

# 딥러닝을 이용한 엔진음 분류 시스템에 대한 연구

허진<sup>1</sup>, 이재명<sup>2</sup><sup>1</sup>한국공학대학교 전자공학과 학부생<sup>2</sup>한국공학대학교 전자공학과 교수

b23602@tukorea.ac.kr, lee@tukorea.ac.kr

## A Study on the Engine Sound Classification System Based on Deep Learning

Jin Heo<sup>1</sup>, Jaemyoung Lee<sup>1</sup><sup>1</sup>Dept. of Electronic Engineering, Tech University of Korea

### 요 약

엔진을 정확하게 분류하는 것은 엔진의 수리 및 유지보수에 있어 중요한 과제 중 하나이다. 하지만 청음훈련을 통해 이를 숙달하는데는 오랜 시간이 걸리고, 엔지니어의 주관적 요인에 큰 영향을 받는다. 이를 해결하기 위해, 엔진의 음향적 특성을 이용한 머신러닝을 통해 엔진을 구분하는 시스템을 제안한다.

### 1. 서론

엔진의 소음을 이용해 엔진을 분류하는 것은 청음훈련을 통해 고도로 숙달된 엔지니어들의 노하우로 꼽힌다. 청음훈련을 통해 엔진을 구분하는 것은 긴 시간과 노력이 필요할 뿐만 아니라 엔지니어의 피로도, 집중력 등 주관적 요인에 영향을 받는다. 본 연구에서는 엔진의 음향적 특성을 이용해 신경망을 훈련시켜 엔진을 구별하는 시스템을 제안한다.

### 2. 음성인식 및 딥러닝을 이용한 엔진 분류 방법

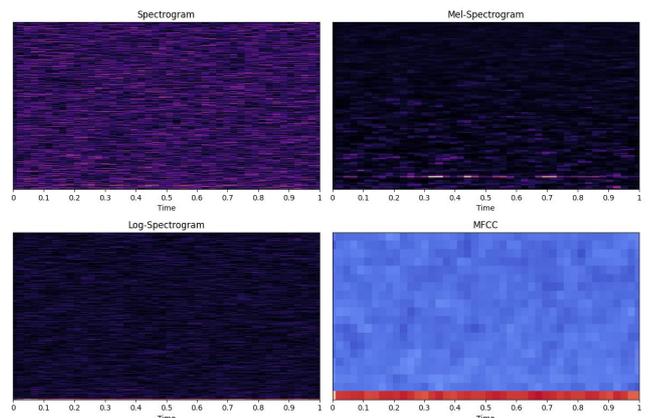
#### 2.1 시뮬레이션 접근방법

본 연구에서는 다양한 형태의 입력 데이터를 이용해 다양한 딥러닝 모델의 성능을 비교한다. 먼저, 엔진 분류에 사용될 엔진음을 특정 간격으로 자른다. 그 후, 특징 추출 단계를 통해 엔진음의 특징을 추출한다. 추출한 특징을 바탕으로, 딥러닝 모델을 사용해 엔진을 분류한다. 입력 데이터는 선형 데이터, 로그를 취한 데이터를 이용한 Spectrogram, MFCC(Mel-Frequency Cepstral Coefficient)등을 사용하였다.

#### 2.2 특징 추출

음성 신호를 미가공 데이터로 학습하게 되면 데이터 용량이 너무 커질 뿐 아니라, 음성 신호의 주파수

영역 특성을 제대로 반영하지 못한다. 따라서 음성 데이터를 특정 구간으로 잘라 푸리에 변환을 적용한 후, Magnitude를 Log Scale로 변환해 Spectrogram을, 이에 Mel-Filter를 적용해 Mel-Spectrogram을 Mel-Spectrogram에 DCT(Discrete Cosine Transform)를 적용해 MFCC를 만들 수 있다. 최소값이 -1인 음성 데이터에 2를 더해 로그를 취한 후 Spectrogram을 추출해 Log-Spectrogram 특징을 추출하였다.



<그림 1> 특징 추출 이미지

#### 2.3 딥러닝을 이용한 엔진 분류

추출한 특징을 바탕으로 딥러닝 모델을 통해 엔진 분류를 진행한다. MLP(multi-layer perceptron) 모델과 CNN(Convolutional neural network) 모델을 통해 엔진을 분류하였다.

