

# 환자를 위한 근전도 기반 불완전 손동작 인식 디바이스의 설계 및 구현

임재봉\*, 서주희\*, 백윤주<sup>o</sup>

## Design and Implementation of an EMG-Based Wrist Band Device with Imperfect Hand Gesture Recognition for Patients

Jaebong Lim\*, Juhee Seo\*, Yunju Baek<sup>o</sup>

### 요약

근전도 센서 기반 손동작 인식 기술은 자연스러운 손동작을 세부적으로 인식할 수 있어 인터페이스 기술로서 활발히 연구되고 있다. 그러나 기존에는 환자의 손동작과 병원 환경을 고려한 환자를 위한 근전도 기반 손동작 인식 디바이스에 대한 연구가 미비하다. 환자는 근력이 약하고 관절 가동 범위가 제한적이므로 지정한 손동작을 완전히 수행하기 어려운 문제가 있다. 그리고 환자의 편의성과 위생을 고려한 손동작 인식 디바이스의 설계 및 구현이 필요하다. 따라서 본 논문에서는 불완전 손동작 인식 기법을 제안하고 환자를 위한 손동작 인식 디바이스를 설계 및 구현하였다. 불완전 손동작을 포함한 근전도 데이터셋을 수집하고 경량 심층신경망 모델을 학습시킴으로써 환자에 특화된 손동작 인식이 가능하도록 하였다. 그리고 제안하는 손동작 인식 디바이스는 온디바이스 손동작 인식이 가능하고 저전력 MCU와 비접촉식 근전도 센서를 기반으로 구현하여 병원 인터페이스로서 활용성이 높다. 본 논문에서는 불완전 손동작 인식에 대해 모델 구조, 경량화, 센서 구성, 사용자 및 세션에 따른 성능평가를 진행하였다. 성능평가 결과 87.68%의 정확도로 불완전 손동작 인식이 가능함을 확인하였고 경량화 후에는 84.98%의 정확도를 보임을 확인하였다.

**Key Words** : Wrist-band device for patients, EMG-based gesture recognition, Imperfect hand gesture

### ABSTRACT

EMG-based hand gesture recognition, which can recognize natural hand gestures in detail, is actively studied as an interface technology for patients. Existing research on gesture recognition does not take into account the characteristics of patients and hospital environments. Because patients have weak muscles and constrained range of motion, it is difficult to fully perform the specified gestures and easy to perform imperfect hand gestures. In addition, a device considering the convenience and hygiene for patients is needed. In this paper, we design and implement a wrist band device with imperfect hand gesture recognition for patients. The proposed method allows hand gesture recognition for patients by collecting an EMG dataset including imperfect hand gestures and training a lightweight deep neural network model. The implemented devices using low-power MCU and dry-type EMG sensors can recognize hand gestures in real-time. In addition, we study the performance of imperfect hand gesture recognition according to model architecture, quantization, sensor configuration, users, and sessions. As a result, the proposed method shows an accuracy of 87.68% and an accuracy of 84.98% after quantization.

\* 이 연구는 2021년도 산업통상자원부 및 산업기술평가관리원(KEIT) 연구비 지원에 의한 연구임(20000515)

• First Author : Pusan National University, School of Computer Science and Engineering, jaebonglim@pusan.ac.kr, 학생회원

◦ Corresponding Author : Pusan National University, School of Computer Science and Engineering, yunju@pusan.ac.kr, 중신회원

\* Pusan National University, School of Computer Science and Engineering, juhee.seo@eslab.re.kr, 학생회원

논문번호 : 202107-160-C-RN, Received July 10, 2021; Revised November 2, 2021; Accepted November 11, 2021

## I. 서 론

의료 서비스의 개선을 위하여 정보통신 기술 (ICT, Information & Communication Technology)을 병원에 적용한 스마트 병원이 활발히 도입되고 있다. 스마트 병원에서는 입원 환자를 위한 진료 안내 시스템과 감염병동을 위한 원격 진료 시스템 등 병원용 ICT 시스템이 활용되고 있다. 이러한 진료 안내와 원격 진료를 위해 환자는 터치 인터페이스를 통해 상호작용할 수 있다<sup>[1]</sup>. 그리고 스마트 병원에는 간호 보조 로봇 및 재활 보조 로봇 등 병원용 로봇이 새롭게 도입되고 있다. 환자는 음성 인터페이스를 통해 로봇과 상호작용하며 간호와 재활 등 의료 서비스를 제공 받을 수 있다<sup>[2]</sup>.

스마트 병원에서는 환자가 병원용 ICT 시스템이나 로봇과 상호작용하기 위한 편리한 인터페이스가 필요하다. 그러나 터치 인터페이스는 접촉식 인터페이스로서 거동이 자유롭지 못한 환자가 활용하는 데 어려움이 있고 위생에도 취약하다<sup>[3]</sup>. 그리고 정보통신 기술에 익숙하지 않은 고령 환자는 터치 인터페이스를 활용하기 어렵다<sup>[4]</sup>. 음성 인터페이스는 거동이 불편한 환자와 고령 환자가 활용하기 용이한 장점이 있으나 주변 소음에 취약하고 다인 병실에서 활용하기 어려운 한계가 있다.

사람에게 직관적이고 자연스러운 의사소통 방식인 손동작 (Hand Gesture) 인터페이스는 터치 인터페이스와 음성 인터페이스의 대안 기술로서 주목받고 있다<sup>[5]</sup>. 환자는 지목, ok, 숫자 등의 손동작을 통해 ICT 시스템이나 로봇과 상호작용 할 수 있다. 손동작 인터페이스는 직관적이고 자연스러운 손동작을 통해 고령 환자가 활용하기 좋고 비접촉식 인터페이스로서 거동이 불편한 환자도 활용하기 용이하다<sup>[6]</sup>. 그리고 소음에 무관하게 사용할 수 있고 다인 병실에서 활용이 적합하다<sup>[7]</sup>.

이러한 손동작 인터페이스를 위해 팔이나 손목에 착용하는 웨어러블 형태의 손동작 인식 디바이스가 활발히 연구되고 있다. 특히 근육의 수축과 이완에 따라 변하는 근육의 전기 신호를 수집할 수 있는 근전도 (EMG, ElectroMyoGraphy) 센서를 활용한 손동작 인식 디바이스는 손가락의 움직임을 세부적으로 인식할 수 있다. 그러므로 직관적이고 자연스러운 손동작을 인식할 수 있어 스마트 병원에서 활용성이 높다<sup>[8]</sup>.

