

생체신호처리를 이용한 비접촉식 열차 운전자 모니터링 시스템 개발

전혜연*, 김정태°, 김길동*, 이재호*

Development of Noncontact Train Driver Monitoring System with Bio Signal Processing

Hye-yeun Chun*, Jungtai Kim°, Gil-dong Kim*, Jaeho Lee*

요약

차량이나 열차의 운전자의 지속적인 모니터링을 통하여 이상상황을 탐지하는 것은 운행 안전성을 높이는 데 큰 기여를 할 수 있다. 운전자 또는 기관사에게 따로 부착하는 센서 없이 비접촉식 방법으로 생체신호를 받아내어 운전자의 상태를 모니터링 할 수 있는 시스템을 개발하였고 본 논문에서는 이에 대한 내용을 기술한다. 생체신호 중 졸음과 밀접한 관계가 있는 시선과 심박수를 인식함으로써 이상 상황을 판단한다. 본 시스템은 다양한 방법으로 수집된 데이터를 바탕으로 머신러닝을 통해 초기 학습을 수행하고 이후 실시간으로 송수신되는 시선 위치와 심박수 데이터에 대해 상황 분류 및 판단 알고리즘을 적용하여 졸음 여부 및 시선의 각도를 판별한다. 졸음 여부 뿐만 아니라 시선의 각도를 판단하기 위해 다항 분류 기법을 적용하였으며 졸음 판별의 경우 이전 값과의 연속성 조건을 부여하여 잘못 인식되는 결과를 줄였다. 시험 결과 90% 이상의 판별 정확도를 확인하였으며 이를 통해 실제 시스템에 적용 가능성을 보인다.

Key Words : Bio signal, Gaze position, BPM, Multi-classification, Driver monitoring system

ABSTRACT

To detect extraordinary condition by monitoring consistently the car driver or the train driver can contribute to improve the operational safety. A system that can monitor the driver by receiving a bio-signal with non-contact method such that without using a sensor attached to the driver was developed. And the process and result of the development is described in this paper. The system detects the driver's status by recognizing the bionic signal such that the gaze angle and heart beat rate of the driver which are highly related with drowsiness. Various measurement data is used to machine learning for the first stage learning and the learned machine can detect the drowsiness and the gaze angle with decision and classification algorithm. Multi-class classification algorithm was adapted to detect various gaze angle. Besides, continuity condition was applied to reduce wrong recognition. Test result represents the decision accuracy over 90% and this shows that this monitoring system can be applied to the real system.

* 본 연구는 한국철도기술연구원 주요사업의 연구비 지원으로 수행되었습니다.

♦ First Author : (ORCID:0000-0002-8540-1545)Korea University of Science and Technology, hychun@krii.re.kr, 정회원

° Corresponding Author : (ORCID:0000-0002-0085-7261)Korea Railroad Research Institute, jtkim@krii.re.kr, 정회원

* Korea Railroad Research Institute

논문번호 : 201810-319-C-RU, Received October 10, 2018; Revised November 20, 2018; Accepted December 7, 2018

I. 서 론

운전자 모니터링 시스템은 운전자의 상태를 파악함으로써 이상이 발견되면 운전자에 경고하여 사전에 사고를 방지하는 시스템이다. 미국고속도로안전협회(NHTSA)에 따르면 매년 전 세계적으로 120만명 이상이 교통사고로 인해 사망하고 있는데 이러한 교통사고 원인의 94퍼센트가 휴먼 에러 즉, 운전자의 과속이나 난폭운전, 음주운전, 전방시야 소홀 등 운전부주의 때문에 발생하는 것으로 알려지고 있다^[1]. 또한 국내의 경우 최근 10년간의 교통사고 분석 결과에 따르면 졸음운전으로 인한 교통사고 사망률은 22.5%이다^[2]. 큰 인명사고를 낼 수 있는 졸음운전은 자동차뿐만 아니라 철도에도 해당된다. 특히 철도 교통은 다수의 승객이 이용하는 대중 교통수단이기 때문에 사고 시 그 피해가 크다. 때문에 운전자의 인적오류에 의해 발생한 사고를 미리 예방할 수 있도록 안전운행 체계를 구축해 나아가는 데에 힘써야한다.

현재까지 졸음 여부를 판별하기 위해 운전자의 다양한 생체신호를 이용하는 방법들이 연구되었다. 먼저 졸음과 연관된 대표적인 생체기관인 눈을 인식하여 졸음 여부를 판별하는 연구가 있다. Song^[3]은 눈의 형태 인식을 통하여 잠은 시간을 측정하고 이 시간이 길어질 경우 운전자에게 경고하는 시스템을 개발하였으며 Choi^[4]는 눈의 깜빡임 속도를 이용하여 졸음 여부를 인식하였다. 그러나 눈으로 판별하는 경우 사람이나 상황에 따라 눈 감는 시간이나 깜빡이는 속도가 차이가 발생할 수 있으므로 졸음을 판별하는 정확한 기준을 정하기 어렵다는 단점이 있다. 이를 보완하기 위하여 뇌파 등의 생체 신호를 이용하는 연구도 있다. 뇌파 측정을 통하여 졸음 여부를 판별하는 경우 정확성이 높으나^[5] 운전자에 직접 기기를 부착하거나 운전자가 헬멧형 측정장치를 써야하므로 적용이 어렵다는 단점이 있다.

