



## 공 학 석 사 학 위 논 문

# 스티어링 휠로부터 측정된 생체신호 데이터에 기계 학습을 적용한 운전자 피로도 모니터링 시스템 개발

2020년 2월

부경대학교대학원

전자공학과

구예진

공 학 석 사 학 위 논 문

# 스티어링 휠로부터 측정된 생체신호 데이터에 기계 학습을 적용한 운전자 피로도 모니터링 시스템 개발

지도교수 정 완 영

이 논문을 공학석사 학위청구논문으로 제출함 2020년 2월 부 경 대 학 교 대 학 원

전자공학과

구 예 진

# 구예진의 공학석사 학위논문을 인준함



Development of Driver Fatigue Monitoring System Using Machine Learning Approaches Based on Physiological Signal from Steering Wheel

Ye-Jin Gu

Department of Electronic Engineering, The Graduate School,

Pukyong National University

#### Abstract

Driver fatigue is one of the major causes of traffic accidents. Therefore, in order to prevent traffic accidents and ensure traffic safety, it is necessary to analyze the fatigue characteristics of the driver. In order to monitor driving fatigue, physiological signals such as heart rate or skin conductivity can be used. Signal changes measured while driving were clinically proven for quantitative analysis of stress and mental fatigue. In this study, we developed a real-time driving fatigue identification and classification system using physiological signals from the hand on the steering wheel for the minimum restraint on the driver.

Experimental procedures were designed and constructed to induce driving conditions similar to those in real life. Driving simulation program is used to measure fatigue, and physiological signals such as skin conductance (GSR), electrocardiogram (ECG) and photoplethysmography (PPG) are recorded during the experiment. A total of 18 subjects participated in this experiment. In addition, thirteen features were extracted from the statistical and time-frequency changes of the physiological signals in relation to fatigue and heart rate variability induced in long-term driving. In the signal analysis, the proposed classification algorithm is designed based on the Time Delay Neural Network (TDNN) using the extracted features. The proposed system can classify fatigue into three levels. The system also identifies persistent fatigue situations or instantaneous stress depending on the activity of the subject. The experimental results show that the accuracy is 77.27% in Support Vector Machine (SVM).

The proposed system can detect and classify fatigue stages based on two non-invasive signals. These signals can be preconfigured and collected during simulation and processed in real time. These driving safety systems for drivers are expected to reduce traffic accidents by providing drivers with fast and reliable real-time notifications. For example, our system can be applied to fatigue monitoring in air traffic.

목 차

영 문 초 록
그 림 차 례 vi
표 차 례 ix
약 어 표 ······ x
제 1 장 서론 1
제 2 장 배경이론 및 관련 이론
2.1. 서두 5
2.2. 바이오 피드백과 피로
2.3. 피로와 스트레스
2.4. 자율 신경계
2.5. 접근법 분석

저	∥ 3 장 데이터 및 방법	5
	3.1. 실험 순서	15
	3.2. 데이터 수집 및 분석	20
	3.3. 전처리	21
	3.4. 특징 추출	27

INTIONAL	
제 4 장 운전자 피로도 분류를 위한 기계학습	34
4.1. Support Vector Machine (SVM) ·····	35
4.2. K-Nearest Neighbor (KNN) ·····	37
4.3. Time Delay Neural Network (TDNN) ·····	39
4.4. Long Short-Term Memory (LSTM)	41
र्भ य दम य	

ጾ	1) 5	장 실험	결과 및 논의	44
	5.1.	운전자	피로도 실험 구성	44
	5.2.	운전자	피로도 실험의 결과 분석	51
	5.3.	결	론	63

참 고 문	- 헌	 65
감사의	글	 70



## 그림차례

- Fig 1. Traffic accidents by time of day.
- Fig 2. Traffic accidents in 2018.
- Fig 3. Human sweat glands.
- Fig 4. Interbeat Interval (IBI).
- Fig 5. Stress Pattern in EDA.
- Fig 6. Autonomic Nervous System.
- Fig 7. Experiment of Fatigue Monitoring.
- Fig 8. Experiment Progress Protocol.
- Fig 9. Proposed System Architecture Block Diagram.
- Fig 10. ECG and SC signals obtained from Hands during Driving.
- Fig 11. Low Pass Filter Analog Circuit.
- Fig 12. PSD of Heart Rate Variability.
- Fig 13. Flow Chart for Data Collection.
- Fig 14. SC Signal Analysis (SCL and SCR).

- Fig 15. SVM Classification Principle.
- Fig 16. LSTM cell.
- Fig 17. LSTM Layer Architecture.
- Fig 18. Experimental Setup for Data Acquisition.
- Fig 19. Conductive Fabric.
- Fig 20. ECG Analog Circuit.
- Fig 21. EDA Analog Circuit.
- Fig 22. Collected Physiological Signals.
- Fig 23. ECG Signal with Discrete Wavelet Transform and Low Pass Filter.
- Fig 24. PPG Signals with Discrete Wavelet Transform and Low Pass Filter.
- Fig 25. IBI of ECG Signal.
- Fig 26. Peaks of Respiratory Signal.
- Fig 27. Class Label Distribution by Test Set.
- Fig 28. Overall Class Label Distribution.
- Fig 29. Three Features of the Driving Data.
- Fig 30. Driving Dataset Consisting of Three Classes.
- Fig 31. LF and HF Features and Maximum Posterior.
- Fig 32. Structure of a deep LSTM architecture.

- Fig 33. Structure of a deep TDNN architecture.
- Fig 34. KNN- Test Set Confusion Matrix.
- Fig 35. SVM Test Set Confusionn Matrix.
- Fig 36. LSTM Test Set Confusion Matrix.
- Fig 37. TDNN Test Set Confusion Matrix.
- Fig 38. MATLAB Prototype Application.



## 표차례

- Table 1. Description of Events included in the Simulation
- Table 2. All Features calculated from measured Physiological Signals
- Table 3. Classification Results of Each Classifier on the Test Set



# 약 어 표

SNS	Sympathetic Nerve System 교감신경계
PSNS	Parasympathetic Nervous System 부교감신경계
HRV	Heart Rate Variability 심박변이도
EDA	Electrodermal Activity 피부전기활동
ECG	Electrocardiogram 심전도
PPG	Photoplethysmography 광전용맥파
SVM	Support Vector Machine
KNN	K-Nearest Neighbor
LSTM	Long Short-Term Memory
TDNN	Time Delay Neural Network
RNN	Recurrent Neural Network
GSR	Galvanic Skin Response 피부전기활동
IPG	Impedance Plethysmography
IBI	Interbeat Interval 맥놀이간간격
HR	Heart Rate 심박
HF	High Frequency 고주파
LF	Low Frequency 저주파
SNR	Signal Noise Ratio 신호 대 잡음 비

- PSD Power Spectral Density 전력 스펙트럼 밀도
- SC Skin Conductance 피부 전도도
- SCL Skin Conductance Level
- SCR Skin Conductance Response
- DWT Discrete Wavelet Transform 이산 웨이블릿 변환
- TP True Positive 참 양성
- TN True Negative 참 음성
- FP False Positive 거짓 양성
- FN False Negative 거짓 음성

# 제 1 장

서 론

운전자 피로는 도로 사고의 주요 원인이며 도로 안전에 큰 영향을 끼 친다[1]. 운전자 피로는 운전 중 피로 및 집중력 저하를 가져올 수 있으 며, 운전 수행 능력을 감소시킨다. 더욱이, 운전은 좁은 의자에 오랫동안 앉아 있기 때문에 일반적인 육체적 노동에 비해 피로가 빨리 온다.



Fig. 1 Traffic Accidents by Time of Day. (도로교통공단 2018년 교통사고 통계분 석-2019년판)

도로교통공단 통계에 따르면 시간대별로 18~20시에 사고(13.5 %)와 사망 자(11.5 %)가 가장 많이 발생하였고, 치사율은 새벽 시간대인 4~6시가 4.8 명으로 가장 높았다.



Fig. 2 Traffic Accidents in 2018. (한국도로공사 2018년 교통사고 현황)

또 교통안전공단에서 실시한 운전자 400명 대상 실태조사 결과에 따르 면 피로누적과 식곤증이 고속도로 졸음운전의 주요 원인이라고 밝혔다. 특히, 운수회사 근무 운전자 10명 중 5명이 만성피로에 시달린다는 조사 결과가 있다. 졸린 운전자는 위험한 상황을 빨리 인지하는 것도 쉽지 않 고 충돌 전에 회피 조치를 취하는데 느리게 반응하기 때문에 졸음운전과 관련된 사고는 다른 유형의 사고보다 더 심각하다. 그림2와 같이 한국도 로공사의 2018년 교통사고 현황에 따르면 고속도로 교통사고의 68 %, 화 물차 교통사고의 80 %가 졸음운전으로 인한 사고였다. 이러한 이유로 운 전자의 피로도 수준을 모니터링하고 운전자의 피로도 수준이 높을 때 경 고하는 시스템을 개발하는 것은 사고를 예방하는데 필수적이다. 신체 생리 신호와 정신 상태 사이의 관계를 고려할 때, 스트레스 상황 을 식별하기 위한 적절한 접근법은 여러 가지 생리신호를 분석하고 스트 레스와 생리신호 사이의 관계를 찾는다. 많은 연구들이 스트레스와 생리 적 신호 사이의 관계를 실험하였다. 지난 10년간 많은 연구자들이 다양한 기술을 사용하여 피로도 모니터링 시스템의 개발을 위해 노력해왔다 [2-4]. 피로도 탐지를 위한 대표적인 방법으로는 뇌파, 심박수, 맥박 및 호흡 과 같은 생리적 현상에 기반한 방법이 많이 사용된다[5-10]. 하지만 현재 대부분의 기술들은 웨어러블 디자인으로 운전자의 신체에 전극을 부착해 야하는 불편함이 있고, 다른 기술로는 특수 콘택트 렌즈나 카메라를 사용 하여 눈과 시선의 움직임을 모니터링하는 기술이 있지만 개인정보법 등 의 문제로 실제 적용되는 데 많은 어려움이 있다.

