

OBD-II 정보를 이용한 운전자 스트레스 모니터링 시스템

조상진* · 조영**

Driving Stress Monitoring System Based on Information Provided by On-Board Diagnostics Version II

Sang-Jin Cho* · Young Cho**

요 약

인간의 생체 신호 데이터가 인간의 상태를 가장 잘 설명할 수 있다 할지라도 실제 운전 중에 운전자의 생체 데이터를 얻어 운전자의 상태를 판단하는 일은 쉽지 않다. 본 논문에서는 이러한 한계를 극복하기 위한 방법 중 하나로 운전자의 주행 정보를 이용한 운전자 스트레스 모니터링 시스템을 제안한다. 운전자의 주행 정보는 OBD-II 스캐너를 통해 취득하고, 실제 운전자의 운전 스트레스 여부는 E4 밴드를 통해 취득한 EDA 데이터를 이용하여 판단한다. 스트레스 감지 모델은 MLP 신경망 모델을 사용하였으며 약 한 달 간의 운행 데이터를 이용하여 학습시켰다. 제안한 시스템을 평가하기 위하여 약 1시간의 운행 데이터를 사용하였고 약 92%의 정확도를 얻을 수 있었다.

ABSTRACT

Although the biosignal is the best way to represent the human condition, it is difficult to acquire the biosignal of a driver driving for detecting driver's condition. As one of the methods to overcome this limitation, this paper proposes a driving stress monitoring system based on information provided by OBD-II(on-board diagnostics version II). The driving information and EDA(Electrodermal activity) data are obtained through the OBD-II scanner and E4 wristband, respectively. EDA data is used as ground truth to distinguish whether driver is stressed or not. MLP(multi-layer perceptron) neural network is used as a model to detect driving stress and is trained using driving data for about a month. To evaluate the proposed system, we used about 1 hour of driving data and the accuracy is 92%.

키워드

On-Board Diagnostics(OBD), Driving Stress, Monitoring System, Electrodermal Activity
온보드 진단기, 운전 스트레스, 모니터링 시스템, 피부 전도도

* 주지메이드 (sjcho@zmade.co.kr)

** 교신저자 : 울산과학기술대학교 전기전자공학부

• 접수일 : 2022. 12. 23

• 수정완료일 : 2023. 01. 17

• 게재확정일 : 2023. 02. 17

• Received : Dec. 23, 2022, Revised : Jan. 17, 2023, Accepted : Feb. 17, 2023

• Corresponding Author : Young Cho

School of Electrical & Electronic Engineering, Ulsan College,

Email : ycho@uc.ac.kr

I. 서론

음주 운전, 과속운전, 범규위반 등 운전자의 위험한 운전 행동은 교통사고 발생의 주된 요인이다. 이에 음주운전을 방지하기 위한 시스템 개발[1]과 운전자의 위험 운전을 정량화하기 위한 연구[2], 도로에서의 돌발 상황을 감지하여 2차 사고를 예방하기 위한 연구[3] 등 안전 운전과 관련된 다양한 연구가 지속적으로 보고되고 있다. 이 연구들이 교통사고의 직접적인 원인과 운전자에 초점을 맞춘 것이라면, 운전자의 상태를 점검함으로써 안전사고를 예방하기 위한 연구도 다양한 분야에서 진행되고 있다. 운전 중 스트레스는 교통사고의 주요 원인 중 하나이며[4] 운전자의 위험한 운전행동(음주운전, 과속운전, 범규위반, 피해사고, 가해사고 등)과도 상관관계가 있다[5]. 미국 국가 안전 보장 위원회(NSC)에 의하면 자동차 사고의 21%가 운전자의 스트레스가 원인이라고 한다[6].

