

Real-Time AI Inference Method for Verification of Vehicle Sudden Unintended Acceleration (SUA)

HeeSeok Choi*

*Researcher, Elkanah Research and Development Center, Elkanah Corp., Seoul, Korea

[Abstract]

In recent years, the number of sudden unintended acceleration (SUA) incidents has been steadily increasing, and research and discussions are actively taking place in many countries, including Korea. Moreover, as drivers involved in accidents caused by pedal misapplication often claim SUA by default, there is a growing need for solutions that can clearly distinguish between technical failure and pedal misapplication. To address this need, this paper presents a foundational study on a cloud-based AI solution for the verification of SUA incidents from the consumer perspective. Specifically, the proposed solution measures the displacement of the brake and accelerator pedals at the exact moment of SUA. In addition, a pedal camera is installed to monitor the driver's pedal operation, while real-time AI inference results are recorded and stored. As a result, the findings of this study are expected to contribute to the development of more reliable SUA verification systems. Furthermore, the proposed approach can serve as a fundamental dataset for improving driver pedal image data processing in future research.

▶ **Key words:** Edge AI, Sudden Unintended Acceleration (SUA), Real-Time Inference, Convolutional Neural Network (CNN), Cloud Computing

[요 약]

최근 자동차 급발진(SUA) 사고의 수가 꾸준히 증가하고 있으며 한국을 비롯한 많은 나라에서 연구와 논의가 이루어지고 있다. 또한 페달 오동작으로 사고가 발생한 경우 운전자가 무조건 자동차 급발진 사고를 주장하는 경우가 증가함에 따라 사고의 주체가 기계의 결함인지 운전자의 부주의인지를 명확하게 파악할 수 있는 솔루션의 개발이 필요한 실정이다. 본 논문에서는 차량 급발진 사고의 소비자 증명을 위한 클라우드 기반 AI 솔루션의 기반 연구를 수행한다. 본 솔루션에서는 차량의 급발진 순간의 브레이크, 가속 페달의 변위량을 측정한다. 또한 페달 카메라를 설치하여 운전자의 페달 조작상태를 파악하고 실시간 AI 추론을 진행하여 그 결과를 기록한다. 제안 연구의 결과를 통해 차량 급발진 사고 시스템 발전에 기여하고 운전자 페달 이미지 데이터 처리 개선을 위한 기반 데이터로 작용할 것을 기대한다.

▶ **주제어:** 엣지 AI, 자동차 급발진, 실시간 추론, 합성곱 신경망, 클라우드 컴퓨팅

-
- First Author: HeeSeok Choi, Corresponding Author: HeeSeok Choi
 - *HeeSeok Choi (hs.choi@elkanah.co.kr), Elkanah Research and Development Center, Elkanah Corp.
 - Received: 2025. 10. 10, Revised: 2025. 10. 21, Accepted: 2025. 10. 29.

I. Introduction

최근 자동차 급발진 의심 사고의 높은 발생률로 인해서 사회적 문제로의 심각성이 커지고 있다[1-2]. 미국 도로 교통 안전청 (NHTSA)에 따르면 미국에서는 매년 16,000건의 차량 사고가 운전 중 페달 오류와 관련되어 있으며, 일본에서는 그 수치가 약 6,000건에 달한다[3]. 후미 충돌, 보행자 부상 등과 관련된 대형 사고는 흔하며, 운전자가 가속 장치를 잘못 작동하여 발생하는 사고의 약 12.6%가 발생한다[4]. 대한민국에서는 1년에 약 430건(하루에 약 2건 발생)의 자동차 급발진 의심사고 신고가 접수되고 있으며 최근 다수의 심각한 사고로 인해 운전자와 자동차 제조사 간의 법적 논쟁이 발생하였다[5]. 미국 항공우주국(NASA)과 NHTSA가 급발진에 대한 여러 조사를 수행한 결과 명확한 사고 원인은 밝혀지지 않았지만 페달 오작동, 페달 무반응, ETC(전자 스로틀 제어), 또는 크루즈컨트롤 오류 및 스로틀 고착 이 4가지 주요 문제로 인해 발생할 가능성이 높다고 결론을 내렸다[6-7]. 운전자의 페달 오작동도 높은 확률로 발생하고 있으며[8-9], 최근 차량 내 많은 전자장치 및 SW의 설치로 인해 SW 내 Race Condition, 동시성 버그, 전역 변수의 과도한 사용과 같은 SW 버그로 인해 발생할 가능성도 높다고 제시하였다[10].

자동차 급발진 사고의 원인은 크게 2가지이다. 첫 번째는 자동차 자체의 결함이다. 급발진 사고는 기계적 결함, 제어 소프트웨어의 오류, 전자 시스템의 결함등의 원인으로 발생하지만 아직 명확하게 절대적인 원인이 밝혀지지는 않은 상태이다[11].

