

기계학습기반 비접촉식 차량용 앰비언트 라이팅 컨트롤 시스템 구현

이 상엽*, 이재규^o

Implementation of Contactless Vehicular Ambient Lighting Control System Based on Machine Learning Method

Sang-yub Lee*, Jae-kyu Lee^o

요 약

본 논문은 차량 내 감성조명인 앰비언트 라이팅을 조절하는 시스템 구현에 관한 것이다. 앰비언트 라이팅은 차량 내 조명 보조 장치로서, 사용자의 감성에 맞게 색상을 변화시키는 기능을 제공한다. 기존 앰비언트 라이팅 조절은 사용자가 중앙 제어 디스플레이 또는 헤드유닛 시스템에 접속하여 시스템 내에서 해당 기능을 활성화 시키고 활성화 된 이후 조명 색상을 변경하기 위해서는 재조정하는 과정이 필요했다. 본 논문에서는 자기장 센서 모듈을 활용하여 자기장 분포 변화에 따른 사용자의 직접적인 기기 조작 없이, 간단한 제스처를 이용하여 비접촉식, 직관적으로 사용자의 의도를 인지할 수 있는 기계학습 알고리즘기반 차량 내 감성조명 조절 시스템 구현 방법을 제안한다.

Key Words : Machine Learning, Vehicular Emotional Lighting, Contactless Control, Gesture Recognition, Magnetic Sensor

ABSTRACT

This paper is about the implementation of a system that controls ambient lighting, which is an emotional lighting in a vehicle. Ambient lighting is an in-vehicle lighting assistant that provides a function to change the color to proper the user's emotions in car. Existing ambient lighting control allows the user to access the central control display or head unit system and activate the corresponding function within the system. In this paper, we propose a method of implementing an in-vehicle emotional lighting control system based on a machine learning algorithm that can easily recognize the user's intention using a simple gesture without the user's direct device manipulation using a magnetic field sensor module

I. 서 론

최근 차량 내 감성 콘텐츠 서비스는 급속도로 발전하고 있다. 자동차 제조사에서는 다양한 소비자의 요

구사항에 맞춰 차량 내 음향서비스, 조명 서비스 등 개인 맞춤형 서비스를 개발하고 있다. 그림1과 같이, 차량 내 감성 조명 서비스는 이미 다양한 차종에 적용되고 있다. 특히, 자율주행 차량이 상용화를 앞두고

* 본 연구는 전라북도 친환경 전기·전자부품 시장창출 사업의 일환으로 수행하였음. [JIAT-19-2770 터치센싱기반 차량용 앰비언트 조명 컨트롤 및 시스템 기술개발]

• First Author : Korea Electronic Technology Institute, syublee@keti.re.kr, 정희원

o Corresponding Author : Korea Electronic Technology Institute, jaekyu@keti.re.kr, 정희원

논문번호 : 202008-207-D-RU, Received August 20, 2020; Revised September 1, 2020; Accepted September 5, 2020

있으며, 이에 따라 차량 내 환경에서 사용자의 감성을 반영할 수 있는 감성조명에 대한 연구가 활발해지고 있다¹⁾. 하지만, 다양한 차종에 적용되고 있는 감성조명, 앰비언트 라이팅 기능은 대부분 사용자가 직접 해당 시스템 접속하여, 별도로 기능을 활성화 시켜야하며, 특히, 운행중에 운전자의 기분상태에 맞춰 조절할 수 없는 상황이다. 본 논문에서는 자기장 센서 모듈을 활용하여 사용자의 제스처를 통해, 직접 색상을 변경하고 차량 내 HMI(Human Machine Interface) 조절이 가능하도록 제스처 인식 기반의 컨트롤 구현에 대해 제안한다. 자기장 센서 모듈은 모듈 내에서 자기장 분포를 생성하고, 사용자의 접근을 인지하여 자기장 분포의 변화를 감지한다²⁾. 변화된 자기장의 분포에 따라 제스처를 매칭하고 해당 제스처를 인식하는 방법을 사용하고 있다. 하지만 자기장 분포 특성상 아닐로그 값의 변화 폭이 크며, 이에 따른 오동작을 발생시킬 가능성이 크다. 특히 차량 내에서 오동작에 대한 문제는 운전 집중도를 저하시킬 수 있기 때문에 위험성이 크다고 볼 수 있다. 본 논문에서는 사용자의 모션에 따른 자기장 센서 값의 오류를 줄일 수 있도록 기계학습 알고리즘을 이용하여 제스처 인식 정확도를 향상시키고 이에 따른 사용자의 제스처를 직관적으로 사용할 수 있는 앰비언트 라이팅 시스템 구현에 대해 설명한다³⁻⁵⁾. 따라서 본론 1절에서는 본 논문에서 사용한 시스템 구성 및 시스템 처리 장치 하드웨어에 대한 사양에 대해 설명하고 2절에서는 자기장 센서 모듈의 데이터 특징과 데이터를 획득하는 방법에 대해 설명한다. 3절에서는 획득한 제스처 데이터를 활용하여 본 논문에서 제안하는 시스템 처리 장치에 적합한 알고리즘을 선정하고 선정된 알고리즘에 대한 제스처 인식 성능 평가를 수행한다. 시스템 구현 측면에서는 실제 개발된 시스템 구성에 대한 방법과 제스처를 통한 앰비언트 라이팅 조절 방법에 대해 설명하고 해당 연구에 대한 결론을 맺는다.