스트레스에 관한 연구는 다양한 분야에서 활발하게 진행되어왔다. 스트레스로 고통받고 있는지를 알아보려는 시도를 포함하여 사람들의 감정 상태를 감지하기 위하여 EEG를 이용하여 뇌파 데이터를 취득, 주파수 특징을 추출하여 좋은 결과를 얻기도 하였다[7-8]. 이 밖에도 심박(Heart Rate)을 이용한 스트레스 수준 측정[9], 심박 데이터와 전기적 피부 반응(Galvanic Skin Response, GSR) 데이터를 퍼지 논리에 기반하여 스트레스를 검출하는 방법[10], 운전자의 스트레스 수준을 측정하기 위하여 피부 온도를 이용하는 방법[11], 동공, 혈압, 전기적 피부 반응을 측정하여 스트레스 수준을 감지하는 다양한 방법[12] 등 다양한 연구 결과들이 보고되고 있다. 특히 운전 스트레스와 관련하여 다양한 생체 신호 데이터를 활용한 결과, 전기적 피부 반응과 심박수가 스트레스와 가장 밀접하게 관련이 있다는 연구 결과가 보고되었다[13].

운전 스트레스 측정에 다양한 생체 신호가 사용되고 좋은 결과를 얻었다 할지라도 실제 운전자에게 적용하기에는 센서를 신체에 부착해야 한다는 한계가 분명하다. 운전자 모니터링을 위해 웨어러블 디바이스를 이용한 연구가 보고되었으나[14], 비접촉 센싱에 대한 많은 연구[15]에서도 알 수 있듯이 앞으로의 연구 방향은 일상생활에 불편함과 거부감이 없는, 지속적으로 모니터링이 가능한 방법을 모색하는 것이다.

이에, 본 논문에서는 센서 부착이 필요없는 자동차 운전 주행 정보를 이용하여 운전자의 스트레스를 모니터링할 수 있는 시스템을 제안한다. 운전자의 피부 전도도(Electrodermal Activity, EDA) 데이터와 운전 데이터를 동시에 취득하여 운전자의 스트레스 상황을 피부 전도도로 판단, 해당 상황에 대한 운전 데이터를 MLP(: Multi-Layer Perceptron) 신경망으로 학습하여 최종적으로 운전자의 운전 데이터만으로 스트레스 여부를 감지할 수 있는 시스템을 제안한다.

II. 배경지식

본 논문은 자동차의 온보드 진단기(on-board diagnostics version II, OBD-II)에서 취득한 정보를 이용하여 운전자의 스트레스 여부를 모니터링하는 시스템에 관해 기술한다. 이해를 돕기 위해 우선 OBD-II에 대해 설명한 후, 운전자의 스트레스 여부를 판단 기준(Ground Truth)이 되는 피부 전도도(Electrodermal Activity, EDA)에 대해 살펴본다.

2.1 OBD-II

온보드 진단기는 자동차에 내장된 컴퓨터 기반의 자가 진단, 모니터링 및 보고 시스템을 의미하는 것으로 다양한 엔진 구성 요소 및 배출 시스템 구성 요소의 성능을 모니터링할 수 있다.

ISO 15031 표준은 배출 관련 진단을 위해 차량과 외부 진단 장비 간의 통신 프로토콜을 설명한다[16]. OBD-II 표준은 ISO 15031 표준을 기반으로 하는 일련의 사양 및 서비스이며 OBD 커넥터 유형, 전기 신호 프로토콜 및 메시지 형식을 지정한다. 또한 모니터링할 매개변수 목록과 전송 및 저장 중에 매개변수와 관련된 데이터를 인코딩하는 방법에 대한 정보도 기술하고 있다.

현재 OBD-II를 지원하는 모든 차량은 크기는 세 가지, 세부적으로는 다섯 가지 표준 프로토콜을 사용한다[17]. 3개의 신호 방식은 VPW-PWM(SAE-J1850), CAN 통신(ISO15765, SAE-J2234), ISO 방식(ISO1941-2, ISO 14230-4)이고 DLC(: Diagnostics Link Connector)라고 불리는 OBD-II 단자는 총 16개 핀으로 구성되어 있으며, 각

각의 신호 방식은 모두 다른 핀을 사용하기 때문에 OBD-II 단자의 외관만 보더라도 어떤 신호 방식을 사용하는지 쉽게 구별할 수 있다. 실험에 사용된 현대차 산타페의 OBD-II 단자는 그림 1과 같으며, 각 핀의 기능은 표 1과 같다[18].