두 번째는 사용자의 페달 오작동이다. 사용자의 가속 페달과 브레이크 페달의 혼용사용으로 발생하며 특히 고령화로 인해 신체의 반응속도가 느려지는 시니어 운전자가 높은 가능성으로 페달 오작동 사고를 발생시킨다[12]. 또한 최근 전기차의 보급률 증가로 인해 차량 사고가 증가하는 추세인데, 전기차는 기본적으로 원 페달 드라이빙 방식으로 주행하기 때문이다. 전기차는 기본적으로 회생제동을 위해서 원 페달 방식을 사용하며 이는 제동 페달을 사용하지 않고 가속 페달만을 사용하여 주행하는 방식이다. 가속 페달을 밟으면 차량이 가속되고 가속 페달에서 서서히 발을 떼면 저절로 제동이 되는 방식이다. 원 페달 방식을 사용할 경우 운전자의 발 위치는 대부분 가속 페달에 위치하게 되며 운전자는 자신의 발이 브레이크 페달에 위치하고 있다고 잘못 판단할 수 있으며, 완전 정차를 위해서 무의식적으로 브레이크 페달을 밟고자 할 경우 순간적으로 발의 위치를 착각하여 가속 페달을 밟아 사고가 발생하는 경

우가 발생한다. 같은 맥락으로 차량이 정차된 상태에서 출발할 경우 순간적으로 발의 위치를 착각하여 가속 페달을 밟게 되고 차량을 멈추기 위해서 브레이크 페달을 더 강하게 밟지만 실제로는 가속 페달을 밟고 있는 상태이기 때문에 차량은 더욱 빨리 가속하게 된다. 전기차는 초반 출력이 내연 기관 차량보다 훨씬 강한 힘을 갖기 때문에 사고에 대한 피해가 훨씬 크며, 운전자에게 심각한 피해를 입힐 가능성이 더욱 높아진다. 또한 최근 차량 사고가 발생할 경우 무분별하게 급발진 의심 사고를 주장하는 사례가 증가함에 따라, 실제로 차량 결함으로 인해 피해를 입은 소비자가 정당한 권리를 보장받지 못하는 문제가 발생하고 있다.

이와 같이 자동차 급발진 의심 사고가 증가하고 있는 실정이지만 차량 내 페달 블랙박스를 설치한 운전자는 거의 드물기 때문에 소비자 과실 여부/차량 결함의 원인을 파악하기 위한 원인 조사에 어려움을 겪고 있으며 법원에서도 차량 결함을 인정하여 제조사에 책임을 부담시킨 사례는 없다[13].

현재 자동차 급발진 사고의 증명 방식은, 사고 차량을 제조사가 수거한 후 폐쇄적으로 자체 테스트를 진행하고, 그 결과를 운전자에게 '사용자 과실 여부' 형태로 일방 통보하는 구조이다. 이 과정에서 운전자 입장에서는 실제 차량 데이터의 진위를 100% 신뢰하기 어렵다. 또한 급발진 사고 판단 기준이 대부분 수동적 데이터 기록 장치인 EDR(Event Data Recorder)에 의존하기 때문에, 데이터의 신뢰성이 충분히 확보되지 않는다[14-15]. 아울러 원-페달(One-pedal) 방식을 사용하는 전기차의 경우 기존 EDR 데이터 기반 증명 방식이 정확하지 않아, 전기차 및 친환경 차량에 특화된 새로운 급발진 사고 증명 방식에 대한 연구도 제시되고 있다[16].

현재 제조물 책임법 상 급발진 의심사고가 발생할 경우 운전자가 직접 차량의 결함을 증명해야 하며 다음의 3가지 상황에 대해 신뢰성 있는 방식으로 증명 해야한다. 1. 급발진 사고 순간에 브레이크 페달을 밟았는지 여부, 2. 브레이크 페달을 적당히 밟은 것이 아닌 충분히 강하게 밟았는지 여부, 3. 가속 페달을 밟았는지 또한 브레이크 페달과 가속 페달을 동시에 밟았는지 여부.

본 연구에서는 차량 내부에 카메라, 6축 관성 센서, OBD-II 센서를 설치하여 소비자가 직접 차량의 결함을 증명할 수 있도록 3가지 상황을 커버할 수 있는 솔루션을 개발한다. 특히 차량 내 설치된 카메라에서는 단순 촬영 데이터 저장에 그치는 것이 아니라 CNN 기술을 적용하여 실시간 AI 추론을 진행하기 위한 세부 연구를 진행한다.

세부 연구는 사용자 페달 사용 판단을 위해 CNN의 추론 클래스의 세분화(Granularity) 정도를 변경 해가며 사용자 페달 판단을 위한 최적의 클래스 개수를 설정한다. 또한 이미지 전이학습의 성능 비교를 통해 제한된 성능과 전력으로 구동되는 차량 내 엣지 서버의 이미지 처리에 적합한 최적의 전이학습 방식을 도출한다.

본 연구를 통해 급발진 의심 사고 발생 시, 차량 제조사의 일방적 판단에 의존하는 과실 여부 규명 방식에서 벗어나, 사용자가 독자적인 방어 장치를 확보할 수 있게 된다. 또한 기존의 단순한 페달 카메라 기능만을 제공하던 솔루션과 달리, AI의 판단 기능과 페달 변위량 센서값을 활용한 분석 기능을 포함하여, 한층 향상된 기능과 성능을 제공하여 불안감을 가진 소비자에게 높은 만족감을 제공한다.

II. Preliminaries

1. Related Works

자동차 급발진 의심사고 관련 연구는 크게 ‘차량 결함’과 ‘사용자 페달 오작동’으로 크게 2가지로 분류할 수 있다.