스트레스는 피로도와 밀접한 관련이 있기 때문에 본 논문에서는 피로 도와 스트레스를 같이 다루었다[11]. 안정적인 상태에서 신체를 유지하는 매커니즘은 교감 신경계(SNS)와 부교감 신경계(PSNS)에 의해 실현된다. 스트레스의 정도에 따라 교감신경을 활성화할 수 있다고 알려져 있으며, 부교감신경계는 신체를 휴식 상태로 되돌릴 수 있다[12]. 자율 신경계의 활동은 심박수, 심박변이도(HRV), 혈압 등과 같은 일부 생리학적 신호를 통해 모니터링 할 수 있다. Ursin과 Eriksen의 연구에 따르면 스트레스에 대한 인지 활성화 이론을 제시하여 스트레스가 많은 상황의 지속 시간을 연구하고 그러한 상황에 대한 레이블 작업을 수행하여 경고와 스트레스 로 나누었다[13].

본 논문에서는 부교감 신경계의 기능에 대한 충분한 정보를 제공하 고 비침습성 장치로 수집하기 위하여 EDA 및 ECG, PPG 신호를 사용하 였다[14]. 피로도 연구에 기초한 대부분의 연구는 개인이 스트레스 상황

3

을 겪고 있는지 여부를 식별하기 위해 피로 상태와 이완 상태를 구별하 려고 시도한다. 따라서 피로가 많은 상황에서 발생하는 정서적 변화에 대 비하여 이를 정확하게 식별할 수 있어야 한다. 본 연구는 장시간 운전에 서의 피로도를 탐지하는 방법을 연구하였다.



# 제 2 장

# 배경 이론 및 관련 연구

### 2. 1. 서두

피로도 감지 연구는 계속해서 연구되고 있다. 본 연구에서는 피부전 도도 및 심박 신호와 Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Time Delay Neural Network (TDNN), Long Short-Term Memory models (LSTM)과 같은 기계학습 알고리즘을 사용하였다.

Ot y

### 2. 2. 바이오 피드백과 피로

바이오 피드백의 기본 개념은 신체에서 일어나는 일에 대한 정보를 제공하는 것이다. 실험자는 근전도 센서, 심전도 센서, 호흡 센서, 맥박 센서 등을 신체에 부착하고 컴퓨터 화면을 통해 실험자의 상태에 따라 변하는 생리적 반응을 확인할 수 있다. 이러한 반응을 통해 실험자의 다 양한 생각, 감정 및 감각에 대한 정보를 수집할 수 있다. 운전자의 피로 도를 측정하기 위해 지난 몇 년 동안 생체 신호 분야에서 다양한 접근법 이 제시되었다.

본 연구는 운전자에게 위화감을 주지 않는 피로도 측정 시스템 개발 을 목표로 시작하게 되었다. 차량 내부에서 운전자의 범위는 스티어링 휠, 제동 및 가속 페달, 기어 스틱 정도로 특정 지을 수 있다. 그 중, 스티어 링 휠은 운전 중 운전자와 항상 접촉하고 있기 때문에 피로도 감지 시스 템의 신호 측정 장치로써 선택되었다[14].

Ani 외[15]는 운전 피로 변형률 지수를 제시하였다. 또한 향후 이 지 수는 운전 중 피로를 최소화하기 위한 대체 솔루션에 대해 도움을 줄 것 이다. 이 연구에서는 근전도, 심박수, 손의 압력, 의자의 압력 분산, 몸의 떨림, 운전 기간을 기반으로 운전 피로 변형률을 계산하였다.

Li 외[16]는 표정 기반의 감정인식을 연구하는데, 생리신호를 이용하 여 표정만으로는 추론하기 힘든 부분을 보완하고자 하였다. 해당 논문에 서 ECG, GSR, 그리고 PPG를 이용하여 생리학적 신호를 측정한다. 더 나 아가 IRS(Individual Response Specificity) 모델을 사용하여 일반 모델보다 더 높은인식 정확도를 달성하였다.

본 연구에 제시된 시스템에 사용된 심박 신호 분석 프로세스는 Charlton 외[17]에 의해 소개되었다. 알고리즘은 호흡 신호 추출, RR 추정 및 분석의 세 단계로 나뉜다. 이들은 ECG, PPG 및 IPG에서 파생된 RR을 LOA(Limit of Agreement) 기술과 코 구강 압력 센서를 사용하여 비교하

6

였다.

#### 가. 심전도와 피부전도도

피부전도도는 스트레스, 불안 인지에 효과적이다. 다만, 피부 저항만 을 측정하기 때문에 바이탈 신호는 측정할 수 없다. 이 때문에 심장의 반 응을 측정하기 위해 심박 변화(ECG)와 피부전도도(EDA)를 결합하여 사용 하였다. 이러한 바이오 피드백은 운전자에게 본인의 피로를 인지하고 대 처하는 데 도움이 될 것이다. 특히, 피부전도도 및 심박 변이도는 분석 방법에 관계없이 진단에 쉽게 사용할 수 있는 강력한 바이오 피드백을 제공한다[18].

#### 나. 피부전도도 (Electrodermal Activity)

피부전도도는 비침습 전극에 의해 측정된 피부의 전기적 활동 신호 이다[19]. 이는 쉽게 측정되고 상대적으로 안정적인 피부전도도 신호는 개인의 신체 상태를 이해하기 위해 측정 가능한 매개 변수를 제공하는 지표로 사용되었다. 땀은 피부전도도와 직접적으로 관련된다. 그림 3과 같이 땀샘은 땀을 만들어내는 피부의 외분비선이다. 피질의 가장 바깥 층 은 자극을 받으면 복잡한 생리적 반응을 일으켜 혈액 모세관이 커져서 땀이 생성되고 땀샘의 끝은 실이 뭉쳐 있는 것처럼 되어있고 긴 관을 통 해 피부표면과 연결되어 있는데, 이를 통해 땀을 배출하게 되고 피부 저

7

항을 변화시킨다. 피부전도도는 땀샘 활동을 반영하며 교감 신경계의 척 도로 활용된다[20]. 보통의 상황에서 피부전도도는 높은 저항 값을 가진 다. 하지만 스트레스, 분노, 불안과 같은 특정 이상 조건에서는 피부 저항 이 점진적으로 감소한다. 이러한 반응에서 피부전도도만을 통해 자율신경 의 변화를 예측하기 어렵기 때문에 심박변이도를 함께 사용하여 예측할 수 있다.



Fig. 3 Human Sweat Glands. (National Cancer Institute)

#### 다. 심박변이도 (Heart Rate Variability)

심박변이도 분석은 심혈관계 연구와 의학에서 많이 이용되고 있다. 심박변이도는 자율 신경계의 상태를 측정하기 위한 비침습적 방법이다. 인간의 생리학적 연구에 따르면 피로가 증가한 후 휴식시 심박변이도가 증가되는 것으로 나타났다[21]. 심박변이도 측정은 심박수의 조절에 대한 신뢰성 있는 정보를 제공하며 건강을 평가하기 위한 중요한 기준이 되었 다. 연속된 심박 사이의 간격을 'Interbeat Interval (IBI)'라고 한다(그림 4). 심박변이도는 연속 IBI의 변화를 나타낸다. 측정의 편의를 위해, 심박 은 일반적으로 RR 간격으로 지칭되는 R파의 피크에서 다음 R파까지 밀 리 초 단위로 측정되며 교감 신경계와 부교감 신경계 간의 균형과 관련 이 있다. 따라서, 피부전도도와 심박변이도를 이용하면 운전자의 상태를 더 정확하게 판단할 수 있을 것이다. 심박수(HR, 분당 비트 수)는 ECG에 서 R-파를 탐지하고 연속적인 R-R 간격을 계산하는 프로그램으로 분석 된다. T-파의 진폭은 R-파 후 50 내지 300 ms 법위의 최댓값이다. R-R 간격 변동의 스펙트럼 밀도는 저주파수 대역(LF, 0.05-0.15 Hz)에서 합산 되어 교감 및 부교감 신경계 작용과 혈압 조절을 반영한다.



Fig. 4 Interbeat Interval (IBI).

#### 2. 3. 피로와 스트레스

#### 가. 피로

피로는 지속적인 피곤한 느낌이며 신체적, 정신적 또는 이 둘의 조합일 수 있다. 만성 피로(Fatigue)는 때때로 피로감(Tiredness)으로 묘사되지만 피곤하거나 졸리는 느낌과는 다르다. 모든 사람은 어느 시점에서 피곤하 다고 느끼지만 대개 낮잠이나 숙면으로 해결된다. 졸린 사람도 운동 후 일시적으로 상쾌하게 느낄 수 있다. 하지만 충분한 수면, 좋은 영양 섭취 및 규칙적인 운동을 하면서도 일상적인 활동을 수행하기가 어렵거나 집 중력이 저하될 때 만성피로하다고 한다. 만성 피로는 두통, 현기증 및 근 육 통증 등과 같은 광범위한 신체적, 정신적, 정서적 증상을 유발할 수 있다.

피로를 유발할 수 있는 원인은 다음과 같다. 1) 의학적 원인 : 갑상선 장애, 심장병 또는 당뇨병과 같은 질병의 징후 2) 생활 습관 관련 원인 : 알코올이나 약물 부작용 또는 운동 부족 3) 직장 관련 원인 : 직장 스트레스 4) 정서적 스트레스 : 우울증과 같은 정신 건강 문제의 일반적인 증상이

며 과민성과 동기 부여 부족을 포함한 다른 징후와 증상을 동반

본 연구에서는 사람들이 높은 피로도 상태에서 운전하는 것을 경고하 고자 한다. 특히, 이 논문에서는 급성 스트레스보다 지속적인 스트레스인 의 식별에 초점을 둔다.