그러나 기존의 근전도 기반 손동작 인식 디바이스 연구에서는 병원 환경에 대한 고려가 미비한 한계가 있다. 기존 연구에서는 저전력 디바이스의 제약적인

성능으로 인하여 온디바이스 (On-Device) 손동작 인식이 어려워 고성능 서버와 통신이 필요한 한계가 있다. 환자에게 병원용 ICT 시스템이나 로봇과의 편리한 인터페이스를 제공하기 위해서는 저전력 온디바이스 손동작 인식이 필요하다<sup>[9]</sup>. 그리고 기존 연구에서는 접촉식 (Wet-type) 근전도 센서를 활용하여 위생 문제가 있으며 팔 착용형이거나 다수의 근전도 센서를 활용하는 등 편의성이 떨어지는 단점이 있다. 환자를 위한 손동작 인식 디바이스를 위해서는 병원 환경을 고려하여 디바이스의 위생과 편의성이 개선되어야 한다<sup>[10]</sup>.

환자는 손동작을 완전히 수행하기 어려워 근전도 기반 손동작 인식의 정확도가 감소하는 문제가 있다<sup>[11]</sup>. 환자는 근력이 약하고 관절 가동 범위가 제약적이므로 인터페이스를 위해 지정한 손동작을 완전히 수행하기 어렵다<sup>[12-16]</sup>. 예를 들어 환자는 주먹을 강하게 쥐거나 손을 활짝 펴는 데 어려움이 크다. 이렇게 일반인과 환자는 손동작에 따른 근전도 신호가 서로 상이하다. 따라서 스마트 병원을 위해서는 환자가 완전히 수행하지 못한 손동작인 불완전 손동작 (Imperfect Hand Gesture) 인식에 대한 연구가 필요하다.

본 논문에서는 병원 환경과 환자의 손동작을 고려하여 환자를 위한 근전도 기반 불완전 손동작 인식 디바이스를 설계 및 구현하였다. 스마트 병원에서 손동작 인터페이스를 위하여 3채널 비접촉식 (Dry-type) 근전도 센서 기반의 손목 밴드형 저전력 손동작 인식 디바이스를 제안하였고 환자의 손동작을 고려하여 불완전 손동작 인식 기법 제안하였다. 제안하는 손동작 인식 디바이스는 전력소모가 낮고 고성능 서버와 통신 없이 손동작 인식이 가능하며 위생과 편의성이 개선하였다. 제안하는 불완전 손동작 인식 기법은 불완전 손동작을 포함한 근전도 데이터셋을 수집하여 심층신경망 모델을 학습시킴으로써 불완전 손동작을 인식할 수 있도록 하였다. 이를 통해 스마트 병원에서 환자가 편리하게 손동작 인터페이스를 활용할 수 있을 것으로 기대된다.

## II. 관련 연구

### 2.1 환자를 위한 손동작 인식 디바이스

웨어러블 형태의 손동작 인식 디바이스는 전력소모를 줄이고 동작시간을 개선하기 위해 저전력 디바이스로 설계되어야 한다. 저전력 디바이스에서 손동작 인식을 위해서는 제약적인 컴퓨팅 성능의 문제로 고성능 서버가 필요하거나<sup>[17-21]</sup> 손동작 인식을 위해 고

표 1. 근전도 기반 손동작 인식 디바이스의 비교  
Table 1. Comparison of EMG-based wrist band devices

	On-Device	Wearing Position	EMG Sensors	Algorithm	Subjects	Hand Gestures
Allard <i>et al.</i> [17]	X	Arm	8 Dry-type	CNN	17	7
Simao <i>et al.</i> [18]	X	Arm	8 Dry-type	FCNN	10	52
Raurale <i>et al.</i> [19]	X	Arm	8 Dry-type	FCNN	10	9
Jiang <i>et al.</i> [20]	X	Wrist	4 Dry-type	LDA	10	16
Huang <i>et al.</i> [21]	X	Wrist	4 Dry-type	LDA	4	12
Zanghieri <i>et al.</i> [22]	O	Arm	8 Wet-type	CNN	3	9
Liu <i>et al.</i> [23]	O	Wrist	4 Wet-type	FCNN	4	10
Tam <i>et al.</i> [24]	O	Wrist	32 Dry-type	CNN	1	8
<b>Proposed device</b>	<b>O</b>	<b>Wrist</b>	<b>3 Dry-type</b>	<b>DS-CNN</b>	<b>5</b>	<b>2</b>

성능으로 설계된 프로세서가 필요한 한계가 있다<sup>22,24</sup>. 환자에게 편리한 인터페이스를 제공하기 위해서는 고성능 서버와 통신이 필요 없는 저전력 손동작 인식 디바이스가 필요하다. 그리고 웨어러블 디바이스에서 널리 활용되는 저전력 MCU (Micro Controller Unit)를 위한 온디바이스 손동작 인식 연구가 필요하다.

기존의 근전도 기반 손동작 인식 디바이스 연구에서는 병원 환경에 대한 고려가 미비한 한계가 있다. 근전도 기반 손동작 인식 디바이스에 대한 비교는 표 1과 같다. 접촉식 근전도 센서를 활용한 손동작 인식 디바이스는 위생에 취약한 문제가 있다<sup>22,23</sup>. 그리고 팔 착용 형태이거나 근전도 센서의 수가 많을 경우 편의성이 떨어지는 문제가 있다. 그러므로 근전도 센서의 수를 줄여 편의성을 개선할 필요성이 있다. 이를 위해 본 논문에서는 3채널 비접촉식 근전도 센서 기반의 손목 밴드형 저전력 손동작 인식 디바이스를 제안하였다.

### 2.2 근전도 기반 손동작 인식

손가락의 움직임은 세부적으로 인식할 수 있는 근전도 기반 손동작 인식은 직관적이고 자연스러운 손동작을 인식하기 용이하여 활발히 연구되고 있다. 근전도 기반 손동작 인식을 활용한 손동작 인터페이스는 비접촉식이고 직관성이 높아 병원에서 환자가 ICT 시스템 및 로봇과의 상호작용을 위해 널리 활용되고 있다<sup>8-10</sup>. 그리고 근전도 센서 종류와 개수, 디바이스의 센서 위치 및 착용 상태 변화, 사용자 변경 등을 고

려한 다양한 연구가 진행되고 있어 스마트 병원에서 실용적으로 활용할 수 있다<sup>26,27</sup>.