1.1 Vehicle Defect Perspective

‘차량 결함’의 관점에서 급발진 의심 사고의 원인 분석과 의도치 않은 가속을 판단하고 차량의 출력을 감소시키는 연구가 이루어지고 있다. 급발진 체크 시스템은 카메라, OBD-II, 거리 측정 센서를 사용하여 차량 상태 정보를 실시간으로 처리하고 가속 페달과 브레이크 페달 및 센서 이미지와 함께 차량의 제어 부품의 작동 상태를 확인 하는 방식으로 급발진의 원인을 찾는 기법을 제시한다[17]. 충돌 회피 시스템은 차량의 급발진을 감지할 경우 자동으로 차량에 주입되는 연료를 차단하여 차량의 주행 성능을 감소시키는 충돌 회피 기능을 제시한다[18]. 하지만 급발진을 감지하는 경우는 오직 사용자가 두 발을 모두 사용하여 브레이크 페달과 가속 페달을 동시에 밟고 있는 경우만 탐지가 가능하다. AI 기반 급발진 탐지 및 완화 시스템은 차량의 의도치 않은 가속이 판단될 경우 엔진의 출력을 차단하고 제동력을 조절하는 기능을 제공한다[19]. 하지만 이 시스템은 기어 변속과 가속 피크와 같은 차량의 특정 이벤트를 분석하여 작동하므로 특정 차량 패턴이나 운전 스타일을 고려되지 않은 시뮬레이션 연구이다.

1.2 User Pedal Malfunction Perspective

‘사용자의 페달 오작동’의 관점에서 사용자의 결함을 찾기 위한 연구는 다음과 같다. 전기차 버스의 페달 신호 분

류 기법은 다양한 신경망 모델을 이용하여 스톱 위치 센서로부터 나오는 시계열 데이터를 분류하고 전기차 전용 페달 신호 분류 기술을 제시한다[20]. 신경망 모델을 TensorFlow Lite로 변환하여 라즈베리 파이와 같은 마이크로컨트롤러에 실시간으로 실행할 수 있게 개발하였지만 복잡한 신경망 구현을 위해서는 지연시간과 메모리 제한 등의 한계가 있다. 차량 행동 감지 기법은 차량 구동계 모델을 활용하여 차량의 부하 토크를 추정하고, 이를 통해 차량 급발진을 판단하는 기술을 제시하였다[21]. 차량의 의도치 않은 가속이 약하게 의심되는 상태에서도 운전자에게 알람을 통해 조치를 유도하고 심각한 가속 판단이 될 경우 차량의 속도를 자동으로 줄이거나 멈추게 설계가 되어 있지만 아직 스스로 보완할 부분이 많다고 언급한다.

III. The Proposed Scheme

본 논문에서 제안하는 차량 급발진 사고 증명 솔루션은 운전자가 직접 차량의 결함을 입증해야 하는 3가지 상황을 포괄적으로 증명할 수 있는 기술을 제공한다.

1. Proposed Solution Architecture

Fig. 1은 차량 급발진 사고 증명 솔루션의 전체 개발 기술 개념도를 나타낸다.

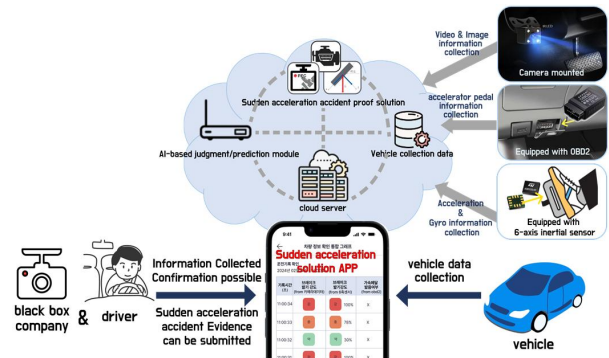


Fig. 1. Development Concept Diagram of Vehicle SUA Verification Solution

IR 카메라, 6축 관성 센서(3축 가속도, 3축 자이로), OBD-II 센서에서 수집된 데이터를 클라우드 서버에서 동기화 작업을 진행하며, 이와 같이 3가지 신뢰성 있는 데이터를 기반으로 급발진 사고 시점 운전자가 어떤 페달을 어느 정도의 세기로 밟았는지 여부를 명확하게 판단 가능하다. 또한 카메라가 운전자의 발 부분을 촬영하며 실시간으로 AI 판단 결과를 제공하며 이를 동시 저장한다. 이를 위

Table 1. Dataset Samples and Structures

Manufacturer	Vehicle Model	Number of Collected Data
KIA	The all-new Sportage	2,405
	Ray	2,405
	Morning Urban	2,406
	Carnival KA4	2,407
Renault	QM6	2,342
Chevrolet	EQUINOX	2,405
KGM	Torres	2,405
Volkswagen	Jetta	2,471
Hyundai	SONATA DN8	2,407
	Casper	2,405

해서 CNN(합성곱 신경망)을 이용하여 급발진 사고 증명 솔루션 전용 이미지 인식 기법을 개발 및 적용하며 차량 내 제한적인 환경에서 최적의 결과를 얻기 위해서 다양한 전이학습과 CNN 클래스의 개수를 세분화함에 따른 성능을 비교 분석한다.

2. Data Collection for AI Training

AI 학습에는 이미지 데이터만을 활용하였으며, Fig. 2와 Fig. 3은 수집된 시계열 센서 데이터를 나타낸다. 또한, 데이터 신뢰성을 확보하기 위하여 Network Time Protocol (NTP) 기반 프로토콜을 통한 시간 동기화 기술을 적용하였다.