#### 나. 스트레스

스트레스는 세 가지로 분류할 수 있다.

- 1) 급성 : 단기 스트레스 요인으로 인한 스트레스
- 2) 일회성 급성 : 자주 또는 주기적으로 발생하는 급성 스트레스

3) 만성 : 장기적으로 스트레스 요인에 의한 스트레스. 건강에 직접적으
로 영향을 끼친다.

대부분의 사람들은 일상 생활에서 심각한 스트레스를 경험하곤 한다. 최 초의 순간적인 스트레스 반응은 유해한 것으로 간주되지 않는다. 하지만 발생 빈도가 증가하거나 지속되면 생리적 증상이 발생할 수 있다. 이러한 스트레스는 매우 바쁘고 혼란스러운 삶과 관련이 있으며 장기간에 걸쳐 발생할 때 몸에 해로운 영향을 끼친다. 스트레스는 외부 자극으로 인한 각성에 선행하는 응급 상태로 볼 수 있다. 그림 5에서 N은 평상시, A는 스트레스를 받기 시작하는 구간, S는 스트레스 자극 직후, R은 회복기를 나타낸다.



Fig. 5 Stress Pattern in EDA.

## 2. 4. 자율 신경계

자율 신경계는 주로 감정적인 반응을 수반하며 몸의 평활근, 심장근 및 분비선에서 호르몬 분비를 조절한다. 자율 신경계는 두 가지 주요 하 위 신경계로 구성되는데, 하나는 교감 신경계로 심박의 속도를 높이고 땀 샘의 분비를 유발하고 다른 신체 기능을 억제하며 또 다른 하나로 부교 감 신경계는 심박을 늦추고 소화와 장운동을 촉진시키는 경향이 있다. 따 라서 정상적인 활동을 위해서는 교감 신경과 부교감 신경계가 균형있게 작용해야 한다. 스트레스는 신체를 경계 상태로 만드는 메커니즘으로 그림6과 같이 자율 신경계에 의해 제어된다.



Fig. 6 Autonomic Nervous System.

### 2. 5. 접근법 분석

M. Patel의 연구에서는 심박변이도를 인간의 생리학적 척도로 사용하는 운전자의 초기 피로를 감지할 수 있는 인공 지능 기반 시스템을 제시

한다. 신경망의 검출 성능은 기록된 ECG 데이터 세트를 사용하여 테스트 되었다. 여기서 신경망을 이용해 90 %의 정확도를 얻을 수 있었다[22].

본 논문에서는 앞선 기술을 응용하여 자동차에 적용하였다. 특히, 여 러 학습 모델을 적용시켜 가장 적합한 학습 모델을 찾을 수 있다. 또한, 학습된 모델은 운전자의 실시간 피로도를 검출하기 위해 사용될 수 있고, 이를 통해 운전자가 건강을 유지하고 사고를 예방하는 데 도움이 될 수 있다.



# 제 3 장

# 데이터 및 방법

### 3. 1. 실험 순서

18명의 건강한 피험자가 가상 운전 시뮬레이션 실험에 참여했다. 대상 자의 평균 연령은 33세였다. 표본의 14명은 운전면허를 소지하고 있었고, 4명은 운전면허를 소지하지 않았다. 피험자 중 운전 시뮬레이션에 대한 경험이 있는 사람은 없었다. 또한 그들은 본 연구의 결과에 영향을 줄 수 있는 어떤 약도 복용하지 않았다.

참가자들은 장시간 운전을 통해 피로 유발 실험을 수행하였다. 교통 상 황을 쉽게 변경하고 제어할 수 있다는 이유로 운전 시뮬레이터를 이용하 여 연구를 수행하였다. 적합한 시뮬레이션 프로그램을 선택하기 위해 여 러 소프트웨어를 조사하고, 'Euro Truck Simulator' (SCS Software, Czech) 를 선정하였다. 해당 시뮬레이터는 속도계와 네비게이션 뿐만 아니라 운 전 풍경, 사이드 미러가 화면에 표시되며, 엔진 및 도로 소음은 헤드폰을 통하여 제공되었다. 운전 시뮬레이터는 고정된 기본 구조를 가지며 스티 어링 휠, 제동 및 가속 페달로 구성되어있다. 각 실험은 대략 60분의 데 이터로 구성되지만, 자극의 시간은 내부 시스템에 따라 매번 달라진다. 시뮬레이션 실험은 유럽의 도로를 배경으로 하는 정적인 환경을 제공한 다. 심박변이도에 따라 피로도 단계를 낮음, 보통, 그리고 높음으로 피로 도 단계를 분류하였다. 스티어링 휠로부터 모니터까지의 거리는 47 cm이 고 18 inch 모니터를 사용하였다. (그림 7)

본 실험에서는 스티어링 휠에서 생체 신호를 측정하기 위해 유연성이 있으면서 얇은 전극이 요구된다. 전도성 전극을 스티어링 휠에 부착하여 심전도와 피부전도도 신호를 얻었다. 실험을 진행하는 동안, 실험자의 손 이 전극과 닿아 있으며, 실험은 다음과 같이 진행하였다.



Fig. 7 Experiment of Fatigue Monitoring.

Driving Practice (30 min.)	Rest (5 min.)	City Driving (5 min.)	Highway Driving (50 min.)	City Driving (5 min.)	Recovery (5 min.)
-------------------------------	------------------	-----------------------------	------------------------------	-----------------------------	----------------------

Fig. 8 Experiment progress protocol.

본 연구에서 실험한 내용은 다음과 같다. 첫 번째 단계는 해당 시뮬레 이터에 적응하기 위해 30분 정도 연습하는 시간을 갖는다. 그 후, 안정을 취하기 위해 5분 동안 휴식을 취한다. 두 번째 단계는 대략 1시간 동안 운전을 하여 피로감이 쌓이도록 한다. 이때, 시작 후 5분동안은 시내에서 주행하고 50분동안 고속도로를 주행한 후, 다시 시내로 돌아와 5분동안 주행 후 운전을 종료한다. 본 실험에서 각 실험 대상자들이 운전 시뮬레 이션을 약 한 시간 정도 진행하는 동안 손으로부터 심전도와 피부전도도 신호를 취득하였다. 모든 실험은 오후 3시에서 6시 사이에 실시하였으며, 그들에게 실험에 참여하기 전에 연구 목적과 절차에 대해서 충분히 설명 하였다. 데이터는 필터링과 특징을 추출하는 전처리 작업을 수행한 후 데 이터를 분석한다. 정확한 분석을 위해 첫 번째 실험과 두 번째 실험의 사 이에 5분간의 휴식 시간이 있었다. 그리고 기계학습 분류기법을 적용하기 위해 레이블을 지정한다. 통계 분석을 수행하여 기계 학습 분류 기술의 적용을 위해 데이터를 변환할 수 있도록 분류 작업을 결정한다.

도로 상황에 따라 시내 주행 동안 피실험자는 복잡하고 꽉 막힌 도 로를 주행하게 된다. 시내를 벗어나 톨게이트를 지나면 고속도로 주행을

17

하게 된다. 마지막으로, 랜덤하게 비가 오거나 밤 시간 주행이 포함되어 있다. 각기 다른 신경망을 비교 및 분석함으로써 가장 좋은 모델이 선택 될 것이다. 제안하는 방법은 그림 8에 설명되어 있다.



Fig. 9 Proposed System Architecture Block Diagram.

- Data Collection : 피실험자는 자연스럽게 전극을 감싸며 스티어링 휠을 잡는다. 스티어링 휠로부터 심전도 및 피부전도도 신호를 실시간으로 수 집한다. 운전 시뮬레이션 프로그램에서 시내와 고속도로를 번갈아가며 진 행한다. - Segmentation : 수집된 데이터는 생체 신호의 특징을 찾기 위해 1분 간 격으로 나눈다. HRV는 심박 변화의 측정이며 심전도 신호에서 R-R 간격 의 시계열을 처리하여 계산된다. 따라서, 특징 분석을 위해 ECG 신화를 R-R 간격으로 변환했다.

- Feature Extraction : 실험에서 얻은 ECG 데이터를 R-R 간격 시계열로 처리합니다. 나눠진 데이터에서 피로도를 판별하기 위해 시간 영역과 주 파수 영역에서 특징을 추출한다.

- Fatigue Labeling : 피로도를 알 수 있는 지표 중 하나인 LF/HF ratio로 부터 운전자의 피로도를 레이블링 하였다.

- Classifier : 앞에서 추출된 특징과 레이블을 입력으로 하는 4 종류의 분 류기 모델을 제작하여 결과를 비교한다.

- Alarm Generation : 운전자의 피로 수준에 따라 'Discomfort'단계의 피 로도에서는 경보가 발생하도록 한다.

실험 동안 각각의 피실험자로부터 PPG, ECG 및 EDA의 3가지 생리 신호를 측정하였다. 생리학적 신호는 직접 제작한 아날로그 회로에 의하 여 수집되었다. PPG 센서는 손목에서, EDA와 ECG 신호는 손으로부터 측정되었다.

19

### 3. 2. 데이터 수집 및 분석

6 채널의 전국을 스티어링 휠에 부착하여 손으로부터 각 참가자의 심박수(ECG), 피부전도도 데이터를 수집하였다. 또한, 결과 비교를 위해 스마트 워치 타입의 센서를 이용하여 심박수(PPG)를 측정하였다. 전국은 전도성 직물을 사용하여 서로 겹치지 않게 스티어링 휠에 부착하였다. 전 국의 안정화를 위하여 데이터를 취득하기 시작하면서 1분간의 안정화 시 간을 가진다. 그림10은 전도성 전국을 이용한 스티어링 휠로부터 측정된 심전도와 피부전도도 신호를 나타내고 있다.



Fig. 10 ECG and SC signals obtained from hands during driving.