표 1과 같이 손동작 인식을 위해서는 LDA (Linear Discriminant Analysis)<sup>[18,19]</sup> 등의 알고리즘보다 FCNN (Fully Connected Neural Network)<sup>[18,19,23]</sup>, CNN (Convolutional Neural Network)<sup>[18,19,23]</sup>와 같은 심층신경망 (Deep Neural Network) 알고리즘이 널리 활용되고 있다. 심층신경망 기반 손동작 인식 모델은 특정 시간의 다채널 근전도 데이터로 구성된 세그먼트 입력에 대해 다수의 손동작 중 하나로 분류한다. 이러한 손동작 인식 모델은 심층신경망 알고리즘의 발전으로 높은 정확도로 손동작을 인식할 수 있다. 그러나 기존에는 제약적인 컴퓨팅 성능에서 동작 가능한 경량 심층신경망<sup>[28,29]</sup>을 활용한 손동작 인식 모델의 연구가 미비하다.

### 2.3 불완전 손동작 인식

근전도 기반 손동작 인식은 근전도 분석을 통해 인터페이스를 위해 지정한 손동작의 수행 여부를 인식한다. 그러나 근전도는 동일한 동작에 대해 환자의 근력과 관절 가동 범위에 따라 상이한 문제가 있다<sup>12-16</sup>. 근력은 근전도 신호의 크기와 연관성이 크고 관절 가동에도 영향을 주어 근전도 패턴 변화의 원인이 된다<sup>12-14</sup>. 관절 가동 범위는 지정한 동작을 수행하는데 영향을 주어 근전도를 상이하게 만든다<sup>15,16</sup>. 환자는 다양한 질병에 의해 일반인과 근력과 관절 가동 범위가 다르다. 특히 환자는 관절 가동 범위의 제약으로 완전히 수행하지 못한 손동작인 불완전 손동작을 빈번히 야기한다.

그러나 환자를 위한 불완전 손동작 인식을 포함한 손동작 인터페이스에 관한 연구가 미비하다. 기존 연구에서는 관절 가동 범위가 제약적인 화상 환자의 손동작을 인식하고자 하였다<sup>11</sup>. 화상 환자의 손동작 인식 정확도 하락 문제를 개선하기 위하여 시계열 분석을 도입하였다. 그러나 기존 연구에서는 완전한 손동작과 불완전 손동작을 동시에 고려하지 않았고 불완전 손동작 인식 기법에 대한 고찰이 미비한 한계가 있다. 본 논문에서는 선행연구<sup>30</sup>를 발전시켜 불완전 손동작 인식 기법을 제안하였다.

## III. 제안하는 손동작 인식 디바이스

본 논문에서는 환자를 위한 근전도 기반 불완전 손동작 인식 디바이스를 제안하였다. 그림 1과 같이 병원 환경을 고려하여 3채널 비접촉식 근전도 센서 기



그림 1. 환자를 위한 손동작 인식 디바이스 구현 (a) 구현한 손동작 인식 디바이스 (b) 구현한 디바이스의 실시간 손동작 인식 (c) 구현한 디바이스의 스마트 병원에서의 활용  
 Fig. 1. Implementation of a wrist band device with hand gesture recognition (a) Implemented device (b) Real-time hand gesture recognition using the device (c) Using the device in smart hospital

반의 손목 밴드형 저전력 손동작 인식 디바이스를 설계 및 구현하였다. 저전력 MCU를 활용하여 디바이스를 구현하고 온디바이스 인식을 위해 손동작 인식 모델을 경량화시키고 이를 디바이스에 탑재시켰다. 적은 수의 비접촉식 근전도 센서를 활용하여 디바이스를 구현하여 위생과 편의성이 개선하였다. 환자는 이렇게 구현한 디바이스를 착용하여 스마트 병원의 ICT 시스템 및 로봇과 상호작용하는데 활용할 수 있다.

환자를 위한 손동작 인터페이스를 위하여 불완전 손동작 인식 기법을 제안하였다. 제안하는 기법은 환자가 근력과 관절 범위의 제약으로 완전히 수행하지 못한 손동작을 고려하였다. 그림 2와 같이 기존 연구에서 고려하지 않았던 불완전 손동작을 포함하여 세분화된 손동작 데이터를 수집하였다. 이를 활용하여 불완전 손동작이 완전한 손동작과 함께 인식되도록 손동작 인식 모델을 학습시켰다. 중립 손동작 또한 다른 손동작과 구별되도록 학습시켰다.

본 논문에서는 다양한 손동작의 기본이 되는 주먹(Fist)과 손펴기(Spread)를 인식한다. 예를 들어 주먹을 쥐고 손을 드는 동작은 멈춤 수신호로 널리 쓰이고 손을 펴고 손을 아래로 흔드는 동작은 가까이 오라

는 수신호로 널리 쓰인다. 그림 2와 같이 주먹과 손펴기를 완전한 주먹, 불완전 주먹, 중립 주먹, 중립 손펴기, 불완전 손펴기, 완전한 손펴기로 세분화하여 데이터를 수집하였다. 그리고 나서 완전한 손동작 데이터와 불완전 손동작 데이터를 다시 통합하여 학습함으로써 주먹, 손펴기, 중립 3가지의 손동작을 인식한다.

### 3.1 손동작 인식 디바이스의 구현

손동작 인식 모델을 내장한 환자를 위한 손동작 인식 디바이스는 저전력 MCU와 각종 센서를 활용하여 구현하였다. MCU는 BLE (Bluetooth Low Energy) 통신을 지원하는 Nordic 사의 nRF52840을 사용하였다. 근전도 센서는 비접촉식 상용 센서인 SEN0240을 활용하였다. 또한 가속도 및 자이로 센서를 통합하여 제공하는 MPU9250을 탑재시켰다. MCU는 센서들을 제어하여 근전도, 가속도, 자이로 데이터를 취득한다. LCD는 FT6236U 및 ST7789V 기반 모듈을 사용하였다.

구현한 손동작 인식 디바이스는 그림 1(a)와 같다. 구현한 디바이스는 세로 5cm 가로 3.3cm의 크기이며 전력소모는 0.2W이다. 전력소모는 오실로스코프와 진류 스코프를 활용하여 측정하였다. 구현한 디바이스는 그림 1(b)와 같이 0.4초의 지연시간으로 실시간으로 손동작 인식이 가능하다. 지연시간 테스트는 Raspberry Pi 3을 활용하여 디바이스와의 BLE 통신 기능을 구현하여 진행하였다.