본 논문은 자동차와 열차에 적용할 수 있는 생체신호처리 기반의 운전자 모니터링 시스템 개발과 관련된 연구 내용을 기술한다. 모니터링 시스템의 신뢰성과 실제 적용성을 확보하기 위하여 생체신호 측정 시 비접촉식 심박수 센서와 시선 인식센서를 활용하였다. 특히 시선 인식 센서의 경우 졸음 여부를 판별할 수 있을 뿐만 아니라 시선의 방향에 있는 다양한 기기를 제어하는 방법으로 활용이 가능하다. 열차의 경우 기관사가 다루고 주시해야 하는 장비가 많아 이 기능이 잘 활용될 수 있다.

영상처리 방식의 경우 주위 환경 특히 조명의 영향

을 많이 받는데, 사용한 심박수 센서의 경우 이의 영향이 비교적 적다. 하지만 신뢰성을 높이기 위해서는 다양한 데이터에 대한 학습과정이 필요한데 Coimbra 대학교 시스템 및 로봇연구 랩에서 공개한 수면 연구 데이터와 함께 실제 측정된 데이터를 활용하였고 머신러닝을 통해 판별의 정확성을 높였다. 이에 대한 자세한 개발과정과 연구내용은 본문에서 기술하며 그 순서는 다음과 같다. 먼저 1절에서는 데이터 수집과 졸음 인식 판단의 전반적인 구조에 대하여 설명한다. 다음으로 2절에서는 데이터를 수집하고 인식하여 전달하는 부분에 대하여 기술하고 3절에서는 머신러닝으로 판별 로직을 구현한 내용에 대하여 기술한다. 4절은 최종 판정 결과 정확성을 높이기 위한 방법을 기술하고 5절에서 실제 데이터를 바탕으로 실험한 내용을 설명한다. 끝으로 결론을 제시한다.

II. 본 론

2.1 데이터 수집 및 졸음 인식 판단 절차

그림 1은 본 연구에서 개발한 시스템의 처리 프로세스를 나타낸 것이다. 운전자 감시 시스템의 개발 및 처리 프로세스는 데이터 수집, 전송, 머신러닝, 판단, 결과 표시 등 다양한 단계로 이루어져 있다. 먼저 운전자 상태 인식을 통한 졸음 여부 판단을 위해 다양한 경로로 생체 데이터를 수집하고 이를 바탕으로 머신러닝을 수행한다. 생체 데이터로는 시선과 심박수를 이용하며 공개 데이터 및 측정 데이터를 모두 활용하였다. 머신러닝 부분에서는 수신된 데이터를 가지고

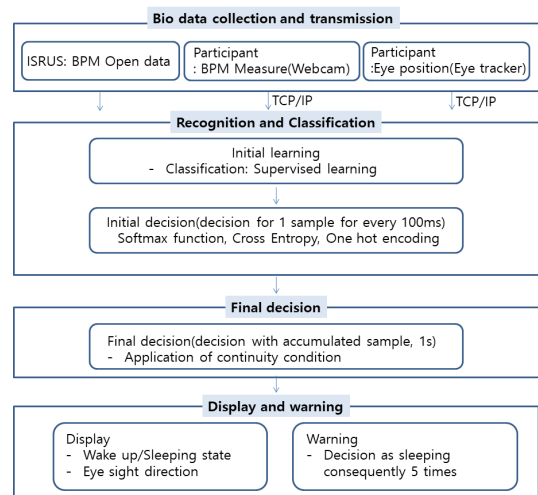


그림 1. 졸음 인식을 위한 학습과 데이터 흐름
Fig. 1. Learning and data flow for the sleep recognition

여러 가지 경우를 분류한 후 졸음 여부 및 시선의 방향에 대한 최종판정을 내린다. 판정 결과와 결과의 연속 상태를 가지고 화면에 표시하고 경보음을 발생한다. 각 단계 별 세부 구조와 동작에 대한 내용은 다음의 절(2절~4절)에서 기술한다.

2.2 생체 데이터 수집 및 전송

생체 데이터로는 시선과 심박수를 활용하였으며 이에 대한 측정을 위해 전용 센서를 사용하였다. 먼저 시선 측정의 경우 눈에 대한 눈동자의 위치를 추정함으로써 수행하였다. 눈에 대한 눈동자의 위치 추정용 센서로는 Tobii사의 Gaming Eye Tracker를 사용하였는데 이는 그림 2^[6]와 같이 안면 영상으로부터 눈의 위치와 크기를 먼저 인식하고 다음 눈동자를 인식한 후 시선을 추정한다. 따라서 운전자가 어떤 방향을 주시하고 있는지 알 수 있다. 실험 참가자에게 센서를 적용한 후 다양한 시선을 갖도록 함으로써 머신러닝을 위한 데이터(약 10,000개 세트)를 수집하였다.


시선만으로 졸음 여부를 판별할 경우 필요에 의해 운전자가 다른 곳을 보거나 눈을 깜빡이느라 감았을 경우 판별성이 떨어지는 단점이 있다. 이를 보완하기 위해 심박수를 측정하여 졸음 여부를 판별하는데 추가적인 지표로 활용하였다. 시선 추정과 마찬가지로 심박수 추정도 다양한 사람에게 정확히 적용할 수 있

기 위해서는 이를 잘 분류할 수 있는 기준을 마련하여야 하며 이를 위해 머신러닝을 활용하였다.


