



CNN 기반 자동차검사소 환경에서의 전기차 주행 경고음 발생장치 특성 분석

김기후¹⁾ · 최봉석²⁾ · 정한석¹⁾ · 윤윤기¹⁾ · 김현준³⁾ · 윤경수^{*1)}

지능형자동차부품진흥원 전략기획본부¹⁾ · (재)경북IT융합산업기술원 미래차연구본부 전장부품연구센터²⁾ ·
한국교통안전공단 첨단자동차검사연구센터 첨단연구개발처소속³⁾

CNN-Based Analysis of Electric Vehicle Acoustic Vehicle Alerting System in Automotive Inspection Station Environments

Gihu Kim¹⁾ · Bongseok Choi²⁾ · Hanseok Jung¹⁾ · Yunki Yoon¹⁾ · Hyunjun Kim³⁾ · Gyeongsu Yoon^{*1)}

¹⁾Strategic Planning Division, Korea Intelligent Automotive Parts Promotion Institute,
201 Gukgasandanse-ro, Guji-myeon, Dalseong-gun, Daegu 43011, Korea

²⁾Automotive Electronics Components, Research Center, Gyeongbuk Institute of IT Convergence Industry Technology,
25 Gongdan 9-ro 12-gil, Jillyang-eup, Gyeongsan-si, Gyeongbuk 38463, Korea

³⁾Advanced R&D Department, Korea Transportation Safety Authority, Korea Advanced Vehicle Inspection Research Center,
288-7 Hyeoksin-ro, Gimcheon-si, Gyeongbuk 39660, Korea

(Received 28 October 2025 / Revised 31 October 2025 / Accepted 31 October 2025)

Abstract : The Acoustic Vehicle Alerting System (AVAS) is mandated by international regulations and included in periodic inspections as part of measures to ensure pedestrian safety with Electric Vehicles (EV). However, reliable verification is often hindered by high background noise in vehicle inspection environments. This study conducts an experimental analysis of AVAS signals obtained from six EV models and proposes a Convolutional Neural Network (CNN)-based classification method. The dataset is constructed using multi-position measurements, segmented into one-second samples, and converted into log-mel spectrogram with noise augmentation reflecting inspection-site conditions. Results showed robust performance, with some models achieving perfect recall, while others exhibited reduced accuracy due to spectral similarities. These trends were confirmed by Receiver Operating Characteristic (ROC), precision-recall, and Principal Component Analysis (PCA) evaluations. The proposed approach demonstrates strong classification capability under noisy conditions and offers practical implications for automated AVAS verification and vehicle-type identification. These features serve as a foundation for improving AVAS measurement methodologies and regulatory applications.

Key words : Electric vehicle(전기차), Acoustic vehicle alerting system(저소음자동차 경고음발생장치), Convolutional neural network(합성곱 신경망), Noise-robust classification(소음 환경 분류), Vehicle inspection automation(차량 검사 자동화)

Nomenclature

A VAS : acoustic vehicle alerting system
EV : electric vehicle
CNN : convolutional neural network
SNR : signal to noise ratio, dB
SPL : sound pressure lever, dB
PCA : principal component analysis

ROC : receiver operating characteristics curve
PRC : precision recall curve
VIC : vehicle inspection automation

Subscripts

i, j : spatial index
 k : feature map channel index

*Corresponding author, E-mail: kadbonow@kiapi.or.kr

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium provided the original work is properly cited.

l : layer index
 n_{class} : number of class

1. 서론

저소음 차량인 전기차의 접근에 대한 보행자 인지는 주로 시각과 청각에 의존한다. 그러나 인간의 유효 시야는 수평 약 180°, 수직 약 130°에 불과하며, 중심부의 ‘선명시야’는 약 4°의 좁은 원뿔형으로 제한된다. 또한, 눈썹, 뺨, 코 등 얼굴 구조로 인해 양안 시야가 비대칭적이어서 시각만으로는 저속 주행 전기차의 접근을 완벽하게 인지하기 어렵고, 사각지대가 발생하게 되나, 청각은 360° 전방위에서 정보를 취득할 수 있으며, 전후·수평·수직 평면에서의 3차원 위치 추적이 가능해 시각보다 넓은 범위를 감시할 수 있는 감각 채널로서 전기차 접근의 인지에 유리하다.¹⁾ 이러한 특성으로 인해 전기차 주행 경고음 발생장치(Acoustic Vehicle Alerting System, AVAS)는 저속 주행 시 보행자의 안전을 위협할 수 있는 상황을 방지하기 위해 도입되었다.