이 데이터는 MCU (Atmel SAM3X8E ARM Cortex-M3)를 통해 컴퓨터

로 보내진다. 데이터는 333Hz의 주파수로 수집되었다. 운전자 피로도의 기준 레이블을 도출하기 위해 Li의 논문을 참고하였다[23]. 피로도는 Low Fatigue(낮음), Normal Fatigue(보통), High Fatigue(높음)으로 나타나며, 수 집된 데이터는 각각 해당 레이블로 지정된다. 본 피로도 측정 시스템에서 High Fatigue 단계에서는 디스플레이 장치로 알림을 준다.

개발된 시스템은 측정 모듈과 진단용 소프트웨어 모듈로 구성된다. 개 발된 시스템은 생리학적 신호 측정을 위한 1개의 PPG 전극, 2개의 EDA 전극 및 4 개의 ECG 전극으로 구성된다.

#### 3. 3. 전처리

전처리 단계의 주요 목표는 원시 신호에서 잡음을 제거하는 것이다. 생리적 신호는 사람마다 크게 다르며 나이, 성별, 수면 및 식이 요법 등 여러 요인에 따라 달라진다. 이에 따른 원인이 신호에 미치는 영향을 최 소화하는 것이 중요하다. 정규화는 정의된 범위 내의 값을 재조정한다. 평균 정규화의 경우, 신호는 표준 정규 분포의 특성을 가질 것이다. 신호 가 다른 측정 단위를 가질 때 뿐만 아니라 최적화 기반 학습 알고리즘의 일반적인 요구 사항이다. 우리는 데이터 셋을 최소한으로 전 처리하여 학 습 모델이 비선형 특징을 추출하도록 한다. 데이터로부터 60초 윈도우가 추출되었으며, 이는 표 1의 9개의 운전 상황 중 하나에 속한다. HRV 또
한 60초 윈도우를 사용하여 시간 및 주파수 영역에서 특징을 계산한다.

Event Num.	Event Description		
1.	Beginning stationary period		
2.	Garage Exit		
3.	City Road		
4.	Toll Booth		
5.	Highway driving period		
6.	Two Lane Merge / Cross over into the other lane		
7.	Rain driving		
8.	Night driving		
9.	End stationary period		

Table 1 Description of events included in the simulation

파워 스펙트럼 밀도는 EDA 및 ECG 데이터의 전력 스펙트럼 분포를 추정하기 위해 적용된다.

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j2\pi nk/T}$$
(1)

ECG 및 PPG 신호로부터 각각 심박 수(HR), 시간 영역에서의 심박

변이도(pNN50), 주파수 영역에서의 심박 변이도(LF, HF, LF/HF ratio) 5가 지 특징이 도출되었다. EDA의 2가지 특징은 SCL 및 SCR을 감지하는 알 고리즘에서 파생된다. 특징을 검출하기 전에 저역통과 필터를 사용하여 ECG 및 PPG 신호의 잡음을 제거하였다.

ECG와 PPG 신호의 피크점은 Local Maxima 개념을 이용하여 찾아진다. p를 반경으로 하는 이웃은 다음과 같이 나타낼 수 있다.

 $N_{\delta}(p) = (p - \delta, p + \delta)$ 

(2)

모든  $x \in E \cap N_{\delta}(p)$  에서  $f(x) \leq f(p)$  일 때, f(p)는 local maxima라고 표 현한다.

또한, ECG의 경우 전력선 노이즈(60 Hz) 및 동잡음와 같은 간섭으로 신호가 왜곡될 수 있다. 따라서 깨끗한 ECG 신호를 얻기 위해 노이즈 필 터링이 필요하다.

#### 가. 이산 웨이블릿 변환 (Discrete Wavelet Transform; DWT)

DWT는 일반적으로 특정 주파수 대역에 속하는 노이즈 패턴을 쉽게 식별할 수 있게 하므로 데이터에 유용한 필터이다. 웨이블릿 변환 (Wavelet Transform)이란 웨이블릿 기저함수를 이용해 데이터를 변환하 는 것을 말한다. 여기서 웨이블릿 기저함수는 적분하면 0이 되고, 진동하 면서 진폭이 0으로 수렴하는 함수를 말한다.

시간 영역과 주파수 영역에서 웨이블릿은 다음과 같이 나타난다.

$$\Psi_{ab}(x) = \frac{1}{2\Phi(\frac{x-b}{a})}$$
(3)

위의 웨이블릿을 이용해 DWT는 로 표현할 수 있다. DWT를 수식으로 표현하면 다음과 같다.

$$DWT: W_f(m,n) = a_0^{\frac{m}{2}} \phi(a_0^{-m}x - nb_0) f(x) dx$$
(4)

연속 웨이블릿 확장 함수를 f(x), 웨이블릿 함수를  $\psi(x)$ , 그리고 스케일 함수를  $\phi(x)$  일 때,

$$f(x) = \sum_{k} c_{j_0}(k) \phi_{j_0,k}(x) + \sum_{j=j_0}^{\infty} \sum_{k} d_j(k) \Psi_{j,k}(x)$$
(5)

 $c_{j_0}$ : approximation and/or scaling coefficients  $d_j(k)$ : detail and/or wavelet coefficients

$$c_{jk}(k) = \langle f(x), \phi_{j_0,k}(x) \rangle = \int f(x)\phi_{j_0,k}(x)dx$$
(6)

$$d_{j}(k) = \langle f(x), \psi_{j,k}(x) \rangle = \int f(x)\phi_{j,k}(x)dx$$
(7)

위의 식과

$$\phi(x,y) = \phi(x)\phi(u), \quad \Psi^{H}(x,y) = \Psi(x)\phi(y) \tag{8}$$

$$\Psi^{\nu}(x,y) = \phi(x)\Psi(y), \qquad \Psi^{D}(x,y) = \Psi(x)\Psi(y)$$
(9)

$$\Psi^{i_{j,m,n}}(x,y) = 2^{j/2} \Psi^{i}(2^{i}x - m, 2^{j}y - n), \quad i = H, V, D$$
(10)

의 관계를 통해 2차 웨이블릿 변환은 다음과 같이 표현할 수 있다.

$$W_{\phi}(j_0 m, n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \phi_{j_0, m, n}(x, y)$$
(11)

$$W^{i_{\Phi}}(j,m,n) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y) \Psi^{i}_{j,m,n}(x,y), i = H, V, D$$
(12)

$$f(x, y) = \frac{1}{\sqrt{MN}} \sum_{m} \sum_{n} W_{\phi}(j_{0}, m, n) \phi_{j_{0}, m, n}(x, y)$$
(13)  
+  $\frac{1}{\sqrt{MN}} \sum_{i=H, V, D} \sum_{j=j_{0}}^{\infty} \sum_{m} \sum_{n} W_{\Psi}^{i}(j, m, n) \Psi_{j}^{i}$ 

본 연구에서는 Daubechies wavelet 알고리즘과 3단계의 트리 구조 필터 뱅크를 이용하여 샘플링된 신호를 분해하였다. 각 레벨에서 데이터 는 저역 통과 및 고역 통과 필터를 통과하고 각 출력은 8배로 다운샘플 링 되었다. 그후, 노이즈는 제거되며 신호 대 잡음비(SNR)의 개선 및 잡 음 제거가 이루어졌다.

#### 나. 저역 통과 필터 (Low Pass Filter)

저역 통과 필터는 입력 신호의 주파수가 차단주파수(*w<sub>cut</sub>*)보다 낮은 신호만 통과하는 필터이다. 따라서 고주파 차단 필터라고 할 수 있다. 연 산증폭기에 대하여 저항은 직렬로, 커페시터는 병렬로 연결하여 구성된다. 가장 간단한 형태로 구현되어 모든 필터의 기본형으로 사용된다. 주로 전 원부에서 저주파를 제거하기 위한 용도나 고주파 제거, 고주파 억제와 각 종 검파 등 전 분야에 걸쳐 고루 사용되는 필터형태이다.



# 3.4 특징 추출

## 가. 심박 변이도 분석

심박변이도는 주로 시간 영역 또는 주파수 영역 분석을 사용하여 결 정될 수 있다. HRV 특징을 시간 영역, 주파수 영역의 두 부분으로 나누 었다.

(1) 시간 영역 측정

시간 영역 측정은 각 RR 간격과 평균 RR 간격을 대조하는 계산법을 사용한다. 일반적으로 RR 간격의 차이가 50 ms를 초과하는 간격의 개수 이다.

$$NN50 = count((RR_{i+1} - RR_i) > 50 ms)$$
(16)

NN50의 백분율이 짧은 기간의 심박변이 구성요소를 나타내며 이는 부교 감신경 활성을 나타낸다.[24]

$$pNN50 = \frac{NN50}{N-1} \times 100 \tag{17}$$

(2) 주파수 영역 측정

주파수 영역 분석은 이산 푸리에 변환 또는 Auto Regressive 분석과 같은 비선형 방법을 사용하여 가변성이 어느 주파수에 있는지 결정한다. 비선형 계산법은 생리학적 원인이 주파수 대역에 연결될 수 있기 때문에 효과적인 분석을 제공한다. 또한 RR 간격 시계열은 불규칙적으로 시간 샘플링 된 신호이므로, 불규칙적으로 시간 샘플링 된 이 신호로부터 스펙 트럼이 계산되면, 추가 고주파 성분이 스펙트럼에서 생성된다. 스펙트럼 그래프는 기본적으로 저주파 대역과 고주파 대역의 두 대역으로 나뉜다. 심박변이도 (0.15-0.40 Hz)의 고주파 대역은 호흡성 부정맥에 의해 변조되는 순수한 미주성 원심 신호 (vagal efferent signal)를 나타낸다.