AH	AI	AJ	AK	AL	AM	AN	AO	AP	AQ
Accelerator	Accelerator O2 Sensor	Exhaust G	Exhaust G	Relative Throttle Position(%)	SR Comr	Engine RPI	Engine Co-Engine	Low	
16.8627	16.4706	1.99997	-65.7	-65.7	99.608	0.39216	1475	85	38.039
16.8627	16.4706	1.99997	-65.7	-65.7	99.608	0.39216	1475	85	38.039
16.8627	16.4706	1.99997	-65.7	-65.7	99.608	0.39216	1475	85	38.039
16.8627	16.4706	1.99997	-65.7	-65.7	99.608	0.39216	1475	85	38.039
16.8627	16.4706	1.99997	-65.7	-65.7	99.608	0.39216	1475	85	38.039
16.8627	16.4706	1.99997	-65.7	-65.7	99.608	0.39216	1475	85	38.039
16.8627	16.4706	1.99997	-65.7	-65.7	99.608	0.39216	1475	85	38.039
16.8627	16.4706	1.99997	-65.7	-65.7	99.608	0.39216	1475	85	38.039
16.8627	16.4706	1.99997	-65.7	-65.7	99.608	0.39216	1475	85	38.039

Fig. 2. Collected On-Board Diagnostics (OBD-II) Data

id	ax	ay	az	gx	gy	gz	timestamp
1	0.01	-0.88	-0.52	2.38	-0.85	-0.24	2025-05-10 13:47:48
2	0.01	-0.87	-0.52	0.06	-0.85	-0.24	2025-05-10 13:47:50
3	0.01	-0.86	-0.51	0.12	-0.85	-0.12	2025-05-10 13:47:52
4	0.01	-0.86	-0.51	0.24	-0.85	-0.18	2025-05-10 13:47:54
5	0.01	-0.86	-0.51	0.06	-0.85	-0.24	2025-05-10 13:47:56
6	0.01	-0.86	-0.51	0.24	-0.85	-0.18	2025-05-10 13:47:58

Fig. 3. Collected 6-axis Inertial Measurement Unit (IMU) Data

CNN 학습을 위한 데이터 셋은 다양한 각도에서 수집되며 일반적인 상황을 고려하여 조명은 설치하지 않았다. 수집된 이미지는 6개 차량 제조사(기아, 르노, 쉐보레, 쌍용(KGM), 폭스바겐, 현대)의 15개 차량 모델을 기반으로 수집되었다. 또한 추가 validation을 위해 3개 제조사의 5개 차량 모델의 이미지를 수집하였다. 데이터의 개수는 총 24,743개의 이미지이며 전체 용량은 약 69GB이다. Table 1.은 메인 학습에 사용된 데이터셋의 샘플과 구조를 나타낸다. 학습과 테스트 데이터셋의 분할은 8:2로 진행하였다.

3. Data Labeling and Preprocessing

학습은 AWS SageMaker 환경에서 진행하였으며 이를 위해 Ground truth 기능을 활용하여 데이터 라벨링 작업을 진행하였다[22]. 6축 관성 센서와 OBD-II에서 수집되는 센싱 데이터는 이상치가 발생할 경우 더욱 중요한 사항이기 때문에 결측치 값 처리는 진행하지 않았다.

4. Transfer Learning

전이학습은 사전 학습된 모델을 새로운 작업의 시작점으로 재사용하는 방법으로 적은 양의 데이터로 훈련하는 것보다 훨씬 더 높은 성능을 낼 수 있는 장점이 있다. 사전 훈련된 모델에서 얻은 지식을 사용하여 작업을 진행하기 때문에 전이 학습을 이용하지 않는 CNN 모델에 비해서 계산 비용을 절감할 수 있으며 고성능을 달성하기 위해서 상대적으로 적은 양의 데이터로도 달성 가능한 장점이 있다. 본 연구에서는 PyTorch를 이용하여 총 6가지 전이학습(MobileNet, ResNet, VGG19, DenseNet, EfficientNet, Inception)을 수행하였다.

5. Class Granularity Adjustment in CNN

본 연구에서는 6개의 전이학습을 진행함과 동시에 이미지 추론 결과의 수를 결정하는 CNN의 클래스 개수에 따른 성능 변화를 비교 분석하였다. 이를 통해 차량 내 제한적인 환경에서 엣지 서버의 성능을 극대화 할 수 있는 최적의 CNN 클래스 개수와 그에 따른 성능을 도출하였다.

IV. Experiments

추론을 위한 본체는 Nvidia사의 Jetson Orin Nano를 사용한다[23]. 학습은 AWS SageMaker 환경에서 8 cVPU, NVIDIA v100(16GB), 61GB RAM로 구성된 ml.p3.2xlarge 타입의 가상머신을 이용하여 실험을 진행하였다. 학습은 PyTorch를 이용하여 진행하였으며, 소프트웨어 환경은 Python 버전 3.10, PyTorch 버전 2.2.0, CUDA 버전 12.1, cuDNN 버전9.1.0을 사용하였다.