머신러닝을 위한 다양한 데이터를 확보하기 위해 총 세 가지 방법으로 심박수 데이터를 수집하였다. 첫 번째로 Coimbra 대학교의 시스템 및 로봇연구팀(ISRUC: Institute of Systems and Robotics, University of Coimbra)에서 제공하는 자료를 이용하여 충분한 학습용 데이터를 확보하였다^[7]. ISRUC에서 수행하는 다양한 연구 중 수면 연구가 있으며 해당 연구 자료가 공개되어 있는데 이 자료의 일부를 그림 3에 나타내었다. 여기에는 다양한 사람들에 대한 신체적 특징, 측정일자, 상태 별 측정 샘플(Epoch) 수가 정리되어 있으며 매 Epoch 마다 졸음/수면 상태(W: Wake, NREM(N1, N2, N3, 뇌파 수준에 따른 수면 모드), REM: Rapid Eye Movement 수면), 산소 포화도(SpO2), 심박수(HBR), 신체위치(BPOS: Body Position) 등의 특징들도 정리되어 있다. 각 항목에 대한 설명은 Khalighi^[8]에 기술되어 있다. 이중 졸음상태와 심박수에 해당하는 값을 활용하여 다양하고 전문적인 데이터가 머신러닝에 입력될 수 있도록 하였다.

두 번째로 그림 4와 같은 Physiolab사의 전자심박수 센서(ECG; Electrocardiogram)를 활용하여 실험참가자의 심박수 데이터를 측정하였다. 이 작업은 앞에서 머신러닝에 적용된 데이터가 외국인들에게서 측정된 데이터이므로 실제 실험에서 운전자와 신체적 특징이 다를 수 있기 때문에 이를 보완하기 위함이다. 운전자 후보 3명의 다양한 상태(각성, 휴식, 졸음 등)에 따라 3,500개의 심박수 데이터를 측정하였다.

마지막으로 비접촉식 심박수 카운터 장치를 이용하여 실험 참가자로부터 데이터를 수집하였다. 이 장치는 MIT에서 개발하였으며 영상센서를 통해 들어오는 동영상 중 안면을 찾고 이중 미간의 미세한 움직임을



(a)



(b)

그림 2. Eye Tracker(아이 트래커)의 설치(a)와 동작(b)[6]
Fig. 2. Installation(a) and Operation(b) of Eye Tracker[6]

Epoch	Stage	SpO2	HR	Events	BPOS	Twin	TriEx	Technote	ID
1 W	0	93	85	B	0.0	0.0		056113	
2 W	94	85	B	0.0	0.0		DATE: 26/12/2012		
3 W	93	78	B	0.0	0.0		HEIGHT: 66 cm		
4 W	94	75	MChg	B	0.0	0.0	WEIGHT: 185 lbs		
5 W	94	81	B	0.0	0.0		AGE: 44		
6 W	95	78	B	0.0	0.0		SEX: Male		
7 W	94	81	B	0.0	0.0				
8 W	95	78	B	0.0	0.0				
9 W	95	87	B	0.0	0.0				
10 W	94	78	B	0.0	0.0				
...									
65 W	93	76	B	0.0	0.0				
66 N1	93	75	B	0.0	0.0				
67 N1	93	75	B	0.0	0.0				
68 W	93	73	B	0.0	0.0				
69 W	93	73	B	0.0	0.0				
70 W	93	75	B	0.0	0.0				
71 W	93	74	B	0.0	0.0				
72 W	93	77	B	0.0	0.0				
73 W	94	80	B	0.0	0.0				
74 W	94	75	B	0.0	0.0				
75 W	94	75	B	0.0	0.0				
76 W	94	75	B	0.0	0.0				
77 N1	94	75	B	0.0	0.0				
78 W	94	75	B	0.0	0.0				
79 N1	94	75	B	0.0	0.0				
80 W	94	80	B	0.0	0.0				
81 N1	94	76	B	0.0	0.0				
82 N1	94	75, RR	B	0.0	0.0				

그림 3. Coimbra Univ의 1인 수면 패턴 연구 데이터셋 샘플[7]
Fig. 3. Data set sample in the study of sleep Patterns of Coimbra Univ[7]

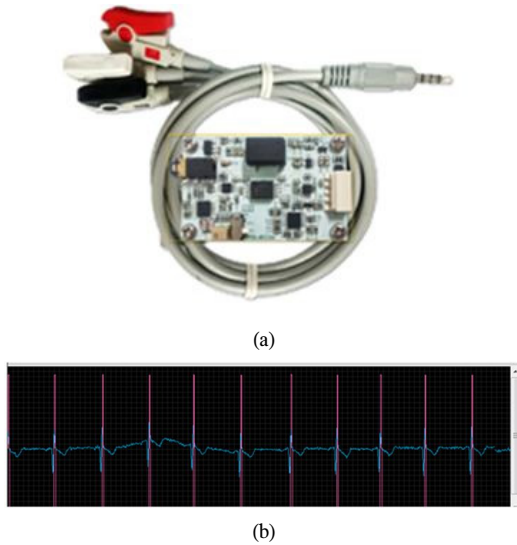


그림 4. ECG 센서 및 데이터 수집의 전사
Fig. 4. ECG sensor and display of measured data

인식하여 심박수를 측정할 수 있다. 그림 5의 (a)와 (b)에 각각 위 소프트웨어의 동작 과정과 본 연구에서 이를 활용하여 데이터를 확보하는 과정을 나타내었다^[9]. 해당 소프트웨어의 기능인 비접촉식 심박수 카운터는 이와 같이 초기 머신러닝을 위한 데이터 수집용으로 사용될 뿐만 아니라 향후 실제 운전자의 심박수 상태를 측정하는 데에도 활용된다.