그림 1. 현대자동차 산타페의 OBD-II 단자
Fig. 1 OBD-II connector of Santa Fe

표 1. OBD-II 커넥터의 핀 구성
Table 1. OBD-II pinout

Pin	Description
1	Discretionary
2	Bus positive line of SAE J1850
3	Discretionary
4	Chassis Ground
5	Signal Ground
6	CAN_H line of ISO 15765-4
7	K line of ISO 9141-2 and ISO 14230-4
8	Discretionary
9	Discretionary
10	Bus negative line of SAE J1850
11	Discretionary
12	Discretionary
13	Discretionary
14	CAN_L line of ISO 15765-4
15	L line of ISO 9141-2 and ISO 14230-4
16	Permanent positive voltage

ECU(Engine Control Unit)는 엔진의 성능이 최고가 되도록 공연비 제어, 점화 시기 제어, 공회전속도의 제어, 자기진단 제어, 페일세이프(fail-safe) 제어, 통신 기능 등을 담당하는데, 만약 시스템에 고장이 발생한 경우에는 그 원인과 고장 코드를 메모리에 저장하고 OBD-II 단자를 통해서 외부의 진단 장비에게 시스템의 이상 부위와 고장을 진단할 수 있도록 하는 역할을 한다. 본 논문에서는 그림 2와 같은 자동차의 OBD-II 단자에 ELM327 프로토콜을 지원하는 OBD 스캐너를 이용하여 ECU가 보내는 정보를 블루투스 통신을 통해 취득한다. ELM327¹⁾은 명령 프로토콜은 가장 널리 사용되는 PC-to-OBD 인터페이스 표준 중 하나이다.



그림 2. ELM327 OBD-II 스캐너
Fig. 2 ELM327 OBD-II scanner

2.2 피부 전도도

피부 전도도는 전기적 피부 반응, 피부 전도 반응 (Skin Conductance Response, SCR)을 포함한 피부의 전기 전도도 변화를 대표하는 단어이다[19]. EDA 신호의 가장 눈에 띄는 특징은 그림 3과 같이 자극에 대한 교감 신경 활성화 반응인 피부 땀샘의 이온 충전으로 인한 갑작스러운 피부 전도 반응의 상승 이벤트이다[20]. 이는 EDA를 통해 얻을 수 있는 스트레스의 특성으로 볼 수 있다[13].

1) <https://en.wikipedia.org/wiki/ELM327>




그림 3. EDA 신호와 SCR의 상승 이벤트
Fig. 3 EDA signal and rapid transient event of SCR

본 논문에서는 운전자의 EDA 신호를 취득하기 위해 Empatica E4 Wristband²⁾를 사용한다. E4 밴드는 혈압을 측정하여 심박수를 알아낼 수 있고, 피부의 전기적 특성 변화를 측정할 수 있으며 모션의 변화와 피부 온도를 측정할 수 있는 센서를 내장하고 있다. 또한, 기술적 스펙에서 의료기기 2a등급을 받았고, FCC 등에서 승인받은 제품이다.




그림 4. (a) E4 밴드와 (b) E4에 장착된 센서들
Fig. 4 (a) E4 wristband and (b) sensors built into E4

III. 데이터 세트

본 논문에서는 운전 스트레스를 감지하기 위해 MLP 신경망을 사용하였다. 이 모델을 학습시키기 위해 사용된 데이터는 40대 중반의 남성이 2019년 10월 22일부터 동년 11월 19일까지 총 29일 동안 현대 산타페 자가용을 운전한 데이터이며, 일반국도와 고속도로에서 교통체증이 없는 시간과 출퇴근 시간의 교통

체증 상황이 모두 포함된 데이터이다.