II. 시스템 구성 및 데이터 처리

2.1 시스템 구성

본 논문에서 제안하는 시스템 구성은 그림 2와 같이 차량용 헤드유닛 내 자기장 센서 모듈을 적용하고, 사용자가 해당 모듈에 근접할 때, 자기장 변화에 따라 제스처 동작을 인식하여 차량 내 조명을 실시간으로 변화시키는 시스템을 구현한다.

시스템 구성에서 볼 수 있듯이, 그림 3과 같이 자기장 센서 모듈과 센서 모듈 내 기계학습 알고리즘을 적



그림 1. 차량 내 앰비언트 라이팅 적용 현황
Fig. 1. Ambient Lighting Control System Cases

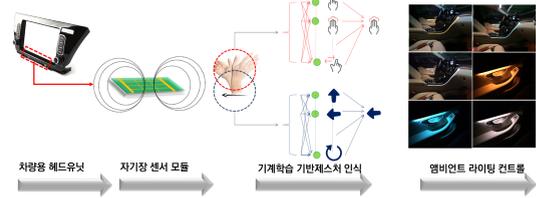


그림 2. 시스템 구성 및 데이터 처리 과정
Fig. 2. System Architecture and Data processing

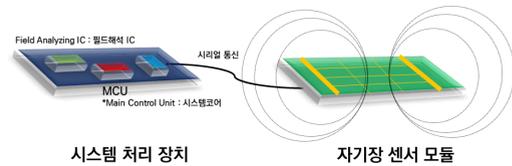


그림 3. 모듈간 연결 구성
Fig. 3. Connection of System Processing Module and Magnetic Sensor Module

용할 수 있는 시스템 처리 장치가 요구된다. 특히, 구현된 제품의 상용화를 위해서, 표 1과 같이 시스템 처리 장치의 시스템의 코어는 낮은 클럭 주파수를 갖는 저사양의 시스템을 사용하며, 이에 적합한 기계학습 알고리즘 사용이 요구된다.

표 1. 시스템 처리장치 사양
Table 1. Specification of System Processing Module

시스템 코어	CortexM4F@120MHz, 512KB FLASH, 192KB RAM
필드해석IC	MCP3461
시리얼통신	USB-Serial

2.2 자기장 센서 모듈

자기장 센서 모듈은 생성된 자기장의 변화를 감지하여 감지된 값을 시스템 처리장치에 전달하는 기능을 한다. 그림 4와 같이, 자기장의 변화는 사용자의 손이 접근하는 것에 따라 변화하게 되어 있으며, 본 논문에서는 단순 접근 유무를 파악하는 것이 아니라, 사

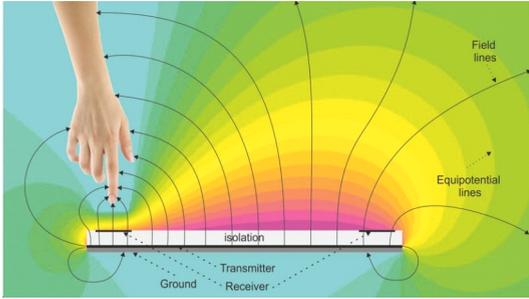


그림 4. 사용자 접근에 따른 자기장의 변화 분포 예
Fig. 4. Example of Magnetic Field Variation with User's Hand Motion

용자의 동작을 제스처에 맵핑하여 인식할 수 있는 기능을 구현한다.

