소리정보를 수집하고, 다양한 소리특징들을 추출하여 특징 벡터를 구성한다. 다음으로, DNN 모델을 통해 선로전환기의 비정상 상황을 분류하여 유지보수 관리자에게 전달하도록 설계하였다. 본 논문에서 탐지 및 분류

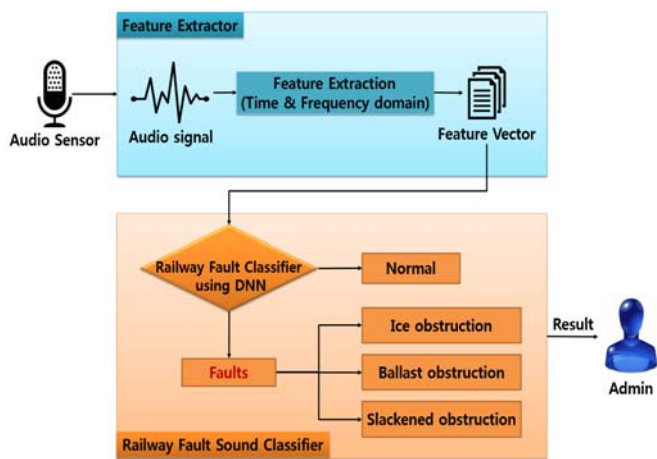
† 교신저자:dhpark@korea.ac.kr

하고자 하는 선로전환기의 비정상 상황들은 1) 선로전환레일 사이에 자갈이 낀 경우; 2) 열하의 온도 및 폭설로 인해 눈이 끼어 얼음이 된 경우; 3) 선로전환기의 나사가 풀린 경우로 정의한다.

본 논문의 구성은 다음과 같다. 2장에서는 본 연구에서 제안하는 소리정보를 활용한 DNN 기반의 선로전환기 비정상 상황 분류 시스템에 대해 설명한다. 3장에서는 제안한 방법을 적용한 실험결과 및 성능을 비교분석하고, 마지막으로 4장에서 본 연구의 결론을 맺는다.

2. 소리정보와 DNN을 이용한 선로전환기 비정상 상황 분류 시스템

본 논문에서 제안하는 선로전환기의 비정상 상황 분류 시스템은 그림 1과 같이 소리특징 추출 모듈과 선로전환기의 비정상 상황 분류 모듈로 구성된다.



(그림 1) 선로전환기의 비정상 상황 분류 시스템

2.1 소리특징 추출 모듈

소리특징 추출 모듈에서는 먼저, 소리 수집 센서(마이크)로부터 선로전환기 동작의 시작과 완료사이에 발생하는 소리를 수집한다. 다음으로, 선로전환기의 동작 소리로부터 time domain 및 frequency domain에서의 다양한 소리특징 정보를 추출하여 특징 벡터를 획득한다.

2.2 선로전환기의 비정상 상황 분류 모듈

선로전환기의 비정상 상황 분류 모듈에서는 획득한 소리 특징 벡터를 활용하여 선로전환기의 정상 및 세 가지 비정상 상황들(얼음이 낀 경우, 자갈이 낀 경우, 나사가 풀린 경우)을 멀티 클래스 분류 문제로 정의하여, DNN 모델을 이용하여 비정상 상황들을 탐지 및 분류한다.