주행 상황과 운전자 상태를 정확히 기록하기 위하여 주행 중 영상은 블랙박스로 저장하였으며, 운전자는 E4 밴드를 착용, 모바일 앱을 이용하여 OBD 데이터와 EDA 데이터를 서버에 저장하였다.

실험에 참여한 남성은 운전자 스트레스에 관한 설문 조사[21] 결과, 약간 공격적이며 혼잡한 교통상황에 짜증이 나는 성향의 운전자인 것으로 파악되었다. 따라서, 운전 데이터도 교통체증이 있는 상황과 없는 상황의 데이터가 대략 47:53의 비율이 되도록 취득하였다. 표 2는 모델 학습에 사용된 데이터 정보를 요약한 것이다.

표 2. 운전 데이터 요약
Table 2. Summary of driving data

	Normal	Traffic jam
Number of files	667	626
valid driving time (min)	748	674

3.1 운전자 주행 데이터

운전자의 주행 데이터는 OBD-II 스캐너와 스마트폰 간 블루투스 통신으로 수집하였다. 모바일 앱은 안드로이드 환경에서 JAVA를 이용하여 구현하였고, 데이터베이스는 Firebase를 사용하였다.

수집 항목은 분당 회전량(rpm), 속도(velocity), 스로틀밸브 열림량(relative_throttle_pos), 가속 페달 위치(accelerator_pos_d) 4가지이고, 주행 중 5분간 수집한 데이터를 csv 파일로 생성하여 POST 방식으로 서버에 전송하도록 하였으며 데이터는 표 3과 같이 80%가 겹치도록 수집하였다.

표 3. 수집 데이터 예시
Table 3. Example of acquired data

Transmit time	Duration
09:51	09:45 - 09:50
09:52	09:46 - 09:51
09:53	09:47 - 09:52

위와 같이 수집된 데이터는 데이터의 안정성을 확보하기 위하여 운전 시작 후 10분, 운전 종료 전 10분

2) <https://www.empatica.com/research/e4/>

의 데이터를 사용하지 않았다.

3.2 피부 전도도 데이터

Empatica의 E4 밴드는 제조사에서 제공하는 E4 realtime이라는 모바일 앱과 연동하여 실시간으로 데이터를 서버에 저장할 수 있으며, 취득한 데이터는 Empatica E4 connect 웹페이지³⁾에서 그래프로 확인할 수 있을 뿐만 아니라 압축파일로 다운로드 받을 수도 있다. 압축파일에는 센서별 취득 데이터가 CSV 파일로 저장되어 있으며, 피부 전도도 데이터는 EDA.csv 파일로 저장되어 있다.

IV. 특징 벡터

4.1 피부 전도도 특징 벡터

J. A. Healey와 R. W. Picard는 운전 스트레스를 검출하기 위해 피부 전도 반응 이외에도 근전도, 심전도, 호흡 신호에서 검출한 특징을 합쳐 모두 22개의 특징을 정의하고 있다[13]. 본 논문에서는 이 중에서도 스트레스와 가장 밀접하다 알려진 EDA의 데이터 특징 파라미터를 기반으로 특징 벡터를 생성한다.

그림 5와 같이 EDA 신호로부터 추출된 OM(Onset Magnitude, Δ 표시), OD(Onset Duration, \circ 표시부터 Δ 표시까지의 시간) 파라미터를 이용하여 얻은 삼각형 면적과 관련된 파라미터를 특징으로 이용한다.




그림 5. EDA 신호에서 추출한 특징
Fig. 5 Features extracted from EDA signal

최종적으로 정의된 특징은 전체 신호에서 계산된 삼각형 면적의 총합, 최대 면적, 최대 기울기, 최대 면

적의 기울기, 총 발생 횟수이다. 면적은 이미 기존 연구[13]에서 특징 벡터로서의 성능을 확인할 수 있으며, 여기에 최대 면적의 기울기, 최대 기울기를 추가한 것은 운전자가 예기치 못한 상황 또는 갑자기 발생한 상황(급정거, 급출발 등)에 대해 인체가 반응한 특성을 추출하기 위함이다.