위처럼 수집되어진 시선과 심박수에 대한 데이터는 좋음 여부 판별의 기준이 된다. 학습이 빨리 이루어지기 위해서는 데이터의 양이 충분함과 동시에 데이터가 머신러닝 플랫폼으로 실시간으로 전달이 되어야 한다. 실시간 데이터 전송은 향후 실제 차량에 탑재되었을 때에도 빠른 판별을 위해 필수적이기 때문에 이를 위해 Ethernet 통신을 사용하였다. 앞에서 기술한 시선과 심박수 측정 장치 중 Eye tracker와 비접촉식 심박수 카운터에 통신 프로그램을 구축하여 탑재시켰다. 반면에 ECG의 경우 직접 플랫폼에 측정 데이터가 저장되며, Coimbra 대학교에서 공개한 수면 데이터도 데이터 자체를 가져온 것이므로 통신 프로그램이 필요하지 않다. Eye tracker의 경우 마이크로컴퓨터가 내장되어 있으며 C#으로 구현된 자체 시선 인식 프로그램을 라이브러리로 제공하므로 통신 프로그램을 추가로 제작하여 같이 링크시켜 탑재하였다. 비접촉식 심박 카운터의 경우에도 Python으로 구현된 인식 및 카운터 프로그램에 추가로 통신 프로그램을 제작하고 연동되도록 하였다.

이 때, 2가지의 센서와 머신러닝 플랫폼이 같은 속



(a)



(b)

그림 5. 비접촉식 심박수 카운터의 동작 (a) MIT에서 제공하는 화면^[9] (b) 실험 참가자(저자)에게 적용한 화면
Fig. 5. The operation of noncontact heart beat counter (a) Image presented by the developer(MIT)^[9] (b) Image of adaptation to the experiment participant(author)

도로 데이터를 생성하고 처리하는 것이 아니므로 수신측(머신러닝 플랫폼)에서 데이터를 제대로 받았는지 확인하는 과정이 필요하다. 그러므로 비교적 간단하고 빠르지만 데이터 송·수신에 문제가 생겼을 경우 인지할 수 없는 UDP(User Datagram Protocol) 대신 재전송이나 오류제어 등을 통해 메시지 전달을 보장하고 흐름제어 및 혼잡제어와 같은 서비스를 제공하는 TCP/IP를 적용했다. 이 프로토콜을 활용하여 상이한 두 센서를 통해 각각 시선 위치값과 심박수 데이터 추출에 적합한 언어로 근거리/원거리에 모두 적용 가능한 데이터 전송 통신 프로그램을 구현하였다.

2.3 인식 및 분류

머신러닝(Machine Learning)은 많은 데이터를 가지고 기계 혹은 장치를 학습시킴으로써 스스로 알고리즘을 찾도록 하는 방법이다. 머신러닝은 데이터에 결과(정답) 포함의 여부에 따라 지도학습(Supervised Learning)과 비지도학습(Unsupervised Learning)으로 나뉘는데 본 연구에서는 데이터 레이블에 정답(좋은 여부)을 포함시킬 수 있어서 지도학습(Supervised Learning)으로 설계하였다. 본 연구에 적용한 지도학

습 방법에서는 레이어의 층 수 및 노드의 수는 각각 2층, 6개로 설정하여 머신러닝을 구축하였다. 각 노드의 계수는 처음엔 임의로 설정되어 있고 입력에 대한 결과값을 가지고 계속 학습하면서 계수를 조정해 나간다. 충분한 데이터를 가지고 학습을 시키면 데이터에 내재된 패턴을 인식하게 되어 입력과 결과 간의 관계성을 인지하게 되며 이를 통해 운전자의 생체 데이터로 줄음 여부를 판별할 수 있게 된다.

플랫폼에 적용된 Learning rate는 0.01로 설정하였다. Learning rate는 반복문 1번마다 이동할 경사(Gradient)의 보폭(Step size)을 뜻한다. Learning rate 값이 클수록 학습 진행도중 cost 값이 경사의 최저점을 지나치게 되기 때문에 계속해서 최저 경사를 찾으며 내려갈수록 무한루프에 빠지거나 경사를 벗어날 수도 있다. 이러한 현상을 오버슈팅(Overshooting)이라 한다. 반면에 이를 너무 작게 할당하게 된다면 알고리즘이 지연되는 현상을 보인다. 이 때 학습이 올바르게 이루어지기 위해서는 데이터의 각 범주에 있는 값의 크기 분포가 일정하여야 한다. 이를 위해 데이터 전처리(Data Preprocessing)을 통해 데이터 정규화(Data Normalization) 방법을 적용하였다. 데이터 정규화에 대한 식은 다음과 같다.