3. 실험 및 결과 분석

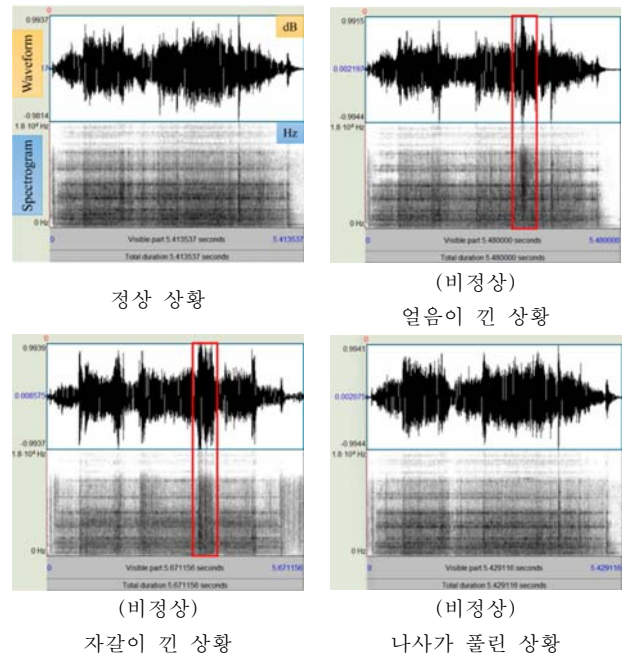
3.1 실험 설계

본 절에서는 실험을 위한 데이터 소개 및 DNN 학습 모델을 이용한 실험 방법에 관하여 설명한다. 먼저, 실험을

위한 소리 데이터는 대전광역시 유성구에 위치한 (주)세화 연구소에 설치된 선로전환기의 테스트베드로부터 그림2와 같이 정상 상황, 자갈이 낀 상황, 얼음이 낀 상황, 나사가 풀린 상황에 대한 환경을 구성하고 소리를 수집하였다. 소리 데이터 수집 후 Adobe Audition 3.0을 통해 선로전환기의 작동 소리를 분할하여 정상 상황 150개, 비정상 상황 430개(자갈 140개, 얼음 140개, 나사 150개)의 소리 데이터를 획득하였다. 각 상황별 획득한 데이터의 파형과 스펙트로그램의 예시는 그림 3과 같다.



(그림 2) 선로전환기의 비정상 상황 환경 구성



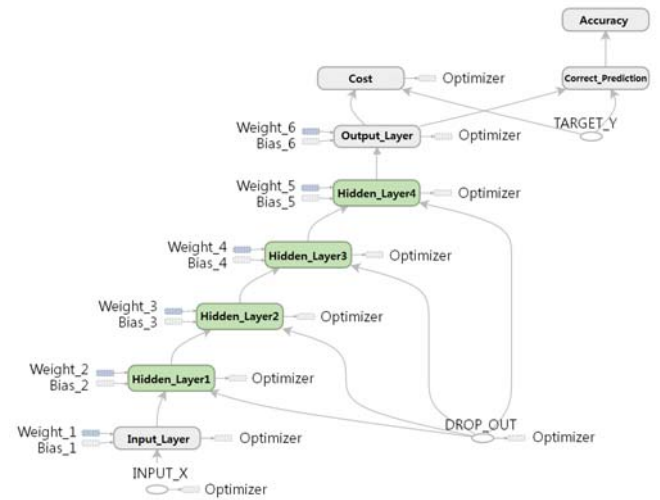
(그림 3) 선로전환기의 상태에 따른 파형 및 스펙트로그램

선로전환기의 비정상 상황 분류를 위하여, 본 실험에서는 최근 구글(google)사에서 개발한 오픈소스 기계학습 엔진인 TensorFlow를 활용하여 DNN 구조를 설계하고 실험을 진행하였다[9]. TensorFlow는 기존의 기계학습 방법론들의 수치적인 계산을 데이터 그래프의 형태로 표현할 수 있다는 특징을 가지며, python 기반의 응용 프로그래밍 인터페이스를 제공하여 구현이 비교적 쉽다는 장점을 가진다.

본 실험에서는 선로전환기의 비정상 상황 분류에 최적화된 DNN 모델을 획득하기 위하여 DNN 모델의 다양한 입

력 파라미터들 중에서 초기값 설정 방법, 활성화 함수의 종류, dropout 비율에 따른 정확도를 측정하고 성능비교 실험을 수행하였다. 먼저, 초기값 설정 방법은 정규분포를 갖는 랜덤초기화 방법과 각 계층의 입력노드와 출력노드의 수에 의존하여 초기값을 설정하는 방법인 Xavier 초기화 방법[10]을 통해 신경망 모델의 성능을 비교하였다. 다음으로 활성화 함수의 종류와 관련된 실험에서는, 신경망 모델에서 널리 사용되는 sigmoid 함수와 ReLU(Rectified Linear Unit) 함수를 비교하여 선로전환기의 비정상 상황 분류에 적합한 모델을 획득하고, 성능을 비교하였다. Sigmoid 함수를 사용하는 경우는 신경망이 깊어질수록 오류역전과 과정에서 경사도가 완만해지는 문제(vanishing gradient)[11]가 발생할 수 있다. 반면, ReLU 함수는 신경망의 깊이가 깊은 경우에도 안정적인 성능을 확보할 수 있다. 마지막으로, dropout의 비율에 따른 DNN 모델의 성능을 측정하고 비교하였다. Dropout 기법[12]은 신경망 모델의 과적합(over-fitting)의 영향을 완화시키는 방법 중 하나로써, 학습 과정에서 임의의 노드를 배제한 후 학습을 진행하는 신경망 모델 학습 기법이다.