실험은 초기 6개의 전이학습 모델을 대상으로 수행되며, 성능이 상대적으로 저조한 전이학습 모델은 단계적으로 배제하는 방식으로 진행된다. 또한 CNN의 클래스 개수를 초기 4개에서 2개, 3개로 단계적으로 변경하며, 성능 측면에서 가장 우수하고 효율적인 클래스 수를 도출하였다. 각 클래스의 분류 체계는 다음과 같다. 클래스가 4개 일 경우: (1) 페달 미조작, (2) 브레이크 페달 약간 조작,

Table 2. Performance Results of the 4-Class Model

Models	Loss		Accuracy		F1-Score	
	Train	Validation	Train	Validation	Train	Validation
MobileNet	0.1243	1.2472	0.9525	0.6595	0.9526	0.6477
ResNet	0.1332	1.5075	0.9478	0.5925	0.9479	0.5712
VGG19	0.7133	1.1360	0.7046	0.5371	0.7093	0.5262
DenseNet	0.3932	2.1522	0.8443	0.4846	0.8443	0.4820
EfficientNet	0.9133	1.1957	0.6169	0.4898	0.6160	0.4527
Inception	1.0843	1.2216	0.5684	0.4313	0.5675	0.4313



Fig. 4. Data collected from the camera for 4 pedal operation classes (clockwise from top-left): (1) No pedal operation, (2) Slight brake pedal operation, (3) Full brake-pedal operation, and (4) Accelerator pedal operation.

(3) 브레이크 페달 완전 조작(풀브레이크), (4) 가속 페달 조작. 클래스가 3개일 경우: (1) 페달 미조작, (2) 브레이크 페달 조작, (3) 가속 페달 조작. 마지막으로 클래스가 2개일 경우: (1) 브레이크 페달 조작, (2) 가속 페달 조작으로 정의된다. Fig. 4는 4가지 페달 동작 클래스를 대상으로 한 분류 시도의 실제 수집 이미지를 나타낸다. 사용자 페달 사용에 대한 실시간 판단의 성능 비교 분석을 위한 정량적 성능평가 지표는 손실함수(Loss), 정확도(Accuracy), 그리고 정밀도(Precision)와 재현율(Recall)의 조화 평균인 F1-Score를 분석한다. 손실 함수(Loss function)는 모델의 예측값과 실제값 간의 오차를 수치로 정량화하는 함수이며, 그 값이 0에 가까울수록 모델의 성능이 우수함을 의미한다.

모델 구성 단계에서 손실함수로 CrossEntropyLoss를 사용하여 모델 끝단의 Softmax 활성화 함수는 제거하였으며 옵티마이저는 AdamW를 사용하여 Momentum도 따로 설정하지 않았다. 또한 배치 크기는 32, 학습률은 $8e-4$, 가중치 감소는 $5e-4$ 로 설정하였다. 데이터의 다양성을 높이기 위해서 데이터 증강 기법을 적용하였다.

1. Performance of the 4-Class Model

Table 2.는 초기 6개의 전이학습 모델을 대상으로 클래스 수를 4개로 설정하여 학습을 진행한 경우의 성능 결과를 제시한다. 실험의 횟수인 Epoch는 모두 30으로 고정하여 진행하였다. 클래스를 4개로 분류하였을 경우 전체적으로 과적합의 경향을 보인다. 이는 여러 가지 요인이 있겠지만 데이터셋의 크기 및 클래스 세분화에 따른 복잡도에 있다. 운전자의 페달 사용을 4단계로 세분화하여 분류할 경우, 예를 들어 ‘브레이크 페달 약간 조작’과 ‘브레이크 페달 완전 조작’과 같이 클래스 간 유사도(inter-class similarity)가 높아, 인간의 시각으로도 명확히 구분하기 어려운 사례가 발생할 수 있다. 이러한 경우 데이터 간 클래스 경계가 불분명해져 결정 경계 학습이 어려워지고, CNN의 성능 역시 제한될 가능성이 있다. 그러나 기존 연구들에 따르면, CNN은 인간이 인지하기 어려운 미세한 패턴을 학습하여 오히려 인간의 식별 능력을 능가하는 성능을 보이는 경우도 보고된 경우도 있다.

MobileNet은 가벼운 네트워크이기 때문에 훈련 데이터는 거의 완벽하게 학습하는 모습으로 작은 데이터 셋에서도 빠른 학습은 잘 수렴하는 결과를 보여주지만 검증 성능은 한계가 있음을 보여준다. ResNet은 Residual 구조인 Skip Connection을 사용하는 덕분에 전체적으로 안정적인 성능을 보여주지만 MobileNet과 비교할 경우 validation의 성능이 약간 떨어지는 경향을 보인다. VGG19은 깊고 무거운 구조이기 때문에 충분히 학습되지 못하는 과소적합의 경향을 보인다. 데이터가 크고 Epoch 횟수가 많을 경우에는 강력하지만 현재 환경에서는 성능 제한적이다. DenseNet은 학습 성능은 나쁘지 않지만, Validation 성능은 급격하게 하락하는 것을 보여준다. 이는 많은 파라미터와 복잡한 연결 구조 때문에 복잡도가 과도하게 높아져 작은 데이터셋에서는 잘 일반화 되지 못하는 특징을 보여준다. EfficientNet도 역시 과소적합의 형태를 보이고 있다. 이는 설계는 효율적이지만 기본적으로 최소 수준 이상의 학습데이터와 적적할 scaling이 필요한 것으로 보인다. Inception은 6가지 전이학습 중 가장 낮은 성능을 보인다. 오히려 CNN 단순구조보다 못한 결과를 보여