$$Normalization = v_n = \frac{v - v_{min}}{v_{max} - v_{min}} \quad (1)$$

여기서 v 는 해당 변수를 의미하며 v_n 은 변환된 새로운 변수를 나타낸다. 일반적으로 데이터 정규화를 이룰 때 모든 범주에 대한 v_n 은 0과 1사이의 값을 갖게 된다. 현 실험에서 가지고 있는 데이터 값 중 심박수의 경우 BPM(beat per minute)으로 0~200사이의 값을 가지며 Eye Position의 경우 0~2000(X축, Y축)의 값의 넓은 분포를 보이고 있어 표본 그대로 학습을 했을 때 NaN 값을 보이며 학습을 제대로 이루지 못하는 현상을 발견하였다. 이러한 현상으로 0~2000의 범위를 가지고 있는 표본의 값들을 0~20 사이의 값으로 변환하였다. 위와 같은 데이터 정규화를 이루어 학습에 적용했을 때 오버슈팅(Overshooting)이 일어나지 않고 학습을 이루는 결과를 나타냈다. 학습 시 사용한 눈 위치 및 심박수 데이터를 표 1에 나타냈는데 여기에서는 데이터의 크기를 직관적으로 알아보기 용이하도록 백분율로 나타내었다.

단순히 줄음 여부만을 판별할 경우, 이진 분류를 통해 보다 쉽게 머신러닝 알고리즘을 구현할 수 있다.

그러나 시선 인식의 장점을 활용하여 시선에 따라 자동차나 열차의 내부 장치를 동작시키는 기능을 구현하고자 본 연구에서는 다항 분류의 방법을 사용하였다. 자동차 운전자의 경우 운전 중에 에어컨, 네비게이션, 오디오 등의 동작을 수행하는 경우가 있으며 열차 기관사의 경우 출입문 취급, MMI 감시, 출발제어, 노치제어, 방송 등과 같이 수행해야 할 일이 많다. 시선 인식을 통한 장치 동작이나 기능 호출은 이러한 경우 많은 도움이 될 것이다.

일반적으로 이진 분류에서는 입력의 범위에 따라 출력력이 0에서 1로 연속적으로 변화될 수 있도록 sigmoid 함수를 사용한다. sigmoid 함수를 이용하여 2개 이상의 범주를 정의하게 된다면 해당 뉴런으로 들어오는 입력들과 바이어스에 의해 출력력이 결정되는 과정에서 오차를 계산이 어려워진다. 2개 이상의 값을 가지는 다중 분류를 할 때 sigmoid 함수를 이용하기 보다는 softmax 함수가 적합함이 Bouchard^[10]에 의해 확인되었다. Sigmoid 함수를 이용하면 해당 자체의 뉴런의 입력, weight, bias로 출력력이 되는 반면에 softmax 함수를 사용하면 전체 뉴런들의 출력값과 비교를 통해 최종 출력 값이 결정이 된다. softmax 함수는 sigmoid 함수보다 여러 입력에 대하여 연속적이고 부드럽게 변화하도록 일반화한 것으로 뉴런의 출력 값에 지수함수를 적용하여 모든 뉴런에서 나온 값이 정규화^[11] 형태를 갖도록 하는 방법이다.

Softmax는 다변수 벡터함수로 정의되며 다음 수식 (2)으로 표현된다.

$$\hat{Y} = S(y_i) = \frac{e^{y_i}}{\sum_{j=0}^k e^{y_j}} \quad (i = 0, 1, 2, \dots, k) \quad (2)$$

여기서 y_i 는 각 범주에 대한 출력값으로써 입력 y_i 값에 대하여 노드의 계수를 곱하여 얻어진다. i 는 결과 노드의 번호를 나타내며 전체 수는 범주(클래스)의 수와 동일하다. 또한 입력 y_i 는 각각에 대하여 평균을 차감하고 표준편차로 나누는 즉 정규화하는 전처리과정을 거쳤다고 가정한다. 만약 2개의 입력이 단일 계층의 기계학습 신경회로망을 거쳐 3개의 범주로 구분된다면 3개의 범주에 대한 각각의 출력은 아래와 같이 식 (3)으로 표현될 수 있다.

$$\begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} = \begin{pmatrix} w_{a1} & w_{a2} & b_a \\ w_{b1} & w_{b2} & b_b \\ w_{c1} & w_{c2} & b_c \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} w_{a1}x_1 + w_{a2}x_2 + b_a \\ w_{b1}x_1 + w_{b2}x_2 + b_b \\ w_{c1}x_1 + w_{c2}x_2 + b_c \end{pmatrix} \quad (3)$$