4.2 운전 데이터의 스트레스 이벤트

시간 동기화된 OBD 속도 데이터와 EDA 데이터의 변화를 비교하며 앞서 정의한 EDA의 이벤트가 발생할 당시의 속도 데이터 변화 패턴을 관찰하였다. 운전자가 가속, 감속 또는 신호대기 상태일 때 의미있는 EDA 이벤트가 발생하였음을 확인할 수 있었다. 따라서, 가속, 감속, 신호대기에 해당하는 OBD 속도 데이터 패턴 정보를 스트레스 이벤트로 정의하였다. 그림 6은 OBD 데이터 중 속도 데이터와 EDA 데이터의 변화를 나타낸 것으로, 속도 데이터(녹색)의 변화 시 EDA 피크(보라색)가 발생함을 확인할 수 있다.

다른 OBD 취득 데이터인 회전량, 스로틀밸브 열림량, 가속 페달 위치의 데이터도 EDA 데이터와 비교해 보았으나, 속도 데이터가 가장 세밀하고 유의미하다고 판단하였다.

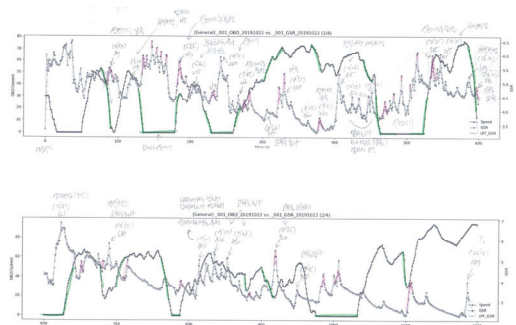


그림 6. 속도 데이터와 EDA 데이터 연관성 비교
Fig. 6 Comparison of Velocity and EDA

4.3 운전 데이터 특징 벡터

운전자의 주행 특징은 그림 7과 같이 OBD 속도 데이터에서 국소 최소점(Local Minimum, \circ 표시)과 국소 최대점(Local Maximum, Δ 표시), 그리고 영점(\square 표시)을 찾아 가속, 감속, 신호대기 상태를 검출하

3) <https://www.empatica.com/connect/>

고, 가감속에 해당하는 삼각형 면적과 신호대기에 해당하는 길이를 특징으로 사용한다. 추가로 통계적 특징을 포함하여 최종 특징벡터로 정의한 것은 OBD 속도 데이터의 평균, 표준편차, 분산, 첨도(kurtosis), 왜도(skewness), 가속 면적 합, 감속 면적 합, 대기시간 합, 최대 가속 면적, 최대 감속 면적, 최대 대기시간, 가속 횟수, 감속 횟수, 대기 횟수이다.




그림 7. 속도 데이터와 특징
Fig. 7 Velocity from OBD and features

4.4 데이터 라벨링

본 논문에서 스트레스 감지 모델 개발을 위해 수집한 데이터는 J. A. Healey와 R. W. Picard의 연구 결과를 바탕으로 스트레스 상황과 그렇지 않은 상황으로 정의된 도로환경에 따라 분류된다. 즉, 일반도로와 고속도로에서 교통체증과 원활한 교통상황은 각각 스트레스 상황과 그렇지 않은 상황으로 분류된다. 이들 데이터를 기반으로 앞서 제시한 EDA 데이터의 특징을 추출, 스코어링 하였고, 이를 통해 이들 상황을 가장 잘 반영하는 임계값을 찾아, 데이터 라벨링에 적용하였다. EDA 스코어링은 클래스 분류의 기준값을 제공하고, 이를 통해 라벨링 EDA-OBD 데이터 쌍을 얻을 수 있었다. 다시 말해, EDA를 기반으로 판별된 스트레스 상황과 그렇지 않은 상황에 대한 운전 데이터를 얻을 수 있었다.

V. 실험 및 결과

5.1 실험 프로토콜

그림 8의 환경에서 다음의 절차에 따라 실험을 진행한다.

1) 실험을 위해 현대 산타페 자동차에 OBD-II 스캐너를 장착하고 운전자는 손목에 E4 밴드를 착용한다.