3. 시뮬레이션 결과

3.1 데이터 수집 및 특징추출

<표 1> 엔진음 데이터 수집

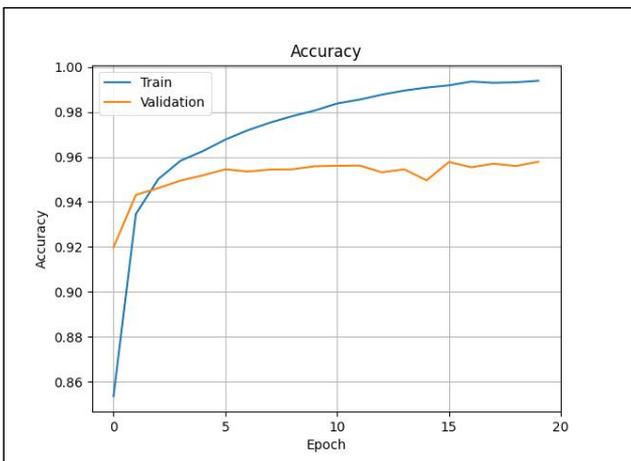
엔진명	RPM	수집방식
현대 G	1300	실제
현대 6.8Liter LPG	1300	실제
현대 G6BA	1300, 1800, 2300	가상
BMW N62	1300, 1800, 2300	가상
BMW M5	1300, 1800, 2300	가상
BMW S85	1300, 1800, 2300	가상
Ferari 3.8L V8	1300, 1800, 2300	가상
Ford GAA	1300, 1800, 2300	가상
Ford Cologne V6	1300, 1800, 2300	가상
GM LS1	1300, 1800, 2300	가상

엔진음의 데이터 수집을 위해 가상 엔진과 실제 엔진음을 병용하였다. 1300, 1800, 2300 RPM에서의 엔진음을 각각 5분가량 수집하였으며, 사용한 엔진은 <표 1>와 같다. 또한, 모델의 성능 향상을 위해 노이즈를 추가하였다. 화이트 노이즈와 가우시안 노이즈를 병용하였다. 엔진음을 각각 0.5초로 자른 후, 자른 데이터에서 특징을 추출하였다.

3.3 모델 설계

MLP의 경우 karsoliya[1]의 경험적 모델 설계 방법과 같이 입력 데이터의 2/3개의 뉴런을 갖는 히든레이어를 3층으로 설계하였다. 손실 함수로는 categorical crossentropy, 활성화 함수로는 Adam, Learning rate는 0.0001을 사용하였으며, 20 Epoch만큼 학습을 진행하였다. CNN 모델의 경우, LeNet-5 모델을 사용하였으며, 20 Epoch만큼 학습을 진행하였다.[2].

3.3 학습 결과 및 평가



<그림 2> MFCC - MLP 학습 Accuracy

<표 2> 모델별 정확도 비교

	MLP	CNN
Spectrogram	99.29%	99.25%
Mel-Spectrogram	99.44%	99.26%
Log-Spectrogram	99.32%	99.14%
MFCC	95.39%	95.55%

모델별 정확도를 비교했을 때, Mel-Spectrogram-MLP의 경우가 가장 높은 정확도를 보였으며, MFCC로 특징추출을 한 경우 가장 낮은 정확도를 보였다. 이는 MFCC의 압축 특성으로 인해 노이즈를 제대로 분류하지 못한 것으로 보인다.

이외의 경우 모두 99%가 넘는 정확도를 보이며, 설계한 모델을 통해 엔진음을 이용한 엔진 구분 시스템이 정확하게 엔진을 구분할 수 있음을 확인하였다. Log-Spectrogram의 경우, 입력 신호의 크기 차이가 크지 않아 로그 스케일화의 장점인 신호의 작은 변화에 집중하는 특성이 발휘되지 못했다. 엔진음 녹음 시 급격하게 튀는 값이 존재한다면, Log Spectrogram이 타 특징추출에 비해 더 높은 성능을 보일 것으로 예상된다.

4. 결론

따라서 본 연구에서는 자동차의 엔진음을 이용해 엔진음을 분류하는 인공지능 모델을 설계하였으며, 이를 통해 효과적인 분류 모델을 생성하였다. 설계한 모델은 높은 정확도를 보이며 엔진음을 이용한 엔진 구분 시스템이 정확하게 엔진을 분류할 수 있음을 확인하였다

제안된 엔진 소음을 활용한 엔진 분류 시스템은 자동차 산업 및 유지보수 분야에서 유용하게 활용될 수 있다. 이를 이용해 기존의 청음훈련에 의존해 숙달되기까지 오랜 기간이 걸렸던 엔진 관리를 인공지능을 이용해 빠르게 판단할 수 있다

참고문헌

[1] Karsoliya, S. Approximating Number of Hidden Layer Neurons in Multiple Hidden Layer BPNN Architecture. Int. J. Eng. Trends Technol. 2012, 3, 714 - 717

[2] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner. Gradientbased learning applied to document recognition. Proceedings of the IEEE, 86(11):2278 - 2324, 1998