그림 5는 사용자의 접근에 따라 자기장의 변화를 보여주고 있다. 본 논문에서는 자기장 센서 모듈의 신호 세기 변화가 아날로그 신호이므로, 변화량이 크기 때문에, 별도의 칼만필터를 이용해서 변화폭을 줄이고, 변화폭이 줄어든 데이터를 자기장 센서 모듈 내 좌표 정보를 활용하여 동작에 따른 좌표값을 기계학습에 적용하고자한다⁷⁾. 특히, 제스처 동작과 관련하여 저사양의 시스템 처리 장치에서 실시간으로 동작을 인식하고 반응할 수 있도록, 좌/우/상/하 4가지 동작 위주의 제스처를 맵핑하고, 4가지 제스처 맵핑에 대한 자기장 센서 모듈 내의 영역 구분과 값의 변화를 산출하여 기계학습 알고리즘에 적용하였다.

표 2는 사용자의 제스처에 따른 자기장 센서 값의 범위와 응용 동작에 대해서 보여준다. 자기장 센서의 출력값은 X축, Y축, Z축에 대해서 맵핑되며, Z축 값의 사용자의 접근을 인식하는 최소한의 높이를 보여주므로, 제스처에 동작에 대한 X축, Y축값을 사용하

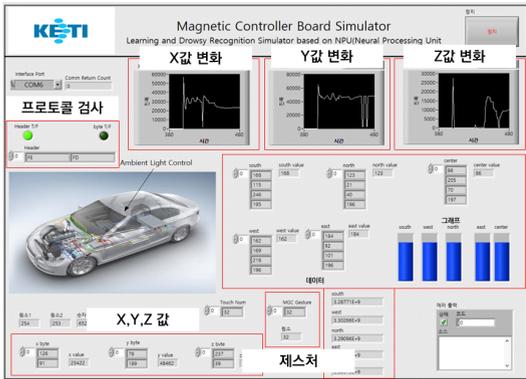


그림 5. 데이터 확인용 시뮬레이터
Fig. 5. Simulator for Monitoring Magnetic Field Variation

표 2. 제스처에 따른 자기장 센서 값의 범위
Table 2. Scope of Magnetic Sensor Variation with User's Hand Motion

	X값	Y값	Z값
좌→우	0 ~ 65,535	30,000~40,000	8,000~1,2000
우→좌	0 ~ 65,535	30,000~40,000	8,000~1,2000
상→하	30,000~40,000	0 ~ 65,535	8,000~1,2000
하→상	30,000~40,000	0 ~ 65,535	8,000~1,2000

여 인식 정확도를 향상시키는데 사용한다. 즉, Z축값은 자기장센서 모듈의 크기에 따라 최대값이 정해져 있으므로, X축값과 Y축값의 변화에 따라 제스처에 맵핑한다.

그림 6에서는 본 논문에서 자기장 센서 모듈 데이터를 이용하여 처리하고자하는 데이터 처리 과정을 보여준다. 필드해석 IC로부터 습득한 자기장 센서 변화량(전압)을 ADC(Analog Digital Converter)를 통해 양자화하며, 양자화된 값을 칼만필터를 통해, 변화량을 줄이는 과정을 거치며, 이때 값을 자기장 센서 모듈의 좌표에 맞도록 정의하며, 좌표값에 따라 제스처에 맵핑한다. 맵핑된 제스처 값은 시스템 처리장치 사양에 만족하는 기계학습을 적용하여 제스처 별로 학습된 값을 인식하는 과정을 수행한다.

본 논문에서는 시스템 처리장치 사양(표 1)에서 볼 수 있듯이, 저사양 내 기계학습 알고리즘 적용을 위해서, Tensor Flow Lite 기반 적용가능한 간단한 기계학습 모델을 통해, 제스처 학습과 제스처 인식을 수행하고 인식된 기능을 바탕으로 앰비언트 라이팅을 조절하는 기능을 구현하였다^{7,8)}. Tensor Flow Lite은 코어 내 메모리 관리를 통해, 병렬연산이 가능한 프로세싱 기법을 제공하고, 이를 이용하여 기계학습 알고리즘이 구현될 수 있는 환경을 제공하는 소프트웨어 프레임 워크이다. 본 논문에서는 다음절에서 소개할 기계학습