그림 1(c)와 같이 구현한 손동작 인식 디바이스를 활용하여 스마트 병원의 간호로봇과 연동하였다. 주먹과 손펴기 손동작을 통해 간호로봇과의 거리를 자연스러운 제스처로 조절할 수 있도록 연동하였다. 이처럼 디바이스의 통신 기능을 활용하여 다양한 병원용 ICT 시스템 및 로봇과 상호작용 가능하다.

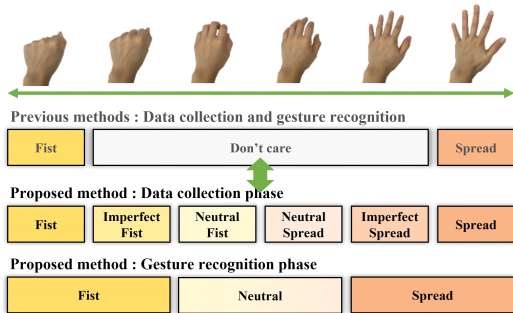


그림 2. 불완전 손동작 인식  
 Fig. 2. Imperfect hand gesture recognition

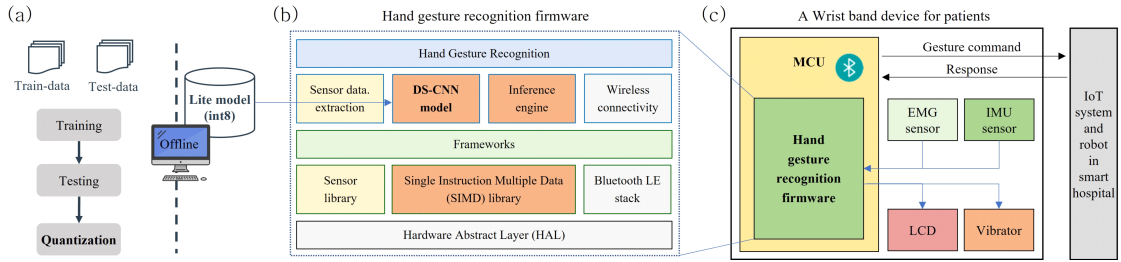


그림 3. 온디바이스 손동작 인식 (a) 손동작 인식 모델의 경량화 과정 (b) 실시간 손동작 인식을 위한 디바이스의 펌웨어 스택 (c) 손동작 인식 디바이스의 구성  
 Fig. 3. Design of a on-device hand gesture recognition (a) Quantization for a deep neural network (b) Firmware of a device for real-time hand gesture recognition (c) The designed wrist band device with hand gesture recognition

### 3.2 온디바이스 손동작 인식의 구현

본 논문에서는 온디바이스 손동작 인식을 위하여 심층신경망 기반 손동작 인식 모델을 학습시키고 이를 경량화시켰다. 그리고 경량화한 손동작 인식 모델을 포함하는 손동작 인식 펌웨어를 설계 및 구현하고 이를 제안하는 디바이스에 탑재하였다.

온디바이스 손동작 인식을 위하여 그림 3(a)와 같이 손동작 인식 모델을 학습 후 경량화를 진행하였다. 저전력 MCU의 제약적인 성능을 고려하여 수 kB 크기 이내의 손동작 인식 모델을 선정하였다. 그리고 정수화 (Quantization)를 통해서 심층신경망의 32bit 실수수를 8bit 정수로 경량화하였다.

그림 3(b)와 같이 온디바이스 손동작 인식을 위하여 제안하는 디바이스를 위한 펌웨어를 설계 및 구현하였다. 펌웨어는 Single Instruction Multiple Data (SIMD) 라이브러리를 기반으로 심층신경망을 가속하도록 구성하였다. 이러한 라이브러리를 기반으로 저전력 MCU를 위한 가속화 엔진을 탑재하고 경량화한 손동작 인식 모델을 탑재하였다.

그림 3(c)와 같이 이렇게 구성한 펌웨어 스택을 제안하는 디바이스에 탑재하여 실시간으로 손동작 인식이 가능하도록 하였다. 저전력 MCU 기반으로 구현된 손동작 인식 디바이스는 센서 데이터 수집부터 손동작 인식까지 온디바이스로 수행한다. 그리고 사용자에게 알림을 주기 위한 통신 및 출력 기능을 포함하여 IoT 시스템 및 로봇과 연동이 용이하도록 구성하였다.

## IV. 제안하는 손동작 인식 기법

### 4.1 불완전 손동작 인식 모델링

본 논문에서는 불완전 손동작을 모델링하고 이를 기반으로 불완전 손동작 인식 기법을 제안하였다. 손동작은 손가락 및 손목의 복합적이고 다양한 동작이

다. 손동작은 다수의 전완 (forearm) 근육이 선택적으로 수축함에 따라 수행된다. 이 중 특정한 손동작은 사람 간 의사소통에서 중요한 의미를 가진다. 기존의 근전도 기반 손동작 인식은 식 1과 같이  $L$ 개의 근전도 센서의 단위 시간  $t$ 의 시계열 데이터  $E^t = \{e_1^t, e_2^t, \dots, e_L^t\}$ 에 대하여 지정한  $K$ 개의 손동작 집합  $H = \{h_1, h_2, \dots, h_K\}$  중 하나로 매핑하는 분류 (Classification) 모델이다.

$$f: E^t \rightarrow H \tag{1}$$

특정한 손동작  $h_k$ 는 다른 손동작  $h_k'$ 나 모든 전완 근육이 이완한 중립 상태인  $h_n$ 에서 특정 전완 근육들이 수축함으로써 수행된다. 손동작은 수축 과정에서 여러 손동작을 거친다. 즉  $h_n$ 에서  $h_k$ 까지 손동작은 연속적이고  $h_k$ 는 완전함에 따라  $h_n, h_{k1}, h_{k2}, \dots, h_{kS} = h_k$  등  $S$ 개로 세분화할 수 있다.  $h_n$ 에서  $h_k$  사이에 불완전 손동작의 기준점  $h_{ki}$ 와 완전 손동작의 기준점  $h_{kp}$ 를 지정하여 중립 손동작  $\{h_n, h_{k1}, \dots, h_{k(i-1)}\}$ , 불완전 손동작  $\{h_{ki}, \dots, h_{k(p-1)}\}$ , 완전 손동작  $\{h_{kp}, \dots, h_{k(S-1)}, h_{kS}\}$  등 3가지 클러스터로 나눌 수 있다. 기존 연구에서는 지정한 손동작을 완전히 수행하는 것을 가정하여  $h_k$ 만을 인식하고자 하였다. 본 논문에서는  $h_{ki}$ 와  $h_{kp}$  기준점을 지정하여 3가지 클러스터별 데이터를 수집하고 활용함으로써 불완전 손동작을 고려하였다.