저주파 대역 (0.04-0.15 Hz)은 RR 간격의 미주 신경과 교감 신경계의 변화에 영향을 주었다. LF/HF ratio는 자율 신경계의 균형 지수를 나타낸 다. 이 값이 높아지면 교감 신경계가 더 우세하고 낮아지면 부교감 신경 계가 우세하다는 의미를 가진다. 따라서, 스트레스 상황에서는 증가하고, 안정된 상태에서는 감소한다고 표현할 수 있다. 그림 12 스펙트럼의 LF 대역에서 HF 대역에 대한 에너지의 합의 비는 다음과 같이 계산된다.



Fig. 12 PSD of Heart Rate Variability.



지의 특징을 추출하였다.

			X	2	CH.	OL	IL.	
Table 2	2 /	All	features	calculated	from	measured	physiological	signals

T

Measure	Description	Section	
	ECG		
HR	Heart Rate	Time-domain	
pNN50	(Num. of pairs of adjacent NN intervals differing by more than 50	measures	

	ms) / (total number of NN intervals)				
HF	Average of normalized high-frequency component (0.15-0.4 Hz) power	Frequency			
LF	Average of normalized low-frequency component (0.04-0.15 Hz) power	domain measures			
LF/HF Ratio	Ratio between average of low- frequency and high-frequency power				
EDA					
SC	Average of total skin conductance (SC) signal	SC measures			
SCL	Average of total SC level (SCL) signal	SCL measures			

#### 나. 피부전도도 분석

SC(Skin Conductivity) 신호는 피부의 비침습 전극에 의해 측정된 EDA를 나타낸다. SC 신호는 느리게 변하는 SCL(Skin Conductivity Level) 과 빠르게 변하는 SCR(Skin Conductivity Response)의 두 가지 신호 유형 으로 구성된다. SC 신호를 SCL과 SCR로 나누기 위해 역컨볼루션 알고리 즘을 적용했다.

EDA 신호는 느리게 변하는 tonic 활동과 빠르게 변화하는 phasic 활동 의 신호로 구성된다. 이 신호들은 각각 skin-conductance level(SCL), skin-conductance response(SCR)로 표현한다. SCL은 기본 수준을 의미하 며, 긴 시간 동안 천천히 변화하는 피부전도도이다. 반면 순간적으로 자 극 발생하면 SCR이 변화된다. 특히, SCR의 변화는 땀샘과 관련된 신경계 활동과 관련이 있는 것으로 알려져 있다. SC 신호를 SCL과 SCR로 나누 기 위해서는 역컨볼루션 알고리즘이 사용되었다.

다음은 컨볼루션의 기본 형태이다(f : filter, g : input, h : output).

$$f * g = h$$
 (19)  
이는 다음과 같이 변형될 수 있다.  
 $\sum_{k=1}^{K_1} \approx_k^i \oplus f_{k,c} = y_c^i$  (20)  
이때, 비용 학수는 다음과 같다. 이 비용 학수를 작게 만들기 위해 7와

이때, 비용 함수는 다음과 같다. 이 비용 함수를 작게 만들기 위해 z와 f를 변경하면서 계산한다.

$$C_{1}(y^{i}) = \frac{\lambda}{2} \sum_{c=1}^{K_{0}} \|\sum_{k=1}^{K_{1}} \approx_{k}^{i} \oplus f_{k,c} - y_{c}^{i} \|_{2}^{2} + \sum_{k=1}^{K_{1}} |\approx_{k}^{i}|^{p}$$
(21)

SC를 SCL과 SCR로 분류하기 위해 MATLAB으로 작성된 cvxEDA 라 이브러리를 사용하였다. 피부전도도로부터 다음과 같은 특징을 추출할 수 있다 : 피부 전도도의 평균, SCL의 평균, SCL의 기울기 변화, SCR의 최댓



# 제 4 장

# 운전자 피로도 분류를 위한 기계학습

장에서는 먼저 Support Vector Machine(SVM), 보 **K-Nearest** Neighbor(KNN), Time Delay Neural Network(TDNN) 및 Long-Short Term Memory(LSTM)에 대한 일반적인 정의와 더불어 문제 정의에 대해 간략하 게 설명한다. 그런 다음 심층 네트워크에 대한 입력 파라미터를 포함하여 아키텍처를 선택하는 과정을 설명한다. 인공신경망 기반 모델은 인간의 뇌에서 사용되는 의사결정 패러다임을 밀접하게 모방한다는 것이 입증되 었다. 이러한 모델은 훈련 특징이 비선형성을 나타내고 결정 경계가 특징 공간에서 비선형 함수로 가장 잘 모델링되는 애플리케이션에서 선호되는 분류기였다. 이는 잡음이 포함된 데이터에도 안정적으로 작동하며 범주형 및 연속형 특징 모두에 유용한 것으로 입증되었다. 본 연구에서는 수집된 실시간 데이터는 전력 잡음, 센서 오류 및 동잡음을 제거하는데 필요한 신호 처리와 필터링이 수행되었지만 데이터 수집 환경과 생체 신호와의 주파수 대역으로 인해 어느 정도 잡음이 존재할 수 있다. 이러한 경우 기 계학습이 좋은 대안 중 하나이다.

34

운전자의 피로도 수준은 HRV의 주파수 분석에 따라 결정되었다. 따라 서 수집된 데이터는 LF/HF의 비에 따라 낮은 피로 상태(Non-Fatigue), 어 느 정도의 피로 상태(Fatigue), 높은 피로 상태(Discomfort)로 분류되었다. 해당 모델은 본 연구의 분류 문제를 이진 클래스 대신 다중 클래스 분류 문제로 모델링 한다. 가중치와 바이어스 파라미터를 계산하기 위해 connectionist approach를 사용한다. 신경망 구조는 운전자의 상태를 나타 내는 특징과 hidden layer를 포함하는 입력 계층으로 구성되며, 예측된 결과가 출력 계층으로 구성된다. 현재 피로도 분류 문제에서 지도 학습 접근법은 모델링 및 동적 시스템 제어에 대한 호환성 때문에 채택되었지 만, 본 시스템에서는 기존의 연구를 토대로 HRV와 SC를 이용한 지도학 습을 시도하였다. 또한, 4가지 분류기를 사용하여 인식 작업에서 얼마나 잘 수행되는지 확인하기 위한 테스트를 수행하였다. 각 특징들은 선형 분 류기를 사용하여 인식 작업에서 얼마나 잘 수행되는지 확인하기 위해 테 스트 되었다.

#### 4. 1. Support Vector Machine (SVM)

SVM은 데이터를 선형으로 분리하는 최적의 선형 결정 경계를 찾는 알 고리즘이다. 지도 학습 알고리즘인 SVM은 통계 학습 이론에 기초하여 공 식화된다. 클래스가 다른 데이터들을 가장 큰 마진(margin)으로 분리해내

10 10

는 선 또는 면을 찾아내는 것이다. 그림 15와 같이 서포트 벡터 머신은 데이터 중 결정 경계의 위치에 큰 영향을 주는 벡터를 의미한다.

훈련 데이터는 데이터 집합  $x_i$ 와 데이터 집합  $y_i$ 이 있을 때, 기준 면 방 정식은 다음과 같다.

$$f(x) = x'\beta + b = 0 \tag{22}$$

여기서  $\beta \in R^d$ 이고 b는 실수이다.



Fig. 15 SVM Classification Principle.

클래스는 다음과 같은 수식으로 나타날 수 있다.

$$class(z) = sign(x'\hat{\beta} + \hat{b}) = sign(\hat{f}(z))$$
(23)

f(z)는 분류 점수이고, z는 결정 경계로부터 떨어진 거리를 나타낸다.

이 알고리즘의 최대 마진을 제공하는 평면을 찾아 최상의 분류를 제 공한다. 큰 마진 분류를 일반화하는 기능은 특징의 차수가 아니라 마진과 훈련 샘플 크기에만 의존한다.

서포트 벡터 머신은 기계 학습은 기계 학습의 분야 중 하나로 패턴 인식, 자료 분석을 위한 지도학습 모델이며, 주로 분류와 회귀 분석을 위 해 사용한다. 예를 들어, SVM은 분류된 화합물에서 단백질을 90 %까지 구분하는 의학 분야에 유용하게 사용되거나 손글씨의 특징을 분류하는 등 다양한 분야에서 사용되고 있다.

## 4. 2. K-Nearest Neighbor (KNN)

KNN은 지도학습 중 분류 문제에 사용하는 알고리즘이다. 이 알고리 즘은 새로운 데이터를 입력 받았을 때 가장 가까이 있는 것이 무엇인지 를 기준으로 새로운 데이터의 종류를 정하는 알고리즘이다. 단순히 주변 에 무엇이 가장 가까이 있는가를 보는 것이 아니라, 주변에 있는 몇 개의 데이터를 고려하여 가장 적절한 클래스를 선택하는 방식을 사용하게 된 다. 이 알고리즘은 샘플 데이터와 학습 데이터 간의 최적 거리를 평가하 는 데 그 성능을 기반으로 한다. KNN의 K는 고려할 주변 데이터의 개수 를 의미한다. K가 작을 경우, 데이터의 지역적 특성을 지나치게 반영하게 된다(overfitting). 반대로 매우 클 경우, 모델이 과하게 정규화되는 경향이 있다(underfitting).

KNN은 거리 측정 방법에 따라 그 결과가 크게 달라지는 알고리즘이다.

## 가. Euclidean Distance

가장 흔히 사용하는 거리 척도로써, 두 관측치 사이의 직선 최단 거리를 의미한다.

$$X = (x_1, x_2, ..., x_n)$$
  

$$Y = (y_1, y_2, ..., y_n)$$
  

$$d_{(X,Y)} = \sqrt{(x_1 - y_1)^2 + \dots + (x_n - y_n)^2} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$
(24)

나. Manhattan Distance

시작점에서 도착점까지 각 좌표축 방향으로만 이동할 경우에 계산되 는 거리이다.

$$d_{Manhattan}(X,Y) = \sum_{i=1}^{n} |x_i - y_i|$$
<sup>(25)</sup>

#### 다. Mahalanobis Distance

변수 내 분산, 변수 간 공분산을 모두 반영하여 거리를 계산하는 방식이 다. 변수 간 상관관계를 고려한 거리 지표이다.

$$d_{Mahalanobis}(X,Y) = \sqrt{(\vec{X} - \vec{Y})^T \sum_{i=1}^{-1} \vec{X} - \vec{Y}}$$
(26)

 $\sum_{i=1}^{-1} = inverse \ of \ covariance$ 

X, Y 사이의 Mahalanobis 거리를 c, X를 (\*1 \*2), Y를 (0, 0)로 두고 위 식을 풀면 아래와 같이 쓸 수 있다.