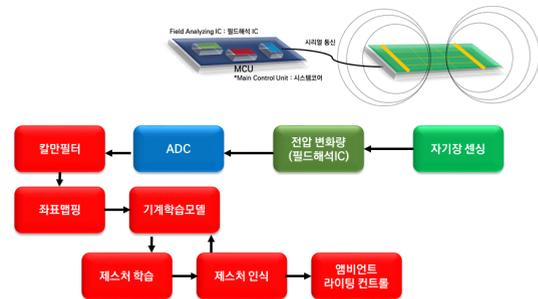


그림 6. 앰비언트 라이팅 컨트롤 데이터 처리 과정
Fig. 6. Data Processing of Ambient Lighting Control System

알고리즘을 Tensor Flow Lite 소프트웨어 프레임워크에 적용하여, 제스처 인식을 수행하였다.

2.3 기계학습기반 제스처 인식

본 논문에서는 제스처 인식을 위해, 데이터 셋 분류 기로서, RBF(Radius Basis Function), KNN(K-Nearest Neighbor), SVM(Support Vector Machine) 알고리즘을 사용하여, 적용하였다¹⁾. 이렇게 적용한 이유는 시스템 처리 장치 사양에 맞춰 적용 가능한 알고리즘을 선정하는 것이 필요하였다. RBF는 구별하고자하는 객체의 카테고리를 구별하는 용도로 사용되며 학습 데이터 셋 벡터의 정보들이 의사결정 공간을 구성하고 해당 공간에 맞는 데이터를 분류하는 방법을 취하며, KNN의 경우, 가장 가까운 이웃을 고려하는 분류방식으로, RBF와 비슷한 원리이지만, 모든 입력 데이터가 항상 인식되고, 분류를 하지 못한 결과가 없으므로 제스처 동작을 결정짓는데 유리하다. SVM은 기계학습 분야에서 단일 알고리즘으로 가장 좋은 알고리즘으로 소개되는 모델이다. 기본적인 방법은 서로 다른 그룹을 나타내는 데이터들이 있을 때, 그룹 간 거리를 가장 잘 분리하는 결정직선을 찾는 방법으로, 결정 직선의 형태가 선형에서부터 다양한 차원으로 변형되면서 최적화를 수행하는 방법이다. 하지만, 차원이 증가되면서 연산량이 급격하게 증가하는 문제가 있어, 본 논문에서는 최적화된 인식률을 보장하는 레퍼런스 알고리즘으로 사용할 예정이다. 그림 8은 기계학습을 수행하는 기본 플로우에 대해서 설명한다. 칼만필터를 거치고 X,Y,Z 값의 좌표값을 획득한 이후 좌표값에 대해 좌/우/상/하 제스처를 맵핑한 후 트레이닝 셋과 테스트 셋을 만든다. 이때, 비율을 7:3으로 구성하며 10 교차검증을 통해 데이터 검증 신뢰성을 갖는다. 3장에서는 개발된 시스템 구현에 대해 엠비언트 라이팅 컨트롤 시스템의 구성과 테스트 진

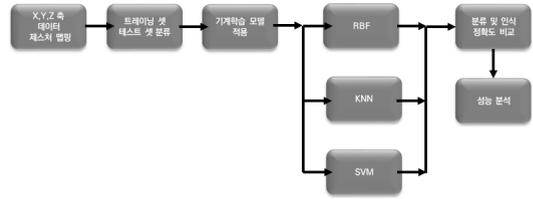


그림 8. 기계학습 알고리즘 기반 데이터 처리 플로우
Fig. 8. Flow Chart of Data Processing applied on Machine Learning Algorithm

행방법, 테스트 결과를 설명하고자 한다.

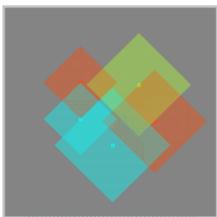
III. 시스템 구현

3.1 시스템 구현

본 논문에서는 제안하는 시스템 구성은 그림 9와 같다. 자기장 센서 모듈과 시스템처리장치가 연결되며, 시스템처리장치 내에서 제스처 인식결과와 연동되는 차량용 헤드유닛 GUI(Graphic User Interface)로 구성된다. 개발된 시뮬레이터에서는 X축, Y축, Z축값의 실시간 변화를 확인할 수 있으며, 시스템 처리장치와 자기장 센서 모듈간의 데이터 처리는 그림 10에서 볼수 있듯이 시스템 처리장치 내 제스처 인식과 엠비언트 라이팅 컨트롤 소프트웨어 모듈간의 데이터

RCE/RBF

The space is mapped partially with certain zones being unclassified (i.e. black color). The zones with multiple colors are zones of uncertainty.