2) 스마트 폰에는 E4 realtime 앱과 OBD 데이터 수집을 위한 앱을 설치한다. 스마트 폰과 E4 밴드는 블루투스로 연결되며 데이터 저장 및 전송을 위해 E4 realtime 앱을 사용한다. 스마트 폰과 OBD-II 스캐너는 블루투스로 연결되며 데이터 취득 및 전송을 위해 제작한 OBD 데이터 수집 앱을 사용한다.

3) 스마트 폰과 서버, 스마트 폰과 E4 connect 간의 TCP/IP 통신을 위해 공유기를 사용한다.

4) 주행 중 OBD-II 스캐너에서 취득한 데이터는 모바일 앱을 통해 서버에 저장되고, 서버에서는 스트레스 감지 모델이 동작하여 해당 데이터에 대한 스트레스 여부를 판별하여 결과를 같이 저장한다.

5) E4 밴드로 취득한 운전자의 EDA 데이터는 운행이 끝난 후 스마트 폰에서 E4 connect로 업로드 한 후, 서버에서 다운로드 받는다. 4.1절에서 설명한 방법으로 특징을 추출, 운전 중 스트레스 상황을 정의한다.

6) 4)의 결과와 5)의 결과를 비교하여 스트레스 감지의 정확도를 산출한다.




그림 8. 실험 환경
Fig. 8 Experimental environment

5.2 실험 결과

운전 스트레스 감지에 사용된 모델은 MLP 신경망으로 입력으로 14개의 운전 특징 벡터가 사용되고 은닉층은 4개, 각각의 뉴런 수는 64, 32, 16, 8이며 활성화 함수로 relu함수를 사용하였다. 출력 층에는 시그모이드 함수를 사용하였다. III절에서 기술한 데이터를 사용하여 학습시켰으며 학습 결과 약 91.42% 정확도를 보였다.

이 모델을 테스트하기 위해 5.1절의 절차에 따랐으며 운전과 차량은 학습 데이터를 제공한 동일인이 동일한 차량으로 운전하였다. 맑은 날씨의 낮 시간(14:40-16:10)에 약 1시간 30분 동안 시내 주행을 하였으며, 신경망

모델이 감지한 결과와 EDA를 기준으로 판단한 결과는 표 4와 같다. 요약하면, 총 66번의 결과 중 5번의 감지 결과가 다르게 나와 92.42%의 높은 정확도를 보였다.

표 4. 실험 결과
Table 4. Experimental result

Time	*GT	**MD	Time	GT	MD
14:55:17	1	1	15:28:18	0	0
14:56:17	1	1	15:29:17	0	0
14:57:17	1	1	15:30:17	0	0
14:58:17	1	1	15:31:17	0	0
14:59:17	0	1	15:32:17	0	0
15:00:17	0	0	15:33:18	0	0
15:01:17	0	0	15:34:17	0	0
15:02:17	0	0	15:35:17	0	0
15:03:17	0	1	15:36:18	0	0
15:04:17	0	0	15:37:17	0	0
15:05:17	0	0	15:38:17	0	0
15:06:17	0	0	15:39:17	0	0
15:07:17	0	0	15:40:17	0	0
15:08:17	0	0	15:41:17	0	0
15:09:17	0	1	15:42:17	1	1
15:10:17	0	1	15:43:17	1	1
15:11:17	0	1	15:44:17	1	1
15:12:17	0	0	15:45:17	0	0
15:13:17	0	0	15:46:17	0	0
15:14:17	0	0	15:47:18	0	0
15:15:18	0	0	15:48:18	0	0
15:16:17	0	0	15:49:17	1	1
15:17:17	0	0	15:50:17	1	1
15:18:18	0	0	15:51:17	0	0
15:19:17	0	0	15:52:17	0	0
15:20:17	0	0	15:53:17	1	1
15:21:17	0	0	15:54:17	1	1
15:22:17	0	0	15:55:18	1	1
15:23:17	0	0	15:56:18	1	1
15:24:17	0	0	15:57:17	1	1
15:25:17	0	0	15:58:18	1	1
15:26:18	0	0	15:59:18	1	1
15:27:18	1	1	16:00:17	0	0

