

인공신경망 기반 손동작 인식기의 설계 및 구현

Design and Implementation of Hand Gesture Recognizer Based on Artificial Neural Network

김민우 · 정우재 · 조재찬 · 정윤호*
한국항공대학교 항공전자정보공학과

Minwoo Kim · Woojae Jeong · Jaechan Cho · Yunho Jung*

School of Electronics and Information Engineering, Korea Aerospace University, Gyeonggi-do, 10540, Korea

[요 약]

본 논문에서는 RCE (restricted coulomb energy) 신경망을 이용한 손동작 인식기를 제안하고, 이의 실시간 학습 및 인식을 위한 하드웨어 구현 결과를 제시한다. RCE 신경망은 네트워크 구조가 학습에 따라 유동적이며, 학습 알고리즘이 여타 신경망에 비해 비교적 간단하기 때문에 실시간 학습 및 인식이 가능하므로 손동작 인식기에 적합한 장점을 갖는다. FPGA 기반 검증 플랫폼을 사용하여 3D 숫자 데이터 셋을 생성하였으며, 설계된 손동작 인식기는 3D 숫자 데이터 셋에 대해 98.8%의 인식 정확도를 나타냈다. 제안된 손동작 인식기는 Intel-Altera cyclone IV FPGA 기반 구현 결과, 26,702개의 logic elements로 구현 가능함을 확인하였으며, 70MHz의 동작 주파수로 실시간 학습 및 인식 결과에 대한 검증을 수행하였다.

[Abstract]

In this paper, we propose a hand gesture recognizer using restricted coulomb energy (RCE) neural network, and present hardware implementation results for real-time learning and recognition. Since RCE-NN has a flexible network architecture and real-time learning process with low complexity, it is suitable for hand recognition applications. The 3D number dataset was created using an FPGA-based test platform and the designed hand gesture recognizer showed 98.8% recognition accuracy for the 3D number dataset. The proposed hand gesture recognizer is implemented in Intel-Altera cyclone IV FPGA and confirmed that it can be implemented with 26,702 logic elements and 258Kbit memory. In addition, real-time learning and recognition verification were performed at an operating frequency of 70MHz.

Key word : Artificial neural network, Hand gesture recognition, IMU sensor, Machine learning, Restricted coulomb energy.

<https://doi.org/10.12673/jant.2018.22.6.675>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 20 November 2018; Revised 30 November 2018
Accepted (Publication) 12 December 2018 (30 December 2018)

*Corresponding Author; Yunho Jung

Tel: +82-2-300-0133

E-mail: yjung@kau.ac.kr

1. 서론

최근 스마트폰 시장의 성장세가 둔화되면서 IoT (internet of things) 산업을 이끌어갈 새로운 성장 동력으로 웨어러블 디바이스가 부상하고 있다. 몸에 부착하거나 착용하여 사용하는 웨어러블 디바이스는 센서를 통해 사용자와 관련된 정보나 사용자 주변 정보를 데이터화 및 처리하여 원하는 정보를 취득하는 장치로, 시계나 안경, 헤드셋 같은 다양한 형태로 상용화 되고 있다 [1]. 웨어러블 디바이스의 응용에는 수면시간, 심장 박동수, 스트레스 레벨 등의 데이터 기반 운동 및 건강관리와 생체 인식, 사용자 행동의 데이터를 결합한 안전-보안 장비, 사람의 움직임을 인지하고 기계를 다루는 HMI (human machine interaction) 등이 있다 [2]. 이 중 사용자의 주의를 분산시키지 않으면서 움직임만으로 기기를 자유롭게 제어할 수 있는 HMI 시스템은 스마트 카, 스마트 홈과 같은 환경에서 필요성이 대두되고 있으며, 특히, 손동작을 학습 및 인식하여 효율적으로 기기를 제어할 수 있는 손동작 인식 시스템에 대한 연구가 활발히 진행되고 있다 [3].