초기 전기차 보급 당시 차량의 정숙성은 장점으로 인식되었으나, 내연기관 차량에 비해 소음이 현저히 적어 특히 저속 주행 시 보행자(시각장애인, 어린이, 고령자, 주의가 분산된 보행자 등)의 차량 접근에 대한 인지가 어려웠다. 이에 따라 미국에선 2010년 12월 및 유럽 연합의 경우 2019년 7월부터 신규 전기차에 AVAS 장착을 의무화하여 법령을 시행 중이다. 차량의 AVAS용 스피커는 주로 차량 전면 범퍼나 엔진룸 내부에 설치되며, 가상의 엔진음을 발생시켜 보행자에게 차량의 접근을 청각적으로 인지시킨다. AVAS의 초기 방식은 엔진룸 내에 장착된 스피커를 통해 가상 엔진음을 재생하여, 보행자가 차량 접근을 청각적으로 인지하도록 하는 방법이 주로 사용되었다.²⁾

그러나 AVAS 스피커 크기의 한계로 저주파 재생 성능에 한계가 있었고, 재생 볼륨을 크게 높이기도 물리적·환경적 제약이 존재한다. 이와 함께, 스피커 장착 위치에 따른 방향별 인지성 편차가 발생하도록 다중 스피커를 사용하는 경우가 있으나, 이 경우에도 재생되는 소리가 실제 엔진/모터음과 달라 청감 이질감을 줄 수 있다.³⁾ 또한, 다중 스피커별로 개별 제어를 추가해야 하므로 원가 상승 문제가 발생하고, 전자제어유닛(ECU: Electronic Control Unit)가 음향 제어 연산을 처리하는 데 부하 증가 문제가 있다. 이에 더해, 가상 엔진음의 생성은 샘플링·합성 기반의 단순 재생이 주를 이루었으며, 주행 상황에 따른 세밀한 변조나 방향성 제어, 환경 적응형 출력 조절 기능이 부족하다.⁴⁾ 이러한 한계로 인해, 최근 연구개발에서는 사용자 및 브랜드 경험을 반영한 사운드 디자인

의 고도화, 상황인지와 적응형, 지향성 및 저주파 보강을 위한 방사 방식의 개선, 규정 정합성 내에서의 다변화 평가·시뮬레이션 환경의 체계화로 이루어지고 있다.

AVAS 사운드 디자인의 고도화는 단순 경고음을 넘어 심리음향 지표와 청취 실험을 결합해 ‘잘 들리며, 거슬리지 않는’ 외장음을 탐색하는 방향으로 소비자 선호 기반의 의미 속성 개발⁵⁾과 설계 지표화⁶⁾에 대한 연구들이 제안되고 있으며, 차량 속도·가속·조향 및 환경소음 등을 기반으로 실시간 음압/스펙트럼을 조정해 가청성과 불쾌감 간 균형을 맞추려는 시도가 증가하고 있다. 산업과 학회 전반에서 맥락 인지형 ML(Machine Learning) 응용이 확대되고 설계·튜닝 자동화에 ML을 결합하는 흐름으로 진행 중이며, 규제 측면에서도 비음향 대체 수단 논의 등을 상황 인지형(Context-aware), 적응형(Adaptive) 요건을 다루는 연구 하고 있다.⁷⁾

또한, 지금까지의 AVAS 관련 연구와 개발은 일반 도로 환경 또는 실험실 조건(무향실, 반무향실 등)에서 가청성, 심리 음향 평가에 집중되었다. 그러나 실제 차량 검사를 위한 자동차검사소는 배경 소음이 높은 환경으로 AVAS 신호가 주변 기계음과 작업 소음에 의해 부분적인 마스킹(Masking)으로 인지성이나 차종 간 음색 식별성이 크게 저하되어, AVAS에 대한 고장을 판별하기 위한 검사 유무에 영향을 미친다.

특히 차량의 AVAS는 제조사별로 음색과 음의 세기를 다르게 개발하고 있으므로, 이에 따라 정상 출력 조건 또한 차종별로 다르게 설정될 필요가 있다. 그러나 현재 검사소 환경에서는 차대 동력기 및 주변 장비로 인한 배경 소음이 AVAS 신호보다 크게 작용하여, 단순 청각 판별에 의존하는 기존 검사 방식으로는 고장 여부를 판별하기 어렵다.

본 논문에서는 차종별 AVAS 음색 특성과 주파수 분포를 분석하여 차량별 주행 경고음 특성을 도출하고, 해당 특성에 적합한 CNN 기반 분류 모델을 설계 및 제안한다. 제안한 모델의 성능은 혼동행렬(Confusion matrix)과 F1-점수(F1-Score), 수신자 조작 특성 곡선(Receiver Operating Characteristic Curve, ROC)과 곡선 아래 면적(Area Under the Curve, AUC), 그리고 주성분 분석(Principal Component Analysis, PCA) 기반 시각화 방법들을 통해 검증한다.