 $\lfloor S_3 \rfloor$ 

$$\sum_{i=1}^{n} \sum_{j=1}^{n} \sum_{i=1}^{n} \sum_{j=1}^{n} \sum_{i$$

## 4. 3 Time Delay Neural Network (TDNN)

TDNN(Time Delay Neural Network)은 시간 불변성을 이용하여 패턴

을 분류하고, 네트워크의 각 레이어에서 모델 컨텍스트(model context)를 목적으로하는 다층 인공 신경 네트워크 아키텍처이다. 이동 불변성 분류 기는 분류하기 전에 명시적 분할을 필요하지 않음을 의미한다. 시간적인 패턴의 분류를 위해, TDNN은 분류하기 전 반드시 시작과 끝 지점을 결 정할 필요가 없다.

TDNN에서는 각 유닛의 시간지연 요소들이 현재 입력신호와 과거 입력 신호들에 대해 각각 다른 가중치를 가지게 되어 과거의 신호와 현재의 신호를 서로 관련시키며 비교하는 방식이다. 이때, 첫 번째 은닉층(hidden layer)의 윈도우 크기를 키우는 것이 인식률 향상에 도움이 되는데 윈도 우 크기를 증가시키면 학습시간이 크게 증가하게 되고 학습데이터도 많 은 양이 필요하게 된다.

회귀 구조를 가진 TDNN에서  $y_{k,j}^m$ 를 m번째 은닉층의 뉴런 (k, j)의 출 력이라고 하면 다음 식과 같이 나타낼 수 있다.

$$y_{k,j}^{m} = w_{k,j,i}^{m} y_{k,j}^{m} + \sum_{p} \sum_{i} w_{k,p,i,j}^{m} o_{k+p-1,i}^{m-1}$$
(28)

여기서  $w_{k,j,i}^m$ 는 회귀 연결 강도를 나타내고  $w_{k,p,i,j}^m$ 는 m번째 층의 뉴런 (k, j)와 (m-1) 번째 층의 뉴런 (k+p-1, i)를 연결하는 연결 강도를 나타내 며 p는 시간 이동 윈도우를 나타낸다. 그리고

$$o_{k,i}^m = f(y_{k,i}^m) \tag{29}$$

이 식에서 함수 f는 sigmoid 함수이다.

## 4. 4 Long Short-Term Memory (LSTM)

RNN의 관련 정보와 그 정보를 사용하는 지점 사이 거리가 멀 경우 역전파시 그래디언트가 점차 줄어 학습 능력이 크게 저하되는 vanishing gradient problem을 해결하기 위하여 고안된 알고리즘이다. LSTM은 RNN 의 은닉 상태에 cell-state를 추가한 구조이다[25].



Fig. 16 LSTM cell.

LSTM 계층의 학습 가능한 가중치는 입력 가중치 W(Input Weights), 순 환 가중치 R(Recurrent Weights), 편향 b(Bias)이다. 행렬 W, R, b는 각각 구성요소의 입력 가중치 결합, 순환 가중치 결합, 편향 결합이다.

$$W = \begin{bmatrix} W_i \\ W_f \\ W_g \\ W_o \end{bmatrix}, R = \begin{bmatrix} R_i \\ R_f \\ R_g \\ R_o \end{bmatrix}, b = \begin{bmatrix} b_i \\ b_f \\ b_g \\ b_o \end{bmatrix}$$
(30)

여기서 I는 입력 게이트, f는 망각 게이트, g는 셀 후보, o는 출력 게이 트를 나타낸다.

LSTM의 수식은 다음과 같다. •는 Hadamard product 연산자이다.

$$f_{t} = \sigma(W_{xh_{f}}x_{t} + W_{hh_{f}}h_{t-1} + b_{h-f})$$
(31)

$$i_{t} = \sigma(W_{xh_{-}i}x_{t} + W_{hh_{-}i}h_{t-1} + b_{h-i})$$
(32)

$$o_t = \sigma(W_{xh_o}x_t + W_{hh_o}h_{t-1} + b_{h-o})$$
(33)

$$g_{t} = tanh(W_{xh_{g}}x_{t} + W_{hh_{g}}h_{t-1} + b_{h-g})$$
(34)

$$c_t = f_t \odot c_{t-1} + i_t \odot g_t \tag{35}$$

$$h_t = o_t \odot \tanh(c_t) \tag{36}$$

f<sub>t</sub>는 forget gate이다. h<sub>t-1</sub>과 x<sub>t</sub>를 받아 시그모이드를 취해준 값이 forget gate가 내보내는 값이다. 시그모이드 함수의 출력 범위는 0에서 1 사이이 기 때문에 그 값이 0이라면 이전 상태의 정보는 잊고, 1이라면 이전 상태 의 정보를 그대로 기억한다.  $i_t \odot g_t$ 는 input gate이다.

h<sub>t-1</sub>과 x<sub>t</sub>를 받아 시그모이드를 취하고, 또 같은 입력으로 하이퍼볼릭탄젠
 트를 취해준 다음 Hadamard product 연산을 한 값이 출력이 된다.



위의 도식은 길이가 S인 특징 채널 C개를 갖는 시계열 X가 LSTM 계 층을 통과하는 흐름을 보여준다. 예를 들어, 첫 번째 LSTM 블록은 네트 워크의 초기 상태와 시퀀스의 첫 번째 시간 스텝을 사용하여 첫 번째 출 력 값과 업데이트된 셀 상태를 계산한다. 시간 스텝 t에서, 이 블록은 네 트워크 ( $c_{t-1}$ ,  $h_{t-1}$ )의 상태와 시퀀스의 다음 시간 스텝을 사용하여 출력 값과 업데이트된 셀 상태  $c_t$ 를 계산한다.

이러한 LSTM은 시퀀스 데이터로부터 학습하기 위한 강력하고 인기 있 는 모델이다[26].

# 제 5 장

## 실험 결과 및 논의

최근 몇 년 동안 생체 신호를 이용한 운전자 모니터링에 관한 많은 프 로젝트가 있었다. 운전자 모니터링의 주된 이유는 운전에 대한 피로감을 측정하기 위함이다.

## 5. 1. 운전자 피로도 실험 구성

#### 가. 하드웨어 설계

전형적인 electrocardiography(ECG) Lead-1 전국 그림 18의 (a)와 같은 구성에 따라 양손과 오른쪽 다리에 배치해왔다. 본 연구에서는 그림 18의 (b)처럼 스티어링 휠 네 곳에 전극을 부착하여 EDA와 ECG 신호를 측정 하였다. 그리고 PPG 신호는 손목에서 데이터를 수집하였다. 그림18에서 전극이 부착된 스티어링 휠을 볼 수 있다. 왼손을 잡는 곳에 EDA 전극과 ECG의 LA(Left Arm) 및 LL(Left Leg) 전극이 오른손을 잡는 곳에는 EDA 전극과 ECG의 RA(Right Arm) 및 RL(Right Leg) 전극이 부착되어 있다.



직물 타입의 건식 전국은 전도성 실로 짜여진 일반적인 나일론 재질로 제조되었으며, 30 cm에 1 Ω 이하의 고전도성 직물이다. 전도성 직물을 대략 4.5 cm X 4 cm의 크기로 절단하여 ECG 전국으로 사용하였으며, EDA 전국은 4 cm X 13 cm의 크기로 절단하여 전도성 실을 사용해 벨크 로를 부착하고 스티어링 휠에 감아서 사용하였다. (그림 19)



Fig. 19 Conductive Fabric (Adafruit Knit Conductive Fabric - Silver).

위의 그림에 나타난 것처럼 ECG 전극 사이는 2개의 전극이 2.5 cm 떨어져 있다. 유사하게, EDA 전극과 ECG 전극은 0.5 cm 거리로 분리하 였다. 전선이 각 전극에 전도성 실로 부착되어 있어 손으로부터 얻은 생 체 신호를 회로에 전달한다. 특히, 전선은 직물의 안쪽에 부착되어 피부 와 직접적으로 접촉하지 않는다.

생체 신호는 333 Hz로 수집되었기 때문에 빠르게 지나가는 심박 신 호의 최고점도 검출할 수 있다. 수집된 신호는 MATLAB에서 처리하였다. 아날로그 회로와 더불어 메인보드는 실제 차량에 적용할 때 디스플레이 장치에 적용할 수 있다. (그림. 20-21)



Fig. 21 EDA Analog Circuit.

#### 나. 전처리 적용 결과

신체로부터의 생체 신호 데이터는 다음 그림 22과 같다.



Fig. 22 Collected Physiological Signals (a) ECG (b) PPG (c) EDA.

(1) 심박변이도(Heart Rate Variability)

피험자의 PPG와 ECG 신호로부터 HRV 분석이 이루어졌다. ECG 데 이터에서 저주파 통과 필터를 사용하여 50 Hz보다 작은 주파수의 데이터 를 통과 시켜 전선으로부터 유도되는 잡음을 제거하였다. 데이터에 이산 웨이블릿 변환 필터(DWT)과 저역 통과 필터를 적용하여 비교하였다. (그 림 23-24) 그 후, 피크 검출 알고리즘을 이용하여 ECG와 PPG 피크 사이 의 간격을 계산했다.



Fig. 23 ECG Signal with Discrete Wavelet Transform and Low Pass Filter (a) Raw ECG Signal (b) DWT ECG Signal (c) LPF ECG Signal.