손동작 인식 시스템은 카메라를 이용하여 영상 정보로부터 사용자의 움직임 정보를 획득하는 비 접촉식 방식과 센서나 장치를 신체에 부착해 데이터를 획득하는 접촉식 방식으로 구분된다. 카메라를 이용한 비 접촉식 방식은 영상의 깊이 정보를 이용하여 인식하는 방식으로, 다양한 연구가 수행되었다 [4]-[6]. 그러나, 카메라의 영상 정보는 주변 환경에 민감하므로 모든 환경에서 신뢰할 수 있는 시스템을 설계하는데 어려움이 따른다 [7]. 이에 비해 웨어러블 디바이스를 활용하는 접촉식 방식은 센서를 직접 부착하기 때문에 비교적 정확한 동작 정보를 얻을 수 있으며, 카메라와 같이 시야, 날씨 등 주변 환경에 대한 제약이 없는 장점을 갖는다. 센서 기반의 손동작 인식 시스템에는 여러 가지 센서가 사용되는데, 대표적으로 관성 측정 센서, 근전도 센서, 뇌파 센서, 심전도 센서, 레이더 센서가 있다 [8],[9]. 이 중, 관성 측정 센서의 경우 환경에 제약 받지 않을 뿐 아니라, 스마트 장치, 스마트 워치, 관성 펜 등 여러 웨어러블 디바이스에 내장되어 있어 여타 센서 기반 시스템에 비해 손동작 인식 시스템에 적합한 특성을 갖는다 [10]. 관성 측정 센서로 추출된 손동작 데이터는 사용자의 신체적 특성 및 사용하는 환경에 따라 다양하고 광범위한 패턴을 갖는다. 따라서, 센서의 상태 및 환경뿐만 아니라 다양한 사용자에 대응하기 위해 실시간 학습 및 인식이 가능한 기계학습 기반의 알고리즘이 필요하다.

관성 센서 기반 손동작 인식에 활용되는 기계학습 알고리즘에는 template 기반 DTW (dynamic time warping) 알고리즘과 MLP (multiple layer perceptron) 등이 있다 [10]-[14]. DTW는 대표패턴과 주어진 입력패턴을 비교하여 두 패턴 사이의 유사성을 판별하는 알고리즘으로, 손동작 인식 분야에서 우수한 분류 성능을 나타내며 다양한 시스템이 제안되었다 [10]-[12]. 또한, MLP를 활용한 시스템은 높은 성능을 지원하며 손동작 인식 응용에 활용 가능성이 제시되었다 [13]. 그러나, DTW의 경우 인

식기를 구현하기 전에 모든 데이터 셋을 수집하고 최적의 template를 찾아야하는 과정에서 많은 시간이 소요되며, MLP의 경우 층 수, 뉴런 개수 등의 네트워크 구조에 대한 최적화 과정과 복잡한 학습 알고리즘을 필요로 하기 때문에 실시간 학습 구현이 불가능한 문제가 존재한다 [13],[14]. 반면, RCE (restricted coulomb energy) 신경망 알고리즘은 입력된 특징 데이터와 저장된 중심점과의 거리 정보를 기반으로 주어진 특징 공간에서 분류 가능한 결정 경계를 생성하는 알고리즘으로, 네트워크의 구조가 고정되어 있지 않고, 학습 과정에 따라 능동적으로 네트워크 구조를 변형 가능하여 다양한 센서 응용을 지원할 수 있는 장점이 있다. 또한, 학습 방법이 비교적 간단하여 실시간 학습을 지원할 수 있기 때문에 손동작 인식 응용에 적합하다 할 수 있다 [15].

이에, 본 논문에서는 RCE 신경망 기반 손동작 인식 알고리즘을 제안하고, 이의 실시간 학습 및 인식을 지원하기 위한 하드웨어 구조 설계 및 FPGA 구현 결과를 제시한다. 또한, 설계된 손동작 인식기의 성능을 평가하기 위한 FPGA 기반 검증 플랫폼을 구성하고, 이를 통해 수집한 3D 숫자 데이터 셋 기반 손동작 인식 성능 평가 결과를 제시한다. 본 논문의 구성은 다음과 같다. 2장에서는 RCE 신경망의 구조와 학습 알고리즘을 설명하고, 3장에서는 하드웨어 구조 설계 결과를 제시한다. 4장에서는 제안된 손동작 인식기의 FPGA 구현 결과 및 검증 플랫폼을 제시하고, 이를 통한 손동작 인식 성능 평가 결과를 제시한다. 마지막으로 5장에서는 본 논문의 결론을 맺는다.

II. Restricted Coulomb Energy (RCE) 신경망


2-1 RCE 신경망의 구조

RCE 신경망은 그림 1과 같이 입력 층, 은닉 층, 출력 층으로 총 3개의 층으로 구성된다. 입력 층은 특정 데이터로 구성되며, 은닉 층의 각 뉴런에 병렬로 연결된다. 은닉 층은 특정 모델을 형성하는 중심점과 반경을 보유한 뉴런들로 구성된다. 각 뉴런의 모델은 원, 가우시안 등 특정 공간에서 데이터를 구분하기 위한 결정 경계를 생성한다. 각 뉴런은 입력받은 특정 데이터와 뉴런의 중심점 사이의 거리를 연산하고 반경과 비교하여 입력 데이터가 해당 뉴런에 포함되는지 판단하며, 출력 층에 결과를 전달한다. 이후 출력 층은 전달받은 정보들을 활용하여 입력된 특정 데이터와 가장 근접한 모델의 클래스 값을 출력한다.