KNN

The entire space is mapped and with a single possible category (i.e. color code) per position. The notion of Unknown and Uncertainty is inexistent.



그림 7. RBF와 KNN 알고리즘 특성 비교
Fig. 7. Characteristic Comparison between RBF and KNN Algorithm

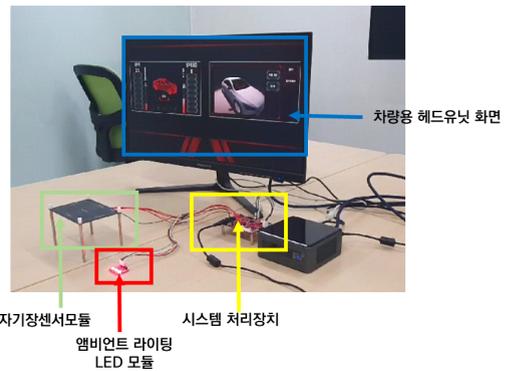


그림 9. 시스템 구현
Fig. 9. Implementation of Proposed System

2bytes	6bytes	1byte	1byte	20bytes	20bytes	2bytes
Header	X, Y, Z	touch	touch	Uncalibrated signal Data	Signal deviation Data	Tail
0x00	0x00	0x00	0x00	0x00	0x00	0x00
0x01	0x01	0x01	0x01	0x01	0x01	0x01
0x02	0x02	0x02	0x02	0x02	0x02	0x02
0x03	0x03	0x03	0x03	0x03	0x03	0x03
0x04	0x04	0x04	0x04	0x04	0x04	0x04
0x05	0x05	0x05	0x05	0x05	0x05	0x05
0x06	0x06	0x06	0x06	0x06	0x06	0x06
0x07	0x07	0x07	0x07	0x07	0x07	0x07
0x08	0x08	0x08	0x08	0x08	0x08	0x08
0x09	0x09	0x09	0x09	0x09	0x09	0x09
0x0A	0x0A	0x0A	0x0A	0x0A	0x0A	0x0A
0x0B	0x0B	0x0B	0x0B	0x0B	0x0B	0x0B
0x0C	0x0C	0x0C	0x0C	0x0C	0x0C	0x0C
0x0D	0x0D	0x0D	0x0D	0x0D	0x0D	0x0D
0x0E	0x0E	0x0E	0x0E	0x0E	0x0E	0x0E
0x0F	0x0F	0x0F	0x0F	0x0F	0x0F	0x0F
0x10	0x10	0x10	0x10	0x10	0x10	0x10
0x11	0x11	0x11	0x11	0x11	0x11	0x11
0x12	0x12	0x12	0x12	0x12	0x12	0x12
0x13	0x13	0x13	0x13	0x13	0x13	0x13
0x14	0x14	0x14	0x14	0x14	0x14	0x14
0x15	0x15	0x15	0x15	0x15	0x15	0x15
0x16	0x16	0x16	0x16	0x16	0x16	0x16
0x17	0x17	0x17	0x17	0x17	0x17	0x17
0x18	0x18	0x18	0x18	0x18	0x18	0x18
0x19	0x19	0x19	0x19	0x19	0x19	0x19
0x1A	0x1A	0x1A	0x1A	0x1A	0x1A	0x1A
0x1B	0x1B	0x1B	0x1B	0x1B	0x1B	0x1B
0x1C	0x1C	0x1C	0x1C	0x1C	0x1C	0x1C
0x1D	0x1D	0x1D	0x1D	0x1D	0x1D	0x1D
0x1E	0x1E	0x1E	0x1E	0x1E	0x1E	0x1E
0x1F	0x1F	0x1F	0x1F	0x1F	0x1F	0x1F

그림 10. 데이터 처리 프로토콜
Fig. 10. Protocol of Data Processing

처리 프로토콜을 구현하였다. 이때, 맵핑된 X축, Y축, Z축 값과 이에 맞는 제스처 동작(touch)에 대한 결과를 교환한다. 트레이닝 데이터 셋과 테스트 셋은 전체 2,000개의 데이터를 사용하였다.