2. 차량별 주행 경고음 특성

차량 주행 경고음은 제작사별 차량의 아이덴티티를 나타내는 음향으로 설계하며, 제작사 별, 차량별 다양한 주행 경고음으로 제작된다. 이러한 차량별 AVAS 특성 분석을 위해 1/3 옥타브 주요 대역과 음압레벨(dB(A))를 분석하였다.⁸⁻¹⁰⁾ 여기서, 1/3 옥타브 대역은 기준 주파수

에 대한 옥타브를 3구간으로 등비 분할하여 설정한 주파수 대역을 말하며, 인간 청각의 주파수 해상도를 표현하기 위해 음향 분석에 자주 사용되는 데이터이다. 음압레벨(dB(A))은 기준음압($20 \mu\text{Pa}$)에 대한 로그 스케일 데시벨로 환산한 값에, 인간의 청각 특성을 반영하기 위해 A-weighting 필터를 적용한 음압레벨을 의미한다.

2.1 차종별 AVAS 데이터 측정 위치

차량별 주행 경고음의 특성 분석을 위해 총 6 종의 차량(BONGO3_EV, IONIQ5, KONA_EV, KORANDO_EV, TESLA_Y, BMW3_PHEV)의 전면부 7 지점에서 AVAS 데이터 수집을 진행하였다.

측정 당시 배경소음의 등가소음도(LAeq)는 40 dB(A) ± 5로 이었으며, 전체 데이터는 6종의 차량에 대해 AVAS 모듈이 장착된 차량의 전면 기준 7지점을 50회씩 반복 측정하였다. 1회당 60초간 측정하여, 배경 소음과 AVAS의 구분을 위해 5초 간격으로 On, Off를 반복하며 측정한다. 차량의 데이터 측정 지점은 전면부 2지점, 하부 5지점이며, Fig. 1과 Table 1과 같다.




Fig. 1 AVAS Measurement Points. (a) Front(above ground), (b) Bottom(above ground), (c) Bottom(from bumper)

Table 1 AVAS Measuring distance

	Vertical position (cm)	Horizontal distance (cm)
Front (above ground)	55	10
	55	20
Bottom (above ground)	5	0
	10	0
Bottom (from bumper)	10	10
	10	0
	10	-10

2.2 차종별 AVAS 특성

본 논문에서 사용한 6개 전기차 차종(‘BONGO3_EV’, ‘IONIQ5’, ‘KONA_EV’, ‘KORANDO_EV’, ‘TESLA_Y’, ‘BMW3_PHEV’)의 AVAS 음향 특성을 1/3 옥타브 분석을 통해 비교한 결과, 차종별 Fig. 2와 같은 특성을 보인다.

‘BONGO3_EV’는 평균 79.5 dB(A)로 가장 높은 전체 음압을 보이며, 500 ~ 1,000 Hz 구간에서 두드러진 피크를 보여 강한 인지성을 나타낸다. ‘IONIQ5’는 74.3 dB(A)로 상대적으로 높은 음압을 가지며, 1,250 Hz 대역에서 뚜렷한 국소 피크가 나타나 중·고주파 강조 특성이 두드러진다. ‘KONA_EV’는 76.3 dB(A)로 전 대역에서 고른 분포와 측정 위치별 일관성이 확인되어, 인지성과 안정성을 동시에 확보한 패턴을 보이며, ‘KORANDO_EV’는 71.4 dB(A)로 낮은 편이나, 200 Hz와 1,000 Hz에서 국소적인 피크가 형성되어 중주파 강조형으로 분류된다.

‘TESLA_Y’의 경우 전체 음압이 낮음에도 불구하고 315 Hz 및 800 ~ 1,250 Hz에서 두 개의 피크가 관찰되며, 곡선이 완만한 형태로 엔진음 유사한 톤을 나타낸다. BMW3-PHEV는 평균 62.5 dB(A)로 가장 낮은 음압을 보이며, 그래프에서도 전반적인 곡선이 하단에 위치하고 저주파 중심의 분포와 일부 국소 피크가 나타나 내연기관음 모사 경향을 보인다.

‘BONGO3_EV’, ‘IONIQ5’, ‘KONA_EV’, ‘KORANDO_EV’의 경우 중·고주파 대역을 강조하여 보행자 인지성을 강화한 반면, ‘TESLA_Y’와 ‘BMW3_PHEV’ 차량은 브랜드 톤과 청감 쾌적성의 특징을 보이며, 저·중주파 중심의 설계를 보였다.