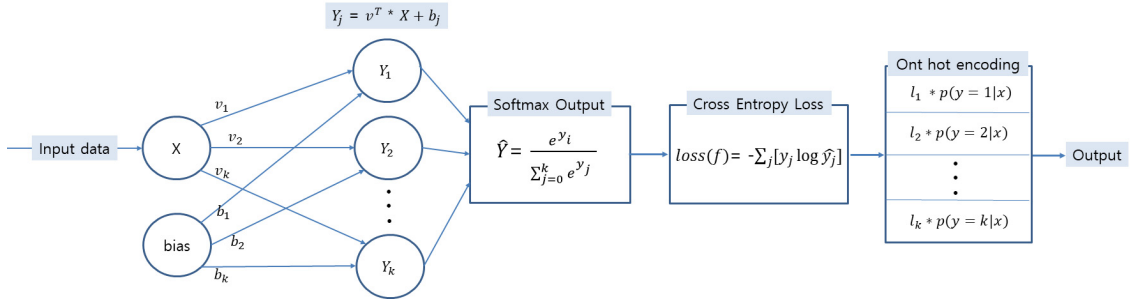


그림 6. 인식 및 분류 알고리즘
Fig. 6. Algorithm of recognition and classification

즉, 범주 k 만큼의 차원을 지니는 입력을 받아 각각의 범주에 대한 출력값으로부터 범주에 속할 확률을 도출하기 위해 식 (2)를 이용한다. 이를 통해 각 출력 결과는 모두 [0,1] 사이의 값을 가지며 모든 예측 성분의 합은 1이 되는 확률 분포의 형태로 변경된다. 따라서 출력 노드의 함수로 softmax 함수를 사용하면 출력력이 해당 범주에 속할 확률로 변환되며 출력 변수 중 가장 큰 값을 가지는 범주가 One-hot encoding을 거쳐 최종 분류 값이 된다.

Softmax 함수를 통해 계산된 k개의 확률 y_j 은 Cross entropy loss function(크로스-엔트로피 손실 함수)를 적용하여 해당 머신러닝 모델이 관측한 데이터들을 정답으로 예측할 확률을 최대화한다. 크로스-엔트로피 손실 함수 다음 식 (4)와 같다.

$$Loss(f) = - \sum_j [y_j \log \hat{y}_j] \quad (4)$$

크로스-엔트로피 손실 함수는 출력 y 의 [0, i]번째 항목에 대해 모두 더한 후 예측한 확률(\hat{y})에서 받은 정답을 고른 후 $-\log$ 를 취해준 값이다. 따라서

One-hot encoding 방법을 적용하면 크로스-엔트로피 손실 함수 값 중 가장 작은 값이 정답으로 예측된다. 모델이 제대로 예측된다면 softmax 함수를 통해 나온 가장 높은 확률 값이 선택될 것이며 정답 예측을 잘 할수록 가장 작은 손실함수를 가지게 된다.

다항 분류의 경우 데이터가 여러 개중 하나의 범주에 귀속되는데 본 연구에서는 크로스-엔트로피 손실 함수로부터 나온 가장 작은 값을 바탕으로 하나의 범주에 귀속이 명확히 되어 이를 학습 과정에 잘 반영되도록 하기 위해 One-hot encoding 방법을 사용하였다. One-hot encoding은 항목수가 k개면 k차원의 벡터를 생성하여 각 입력 x 값에 각각의 예측 확률을 곱한 결과 가장 작은 손실 함수 값인 정답 클래스에 해당되는 범주에 1을 부여하고 나머지는 0으로 처리하는 방법이다.

본 연구에서는 표 1에 나타난 바와 같이 시선의 좌표를 구분하여 대표적인 값에 해당하는 범주만이 선택되도록 하였다. 표 1에는 시선에 대한 x좌표와 y좌표, 심박수(BPM: Beats Per Minute)와 각각에 대한 정규화 값(N_BPM: Normalized Beats Per Minute)이 정리되어 있으며 이에 대한 One-hot encoding 값도

표 1. 데이터에 대한 One-hot encoding
Table 1. Dataset of One-hot encoding

No.	Eye x (pixel)	N_x (pixel)	Eye y (pixel)	N_y (pixel)	BPM	N_BPM	output 1	output 2	output 3	output 4
1	0	0	0	0	66.7	6.67	1	0	0	0
2	0	0	0	0	68.8	6.88	1	0	0	0
431	857	8.57	264	2.64	85.4	8.54	0	1	0	0
432	922	9.22	319	3.19	86.2	8.62	0	1	0	0
707	1701	17.01	716	7.16	82.9	8.29	0	0	1	0
708	1657	16.57	657	6.57	84	8.4	0	0	1	0
1087	1843	18.43	821	8.21	82.2	8.22	0	0	0	1
1088	1849	18.49	814	8.14	88.9	8.89	0	0	0	1

표시되어 있다. 이처럼 One-hot encoding 방법을 이용함으로써 다항 분류에서 출력 값을 뚜렷이 구분시킬 수 있다. 이 때 다항분류가 보다 잘 이루어지도록 One-hot encoding을 머신러닝의 최종단(Final layer)에서 사용하였다.

2.4 최종 결과 판별

대용량의 데이터로 머신러닝 플랫폼을 학습시킨 후 실제 환경에 적용하여 졸음 여부 및 시선을 인식하는 지 여부를 살펴본 후 검증을 수행하였다. 이 때 학습시킨 데이터에만 최적화되어 실제 데이터가 학습한 데이터와 약간의 차이만 있어도 잘못된 결과를 도출하는 경우가 2가지 발생할 수 있는데 각각 오버피팅(Overfitting)과 언더피팅(Underfitting)이다¹²⁾. 오버피팅과 언더피팅은 머신러닝 알고리즘의 신뢰성과 정확성을 저하시키는 주요 원인인데 이 중 본 연구에서는 다양한 환경에서 학습용 데이터가 수집이 되었으므로 오버피팅 현상이 발생할 수 있으며 이에 대한 극복이 필요하다. 이를 위해서는 데이터의 수를 줄이는 방법이 있으나 이 경우 학습이 느려지거나 언더피팅이 발생할 수 있으므로 본 연구에서는 운전자 상태의 연속성을 이용하여 보정하는 방법을 사용하였다.