은닉 층은 뉴런 집합 $N = [n_1, n_2, \dots, n_j, \dots, n_l]$ 로 구성되며, 각 뉴런 n_j 는 아래의 식 (1)의 정보를 포함한다.

$$n_j = [c_j^1, c_j^2, \dots, c_j^d, r_j] \tag{1}$$

여기서 $j \in \{1, 2, 3, \dots, l\}$ 은 각 뉴런의 인덱스를 의미하며, l 은



Feature set Input layer Hidden layer Output layer
그림 1. RCE 신경망 구조
Fig. 1. Structure of RCE neural network.

학습 과정에서 생성된 뉴런의 총 개수를 의미한다. 입력된 특징 벡터의 차원이 d 일 때, 각 뉴런 n_j 는 반경 r_j 와 특징 벡터의 차원과 같은 d 차원의 중심점 $c_j = [c_j^1, c_j^2, \dots, c_j^d]$ 를 저장한다.

2-2 RCE 신경망 학습 알고리즘

학습 과정에서 입력되는 d 차원의 특징 벡터 수를 m 이라 할 때, 특징 벡터 집합은 $F = \{f_1, f_2, \dots, f_i, \dots, f_m\}$ 으로 표현할 수 있다. 여기서 f_i 는 특징 벡터를 나타내며, 특징 벡터는 식 (2)와 같이 구성된다. f_i^k 는 특징 벡터 f_i 를 구성하는 k 번째 특징 데이터를 의미한다. 특징 벡터는 각 뉴런 n_j 에 순차적으로 입력되며 식 (3)과 같이 뉴런 중심점과의 거리 값을 연산한다. 이후, 식 (4)와 같이 연산된 거리 값과 반경 r_j 를 비교함으로써, 해당 특징 벡터가 각 뉴런 n_j 영역에 활성화되는지 여부를 판단한다.

$$f_i = [f_i^1, f_i^2, \dots, f_i^k, \dots, f_i^d] \tag{2}$$

$$d(f_i, c_j) = \sqrt{(f_i^1 - c_j^1)^2 + \dots + (f_i^d - c_j^d)^2} \tag{3}$$

$$d(f_i, c_j) \leq r_j \tag{4}$$

특정 뉴런 n_j 에서 식 (4)를 만족하는 경우, 해당 뉴런이 활성화 되었다고 판단하는 반면, 특징 벡터 f_i 에 대해 모든 뉴런이 식 (4)를 만족하지 못하는 경우 중심점 $[f_i^1, f_i^2, \dots, f_i^d]$ 을 갖는 새로운 뉴런 n_{l+1} 을 생성하고, 총 뉴런 개수 l 을 1 증가시킨다.

III. 하드웨어 구조 설계

실시간 학습 및 인식을 지원하기 위해 그림 2와 같이 손동작

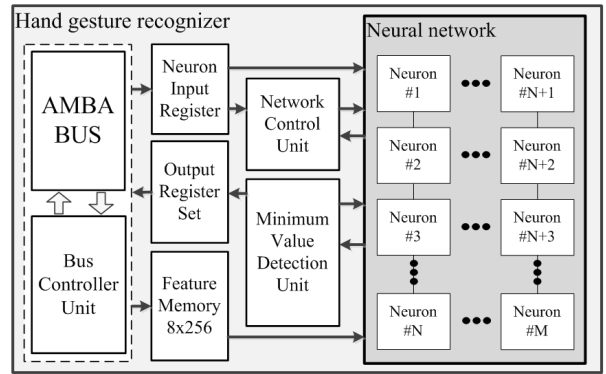


그림 2. 손동작 인식기의 블록도
Fig. 2. Block diagram of hand gesture recognizer.

인식기 (hand gesture recognizer)가 설계 및 구현되었다. 설계된 손동작 인식기는 입출력 레지스터 (input/output register)와 특징 데이터 메모리 (feature memory), 뉴런 (neuron)으로 구성된 신경망 (neural network), 네트워크 제어부 (network control unit)로 구성된다. Micro control unit (MCU)가 동작에 필요한 파라미터 및 제어 신호를 입력 레지스터 (input register)에 설정하면, 네트워크 제어기 (network controller)가 해당 값을 읽으며 학습, 인식 동작을 시작한다. 이후, 입력 레지스터에 설정된 클래스 및 학습 파라미터, 특징 메모리 (feature memory)의 특징 데이터는 신경망 (neural network) 내의 모든 뉴런 (neuron)에 병렬적으로 전송되며 각 뉴런별로 거리 값 연산 등 동작을 수행한다. 하드웨어의 모든 동작이 끝나면 입력 레지스터가 초기화되고, 출력 값이 출력 레지스터 (output register)에 저장된다.