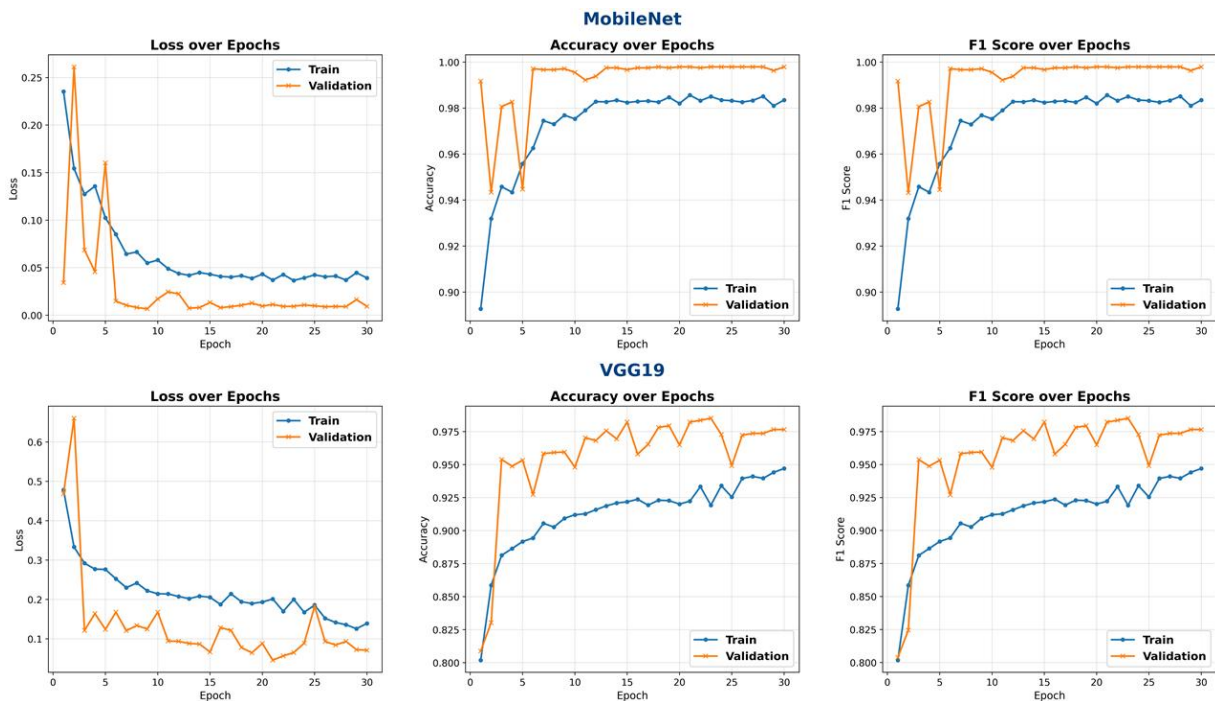


Fig. 5. Performance Results of the 2-Class Model

Table 3. Performance Results of the 2-Class Model

Models	Loss		Accuracy		F1-Score	
	Train	Validation	Train	Validation	Train	Validation
MobileNet	0.0392	0.0094	0.9835	0.9979	0.9835	0.9979
VGG19	0.1393	0.0711	0.9470	0.9765	0.9470	0.9765

주고 있다. 6가지 전이학습 모델의 성능을 비교한 결과, 클래스 분류를 지나치게 세분화할 경우 클래스 간 유사도가 높아져 전반적인 성능 저하가 발생함을 확인하였다.

2. Performance of the 2-Class Model

Fig. 5은 클래스 수를 2개로 설정하여 학습을 진행한 경우의 성능 결과를 제시한다. 본 실험에서는 클래스 수를 4개로 설정하였을 때 상대적으로 가장 우수한 성능을 보인 MobileNet과 중간 수준의 성능을 나타낸 VGG19을 대상으로, 동일한 epoch 30으로 학습을 수행하였다.

Table. 3은 Fig. 5에서 도표로 표현한 성능 결과의 구체적인 수치가 제시되어 있다. 클래스를 2개로 분류한 모델을 적용한 경우, 4개의 클래스를 적용한 경우와 비교했을 때 전체적인 성능이 향상되었다. MobileNet의 경우 훈련과 검증 단계에서의 Loss 값이 매우 낮았으며 모델이 잘 수렴하였고 과적합의 징후도 거의 없었다. VGG19는 성능이 우수한 편에 속하나 상대적으로 MobileNet 보다 수치가 상대적으로 높았다. Accuracy와 F1-Score 관점에서 MobileNet은 우수한 분류 정확도와 균형 성능을 보여주었다. VGG19도 MobileNet보다는 낮지만 여전히 높

은 수준을 보였다. 두 모델 모두 훈련과 검증 단계의 성능 차이가 크지 않아 일반화 성능이 좋은 결과를 나타낸다.