### 4.2 불완전 손동작 인식 기법

앞서 모델링한 불완전 손동작을 활용하여 심층신경망 기반의 불완전 손동작 인식 기법을 제안하였다. 먼저 인식할 손동작은 주먹과 손펴기  $K=2$ 가지로 지정하였다. 그리고 실험자에게  $h_{ki}$ 와  $h_{kp}$  기준점을 제시



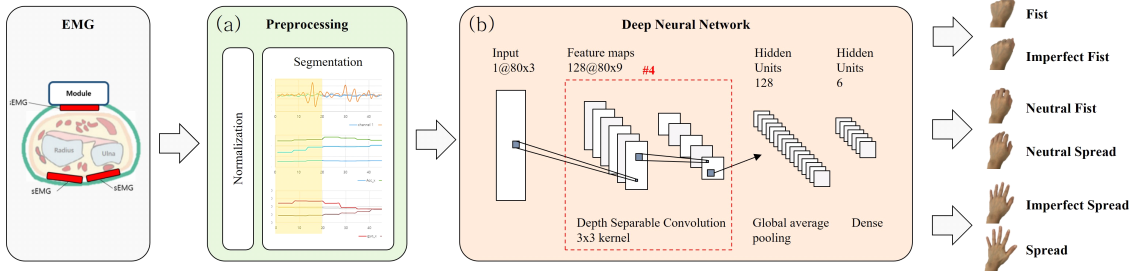


그림 4. 제안하는 불완전 손동작 인식 기법 (a) 센서 데이터의 전처리 과정 (c) 손동작 인식을 위한 심층신경망 모델  
 Fig. 4. Proposed imperfect hand gesture recognition method a) Preprocessing of sensor data (b) A deep neural network for hand gesture recognition

하여 완전한 주먹, 불완전 주먹, 중립 주먹, 중립 손펴기, 불완전 손펴기, 완전한 손펴기로 세분화하여 데이터를 수집하였다. 그리고 나서 완전한 손동작 데이터와 불완전 손동작 데이터를 다시 통합하여 학습함으로써 주먹, 손펴기, 중립 3가지의 손동작을 인식하도록 구성하였다. 즉 불완전 손동작이 완전한 손동작과 함께 인식되도록 손동작 인식 모델을 학습시키고 중립 손동작 또한 다른 손동작과 구별되도록 학습시켰다.

손동작 인식 모델의 입력을 위한 전처리는 그림 2(a)와 같이 정규화 (Normalization) 과정과 세그멘테이션 (Segmentation) 과정으로 구성하였다. 디바이스에 3개의 근전도 센서를 활용하여 채널 (Channel)의 근전도 데이터를 취득하였다. 각 채널의 데이터는 10bit 해상도의 데이터이고 샘플링레이트 (Sampling Rate)는 333Hz이다. 취득한 근전도 데이터는 -1부터 1 사이의 데이터의 범위로 정규화시켰다. 정규화를 통해 착용 상태나 사용자에 따른 변화에 따른 데이터 변화를 최소화하였다. 시계열 데이터인 근전도 데이터는 개의 데이터를 모아 세그먼트로 구성하였다.

심층신경망 기반 손동작 인식 모델은 그림 2(b)와 같다. 근전도 3채널에 대한 세그먼트를 활용하여 크기의 2D 세그먼트 입력을 구성하였다. 손동작 인식 모델은 세그먼트 입력에 대해 주먹, 중립, 손펴기로

분류하여 출력한다. 심층신경망은 5층 (Layer)의 Depth Separable Convolutional Neural Network (DS-CNN)로서 Depth Separable 콘볼루션 층 4개, 전연결 (Fully Connected) 층 1개로 구성하였다.

### 4.3 불완전 손동작 데이터셋

환자를 위한 손동작 인식 모델을 학습하기 위해 불완전 손동작을 포함한 근전도 데이터를 수집하였다. 이러한 불완전 손동작 데이터셋은 표 2와 같이 6가지 손동작을 5가지 팔동작과 조합하여 수집하였다. 손동작은 완전 주먹, 불완전 주먹, 이완 주먹, 이완 손펴기, 불완전 손펴기, 완전 손펴기를 포함하고 팔동작은 정지 동작 (Stop), 손바닥을 위로 향하고 올리고 내리는 동작 (Lift), 손바닥을 아래로 향하고 올리고 내리는 동작 (Drop), 바닥을 쓰는 동작 (Sweep), 팔을 들어 좌우로 흔드는 동작 (Wave)을 포함한다. 그리고 완전 손동작과 불완전 손동작의 기준점인  $h_{ki}$ 와  $h_{kp}$ 은 각각 80%와 100%로 실험자에게 제시하였다. 즉 완전 손동작은 최대한 손동작을 완전히 수행하도록 했고 불완전 손동작은 완전 손동작 대비 80%만 수행하도록 하였다.

데이터셋은 5명의 실험자 (남자 3명, 여자 2명)를 대상으로 착용 상태를 최대한 이상적으로 유지하여 수집하여 다른 요인을 최대한 배제하였다. 실험자는

표 2. 수집한 데이터셋에 포함된 손동작의 종류  
 Table 2. Hand gestures in the collected dataset

Stop	1	2	3	4	5	6
Lift	7	8	9	10	11	12
Drop	13	14	15	16	17	18
Sweep	19	20	21	22	23	24
Wave	25	26	27	28	29	30

표 3. 수집한 불완전 손동작 데이터셋의 구성  
 Table 3. The collected imperfect hand gesture dataset

	Gender	Session #	Amount of collected time
User 1	Female	16	77 min
User 2	Female	2	14 min
User 3	Male	2	10 min
User 4	Male	2	10 min
User 5	Male	2	10 min
<b>Total</b>	-	<b>24</b>	<b>121 min</b>

한 세션 동안 30개 동작을 순차적으로 수행하였다. 손 동작은 약 20초 동안 수행하고 약 10초 정도 휴식 후 다음 동작을 이어서 수행하였다. 즉 20초간 손동작을 동일하게 유지하여 데이터를 수집하였고 10초간 휴식 및 손동작 전환 동안은 수집을 진행하지 않았다. 세션 간에는 디바이스를 재착용하였다. 그 결과 표 3과 같이 총 121분의 데이터셋을 수집하였다.