설정하였다.



(그림 4) TensorBoard를 활용한 DNN 모델의 구조

3.2 소리특징 추출 결과

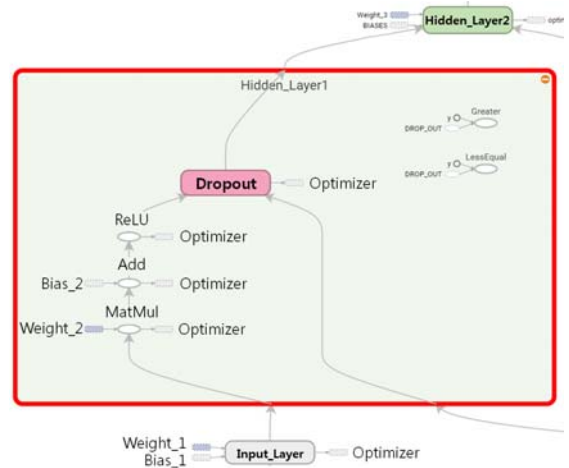
소리특징 추출에는 PRAAT 5.3.52를 사용하였으며, 그 결과 Time domain 특징 16개와 Frequency domain 특징 48개를 추출하였다. 추출된 특징들은 다음과 같다.

● Frequency domain (48개)

Formant 1~9, PSD(Power Spectral Density) 1~39 (100~4,000Hz 구간에서 100Hz 단위로 추출)

● Time domain (16개)

RMS(Root Mean Square), ABE(Absolute Extremum), Intensity, Harmonicity, Power, Energy, Shimmer Parameter - local, ShdB, APQ3, APQ5, DDA, Jitter Parameter - local, Absolute, RAP, PPQ5, DDP



(그림 5) 은닉 계층의 내부 구조

3.3 선로전환기의 비정상 상황 분류결과 및 성능비교 분석

선로전환기의 비정상 상황 분류를 위한 DNN 모델은 입력 계층, 출력 계층, 그리고 4개의 은닉 계층으로 구성되며, 각 은닉 계층마다 512개의 노드로 구성된다. 실험에 사용된 DNN 모델을 TensorBoard로 표현한 구조는 그림 4와 같으며, 은닉 계층의 내부 구조는 그림 5와 같다. 모델 학습에는 정상 상황의 소리데이터와 비정상 상황의 소리데이터를 각각 70%(406개), 테스트에는 나머지 30%(174개)를 사용하였으며, 학습율(learning rate)과 반복 횟수(epoch)는 모든 실험 케이스에 대해 각각 0.003과 3000으로 동일하게 설정하고 실험을 진행하였다.

실험 결과, 표 1과 같은 결과를 획득하였으며 정규분포를 갖는 랜덤 초기화 방법과 활성화 함수로 sigmoid 함수를 사용하고, dropout을 사용하지 않은 경우를 기준 모델로

<표 1> DNN의 파라미터에 따른 성능 비교

	Weight Initialization	Activation Function	Dropout Ratio	Accuracy
	Normal			
Baseline	distributed random	sigmoid	0	75.86%
Case 1	Xavier	sigmoid	0	77.83%
Case 2	Xavier	sigmoid	0.1	77.01%
Case 3	Xavier	sigmoid	0.2	78.16%
Case 4	Xavier	sigmoid	0.3	72.41%
Case 5	Xavier	sigmoid	0.4	68.96%
	Normal			
Case 6	distributed random	ReLU	0	83.57%
Case 7	Xavier	ReLU	0	90.03%
Case 8	Xavier	ReLU	0.1	92.51%
Case 9	Xavier	ReLU	0.2	93.10%
Case 10	Xavier	ReLU	0.3	90.80%
Case 11	Xavier	ReLU	0.4	87.35%