MobileNet은 VGG19와 비교했을 때 더 작은 Loss 값과 더 높은 Accuracy, F1-Score 값의 성능을 보였으며 이는 MobileNet이 매개변수의 수와 계산 요구 사항을 크게 줄인 경량 모델임에도 불구하고 Depthwise Separable Convolution을 통한 효율적인 구조 설계와 파라미터 사용 최적화, 정규화 및 최적화 기법의 적용이 잘되어 경쟁력 있는 성능을 보여준다. 흥미롭게도, 본 실험에서는 검증 데이터에서의 성능이 훈련 데이터보다 더 높게 나타나는 현상이 관찰되었다. 이는 일반적으로 훈련 과정에서 적용된 정규화 기법(예: 드롭아웃, 가중치 감쇠 등)으로 인해 학습 시 모델의 표현력이 의도적으로 제한되지만, 검증 단계에서는 이러한 제약이 적용되지 않기 때문에 발생할 수 있다. 또한 훈련 데이터에 비해 검증 데이터의 난이도가 상대적으로 낮거나 데이터 분할 과정에서 분포 차이가 존재하는 경우에도 이러한 결과가 나타날 수 있다. 따라서 본 결과는 과적합의 신호라기보다는 정규화 효과 및 데이터셋 특성에 기인한 것으로 해석할 수 있다.




Fig. 6. Performance Results of the 3-Class Model

Table 4. Performance Results of the 3-Class Model

Models	Loss		Accuracy		F1-Score	
	Train	Validation	Train	Validation	Train	Validation
MobileNet	0.5046	4.2616	0.6570	0.5624	0.6580	0.4876

3. Performance of the 3-Class Model

Fig. 6은 클래스 수를 3 개로 설정하여 학습을 진행한 경우의 성능 결과를 제시한다. 본 실험에서는 클래스 수를 2개, 4개로 설정하여 학습을 진행하였을 경우 가장 우수한 성능을 보여줬던 MobileNet 전이학습 만을 단독으로 학습 하였다. 실험 결과, 훈련 데이터에서는 약 65%의 정확도와 F1-Score를 보였으나 검증 데이터에서는 각각 56.2%와 48.7%로 성능이 현저히 저하되었다. 또한, 검증 단계에서의 손실 함수 값이 약 4.2로 나타나 훈련 단계의 손실 함수 값 약 0.5에 비해 현저히 증가하였으며, 이는 모델이 일반화에 실패하고 과적합 현상이 발생하였음을 시사한다.

주목할 만한 점은 2-클래스 및 4-클래스 실험에서 비교적 안정적인 성능을 확보한 반면, 3-클래스 실험에서는 오히려 성능이 크게 저하되었다는 점이다. 이는 2-클래스 실험에서는 명확한 이진 구분으로 인해 안정적인 성능을 확보하였고, 4-클래스 실험에서도 각각의 클래스가 상대적으로 뚜렷하게 구분되었던 것과 대조적이다. 3-클래스로 축소하는 과정에서 중간 클래스의 정의가 모호해지면서 경계가 불명확해졌고, 이로 인해 모델의 판별력이 저하된 것으로 판단된다. 또한 클래스 재구성 과정에서 데이터 분포의 불균형이 심화되었을 가능성이 있으며, 이로 인해 다수 클래스에 대한 예측 편향이 발생하여 소수 클래스의 분류 성능이 더욱 떨어진 것으로 보인다. 따라서 3-클래스 분류 체계는 모델의 성능을 저해하는 요인으로 작용했으며, 향후 실험에서는 클래스 정의 방식과 데이터 균형 조정이 중요한 변수임을 시사한다.

Fig. 7은 최종적으로 2-클래스의 MobileNet이 적용되어 동작하는 차량 급발진 사고 증명 솔루션의 모습을 나타낸다.

V. Conclusions

본 연구에서는 페달 동작 인식 문제를 대상으로 다양한 전이학습 모델을 적용하여 클래스 세분화 수준(2-class, 3-class, 4-class)에 따른 성능을 비교분석하였다.

실험 결과, granularity 수준이 단순한 2-class 설정에서 가장 낮은 손실과 가장 높은 정확도 및 F1-score를 확보할 수 있었다. 반면, 3-class의 경우 클래스 경계가 모호해 성능이 저하되었고, 4-class 역시 2-class보다 낮은 성능을 보였다. 이는 CNN 클래스의 granularity 수준이 모델의 일반화 성능과 직결되는 중요한 요인임을 시사한다. 따라서 최종 차량 급발진 사고 증명 솔루션에는 MobileNet 전이학습 기반 2-class 모델을 적용하였다.

ACKNOWLEDGEMENT

This work was supported by the Technology Development Program (No. RS-2024-00467561) funded by the Ministry of SMEs and Startups (MSS, Korea).

REFERENCES

- [1] S. Kane, E. Liberman, T. DiViesti, and F. Click, "Toyota sudden unintended acceleration," *Safety Research & Strategies*, 2010.
- [2] M. T. Kirsch, V. A. Regenie, M. L. Aguilar, O. Gonzalez, M. Bay, M. L. Davis, ... and R. A. Kichak, "Technical support to