#### 4.4 손동작 인식 모델의 학습

손동작 인식 모델은 수집한 불완전 손동작 데이터셋을 활용하여 학습하고 경량화한 후 손목 밴드 디바이스에 탑재시켰다. 학습을 위한 서버는 인텔 CPU (Intel Core i7-7700)와 엔비디아 GPU (Nvidia Geforce RTX 3090)를 내장한 컴퓨터를 활용하였다. 손동작 인식 모델은 심층신경망 프레임워크인 텐서플로 (TensorFlow)를 활용하여 구현하였다. 100 epoch 반복한 학습 과정은 배치 (Batch) 크기를 64개 데이터로 학습률 (Learning Rate)을 0.001로 설정해 Adam 최적화 함수를 적용하였다.

경량화 과정은 텐서플로를 활용하여 구현하였고 학습한 모델은 MCU를 위한 SIMD 라이브러리를 위해 변환하였다. MCU에서 심층신경망을 활용하기 위해서는 심층신경망 모델의 크기를 줄이고 MCU를 위한 심층신경망 추론 가속 기술을 활용할 필요가 있다. 이를 위하여 손동작 인식을 위한 심층신경망 모델에 대하여 고정소수점 방식의 8bit 정수화를 적용하여 모델을 경량화하고 MCU에서 CMSIS-NN<sup>[28]</sup> 라이브러리를 적용하여 추론을 가속하였다.

### V. 성능평가

본 논문에서는 모델 구조, 경량화, 센서 구성, 사용자 및 세션에 따른 성능평가를 진행하여 제안하는 디바이스가 스마트 병원에서 환자가 활용하기 적합함을 확인하였다. 모델 구조, 경량화, 센서 구성, 사용자에 따른 성능평가는 사용자 간 교차검증

(Cross validation)을 진행하였고 세션에 따른 성능평가는 세션 간 교차검증을 진행하였다. 사용자 간 교차검증은 한 명의 사용자의 데이터를 테스트에 번갈아 활용하였고 나머지 사용자의 데이터를 학습에 활용하였다. 세션 간 교차검증은 한 개 세션을 테스트 데이터로 번갈아 활용하였다.

#### 5.1 모델 구조 및 경량화에 따른 성능평가

손동작 인식을 위한 심층신경망 모델 구조에 따른




그림 5. 심층신경망 기반 손동작 인식 모델의 구조 비교  
Fig. 5. Comparison of hand gesture recognition model based on neural network

성능을 비교하였다. 그림 5와 같이 제안하는 기법에서 활용한 DS-CNN을 FCNN 및 CNN과 비교하였다. 각 모델은 각 층의 채널 수 조정을 통해 모델 크기를 변경하여 표 4와 같이 비교하였다. 각 모델은 세그먼트 크기  $W$ 는 동일하게 80으로 고정하였고, epoch는 100으로 고정하여 학습시켰다. 정확도는 사용자 별 교차검증을 진행하고 이를 평균내어 비교하였다. 실험 결과 그림 6과 같이 제안하는 기법의 DS-CNN이 다른 모델과 비교하여 모델 크기 대비 정확도가 높음을 확인하였다.

선정한 53k개 파라미터의 DS-CNN 모델에 대해 세그먼트 크기와 경량화에 따른 정확도를 평가하였다. 그림 7과 같이 세그먼트 크기  $W$ 가 80이 될 때까지 지

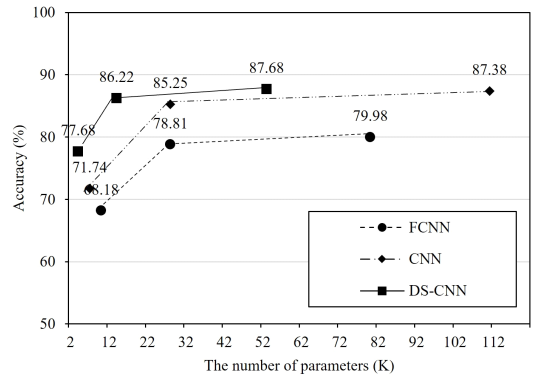


그림 6. 모델 구조에 따른 정확도 비교 결과  
Fig. 6. Comparison of accuracy according to models

표 4. 모델 구조에 따른 성능평가 결과  
Table 4. Comparison according to segment size

	FCNN			CNN			DS-CNN		
	32	64	128	16	32	64	32	64	128
Channel #	32	64	128	16	32	64	32	64	128
Parameter #	10k	28k	80k	7k	28k	111k	4k	14k	53k
Accuracy (%)	68.18	78.81	79.98	71.74	85.25	87.38	77.68	86.22	87.68

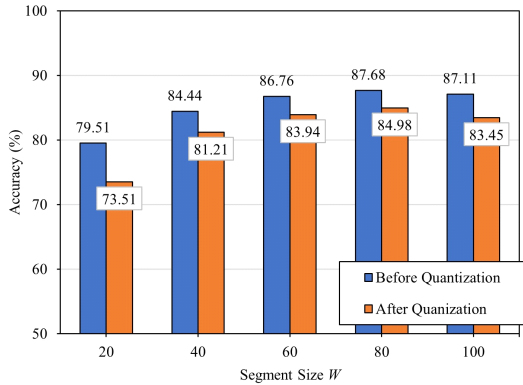


그림 7. 정수화에 따른 정확도 비교 결과  
Fig. 7. Comparison according to the quantization

속해서 정확도가 향상되었다. 그리고 심층신경망의 32bit 실수 파라미터를 8bit 정수 파라미터로 변환하는 정수화로 인한 인식 정확도의 변화를 평가하였다. 정수화 수행 전과 후의 정확도를 비교한 결과 세그먼트 크기 80에서 정수화 전 인식 정확도가 87.68%이고 정수화 후 인식 정확도가 84.98%로 가장 높음을 확인하였다.