Fig. 24 PPG Signal with Discrete Wavelet Transform and Low Pass Filter (a) Raw PPG Signal (b) DWT PPG Signal (c) LPF PPG Signal.

그림 25, 26은 각각 ECG와 PPG의 최고점 검출 알고리즘의 결과를 보여 준다.



Fig. 26 Peaks of Respiratory Signal.

## 5. 2. 운전자 피로도 실험의 결과 분석



아래의 그림은 테스트 셋의 레이블 분포를 나타낸 그래프이다.

Fig. 28 Overall Class Label Distribution.

마지막으로 기계학습 알고리즘을 적용하여 패턴을 분류하려고 하였다. KNN, SVM, LSTM 및 TDNN의 4 가지 알려진 학습 알고리즘으로 테스트 했다. 분류기에 대한 입력 정보는 EDA 및 ECG 신호에서 추출된 특징으 로 모든 분류기에 동일하게 적용하였다. 본 연구에서는 훈련 70 %, 검증 15 %, 테스트 15%로 데이터를 분할하여 사용하였다.



Fig. 29 Three features of the driving data.

그림은 7가지 특징 중 EDA의 평균, 심박수, LF/HF ratio를 정규화 후 3 차원 공간에 표현한 것이다.



Fig. 30 Driving Dataset Consisting of Three Classes.

우선 각 분류기는 다음과 같은 옵션을 가진다. 가중 KNN 분류기에 유 클리드 거리 측정법을 선택되었다. 서로 다른 K에 대해 훈련 된 모델은 K가 10일 때 정확도가 49.2%로 가장 높았다 (그림 30).



Fig. 31 LF and HF Features and Maximum Posterior.

그림 31은 선형 SVM을 사용하여 선형 커널 함수를 사용하여 분류한 결과이다. 그림에서 각각 0은 Low, 그리고 1은 Normal, 2는 High를 나타 낸다. 5배 교차 검증 방법이 본 실험에 사용되었다.



Fig. 32 Structure of a deep LSTM architecture.

또한, 100개의 은닉 유닛을 갖는 LSTM 계층을 생성하였다. 'Adam' Optimizer를 지정하고 'GradientThreshold'를 1로 지정하였다. 미니 배치 의 크기를 27로 설정하고 최대 Epoch 횟수를 250으로 설정하였다 (그림 32).



Fig. 33 Structure of a deep TDNN architecture.

TDNN은 일반 MLP와 달리 각 계층의 TDNN는 아래 계층의 출력 컨텍 스트 창에서 입력을 얻는다. 훈련 시간 동안 시간에 따른 가중치를 공유 하여 시간 이동 편차가 계산된다. 이 경우 7개의 입력을 가진 10개의 은 닉층이 포함되어 있고 Bayesian Regularization을 사용하여 분류하였다 (그림 33).





본 연구에서는 3개의 클래스를 사용했을 경우와 4개의 클래스를 사용 했을 경우 정확도를 비교하였다 (그림 29). KNN을 제외하고는 3개의 클 래스를 사용했을 때가 4 개의 클래스를 사용했을 때보다 분류 결과가 좋 은 것으로 나타났다. TDNN 분류기를 사용하면 3 개의 클래스 분류에서 정확도가 68.31 %에서 86.27 %로 증가하였다. 또한, TDNN 분류기는 SVM, KNN 및 LSTM 분류기와 비교했을 때 가장 결과가 좋았다. 두 경우 모두 에서 TDNN이 정확도가 가장 좋았다. 4개의 클래스의 경우, 상관계수 p 가 .8644 로 PPG 특징 벡터와 ECG 특징 벡터가 강한 양적 선형관계를 보였고, 3개의 클래스의 경우, .5806으로 뚜렷한 양적 선형관계를 나타내 었다. 이를 통해, PPG 특징 벡터와 ECG 특징 벡터는 서로 관련이 있으 며, 스티어링 휠에서 측정한 ECG 데이터가 유의미하였다. 이 장에서는 제안된 시스템의 성능을 평가하여 피험자로부터 얻은 데이터에서 피험자 를 감지한다. 본 시스템으로 계산한 특징을 기반으로 정해진 레이블과 비 교했다.

3 단계로 나누는 경우,

 $0.75 \leq (\frac{LF}{HF} ratio),$  "High Fatigue"  $0.50 \leq \left(\frac{LF}{HF} \ ratio\right) < 0.75$ , "Normal Fatigue"  $\left(\frac{LF}{HF} \ ratio\right) < 0.5$ , "Low Fatigue"

운전자가 위험 상태일 때 경고를 실시간으로 주기 위해 Low Fatigue와 Normal Fatigue를 정상 상태로 정의하고, High Fatigue의 경우 위험 상태 로 정의하였다. 운전자 피로의 분류를 위한 지표에 대한 연구가 없기 때 문에 이미 발표된 다른 유사한 연구와 비교 및 분석은 없다. 그러나 이 연구는 심박변이도를 기반으로 진행된 피로도 및 스트레스 연구에 중점 을 둔 이전 연구를 기반으로 한다.

수집된 데이터는 분류 성능을 결정하기 위해 분석되었다. 이 목적으로 선택된 통계량 추정치는 민감도(Sensitivity), 특이성(Specificity), 정밀도 (Precision), 재현율(Recall) 및 F1-score이다. 추정기의 계산을 위해서는
TP(정상 상태를 정상 상태로 판단한 경우), TN(위험 상태를 위험 상태로 판단한 경우), FN(위험 상태를 정상 상태로 감지한 경우), FP(정상 상태를 위험 상태로 감지한 경우)의 값이 필요하다. 민감도(TPR)는 정확하게 식 별된 양성의 비율을 측정한 값이며, 특이성(TNR)은 식별된 실제 음성의 비율을 측정합니다. 또한 F1은 시스템의 정밀도와 재현율을 모두 고려한 다. 정밀도(P)는 정확한 양성 결과의 수를 전체 양성 검출 횟수로 나눈 값이고, 재현율(R)은 정확한 양성 결과 수를 양성 결과로 나눈 값이다. 재현율은 실제 양성인 값 중에서 양성 결과라고 예측한 것의 비율이다. F1-score는 정밀도 및 재현율의 가중 평균으로 해석될 수 있으며, 정밀도 및 재현율 측정 값 간의 상충 관계를 반영하며 1에서 최멋값을 가지고, 0 일 때 가장 좋지 않은 결과를 보인다. 다음의 수식을 사용하여 각 분류기 에 대해 가중치 F-score를 계산했다.

$$\frac{TP}{(TP+FN)} imes 100$$

(37)

$$P = \frac{TP}{TP + FP} \tag{38}$$

$$R = \frac{TP}{TP + FN} \tag{39}$$

$$F_1 = \frac{2 * P * R}{P + R} \tag{40}$$

특정 분류기의 선호도를 평가하기 위해 이러한 계수들이 사용된다. 표 4는 정의된 3개의 클래스를 구별하기 위해 테스트 된 분류기로 달성한 평균 성능을 나타낸다. 표에 나타난 바와 같이, TDNN에 대해 0.6701의 정밀도, 0.8074의 재현율, 0.7323의 F1-score를 달성하였다. LSTM에서 달 성된 정밀도, 재현율 및 F1-score는 각각 0.6701, 0.8783, 그리고 0.7602이 다. 또한, SVM의 경우, 정밀도는 0.7886, 재현율은 0.8644, F1-score는 0.8247으로 나타났다. 마지막으로, KNN에 대해 얻은 결과는 정밀도 0.8505, 재현율 0.7534, F1-score 0.7990으로 표현되었다. SVM이 가장 최 적인 분류기라는 것을 알 수 있다. 본 연구의 경우, 이상적인 분류기 구 성은 모집단에 비해 높은 평균 성능과 일관성을 가져야한다.

Classification	Classifier Model				
Results	KNN	SVM	LSTM	TDNN	
TP	130	153	130	165	
FN	61	68	74	38	
FP	64	41	64	29	
TN	31	24	18	54	
Sensitivity/TPR (%)	80.74	86.44	87.83	75.34	

Table 3 Classification Results of Each Classifier on the Test Set

Specificity/TN Rate (%)	48.80	62.38	53.62	56.71
Accuracy (%)	66.78	77.27	71.32	70.97
Precision	0.6701	0.7886	0.6701	0.8505
Recall	0.8074	0.8644	0.8783	0.7534
F1	0.7323	0.8247	0.7602	0.7990





Fig. 37 LSTM - Test Set Confusion Matrix.



Predicted label

Predicted label

Fig. 38 TDNN - Test Set Confusion Matrix.

앞서 실험한 결과를 기준으로 SVM 검출 기법을 이용하여 실시간 운전 자에게 현재 피로 상태를 보여줄 수 있다. 운전자에게 직접적으로 현재의 피로도 상태를 전달함으로써 운전자 스스로 피로를 해소할 수 있는 기회 를 제공하고자 한다. 아래는 실제 차량의 클러스터를 모형으로 제작된 실 시간 피로도 측정 프로그램의 사용자 인터페이스 출력 화면 예시이다. 기 존 차량의 주행 패턴으로 파악하는 운전자 피로측정 형태와 결합 되면 보다 효과적으로 운전자의 피로도를 관리할 수 있을 것으로 판단된다.

차량에서 실시간 피로도 측정을 위해 MATLAB 프로토 타입 응용 프로 그램을 개발하였다. MATLAB guide를 이용하여 차량의 디스플레이 장치 에 적용되도록 디자인 및 프로그램을 제작하였고 Serial 통신으로부터 운 전자의 생체 신호를 수집한다. 다음 그림은 사용자 인터페이스의 사진이 다.

62



## 5.3. 결론

본 실험에서는 피로도 유발 실험을 수행하면서 동시에 광혈류(PPG), 피 부전도도(EDA) 및 심전도(ECG)를 측정했다. 이러한 생체 신호를 스티어 링 휠로부터 수집하였다.