이러한 결과는 AVAS의 설계 방향이 인지성 중심 설계와 브랜드 톤 중심 설계로 양분됨을 보여준다. 본 연구에서는 이와 같은 차종별 스펙트럼 차이를 기반으로 CNN을 활용한 차량 분류 알고리즘을 제안한다.

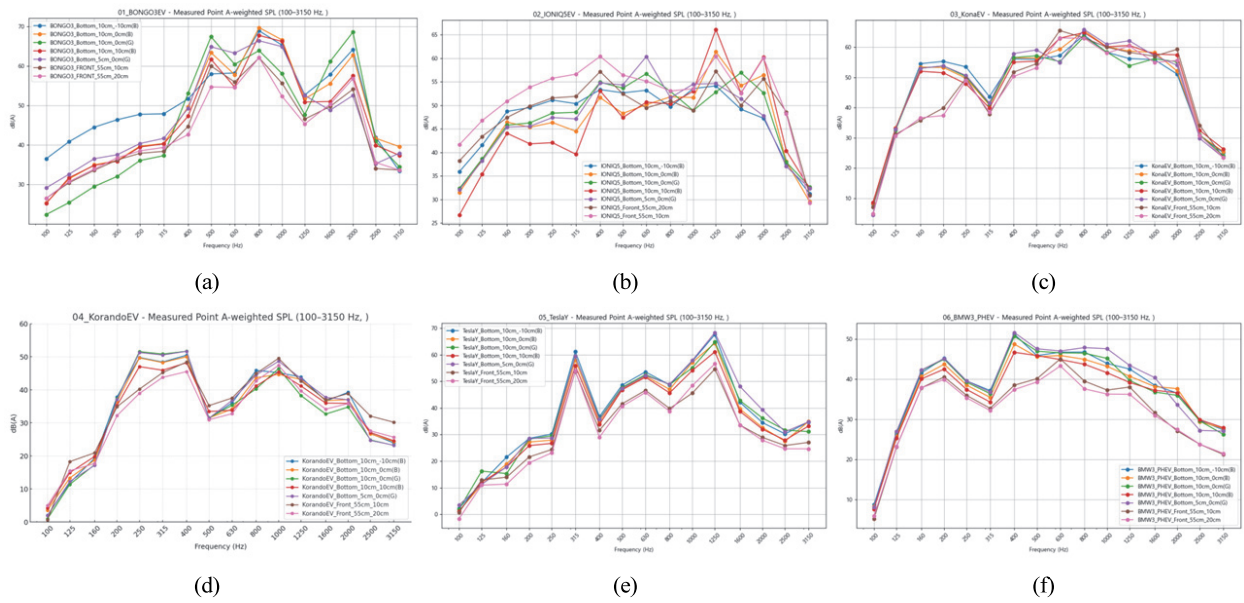


Fig. 2 Measurement of AVAS signal characteristics in 1/3 octave; (a) BONGO3_EV, (b) IONIQ5, (c) KONA_EV, (d) KORANDO_EV, (e) TESLA_Y, (f) BMW3_PHEV




Fig. 3 AVAS Data preprocessing workflow

3. CNN을 통한 전기차 주행 경고음 분류

차량별 AVAS 신호 분류를 위해 waveform 대신 log-mel spectrogram으로 변환하여 CNN 입력으로 사용한다.

Waveform은 높은 해상도를 가지지만 불필요한 잡음과 변동성이 커서 특징 추출의 효율이 낮고, 데이터 차원이 커 학습 효율이 떨어지는 한계가 있다.

반면 Log-mel spectrogram은 인간 청각의 주파수 인지 특성을 반영하여 시간-주파수 영역에서 음색과 에너지 분포를 명확히 표현할 수 있으며, 로그 변환을 통해 차량별 AVAS 신호의 미세한 차이를 효과적으로 나타낸다.

이러한 변환은 과정을 2차원 이미지 형태로 구조화하여 CNN의 공간적 패턴 특성을 활용할 수 있게 하며, 데이터 차원을 축소하여 학습 효율을 높이고 과적합 위험을 줄여주는 효과가 있어 AVAS의 음색과 주파수 특성




Fig. 4 Log-mel spectrogram examples with noise augmentation (SNR 5, 10, 15 dB) for CNN training; (a) Original, (b) SNR 5, (c) SNR 10, (d) SNR 15.

분석에 log-mel spectrogram을 사용한다.

3.1 데이터 수집 및 전처리

데이터 수집과 전처리는 Fig. 3과 같이 6종의 전기차에 대해 차량별 7지점(Fig. 1), 60초간 50회 AVAS 데이터 측정한다. 각 차량마다 1초 길이 세그먼트를 균등 간격으로 추출해 800개 원본 샘플을 구성하고, 학습 시 노이즈 환

경을 고려하여 Fig. 4와 같이 SNR 5/10/15 dB 잡음을 합성해 원본 포함 차량별 3,200개의 학습 데이터를 생성하였다. 테스트 데이터 셋은 실제 검사소 환경에서 취득한 데이터와, 검사소에서 측정된 배경소음(차대동력기, 압축기, 유압장치, 롤러 마찰음 등)을 합성하여 구성한다.