### 5.2 센서 구성에 따른 성능평가

그림 8과 같이 제안하는 손목 밴드 디바이스를 위해 근전도 센서의 개수와 위치에 따른 정확도를 평가하였다. 근전도 센서 1개를 사용하는 경우에는 인식 정확도는 33.37%로서 세분화된 손동작을 인식하는데는 어려움이 있는 것을 확인하였다. 근전도 센서가 2개일 경우에는 손목 하단에 센서를 부착하는 것이

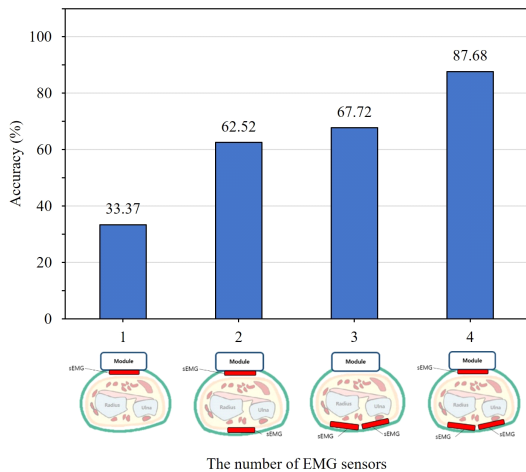


그림 8. 근전도 센서 개수에 따른 정확도 비교 결과  
Fig. 8. Comparison according to the number of EMG sensors

67.72%로 정확도가 높음을 확인하였다. 손목 상단에 1개의 근전도 센서를 부착하고 하단에 2개의 근전도 센서를 부착하여 3개의 센서를 사용한 경우에는 87.68%로 높은 정확도를 달성하였다. 이 결과를 통해 제안하는 디바이스를 3개 근전도 센서로 구성하고 센서를 배치하였다.

### 5.3 사용자와 세션에 따른 성능평가

그림 9와 같이 여러 사용자 간 교차검증과 그림 10과 같이 여러 세션 간 교차검증을 진행하였다. 53k개 파라미터의 DS-CNN 모델에 대해 5명의 사용자를 교차검증 한 결과로 평균 87.68%, 최대 91.55%, 최저 85.2%의 정확도를 보였다. 다음으로 한 명의 사용자 (User 1)의 16개 세션에 대해 교차검증을 진행하였다. 실험 결과로 평균 94.03%, 최대 98.91%, 최저 84.39%의 정확도를 보였다. 따라서 제안하는 기법은 사용자와 세션에 무관하게 잘 동작함을 확인하였다.




그림 9. 사용자 간 교차검증 결과  
Fig. 9. Result of cross validation according to users

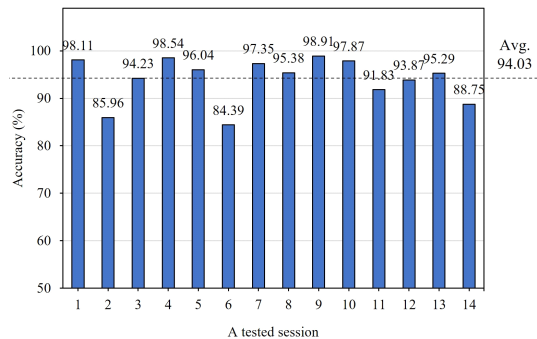


그림 10. 한 사용자의 세션 간 교차검증 결과  
Fig. 10. Result of cross validation according to sessions



## VI. 결 론

본 논문에서는 환자 손동작 인식을 위해 불완전 손동작 인식 기법을 제안하고 환자를 위한 손동작 인식 디바이스를 설계 및 구현하였다. 제안하는 불완전 손동작 인식 기법은 환자가 완전히 수행하지 못한 손동작을 근전도를 기반으로 세부적으로 인식할 수 있다. 그리고 설계 및 구현한 손동작 인식 디바이스는 환자의 편의성과 위생을 개선하였고 온디바이스 손동작 인식이 가능하다. 이러한 손동작 인식 디바이스는 스마트 병원에서 환자가 다양한 ICT 시스템 및 로봇과 상호작용하는데 활용될 수 있을 것으로 기대된다.

그리고 본 논문에서는 모델 구조, 센서 구성에 따른 불완전 손동작 인식의 성능을 고찰하였다. 그 결과 DS-CNN 모델이 좋은 성능을 보임을 확인하였고 근전도 센서는 손목 상단 1개, 하단 2개의 구성이 최적임을 확인하였다. 추후에는 많은 환자를 대상으로 제안하는 디바이스와 기법을 검증하기 위해 임상연구윤리위원회 (IRB, Institutional Review Board)를 진행하여 데이터를 수집하고 실험을 진행할 계획이다.

## References

- [1] S. Yoo, S. Jung, S. Kim, E. Kim, K. Lee, E. Chung, and H. Hwang, "A personalized mobile patient guide system for a patient-centered smart hospital: Lessons learned from a usability test and satisfaction survey in a tertiary university hospital," *Int. J. Med. Informatics*, vol. 91, pp. 20-30, Apr. 2016.
- [2] S. Cooper, A. Di Fava, C. Vivas, L. Marchionni, and F. Ferro, "ARI: The social assistive robot and companion," *IEEE Int. Conf. Robot and Human Interactive Commun.*, Sep. 2020.
- [3] J. Roth, B. Batzer, B. Hug, and A. Widmer, "Defect rates in touchless versus mechanical hand hygiene dispensers," *Infection Control & Hospital Epidemiology*, vol. 39, no. 3, pp. 359-360, Mar. 2018.
- [4] C. Leonardi, A. Albertini, F. Pianesi, and M. Zancanaro, "An exploratory study of a touch-based gestural interface for elderly," *Nordic Conf. Human Comput. Interaction*, Oct. 2010.
- [5] Y. Song, D. Demirdjian, and R. Davis, "Continuous body and hand gesture recognition for natural human computer interaction," *ACM Trans. Interactive Intell. Syst.*, vol. 2, no. 5, pp. 1-28, Mar. 2012.
- [6] K. Lamb and S. Madhe, "Hand gesture recognition based bed position control for disabled patients," *Conf. Advances in Sign. Process.*, Jun. 2016.
- [7] K. Adamer, D. Bannach, T. Klug, P. Lukowicz, M. L. Sbodio, M. Tresman, A. Zinnen, and T. Ziegert, "Developing a wearable assistant for hospital ward rounds: An experience report," *Int. Conf. Internet of Things*, Mar. 2008.
- [8] I. Moon, M. Lee, and M. Mun, "A novel EMG based human-computer interface for persons with disability," *IEEE Int. Conf. Mechatronics*, Jun. 2004.
- [9] I. Moon, M. Lee, J. Chu, and M. Mun, "Wearable EMG-based HCI for electric-powered wheelchair users with motor disabilities," *IEEE Int. Conf. Robotics and Automat.*, Apr. 2005.
- [10] T. Reza, S. M. Ferdous, N. Hasan, Rokonzaman, K. F. Ahmed, and S. Muttalib, "A low cost surface electromyogram (sEMG) signal guided automated wheel chair for the disabled," *Int. J. Scientific & Eng. Res.*, vol. 3, no. 2, Feb. 2012.
- [11] R. Zsolczay, R. Brown, F. Maire, and S. Turkay, "Vague gesture control: implications for burns patients," *Australian Conf. Human Comput. Interaction*, Dec. 2019.
- [12] J. H. van Dieen, J. Cholewicki, and A. Radebold, "Trunk muscle recruitment patterns in patients with low back pain enhance the stability of the lumbar spine," *Spine*, vol. 28, no. 8, pp. 834-841, Apr. 2003.
- [13] S. Pirouzi, J. Hides, C. Richardson, R. Darnell, and R. Toppenberg, "Low back pain patients demonstrate increased hip extensor muscle activity during standardized sub-maximal rotation efforts," *Spine*, vol. 31, no. 26, pp. 999-1005, Dec. 2006.