최종 판단 전에 머신러닝을 통해 출력되는 값은 일시적인 시선과 심박수 측정값으로부터 판단한 값이며 여기에는 오버피팅 등에 의한 오류가 발생할 수 있다. 특히 운전자가 일시적으로 눈을 감았거나 다른 곳을 주시할 경우 잘못된 결과를 도출할 가능성이 높다. 그런데 운전자가 졸음의 상태에 있는 경우 이 상태는 일정 시간 유지되므로 이를 이용한 것이다. 즉 머신러닝 플랫폼에서는 100ms마다 운전자의 상태를 판단하여 출력하며 최종 결과 판정기에서는 이 판단 결과를 시간에 따라 지속적으로 수집하며 비교하며 일정 시간 연속적인 값을 보이는 비율이 지정된 비율의 이상이 될 경우 최종 추정 결과를 출력한다. 시행착오를 거쳐 비교 시간 길이는 100ms로 하며 최종 졸음 판단은 1초로 놓는 것이 좋은 결과를 나타냄을 확인하였다. 연속적으로 5회 졸음으로 판단할 경우 경고음을 나타내도록 설정하였으며 이는 사용자에 따라 변경가능하다. 다만 본 연구에서는 결과 판단 및 경고음 발생의 최적화를 위해 1초마다 졸음을 판단하고 5초 동안 연속 졸음으로 판명 시 경고를 내도록 하였다. 이러한 필터링 과정을 통해 일시적인 추정 결과 값에 에러가 발생하더라도 최종 결과 추정에서는 이를 제거하고 보다 정확한 추정 결과를 도출할 수 있다.

2.5 실험 및 결과

이 절에서는 실제 실험을 통해 구현한 운전자 모니터링 시스템의 운전자 상태 추정 정확도를 검증한 내용에 대하여 기술한다. 여건 상 열차에 장착하여 실험할 수 없어서 실제와 유사한 운전 환경에서의 판별 정확도를 검증하기 위해 자동차를 이용하였다. 총 30km를 이동하면서 운전자의 상태를 각종 상태를 잘 판별하는지 여부를 확인하였다. 동승자의 감시 하에 정차 구간에서는 실제로 졸거나 조는 척을 하는 실험도 수행하였다.

앞에서 기술한 바와 같이 다양한 방법으로 수집한 데이터를 전송하여 머신러닝을 수행하고 이에 대한 최종 결과를 도출하는 루틴을 운전자 모니터링 시스템에 탑재한 후 이 시스템을 그림 7과 같이 실제 자동차에 장착하여 실험을 수행하였다. 총 1시간 동안 약 36,000개의 샘플을 획득하여 판별을 하였는데 판별은 운전자의 졸음 여부와 함께 졸지 않은 경우 시선의 방향도 추정하게 된다. 시선은 앞에서 기술한 바와 같이 전방, 우측 상향, 우측 하향의 3가지 중 하나로 판별한다. 좌측의 경우 왼쪽 사이드 미러가 있는데 이 경우 운전자가 고개를 돌려서 보기 때문에 본 실험의 Eye tracker에서는 눈동자 미인식으로 판별되었다. 보안을



(a)



(b)

그림 7. 실제 실험 환경 (a) 주간 시험 (b) 야간 시험
Fig. 7. Real test environment (a) Day test (b) Night test

위해서는 좌측에 추가의 Eye tracker를 장착하여 연동시켜 구동할 필요가 있다.

총 36,000개의 운전자 심박수 및 시선 데이터 샘플에 대하여 각각의 샘플에 대한 판별을 거친 후 연속성 조건을 부가한 총 1,300건의 최종 판단을 얻게 되었다. 이 판단 결과와 실제 운전자의 상태를 비교하여 정확도를 구하였고 그 결과를 표 2에 정리하였다. 표 2는 운행환경(낮/밤)과 운전자의 상태(조는 경우/안 조는 경우)에 따라 전체 판정한 샘플 수 대비 맞게 판정한 샘플의 수를 나타낸 것이다. 전반적으로 낮에는 95.8%의 정확도를 나타내며 밤에는 86.4%의 정확도를 나타낸다. 평균 정확도는 92.2%이다. 앞서서도 기술한 바와 같이 Eye tracker가 전문적인 인식용이 아닌 게임용이어서 시선 인식의 범위가 좁기 때문에 시선이 약간만 벗어나도 시선 미인식으로 인하여 조는 것으로 판단하는 경우(False alarm)가 오차가 발생하는 케이스의 많은 부분을 차지하였다. 다만 일단 시선이 범위 안에 들어 줄지 않는 것으로 판정이 되면 시선의 방향(전방, 우상, 우하)에 대한 인식은 모두 정확하게 인식을 하였다.