3.2 CNN 구조 설계

본 연구에서 설계한 CNN 구조는 입력된 Fig. 5와 같이 Log-mel spectrogram으로부터 차량별 AVAS의 고유 음향 특성을 추출하고, 이를 기반으로 차종 분류와 정상·비정상 판별을 수행하도록 구성된다. 네트워크는 크게 특징 추출부(Feature extraction), 전역 평균 풀링(Global average pooling), 그리고 분류기(Classifier head)의 세 부분으로 나뉜다.

먼저, 특징 추출부는 총 다섯 개의 합성곱 블록(ConvBlock)으로 구성된다. 각 블록은 합성곱(Convolution), 배치 정규화(Batch normalization), ReLU 활성화 함수로 이루어지며, 일부 블록에는 맥스풀링(Max pooling)과 Dropout이 결합된다. 채널 수는 32→64→128→192→256 순으로 증가하며, 마지막 블록에서는 풀링을 생략하여 고수준 특징 정보를 유지하였으며, 합성곱 연산은 다음과 같이 정의된다. 여기서, $W^{(l)}$ 과 $b^{(l)}$ 은 l 번째 층의 합성곱 커널과 편향을 의미하고, BN (Batch Normalization)은 배치 정규화를 나타낸다.

$$Y^{(l)} = ReLU(BN(W^{(l)} * X^{(l)} + b^{(l)})) \quad (1)$$

최종 특성맵(Feature map)에 대해 전역 평균 풀링(Global average pooling)을 적용하여 공간적 차원을 제거하고 채널별 평균값을 벡터 형태로 변환하고, 도출된 특징 벡터는 분류기의 입력으로 전달된다.

$$g_k = \frac{1}{h \cdot w} \sum_{i=1}^h \sum_{j=1}^w F_{k,i,j}, k = 1, \dots, 256 \quad (2)$$

분류기(Classifier head)는 두 단계의 완전연결층(Fully connected layer)으로 구성한다. 첫 번째 층은 256→128차원으로 축소하며 ReLU 활성화와 Dropout을 적용하여 일반화 성능을 높인다. 두 번째 층은 128 → n_{class} 차원으로 매핑되고 출력은 소프트맥스(Softmax) 함수를 통해 각 차량 클래스에 대한 확률로 반영되며, 다중 클래스 분류를 위한 교차 엔트로피 손실을 사용하는 구조로 설계한다.

모델 학습은 다중 클래스 분류를 위한 교차 엔트로피(Cross entropy) 손실을 사용한다.

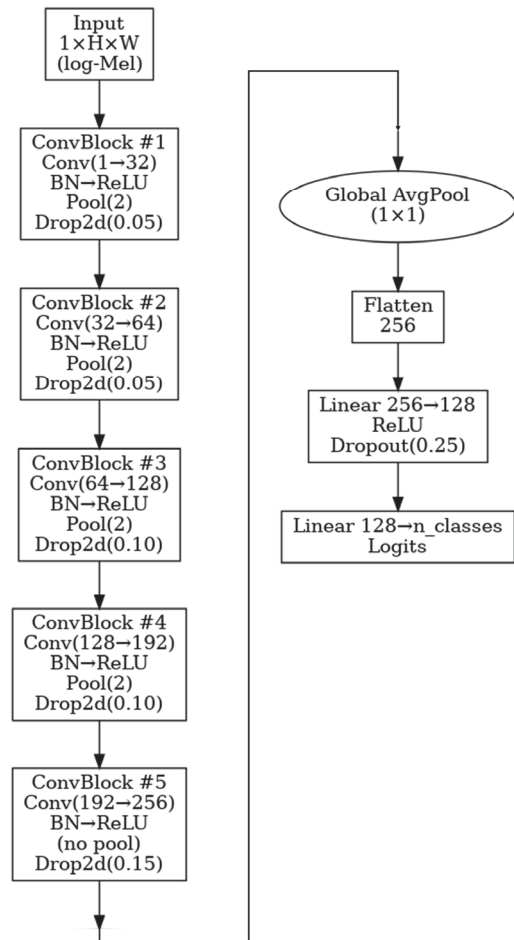


Fig. 5 CNN architecture for AVAS classification using log-mel spectrogram inputs.

$$\hat{y}_i = \frac{\exp(z_i)}{\sum_{j=1}^{n_{class}} \exp(z_j)}, i = 1, \dots, n_{class} \quad (3)$$

이와 같은 구조를 통해 제안된 CNN은 Log-mel spectrogram 상의 주파수-시간 패턴을 효과적으로 학습하고, 차종별 AVAS의 고유 특성 기반 주변 소음이 높은 환경에서도 차량의 분류를 할 수 있도록 설계한다.