- the National Highway Traffic Safety Administration (NHTSA) on the reported Toyota Motor Corporation (TMC) unintended acceleration (UA) investigation," NASA Engineering and Safety Center Technical Assessment Report, Jan. 2011.
- [3] National Highway Traffic Safety Administration, Technical Assessment of Toyota Electronic Throttle Control (ETC) Systems, NHTSA-UA Report, 2011.
- [4] J. Yuan, Research on Control Strategy of Assistance System for Misoperation of Accelerator Pedal Based on Multi-Sensor Data Fusion, Ph.D. dissertation, Jilin Univ., Jilin, China, 2019.
- [5] Korea Transportation Safety Authority, Annual Number of Investigations on SUA and Vehicle Defects, www.ilyoeconomy.com/news/articleView.html?idxno=63783
- [6] National Research Council, The Safety Promise and Challenge of Automotive Electronics: Insights from Unintended Acceleration, Transportation Research Board, 2012. DOI: 10.17226/13342
- [7] J. K. Pollard and E. D. Sussman, "An examination of sudden acceleration (No. DOT-HS-807-367)," U.S. Department of Transportation, National Highway Traffic Safety Administration, 1989.
- [8] S. L. Ho, X. G. Nguyen, V. H. Pham, T. B. Nguyen, and V. T. Truong, "A study on anti-pedal error system in car based on hydraulic approach," Regional Conference in Mechanical Manufacturing Engineering, pp. 1080-1089, Singapore, 2021. DOI: 10.1007/978-981-16-8133-5_108
- [9] N. M. A. Ismail, M. Z. Baharom, Z. Ahmad, M. H. A. Hassan, J. Karjanto, Z. M. Jawi, and K. A. A. Kassim, "A review on the pedal error cases among car drivers in Malaysia," International Human Engineering Symposium, pp. 313-325, Singapore, 2023. DOI: 10.1007/978-981-99-0032-3_27
- [10] P. Koopman, "A case study of Toyota unintended acceleration and software safety," Presentation, Sept. 17, 2014.
- [11] R. A. Belt, "Answers to some remaining questions on Belt's theory of sudden acceleration," 2015.
- [12] D. Z. Chan, I. J. Jamaludin, N. M. A. Ismail, Z. Ahmad, and M. Z. Baharom, "Investigation of force and reaction time on car pedals during natural driving," AIP Conference Proceedings, vol. 2998, no. 1, 2024. DOI: 10.1063/5.0212345
- [13] J. K. Choi, "Sudden unintended acceleration and product liability - Introduction of US precedents and their implications," The Journal of Comparative Private Law, vol. 30, no. 4, pp. 35-67, 2023. DOI: 10.34189/jcpl.2023.30.4.003
- [14] M. Kim and J. W. Jang, "Implement automobile black box system for proving cause of sudden unintended acceleration," Journal of the Korea Institute of Information and Communication Engineering, vol. 18, no. 6, pp. 1429-1434, 2014. DOI: 10.6109/jkiice.2014.18.6.1429
- [15] C. Wei, X. Gao, and D. Huang, "Applications of EDR data in traffic accident reconstruction," International Conference on Electrical and Control Engineering, pp. 5201-5204, Yichang, China, 2011. DOI: 10.1109/ICECE.2011.1057
- [16] S. B. Lee, D. H. Kim, and B. J. Moon, "A study on the improved EDR storage data to identify the cause of unintended acceleration of eco-friendly vehicles," Journal of Auto-Vehicle Safety Association, vol. 14, no. 3, pp. 17-22, 2022.
- [17] J. H. Cha, T. H. Kim, and J. W. Jang, "Design of sudden unintended acceleration check system using distance measurement sensor," Advances in Computer Science and Ubiquitous Computing: CSA-CUTE2016 8, pp. 23-28, Singapore, 2017. DOI: 10.1007/978-981-10-7605-3_4
- [18] E. Wotango, P. Ali, R. B. Nallamotheu, S. Kebede, N. Bekele, and K. Thanaiah, "Collision avoidance system: Fuel cut off mechanism for unintended pressing of accelerator pedal," SSRN, 2022. DOI: 10.2139/ssrn.4117493
- [19] H. Yu and R. Langari, "A neural network-based detection and mitigation system for unintended acceleration," Journal of the Franklin Institute, vol. 355, no. 10, pp. 4315-4335, 2018. DOI: 10.1016/j.jfranklin.2018.03.010
- [20] S. Chiurato, Neural Network-Based Classification of Electric Vehicle Acceleration Pedal Signals: From Training to Microcontroller Deployment, Ph.D. dissertation, Politecnico di Torino, Italy, 2023. DOI: 10.6092/polito/chiurato23
- [21] A. P. Ghube, A. Chauhan, and K. K. Nidubrolu, "Detection of unintended vehicle behaviour for driver safety (No. 2024-26-0106)," SAE Technical Paper, 2024. DOI: 10.4271/2024-26-0106
- [22] AWS, Amazon SageMaker Ground Truth: Build Highly Accurate Datasets and Reduce Labeling Costs by up to 70%, <https://aws.amazon.com/ko/blogs/korea/amazon-sagemaker-ground-truth-build-highly-accurate-datasets-and-reduce-labeling-costs-by-up-to-70/>
- [23] Nvidia, "Jetson Orin Nano," [Online]. Available: <https://www.nvidia.com/en-us/autonomous-machines/embedded-systems/jetson-orin/>

Authors



HeeSeok Choi received the B.S. degree in Information and Communication Engineering from Baekseok University, South Korea, in 2012, and the integrated M.S. and Ph.D. degrees in Computer Science and Engineering

from Korea University, South Korea, in 2020. He is currently working as the CEO of Elkanah Corp. and as an adjunct professor at Pyeongtaek University since 2023. He is interested in Edge AI, Sudden Unintended Acceleration (SUA), real-time inference, Convolutional Neural Networks (CNNs), Cloud Computing, AI convergence platforms, and IoT services.