*GT : Ground Truth

**MD : Model Decision

VI. 결론

인간의 생체 신호 데이터가 인간의 상태를 가장 잘 설명할 수 있다 할지라도 실제 운전 중에 운전자의 생체 데이터를 얻어 운전자의 상태를 판단하는 일은 쉽지 않다. 본 논문에서는 이러한 한계를 극복하기 위한 다양한 방법 중 한 가지로 운전 주행 정보를 이용한 운전자 스트레스 모니터링 시스템을 제안하였다. 약 한 달간의 운전 데이터를 취득하여 EDA 데이터와 운전 데이터 중 속도 데이터를 비교하여 속도와 운전 스트레스 간 유의미한 상관관계가 있음을 확인하였고, 이를 바탕으로 모델을 설계, 테스트를 수행하였다. 90%가 넘는 정확도를 얻을 수 있었지만 본 논문에서 수행한 실험에도 한계는 있다. 한 사람만의 데이터를 사용하였다는 점이다. 많은 사람의 운전 데이터를 적용하여 모델을 일반화시키지 못한 점은 아쉬운 점으로 남는다. 이를 위해서는 지금보다 훨씬 많은 시간과 비용이 투자되어야 할 것이다. 최소 1년 이상의 데이터가 누적되어야 계절별 특성도 반영할 수 있을 것이라 예상된다.

References

- [1] J.-H. Son, H.-Y. Lee, H.-J. Bae, Y.-H. Kim, and B.-J. Lee, "Driving under influence Prevention System Using Fingerprint sensors with Arduino," *J. of the Korea Institute of Electronics Communications Sciences*, vol. 17, no. 5, 2022, pp. 969-976.
- [2] H.-M. Lee, W.-W. Lee, and J.-A. Jang, "Quantification Method of Driver's Dangerous Driving Behavior Considering Continuous Driving Time," *J. of the Korea Institute of Electronics Communications Sciences*, vol. 17, no. 4, 2022, pp. 723-728.
- [3] Y.-H. Kong, H.-J. Kim, Y.-J. Yi, and S.-J. Kang, "Development of Incident Detection Algorithm using GPS Data," *J. of the Korea Institute of Electronics Communications Sciences*, vol. 16, no. 4, 2021, pp. 771-782.
- [4] A. Tjolleng, K. Jung, W. Hong, W. Lee, B. Lee,