표 2. 시험 결과(맞게 판정한 수/전체 판정 수)
Table 2. Experimental results (Number of correct decision / Number of decision)

Environment	Drowsy	Awake	Total	Correct (%)	Missing (%)	False Alarm (%)
Day	75 / 77	691 / 723	766 / 800	95.8	2.6	4.4
Night	50 / 56	382 / 444	432 / 500	86.4	10.7	14.0
Total	126 / 133	1072 / 1167	1198 / 1300	92.2	5.3	8.1

III. 결 론

시선과 심박수 두 가지 생체신호를 인식하여 운전자의 상태를 판별함과 동시에 시선의 방향에 따라 기기를 제어할 수 있도록 하는 시스템을 개발하였다. 다양한 방법으로 많은 데이터를 수집하고 이를 가지고 머신러닝을 수행함으로써 스스로 비교적 정확히 판단할 수 있는 시스템을 구축하였다. 이 때 졸음 여부뿐만 아니라 시선의 방향을 인식하도록 함으로써 향후 다양한 기기를 제어할 수 있도록 하였으며 이를 위해 다항 분류가 잘 학습될 수 있도록 softmax 함수, 크로스-엔트로피 손실 함수, One-hot encoding을 적용하

였다. 최종 졸음 판단에서는 판단의 연속성 조건을 적용함으로써 판단의 오류를 줄였다. 실제 도로를 주행하며 인식을 수행한 결과 90%이상의 정확성을 얻게 되었다. 더욱 다양한 조건에서 시험을 수행하고 인식 정확도를 높임과 동시에 실제 장치와 연동하여 시선을 통한 기기 제어 시스템을 개발하는 것은 추가로 연구해야할 부분이다.

References

- [1] S. T. Ha, "Drowsy driving accidents, prevent them with technology," *News Article in The Korea Economic Daily*, Aug. 25 2017.
- [2] J. S. Kim, "Drowsy driving is a staggering stunt driving," *News Article in The News Town*, Jul. 16 2018.
- [3] H. Song, J. Choi, C. Lee, B. Choi, and J. Yoo, "Implementation of a safe driving assistance system and doze detection," *The IEEK - Signal Processing*, vol. 49, no. 3, pp. 30-39, 2012.
- [4] J. Choi, H. Song, S. H. Park, and C. D. Lee, "Implementation of driver fatigue monitoring system," *J. KICS*, vol. 37, no. 8, pp. 711-720, 2012.
- [5] K. Huh and S. Kang, "Drowsiness detection technology of car driver," *J. Inst. Control, Robotics and Syst.*, vol. 21, no. 1, pp. 37-43, 2015.
- [6] *Eye trackers for PC gaming*, <https://tobiigaming.com/products/>, visited on 9th Sep. 2018.
- [7] S. Khalighi, T. Sousa, J. M. Santos, and U. J. Nunes, "ISRUC-Sleep: A comprehensive public dataset for sleep researchers," *Computer Methods and Programs in Biomed., Elsevier*, pp. 180-192, 2016.
- [8] S. Khalighi, T. Sousa, G. Pires, and U. Nunes, "Automatic sleep staging: A computer assisted approach for optimal combination of features and polysomnographic channels," *Expert Syst. with Appl.*, vol. 40, no. 17, pp. 7046-7059, 2013.
- [9] M. Humphries, "Measure your heart rate using a webcam and your forehead," *News Article in The Geek.comKorea Economic Daily*, Apr. 16

2013.

- [10] G. Bouchard, *Efficient bounds for the softmax function, applications to inference in hybrid models*, Xerox Research Center Europe, Meylan, May 2008.
- [11] F. F. Li, J. Johnson, and S. Yeung, "Neural networks part 2: setting up the data and the loss," Course notes in CS231n Convolutional Neural Networks for Visual Recognition, Stanford University, Apr. 2018.
- [12] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, The MIT Press, Cambridge, MA, USA, 2016.

전 혜 연 (Hye-yeun Chun)



2018년 2월 : 상명대학교 정보통신공학과 졸업
2018년 9월~현재 : 과학기술연합대학원대학교 교통시스템공학전공 석사과정
2018년 9월~현재 : 한국철도기술연구원 연구원

<관심분야> 머신러닝, 열차신호

김 정 태 (Jungtai Kim)



1997년 2월 : 서울대학교 전기공학부 졸업
1999년 2월 : 서울대학교 전기공학부 석사
2011년 8월 : KAIST 전기및전자공학과 박사
2012년 8월~현재 : 한국철도기술연구원 선임연구원

<관심분야> 열차제어, 신호처리, 임베디드 시스템

김 길 동 (Gil-dong Kim)



1986년 2월 : 명지대학교 전기공학과 졸업
1991년 2월 : 명지대학교 대학원 전기공학과 석사
2003년 2월 : 명지대학교 대학원 전기공학과 박사
1995년 1월~현재 : 한국철도기술연구원 수석연구원

<관심분야> 열차추진제어, 전동차차량설계

이 재 호 (Jaeho Lee)



1989년 8월 : 광운대학교 공과대학원 전자공학과 졸업
2005년 2월 : 고려대학교 공과대학원 메카트로닉스공학과 박사
1989년 8월~1995년 1월 : 단암전자통신(주)선임연구원

1995년 2월~현재 : 한국철도 기술연구원 책임연구원
<관심분야> 철도신호, 위치 감지