- [14] D. Staudenmann, K. Roeleveld, D. F. Stegeman, and J. H. van Dieen, "Methodological aspects of SEMG recordings for force estimation - a tutorial and review," *J. Electromyography and Kinesiology*, vol. 20, no. 3, pp. 375-387, Jun. 2010.
- [15] J. F. Signorile, K. M. Lew, M. Stoutenberg, A. Pluchino, J. E. Lewis, and J. Gao, "Range of motion and leg rotation affect electromyography activation levels of the superficial quadriceps muscles during leg extension," *J. Strength and Conditioning Res.*, vol. 28, no. 9, pp. 2536-2545, Sep. 2014.
- [16] R. Neblett, T. G. Mayer, R. J. Gatchel, J. Keeley, T. Proctor, and C. Anagnostis, "Quantifying the lumbar flexion relaxation phenomenon: Theory, normative data, and clinical applications," *Spine*, vol. 28, no. 13, pp. 1435-1446. Jul. 2003.
- [17] U. Cote-Allard, C. L. Fall, A. Drouin, A. Campeau-Lecours, C. Gosselin, K. Glette, F. Laviolette, and B. Gosselin, "Deep learning for electromyographic hand gesture signal classification using transfer learning," *IEEE Trans. Neural Syst. and Rehabilitation Eng.*, vol. 27, no. 4, pp. 760-771, Apr. 2019.
- [18] M. Simao, P. Neto, and O. Gibaru, "EMG-Based online classification of gestures with recurrent neural networks," *Pattern Recognition Lett.*, vol. 128, pp. 45-51, Dec. 2019.
- [19] S. Raurale, J. McAllister, and J. M. del Rincon, "EMG wrist-hand motion recognition system for real-time embedded platform," *IEEE Int. Conf. Acoustics, Speech and Sign. Process.*, May 2019.
- [20] S. Jiang, B. Lv, W. Guo, C. Zhang, H. Wang, X. Sheng, and P. B. Shull, "Feasibility of wrist-worn, real-time hand, and surface gesture recognition via sEMG and IMU sensing," *IEEE Trans. Ind. Informatics*, vol. 14, no. 8, pp. 3376-3385, Aug. 2018.
- [21] Y. Huang, W. Guo, J. Liu, J. He, H. Xia, X. Sheng, H. Wang, X. Feng, and P. B. Shull, "Preliminary testing of a hand gesture recognition wristband based on EMG and inertial sensor fusion," *Int. Conf. Intell. Robotics and Appl.*, Aug. 2015.
- [22] M. Zanghieri, S. Benatti, A. Burrello, V. Kartsch, F. Conti, and L. Benini, "Robust real-time embedded EMG recognition framework using temporal convolutional networks on a multicore IoT processor," *IEEE Trans. Biomed. Cir. and Syst.*, vol. 14, no. 2, pp. 244-256, Apr. 2020.
- [23] X. Liu, J. Sacks, M. Zhang, A. G. Richardson, T. H. Lucas, and J. Van der Spiegel, "The virtual trackpad: An electromyography based, wireless, real-time, low-power, embedded hand gesture recognition system using an event-driven artificial neural network," *IEEE Trans. Cir. and Syst.*, vol. 64, no. 11, pp. 1257-1261, Nov. 2017.
- [24] S. Tam, M. Boukadoum, A. Campeau-Lecours, and B. Gosselin, "A fully embedded adaptive real-time hand gesture classifier leveraging HD-sEMG and deep learning," *IEEE Trans. Biomed. Cir. and Syst.*, vol. 14, no. 2, pp. 232-243, Apr. 2020.
- [25] Y. Zhang, Y. Chen, H. Yu, X. Yang, W. Lu, and H. Liu, "Wearing-independent hand gesture recognition method based on EMG armband," *Pers. and Ubiquitous Comput.*, vol. 22, pp. 511-524, May 2018.
- [27] F. Kerber, M. Puhl, and A. Kruger, "User-independent real-time hand gesture recognition based on surface electromyography," *Int. Conf. Human-Comput. Interaction with Mob. Devices and Serv.*, Sep. 2017.
- [28] L. Lai, "CMSIS-NN: Efficient neural network kernels for ARM Cortex-M CPU," arXiv preprint arXiv:1801.06601, 2018.
- [29] Y. Zhang, N. Suda, L. Lai, and V. Chandra, "Hello Edge: Keyword spotting on micro-controllers," arXiv preprint arXiv:1711.07128, 2017.
- [30] J. Seo, J. Lim, B. Kim, Y. Jeon, and Y. Baek, "Design and implementation of deep learning based gesture recognition device in hospital environment," in *Proc. Symp. KICS*, Jan. 2019.

**임재봉 (Jaebong Lim)**



2016년 2월 : 부산대학교 컴퓨터공학과 공학학사  
2018년 2월 : 부산대학교 컴퓨터공학과 공학석사  
2018년 3월~현재 : 부산대학교 컴퓨터공학과 박사과정

<관심분야> 임베디드 시스템, 임베디드 AI  
[ORCID:0000-0002-1461-5693]

**백윤주 (Yunju Baek)**



1990년 2월 : 한국과학기술원 전산학과 공학학사  
1992년 2월 : 한국과학기술원 전산학과 공학석사  
1997년 2월 : 한국과학기술원 전산학과 공학박사  
1999~2002년 : 네이버 CTO

2003년~현재 : 부산대학교 컴퓨터공학과 교수  
<관심분야> 임베디드 시스템, 임베디드 AI  
[ORCID:0000-0002-3873-2624]

**서주희 (Juhee Seo)**



2017년 2월 : 동의대학교 컴퓨터공학과 공학학사  
2019년 2월 : 부산대학교 컴퓨터공학과 공학석사  
<관심분야> 임베디드 시스템, 웨어러블 디바이스  
[ORCID:0000-0002-5990-7390]