분석 결과를 살펴보면, 초기값 설정 방법과 관련된 실험에서는 Xavier 초기화 방법을 사용하는 경우가 기존의 랜덤 초기화 방법보다 우수한 성능을 보임을 알 수 있다 (Baseline-Case1, Case6-Case7). 다음으로 활성 함수와 관련된 실험에서는 ReLU 함수를 사용하는 경우가 sigmoid 함수를 사용한 모델과 비교하여 각각 약 7.7% (Baseline-Case6)와 약 12.2%(Case1-Case7)의 성능 향상이 있음을 알 수 있다. Dropout의 비율과 관련된 실험에서는 Case 9와 같이 dropout 비율이 0.2인 경우가 약 93.10%로 가장 좋은 정확도를 보임을 알 수 있다. 성능 분석 결과를 종합하면, Xavier 초기화 방법 및 ReLU 함수를 사용하는 경우가 기존 모델에 비해 14%의 성능향상이 있었으며, dropout 비율을 0.2로 설정한 경우가 선로전환기의 비정상 상황 분류에 최적화된 DNN 모델임을 확인하였다.

4. 결론

본 논문에서는 DNN을 활용하여 선로전환기의 작동 시 발생하는 소리정보로부터 선로전환기의 비정상 상황들을 탐지 및 분류하는 시스템을 제안하였다. 제안한 시스템은 먼저, 상황에 따른 선로전환기의 작동 소리정보를 수집하고, 다양한 소리 특징정보들을 추출하여 특징벡터를 획득한다. 다음으로 DNN 모델을 통해 선로전환기의 비정상 상황을 분류하여 유지보수 관리자에게 전달하도록 설계하였다. 실험을 통해 선로전환기의 비정상 상황 분류에 최적화된 DNN 입력 파라미터들을 획득하였다. 특히, Xavier 초기화 방법 및 ReLU 함수를 사용하는 경우가 기존 모델 대비 약 14%의 성능 향상이 있었으며, 최종적으로 dropout 비율이 0.2인 경우, 약 93.10%의 정확도를 갖는 안정적인 결과를 획득하였다. 제안된 시스템을 통해 선로전환기의 비정상 상황을 조기에 탐지 및 분류하여 선로전환기의 결함을 사전에 인지하여 관리자가 능동적이고 지능적으로 선로전환기의 유지보수 활동을 할 수 있을 것으로 기대된다.

감사의 글

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

- [1] P. Liu, L. Yang, Z. Gao, S. Li, and Y. Gao, "Fault tree analysis combined with quantitative analysis for high-speed railway accidents," *Safety Science*, Vol. 79, pp. 344-357, 2015.
- [2] M. Guo, W. Wei, G. Liao, and F. CHu, "The impact of personality on driving safety among Chinese high-speed railway drivers," *Accident Analysis & Prevention*, Vol. 92, pp. 9-14, 2016.
- [3] C. Kim and G. 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] 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.
- [5] 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.
- [6] 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.
- [7] J. Schmidulber, "Deep learning in neural networks: an overview," *Neural Network*, Vol. 61 pp. 85-117, 2015.
- [8] G. E. Dahl, T. N. Sainath, G. E. Hinton, "Improving deep neural networks for LVCSR using rectified linear units and dropout," *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 8609-8613, 2013.
- [9] <http://www.tensorflow.org> [Accessed : 09. Sep. 2016]
- [10] K. He, X. Zhang, S. Ren, and J. Sun, "Delving deep into rectifiers: surpassing human-level performance on imagenet classification," *Proceedings of the IEEE International Conference on Computer Vision*. pp. 1026-1034, 2015.
- [11] A. L. Maas, A. Y. Hannum, and A. Y. Ng., "Rectifier nonlinearities improve neural network acoustic models," *Proc. ICML*. Vol. 30, No. 1, 2013.
- [12] J. Li, X. Wang, and B. Xu, "Understanding the dropout strategy and analyzing its effectiveness on LVCSR," *2013 IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 7614-7618, 2013.