4. 실험 결과 및 분석

본 논문에서 제안한 CNN 모델의 성능은 실제 검사소 환경에서 취득한 AVAS 데이터와 배경소음(차대동력기, 압축기, 유압장치, 롤러 마찰음 등)을 합성한 테스트 데이터 셋을 이용하여 검증한다. 입력값은 800개의 1초 단위의 Log-mel spectrogram을 병합하여 사용한다.

4.1 Confusion Matrix 분석

혼동행렬 (Confusion Matrix) 분석은 분석은 분류 모델의 예측 결과를 실제 라벨과 비교하여 정확도 · 오분류 경향을 시각적으로 평가하는 방법이다. 행은 실제 클래스, 열은 예측 클래스를 나타내며, 이를 통해 특정 클래스 간 혼동 정도와 분류 경향성(Precision, Recall 등)을 직관적으로 파악할 수 있다. 따라서 Confusion Matrix는 모델의 전반적인 성능뿐 아니라 오류 발생 패턴 분석과 개선 방향 도출에 유용하다.

혼동행렬 분석 방법을 적용하여 도출한 실험결과는 Fig. 6과 같이 나타난다. 해당 결과에 따르면 ‘IONIQ5’와 ‘KONA_EV’에서 가장 낮은 분류 성능을 보이며, 두 클래스는 ‘BMW3_PHEV’와의 경계에서 동일하게 발생한다.

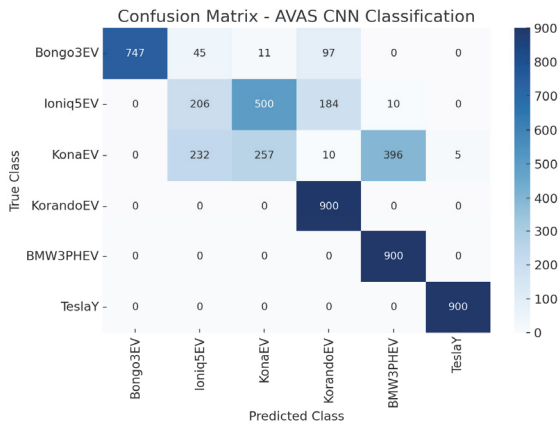


Fig. 6 Confusion matrix of AVAS classification

반면, ‘KORANDO_EV’, ‘BMW3_PHEV’ 그리고 ‘TESLA_Y’는 recall 값이 1.0으로 안정적인 분류가 됨을 보이고, 전체 정확도는 약 72.4%로 나타난다.

Table 2의 정량적 지표에서, ‘BONGO3_EV’는 전체적으로 균형 잡힌 성능이고, ‘IONIQ5’와 ‘KONA_EV’는 각각 F1-score가 0.2979, 0.3082로 다른 클래스 대비 낮은 수치를 보인다. 이는 Precision과 Recall이 모두 낮게 나타난 결과와 일치한다.

Table 2 Classification performance metrics (per class)

Class	Recall	Specificity	Precision	F1-score
BONGO3_EV	0.83	1	1	0.9071
IONIQ5	0.2289	0.9384	0.4265	0.2979
KONA_EV	0.2856	0.8864	0.3346	0.3082
KORANDO_EV	1	0.9353	0.7557	0.8608
BMW3_PHEV	1	0.9098	0.6891	0.816
TESLA_Y	1	0.9989	0.9945	0.9972

반면, ‘KORANDO_EV’와 ‘BMW3_PHEV’는 Recall이 1.0으로 높게 유지했으나 Precision은 각각 0.7557, 0.6891로 오분류 가능성이 존재함을 보여준다. 마지막으로, ‘Tesla_Y’는 Recall 1.0, Precision 0.9945, F1-score 0.9972로 모든 지표에서 가장 높은 성능을 보인다.