표 3에서는 시스템 구성에서 인식된 제스처에 따라 차량용 헤드유닛 화면이 변경되는 상태를 보여준다. 특히, 차량용 헤드유닛 화면 내 색상이 제스처 동작에 따라 LED 모듈과 연동되어 앰비언트 라이팅 컨트롤 기능이 구현된 부분을 보여주며 응용 프로그램에 제스처 동작을 반영하여 기능이 동작하는 것을 보여준다. 가능한 제스처 동작은 좌/우/상/하 4가지 동작이며, 각각 이동에 대해 응용 프로그램이 응답하는 기능을 구현하였다. 특히, 좌/우에 해당하는 제스처 변화에 대해서는 앰비언트 라이팅 컨트롤과 연동하여 색상이 변경되도록 구현하였으며, 상/하에 해당하는 제스처 변화에 대해서는 음량 조절에 대한 기능을 구현하였다. 2절 테스트 결과에서는 기계학습 알고리즘에 따른 성능을 분석하고 시스템에 적용한 상태에서 제스처에 따른 동작 정확도를 확인하였다.

표 3. 동작에 따른 인식정확도 테스트 환경
Table 3. Test Environment for Recognition Validation with User's Hand Motion

동작	차량용 헤드유닛 화면 동작 적용 전	차량용 헤드유닛 화면 동작 적용 후
좌 ↓ 우		
우 ↓ 좌		
상 ↓ 하		
하 ↓ 상		

3.2 테스트 결과

3장 1절에서 수행한 시스템 구현 테스트를 통해 각 모델에 대한 제스처 동작 정확도를 확인하였다. 특히, 설계된 학습모델에 대한 ROC(Receiver Operating Characteristic)커브를 통해 해당 모델의 적합성을 확인하였다. 표 4에서는 해당 동작에 따른 정확도를 학습모델별로 표기하였다. 표 4에서 볼 수 있듯이, 제스처 동작은 시스템 구현에서 제안하는 4가지 동작에 대해서 각 500개의 데이터셋 (전체 2,000개) 결과를 확인하였고, 처리 시간에 대한 요소를 추가하였다. 소요시간을 추가한 이유는 시스템에 요구하는 시스템 코어 사양의 한계로 인해, 간단한 알고리즘이 요구되는 상황임을 확인하기 위해서 표기하였다. 결과에서 확인할 수 있듯이, RBF 모델을 사용하여 제스처 동작에 따른 색상변화 및 응용 프로그램 구동 정확도는 평균 66.8% 이고, 시스템 처리 장치에서 인식되는 걸리는 처리시간은 평균 83.2ms 소요되었다. 동일한 조건에서 KNN 모델을 이용하여 측정된 정확도는 평균 77.7% 이고, 소요시간은 평균 91.5ms이 걸렸다. SVM 모델은 모델성능이 높다는 것을 미리 예측할 수 있듯이, 평균 86.4% 정확도를 보이고, 소요시간은 평균 128.2ms이 걸리는 것을 확인하였다. 실제 시스템 적용측면에서는 100ms이 넘어가는 경우, 사용자의 동작에 대한 시스템 반응을 확인함에 있어, 사용자가 불

표 4. 학습모델에 따른 인식정확도 결과
Table 4. Test Result for Recognition Accuracy of Applied Learning Model