- H. You, J. Son, and S. Park, "Classification of a Driver's cognitive workload levels using artificial neural network on ECG signals," *Applied Ergonomics*, vol. 59, part A, 2017, pp. 326-332.
- [5] S. Lee and S. Lee, "Validation and Development of the Driving Stress Scale," *Korean J. of Culture and Social Issues*, vol. 14, no. 3, 2008, pp. 21-40.
- [6] National Safety Council, "Understanding the Distracted Brain: Why Driving while Using Hand-free Cell Phone Is Risky Behavior," *Report*, Mar. 2010.
- [7] S. A. Hosseini, M. A. Khalilzadeh, and M. Branch, "Emotional Stress Recognition System Using EEG and Psychophysiological Signals: Using New Labelling Process of EEG Signals in Emotional Stress State," In *Proc. Int. Conf. Biomedical Engineering and Computer Science*, Wuhan, China, Apr. 2010.
- [8] R. Khosrowabadi, C. Quek, K. K. Ang, S. W. Tung, and M. Heijnen, "A Brain-Computer Interface for classifying EEG Correlates of Chronic Mental Stress," In *Proc. Int. Joint Conf. Neural Networks (IJCNN)*, San Jose, CA, USA, Aug. 2011.
- [9] J. Choi and R. Gutierrez-Osuna, "Removal of Respiratory Influences from Heart Rate Variability in Stress Monitoring," *IEEE Sensor J.* vol. 11, no. 11, 2011, pp. 2649-2656.
- [10] A. Santos, C. Sánchez, J. Guerra, and G. Bailador del Pozo, "A Stress-Detection System Based on Physiological Signals and Fuzzy Logic," *IEEE Trans. Industrial Electronics*, vol. 58, no. 10, 2011, pp. 4857-4865.
- [11] T. Yamakoshi, K. Yamakoshi, S. Tanaka, M. Nogawa, S. B. Park, M. Shibata, Y. Sawada, P. Rolfe, and Y. Hirose, "Feasibility Study on Driver's Stress Detection from Differential Skin Temperature Measurement," In *Proc. 30th Annual Conf. IEEE in Engineering in Medicine and Biology Society*, Vancouver, Canada, Aug. 2008.
- [12] Z. Jing, A. B. Barreto, C. Chin, and L. Chao, "Realization of stress Detection Using Psychophysiological Signals for Improvement of Human-Computer Interactions," In *Proc. IEEE SoutheastCon*, Fort Lauderdale, FL, USA, Apr. 2005.
- [13] J. A. Healey and R. W. Picard, "Detecting stress during real-world driving tasks using physiological sensors," *IEEE Trans. Intelligent Transportation Systems*, vol. 6, no. 2, 2005, pp. 156-166.
- [14] B. Kim and B. Lee, "Bio-signal-based Driver's Emotional Response Monitoring System: System Implementation," *J. of the Korea Institute of Electronics Communications Sciences*, vol. 13, no. 3, 2018, pp. 667-683.
- [15] S. Hong, "Design and implementation of healthcare system based on non-contact biosignal measurement," *J. of the Korea Institute of Electronics Communications Sciences*, vol. 15, no. 1, 2020, pp. 185-190.
- [16] ISO 15031-3, *Road vehicles – Communication between vehicle and external equipment for emissions-related diagnostics – Part 3: Diagnostic connector and related electrical circuits: Specification and use*, ISO, 2016.
- [17] M. Kim, S. Lee, and S. Park, "A Development of EURO 6 Smart Cluster System Using OBD-II Standard Interfaces and Smart Cluster Interface," *Trans. Korean Society of Automotive Engineers*, vol. 26, no. 1, 2018, pp. 85-96.
- [18] SAE J1962, *Diagnostic Connector Equivalent to ISO/DIS 15031*, Society of Automotive Engineers, 2002.
- [19] H. D. Critchley, "Review: Electrodermal Responses: What Happens in the Brain," *The Neuroscientist*, vol. 8, no. 2 2002, pp. 132 - 142.
- [20] H. F. Posada-Quintero and K. H. Chon, "Innovations in Electrodermal Activity Data Collection and Signal Processing: A Systematic Review," *Sensors*, vol. 20, no. 2, 2020, pp. 479.
- [21] E. Gulian, G. Matthews, A. I. Glendon, D. R. Davies, and L. M. Debney, "Dimensions of driver stress," *Ergonomics*, vol. 32, no. 6, 1989, pp. 585-602.

저자 소개



조상진(Sang-Jin Cho)

1997년 울산대학교 전자공학과 졸업(공학사)

2002년 울산대학교 대학원 전자공학과 졸업(공학석사)

2007년 울산대학교 대학원 컴퓨터공학과 졸업(공학박사)

2009년~2017년 울산대학교 산학협력단 연구교수

2017년~2019년 지니어스(Zimmias) 기술이사

2020년~현재 (주)지메이드 대표이사, 울산과학기술대학교 전기전자공학부 겸임교수

※ 관심분야 : u-헬스케어 시스템, 인공지능, 신호처리



조 영(Young Cho)

2006년 울산대학교 수학과 졸업(이학사)

2008년 울산대학교 대학원 수학과 졸업(이학석사)

2014년 울산대학교 대학원 수학과 졸업(이학박사)

2022년 울산과학기술대학교 전기전자공학부 조교수

※ 관심분야 : 통신이론, 데이터통신, 인공지능