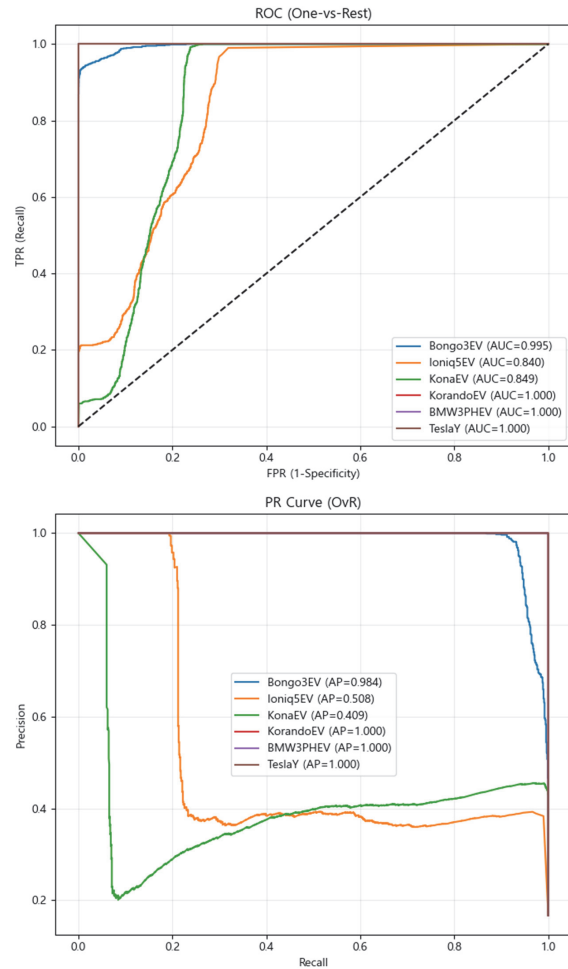


Fig. 7 ROC and Precision-recall curve

4.2 ROC Curve 분석

ROC Curve(Receiver Operating Characteristic Curve) 분석은 이진 분류 모델의 판별 성능을 시각적으로 평가하는 방법이다. 모델의 임계값(Threshold)을 변화시키면서, x축에 False Positive Rate(FPR, 거짓양성률), y축에 True Positive Rate(TPR, 민감도)를 표시하여 그린 곡선이다. 곡선이 좌상단에 가까울수록 모델이 양성과 음성을 잘 구분함을 의미하며, 곡선 아래 면적(Area Under the Curve, AUC)이 1에 가까울수록 분류 성능이 우수하다고 평가된다.

ROC Curve 분석에 대한 실험 결과는 Fig. 6으로 표현된다. ‘KORANDO_EV’, ‘BMW3_PHEV’, ‘TESLA_Y’ 그

리고 ‘BONGO3_EV’의 경우 AUC 값이 1.00과 0.995 수준으로 높은 성능을 나타내지만, ‘IONIQ5’와 ‘KONA_EV’의 AUC 경우 0.84와, 0.849로 상대적으로 낮은 수치를 보여 분류 신뢰도가 떨어지는 것으로 나타난다. 이는 Precision-Recall 곡선에서도 동일하게 ‘IONIQ5’(0.5058)와 KONA_EV(0.409)가 가장 낮은 성능을 보인다.

4.3 PCA 기반 오분류 데이터 특성 분석

주성분 분석(Principal component analysis)을 통한 시각화는 고차원 데이터를 저차원 공간으로 투영하여 데이터 간 분포와 군집 특성을 시각적으로 표현하는 방법이다. AVAS와 같은 음향 신호 분석에서는 차량 간 스펙트럼 유사도나 분리 정도를 직관적으로 확인할 수 있으며, 클래스 간 분리도 및 특징 추출의 유효성을 검증하는 보조 지표로 활용된다.

PCA 기반 데이터 분석 방법을 적용한 실험결과는 Fig. 8과 같이 나타난다. 해당 분석 결과는 CNN 분류기의 Softmax 확률 벡터를 기반으로 주성분 분석(PCA)을 수행하여, 차종별 오분류 데이터의 분포를 의미한다.




Fig. 8 Class overlap in PCA feature space

‘KORANDO_EV’, ‘BMW3_PHEV’, ‘TESLA_Y’ 클래스는 응집도가 높고 다른 집단과의 중심 간 거리(유클리디언 거리)가 크게 나타나 안정적으로 구분되는 특성을 보인다. 이 결과는 Confusion matrix에서의 높은 재현율(Recall ≈ 1.0)과 일치하며, 해당 클래스들의 Softmax 확률이 특정 클래스 꼭짓점 방향으로 쏠려 있음을 나타낸다.