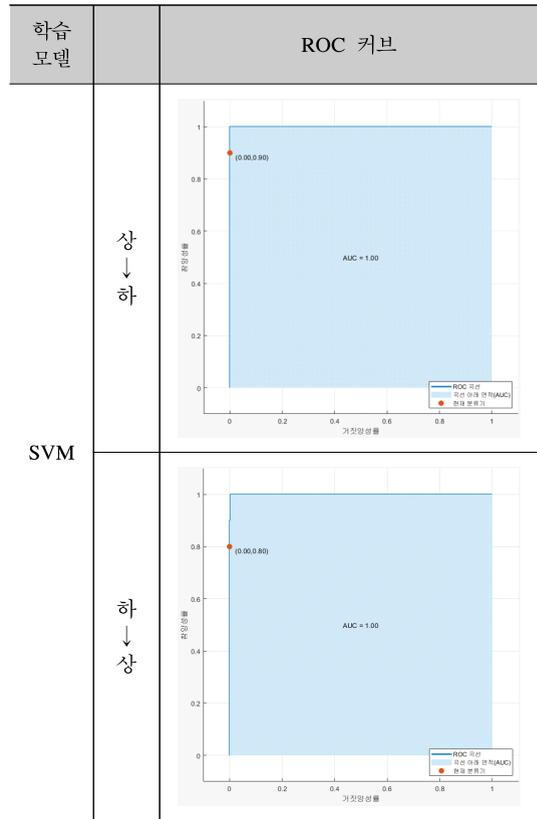
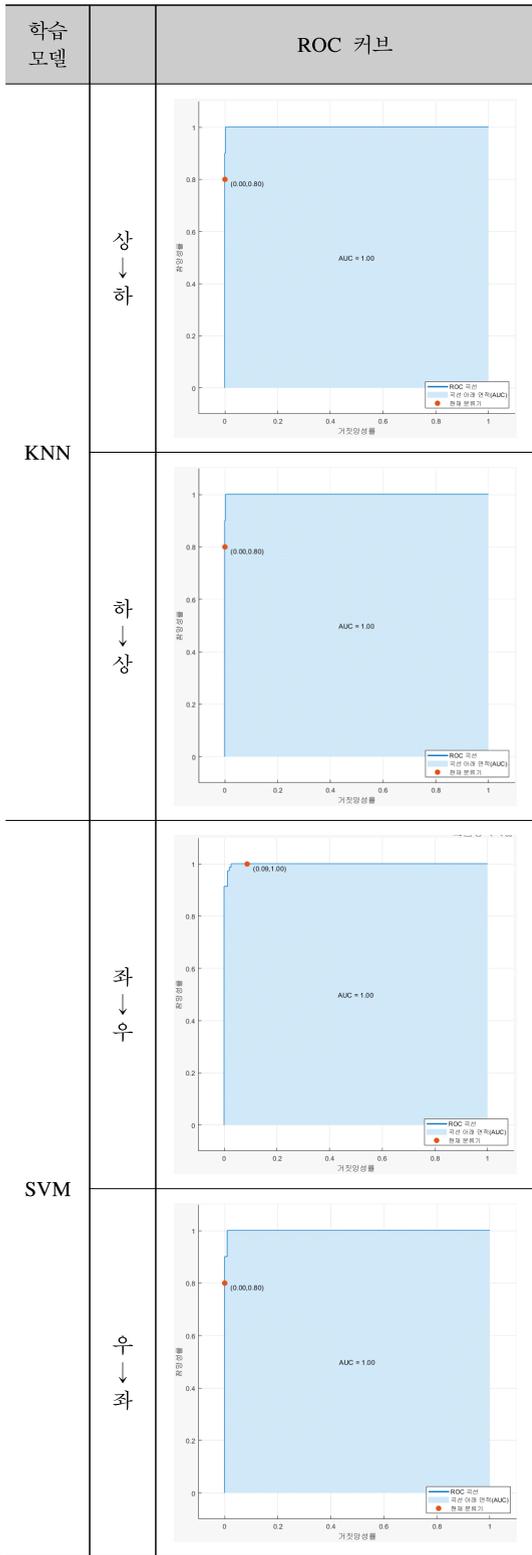
학습 모델	제스처 동작	정확도(%)	처리 시간(ms)
RBF	좌 → 우	64.2	84
	우 → 좌	67.3	82
	상 → 하	66.8	81
	하 → 상	69.2	86
	평균	66.8	83.2
KNN	좌 → 우	76.7	91
	우 → 좌	77.7	89
	상 → 하	78.2	92
	하 → 상	78.5	94
	평균	77.7	91.5
SVM	좌 → 우	82.4	125
	우 → 좌	85.6	127
	상 → 하	88.6	132
	하 → 상	89.1	133
	평균	86.4	128.2

편함을 느낄 수 있기 때문에 시스템에 사양에 적합하며 상용제품으로 활용할 수 있는 정확도와 인식속도를 가진 KNN기반 앰비언트 라이팅 시스템을 개발하였다. 본 논문에서는 구현되는 어플리케이션(조명 컨트롤, 음량 조절 등) 다양한 응용에서 높은 인식률을 가질 수 있도록 네 가지 제스처 동작 중 각각 2쌍의 동작에 대해(좌 → 우, 우 → 좌), (상 → 하, 하 → 상) 단일 동작을 수행하도록 구현하여 개별적으로 정확도를 일부 향상 시켰다.