기계 학습과 다양한 알고리즘을 결합한 제안된 방법을 평가하기 위해 다음 세 단계를 수행했다. 먼저, 피험자로부터 피로도 데이터를 수집했다. 결과에 따르면, 피로도 수준은 본 연구에서 의도된 피로도 수준과 관련이 있는 것으로 확인되었다. 예를 들어, 시간이 진행됨에 따라 피로도가 점 차 증가하면서 도착지가 보이기 시작할 때 다시 감소하는 양상을 보였다. 다시 말해, 이번에 진행했던 시뮬레이션 실험은 의도한 피로도 수준을 유 발할 수 있었다. 다음으로, 입력 특징을 변경하면서, 각 기계 학습의 분류 정확도를 평가했다. 일반적으로 기존의 기계 학습 알고리즘의 성능은 해 당 파라미터에 의해 좌우된다. 따라서 최적의 매개 변수를 찾기 위해 기 계 학습에 다양한 값을 적용했다.

본 논문의 목적은 운전자 피로도 분류를 위해 생체 신호의 특징으로부터 4 가지 기계학습 방법을 적용하는 것이다. 또한, 시뮬레이션 프로그램을 이용하여 웨어러블 장치에서 수집한 운전자의 생체 신호를 사용했다. 피실험자는 시뮬레이터에서 운전을 수행했으며, 이 과정에서 피로도 측정이 실행되었다. 각 윈도우 데이터는 심박변이도에 의해 라벨링 되었으며, 이 과정은 레이블을 생성하기 위해 비디오 디코딩을 사용하는 것과 비교하여 효율적이며 객관적이다. 생리학 신호(ECG, PPG, EDA)에 대해 KNN을 제외하고는 4개의 클래스로 분류할 때보다 3개의 클래스의 성능이 더 좋았다. 또한, 경보를 판단하는 경우, 표 3와 같이 SVM에서 정확도 77.27 %와 F1-score 0.8247로 가장 좋은 결과를 달성하였다. 따라서 SVM 분류기를 본 시스템에 적용하여 실시간으로 운전자의 스트레스 정도를 측정할 수 있다.

64

## 참 고 문 헌

- S. K. Lal and A. Craig, "A critical review of the psychophysiology of driver fatigue," *Biological psychology*, vol. 55, no. 3, pp. 173– 194, 2001.
- [2] M. Ingre, T. Åkerstedt, B. Peters, A. Anund, and G. Kecklund, "Subjective sleepiness, simulated driving performance and blink duration: examining individual differences," *Journal of sleep research*, vol. 15, no. 1, pp. 47–53, 2006.
- [3] E. Michail, A. Kokonozi, I. Chouvarda, and N. Maglaveras, "EEG and HRV markers of sleepiness and loss of control during car driving," in 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2008, pp. 2566–2569: IEEE.
- [4] W.-B. Horng, C.-Y. Chen, Y. Chang, and C.-H. Fan, "Driver fatigue detection based on eye tracking and dynamic template matching," in *IEEE International Conference on Networking, Sensing and*

Control, 2004, 2004, vol. 1, pp. 7-12: IEEE.

- [5] J. F. Coughlin, B. Reimer, and B. Mehler, "Driver wellness, safety & the development of an awarecar," *AgeLab, Mass Inst. Technol., Cambridge, MA*, 2009.
- [6] B. Mehler, B. Reimer, J. F. Coughlin, and J. A. Dusek, "Impact of incremental increases in cognitive workload on physiological arousal and performance in young adult drivers," *Transportation Research Record*, vol. 2138, no. 1, pp. 6–12, 2009.
- [7] J. A. Healey and R. W. Picard, "Detecting stress during real-world driving tasks using physiological sensors," *IEEE Transactions on intelligent transportation systems*, vol. 6, no. 2, pp. 156–166, 2005.
- [8] E. Rogado, J. L. Garcia, R. Barea, L. M. Bergasa, and E. López,
  "Driver fatigue detection system," in 2008 IEEE International Conference on Robotics and Biomimetics, 2009, pp. 1105-1110: IEEE.
- [9] L. Salahuddin, J. Cho, M. G. Jeong, and D. Kim, "Ultra short term analysis of heart rate variability for monitoring mental stress in mobile settings," in 2007 29th annual international conference of the ieee engineering in medicine and biology society, 2007, pp. 4656–4659: IEEE.
- [10] J. Vicente, P. Laguna, A. Bartra, and R. Bailón, "Detection of

driver's drowsiness by means of HRV analysis," in *2011 Computing in Cardiology*, 2011, pp. 89-92: IEEE.

- [11] C. Tsigos and G. P. Chrousos, "Hypothalamic-pituitary-adrenal axis, neuroendocrine factors and stress," *Journal of psychosomatic research*, vol. 53, no. 4, pp. 865–871, 2002.
- [12] H. Ursin and H. R. Eriksen, "The cognitive activation theory of stress," *Psychoneuroendocrinology*, vol. 29, no. 5, pp. 567–592, 2004.
- [13] N. Sharma and T. Gedeon, "Objective measures, sensors and computational techniques for stress recognition and classification: A survey," *Computer methods and programs in biomedicine*, vol. 108, no. 3, pp. 1287–1301, 2012.
- [14] J. Krajewski, D. Sommer, U. Trutschel, D. Edwards, and M. Golz, "Steering wheel behavior based estimation of fatigue," 2009.
- [15] M. F. Ani, M. Minhat, W. H. W. Mahmood, S. R. Kamat, and M. Fukumi, "Development of driving fatigue strain index to analyze risk levels of driving activity," in 2017 International Conference on Electrical, Electronics and System Engineering (ICEESE), 2017, pp. 95–99: IEEE.
- [16] C. Li, C. Xu, and Z. Feng, "Analysis of physiological for emotion recognition with the IRS model," *Neurocomputing*, vol. 178, pp. 103-111, 2016.
- [17] P. H. Charlton, T. Bonnici, L. Tarassenko, D. A. Clifton, R. Beale,

and P. J. Watkinson, "An assessment of algorithms to estimate respiratory rate from the electrocardiogram and photoplethysmogram," *Physiological measurement,* vol. 37, no. 4, p. 610, 2016.

- [18] N. D. Ahuja, A. K. Agarwal, N. M. Mahajan, N. H. Mehta, and H. N. Kapadia, "GSR and HRV: its application in clinical diagnosis," in 16th IEEE Symposium Computer-Based Medical Systems, 2003. Proceedings., 2003, pp. 279–283: IEEE.
- [19] M. E. Dawson, A. M. Schell, and D. L. Filion, "The electrodermal system," 2017.
- [20] H. Kurniawan, A. V. Maslov, and M. Pechenizkiy, "Stress detection from speech and galvanic skin response signals," in *Proceedings of the 26th IEEE International Symposium on Computer–Based Medical Systems*, 2013, pp. 209–214: IEEE.
- [21] M. Malik and A. J. Camm, "Heart rate variability," *Clinical cardiology*, vol. 13, no. 8, pp. 570–576, 1990.
- [22] M. Patel, S. K. Lal, D. Kavanagh, and P. Rossiter, "Applying neural network analysis on heart rate variability data to assess driver fatigue," *Expert systems with Applications*, vol. 38, no. 6, pp. 7235– 7242, 2011.
- [23] G. Li and W.-Y. Chung, "Detection of driver drowsiness using wavelet analysis of heart rate variability and a support vector

machine classifier," Sensors, vol. 13, no. 12, pp. 16494-16511, 2013.

- [24] "Assessing Methods of Heart Rate Variability," Annals of Clinical Neurophysiology, vol. 16, no. 2, pp. 49–54, 12 2014.
- [25] S. Hochreiter and J. Schmidhuber, "Long short-term memory," Neural computation, vol. 9, no. 8, pp. 1735–1780, 1997.
- [26] Z. C. Lipton, D. C. Kale, C. Elkan, and R. Wetzel, "Learning to diagnose with LSTM recurrent neural networks," *arXiv preprint arXiv:1511.03677*, 2015.



## 감사의 글

이 논문이 나오기까지 수많은 사람들의 도움을 받았습니다. 그분들의 도움이 없었다면 논문이 나올 수 없었을 것이기에 이 자리를 빌려 감사의 인사를 드리고자 합니다.

먼저 석사 학위를 무사히 마칠 수 있도록 항상 성심성의껏 지도 해주시고, 많은 기회와 조언을 주신 정완영 교수님 감사드립니다. 교수님의 지도를 통해, 연구가 무엇인지, 제게 부족한 점이 무엇이고 어떤 방향으로 나아가야 할 지에 대해 알 수 있었던 것 같습니다. 그리고 바쁘신 가운데에도 제 학위 논문의 심사위원을 맡아주시고 좋은 조언을 해 주신 김종진 교수님과 문광석 교수님 두 분께 감사드립니다. 교수님의 제자로써 부족함이 없는 연구자가 될 수 있도록 잘 하겠습니다. 감사합니다.

25 년동안 제게 많은 힘과 용기를 주신 아버지와 어머니, 현재 열심히 국방의 의무 중인 동생에게 고마움을 전합니다.

연구를 진행할 때 바쁘지만 실험을 같이 도와준 동료들 모두 고맙습니다. 홍기환 박사님, Hau, Sejan, Long, Ali, Rahman, Dung, Dau, 그리고 바쁜 일정에도 많이 행정 업무를 도와준 이나연 선생님 감사합니다. 특히, 현재 다른 곳에서 열심히 연구하고 있을 안진영 박사님과 Vega 에게 감사드립니다. 그리고 , 첫 타지생활에 2 년이란 기간동안 함께 고생한 은진 언니, 함께할 수 있어 감사했습니다.

끝으로 이 논문이 나오기까지 아낌없는 도움을 주신 분들께 다시 한번 감사의 마음을 전합니다.