하지만, ‘IONIQ5’, ‘KONA_EV’, ‘BMW3_PHEV’는 PCA 공간에서 상호 중첩 영역이 크게 형성되는 것을 보이며, 특히 ‘IONIQ5’의 경우 예측 시 ‘KONA_EV’, ‘BMW3_PHEV’와 섞이는 띠(Band) 형태의 분포를 보인다. 이는 중심 간 거리 분석에서도 작은 값으로 나타나, 세 클래스 간 음향적 특성이 유사하여 Posterior 확률이 유사하게 분포하는

경향이 있음을 나타내고 있다. 즉, 스펙트럼 구조, 주파수 대역 기여도(1/3 Octave), 과도 패턴(Transient pattern) 등이 상호 유사하여 CNN 구분의 경계가 낮았던 결과로 해석된다. 또한 ‘BONGO3_EV’는 전반적으로 잘 분리된 클러스터를 형성하는 것처럼 보인다. 하지만, 일부 데이터들은 ‘KORANDO_EV’와의 경계 영역으로 분포하여 실제 분류 결과에서도 ‘BONGO3_EV’를 ‘KORANDO_EV’로 오분류가 발생한다. 이는 특정 하모닉 구조나 배음 에너지 분포가 ‘KORANDO_EV’와 근접하여 발생하는 것으로 추정된다.

5. 결론

본 논문에서는 전기차 6개 차종의 AVAS 음향 신호를 대상으로 CNN 기반 분류 모델을 설계하고, 실제 검사소 환경에서의 적용 가능성을 보인다.

실험 결과, 제안된 CNN 모델은 ‘KORANDO_EV’, ‘BMW3_PHEV’, ‘TESLA_Y’에서 매우 높은 분류 성능을 나타내었으며, ‘BONGO3_EV’ 또한 안정적인 결과를 보인다. 그러나 ‘IONIQ5’와 ‘KONA_EV’는 ‘BMW3_PHEV’와의 스펙트럼 유사성으로 인해 혼동이 크게 발생하고, 분류 성능이 상대적으로 낮다. Confusion matrix, ROC 및 Precision-recall curve, PCA 기반 시각화 분석을 통해 이러한 결과가 차량 간 음향 스펙트럼의 중첩에서 발생함을 보여준다.

제안된 CNN 모델은 실제 자동차검사소 환경에서도 차량별 AVAS 신호의 차이를 1/3 octave 주파수 대역으로 구분한다. 즉, 이러한 점은 차량별 고유 주파수 대역을 가지고 있다는 점을 보여준다. 향후에는 다양한 환경 조건(계절, 장비 노후화, 배경 소음 스펙트럼 변화)을 반영한 확장형 데이터 셋 구축하여 Attention mechanism 기반 CNN 및 Transformer 계열 모델을 도입하여 분류 성능을 고도화하는 연구를 수행하고자 한다.

후 기

본 논문은 국토교통부/국토교통과학기술진흥원(과제 번호: RS-2023-00243574, 전기차동차 안전성 평가 및 통합 안전 기술 개발)의 지원을 받아 수행함.

References

- 1) A. Fortino, L. Eckstein, J. Viehöfer and J. Pampel, “Acoustic Vehicle Alerting Systems (AVAS) Regulations, Realization and Sound Design Challenges,” SAE International Journal of Passenger Cars - Mechanical Systems, Vol.9, No.3, pp.995–1003, 2016.

- 2) M. J. Kim, "Brake System of Vehicle Having Noise Generator," Korean Patent No.10-1307799-0000, 2013.
- 3) H. S. Park, S. M. Yoo and J. H. Jo, "Virtual Engine Sound System and a Vehicle Comprising the Same," Korean Patent No.10-1427622-0000, 2014.
- 4) H. S. Park, S. M. Yoo and J. H. Jo, "Electric Vehicle and Method," Korean Patent No.10-1469781, 2014.
- 5) P. Bazilinsky, M. Shadab Alam and R. Merino Martinez, "Psychoacoustic Assessment of Synthetic Sounds for Electric Vehicles in a Virtual Reality Experiment," 11th Convention of the European Acoustics Association, pp.1–8, 2025.
- 6) B. Kullukcu, M. Engel, S. Atamer and E. Altinsoy, "Psychoacoustic Modeling of Avas Sounds: Consumer-Centric Semantic Attribute Development for Electric Vehicles," 11th Convention of the European Acoustics Association, pp.1–8, 2025.
- 7) UNECE, GRBP-80-20/Rev.1, 2024. 09. 18.
- 8) ISO 16254:2016, "Acoustics — Measurement of Sound Emitted by Road Vehicles of Category M and N at Standstill and Low Speed Operation — Engineering method," International Organization for Standardization, 2016.
- 9) S. W. Seo, J. H. Han, Y. Y. Ki, B. G. Jo, H. J. Lee and G. S. Yoon, "Basic Research on the Inspection System of Electric Vehicle AVAS," Transactions of KSAE, Vol.32, No.12, pp.582–589, 2024.
- 10) S. K. Lee, J. S. Baek, M. U. Han and S. M. Lee, "Design and Implementation of a Warning Sound in an Electric Vehicle," Transactions of KSAE, Vol.26, No.5, pp.582–589, 2018.