특히, 표 5에서는 각 제스처 분류 모델에 대한 ROC 커브와 AUC(Area Under Curve)에 결과를 표시하였으며, 모든 동작에서 확인할 수 있듯이, 좌→우에 대한 정확도가 저하되는데 실제 분류 모델에서도 학습 모델별로 동일한 결과를 확인할 수 있다. 이는 향후 자기장센서 모듈 자체의 설계 비대칭성에 대해 검토가 필요함을 확인하게 되었다.

표 5. 학습모델에 따른 ROC 결과
Table 5. Test Result for ROC of Applied Learning Model

학습 모델		ROC 커브
RBF	상 ↓ 하	
	하 ↓ 상	
	좌 ↓ 우	
	우 ↓ 좌	
KNN	좌 ↓ 우	
	우 ↓ 좌	



IV. 결론 및 향후 연구 방향

본 논문에서는 제안하는 시스템은 최소한의 사양으로 기계학습 알고리즘을 적용하여, 사용자의 제스처에 반응하여 차량 내 조명을 조절하는 시스템이다. 특히, 자기장 센서 모듈을 사용하여 사용자가 운전 집중하면서 직접적인 접촉없이, 실시간, 직관적으로 변경할 수 있는 HCI(Human Communication Interface) 기능을 제공하는 시스템을 구현하였다. 자기장 센서 모듈은 자기장 변화의 특성상 움직임에 따라 정확한 값을 기준으로 동작을 분류할 수 없으므로 본 논문에서 제안한 기계학습을 통해, 사용자의 동작을 인식하도록 개발하고, 시스템 사양과 응답속도에 맞는 알고리즘을 선정하여 성능을 평가하였다. 추후, 기존 알고리즘 뿐 만아니라, 기존 알고리즘을 변형한 다양한 기법을 통해서 정확도를 향상시키는 연구개발을 진행할 예정이다. 또한 본 연구를 통해서 향후 언택트 기술에 부합하는 다양한 응용 제품에도 적용할 예정이다.

References

[1] S. Choi, S. Lee, and J. Cho, "A study on future autonomous vehicle interior lighting scenario structure based on contextual user research," in *Proc. HCI KOREA 2018*, pp. 945-948, 2018.

[2] P. Ripka and M. M. Arafat, "Magnetic sensors: Principle and applications," *Ref. Module in Mater. Sci. and Mater. Eng.*, pp. 1-11, 2019.

[3] S. Lee, J. Lee, and H. Cho, "A hand gesture recognition method using inertial sensor for rapid operation on embedded device," *TIIS*, vol. 14, no. 2, pp. 757-770, 2020.

[4] M. Yuan, H. Yao, C. Qin, and Y. Tian, "A dynamic hand gesture recognition system incorporating orientation-based linear extrapolation predictor and velocity-assisted longest common subsequence algorithm," *TIIS*, vol. 11, no. 9, pp. 4491-4509, 2017.

[5] W. Xu and E.-J. Lee, "A novel method for hand posture recognition based on depth information descriptor," *TIIS*, vol. 9, no. 2, pp. 763-774, 2015.

[6] B. Gao and S. Gao, "Maximum likelihood principle and moving horizon estimation based adaptive unscented Kalman filter," *Aerospace Sci. and Technol.*, vol. 73, pp. 7-196, 2018.

[7] J. Manning, "Machine-learning space application on smallsat platform with TensorFlow," *Small Satellite Conf.*, pp. 1-8, 2018.

[8] R. Khandelwal, "A basic introduction to TensorFlow lite," Retrieved Jun. 15, 2020, from <https://towardsdatascience.com>.

이 상 엽 (Sang-yub Lee)



2003년 : 연세대학교 공학사
 2005년 : 연세대학교 공학석사
 2019 : 고려대학교 컴퓨터정보학 박사
 2005년~2009년 : 삼성전기 중앙 연구소 선임연구원
 2009년~현재 : 전자부품연구원 지능융합SW연구센터 책임연구원
 <관심분야> 차량용 임베디드 시스템, 임베디드 인공지능 시스템

[ORCID:0000-0002-3011-8750]

이 재 규 (Jae-kyu Lee)



2010년 : 전북대학교 공학사
 2012년 : 전북대학교 공학석사
 2015년~현재 : 고려대학교 컴퓨터정보학 박사과정
 2012년~현재 : 전자부품연구원 지능융합SW연구센터 선임연구원

<관심분야> 차량용 임베디드 시스템, 임베디드 인공지능 시스템, 시각지능 시스템

[ORCID:0000-0002-0574-5381]