그림 3은 네트워크 제어기와 신경망간의 인터페이스를 나타낸다. 네트워크 제어기는 뉴런들의 정보를 활성화된 뉴런 검출기 (fired neuron detection unit)를 통해 수신하고, 각 동작 및 네트워크 상태에 따라 뉴런들을 제어하는 제어 신호를 신경망에 전송한다. 또한, 뉴런들의 출력 값을 확인하여 현재 신경망의 상태를 파악하고, 상태에 따라 전체적인 동작 혹은 출력 신호를 제어한다.

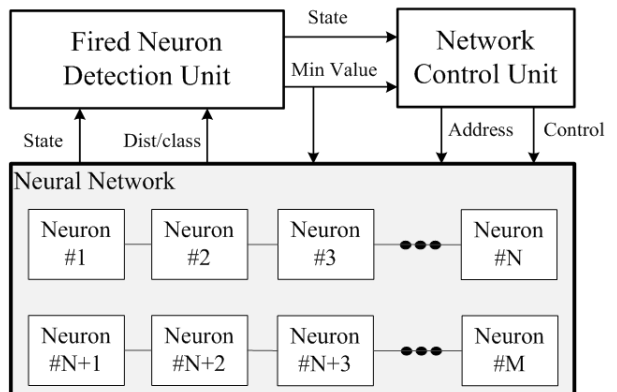


그림 3. 네트워크 제어부와 신경망 간의 인터페이스
Fig. 3. Interface between network control unit and neural network.

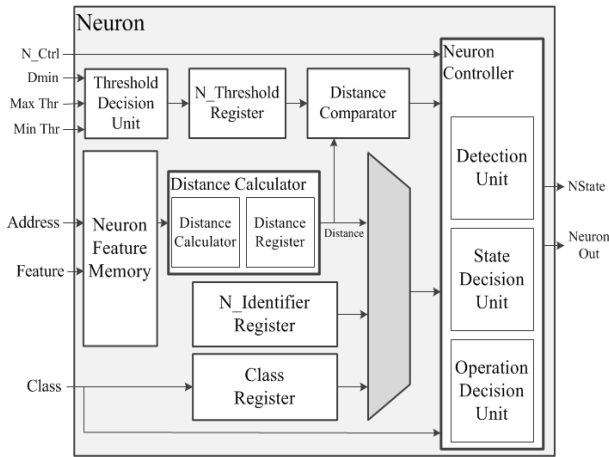


그림 4. 뉴런 블록의 블록도
 Fig. 4. Block diagram of the neuron block.

그림 4와 같이 설계된 뉴런 블록은 각 뉴런별 중심점을 저장하는 뉴런 특징 메모리 (neuron feature memory), 거리를 계산하기 위한 연산기 (distance calculator), 임계값과 클래스와 같은 학습 파라미터를 저장하는 레지스터, 뉴런의 상태 및 동작을 제어하는 뉴런 제어기 (neuron controller)로 구성된다. 각 뉴런은 학습 여부에 따라 거리 연산 혹은 중심점 저장 프로세스를 수행하며, 모든 뉴런의 출력 값은 활성화된 뉴런 검출기를 통해 네트워크 제어기 혹은 출력 레지스터 집합으로 전송된다. 활성화된 뉴런 검출기를 통해 뉴런 블록과 네트워크 제어기 간의 통신이 이루어지며, 네트워크 제어기의 제어 신호를 통해 각 동작을 수행한다. 모든 뉴런의 출력 값은 활성화된 뉴런 검출기를 통해 네트워크 제어기 혹은 출력 레지스터로 전송된다.

IV. FPGA 기반 구현 및 검증 결과

제안된 손동작 인식기는 Verilog HDL을 이용하여 RTL 설계 후, Intel-Altera cyclone IV (EP4CE115) FPGA 디바이스를 활용하여 구현 및 검증되었다. 표 1은 구현 결과를 보여주며, 제안된 RCE 프로세서는 총 26,702개의 logic elements, 13,906개의 registers, 258,048 bit의 memory로 구현 가능함을 확인하였다. 또한, 70MHz의 동작 주파수로 구현 및 검증하여, 학습에는 0.26us, 인식에는 0.2us로 실시간 처리가 가능함을 확인하였다.

표 1. 제안된 손동작 인식기의 FPGA 기반 구현 결과
 Table 1. FPGA implementation results of the proposed hand gesture recognizer

	RCE neural network processor
FPGA device	Cyclone IV (EP4CE115) FPGA
Logic elements	26,702
Register	13,906
Embedded memory	258K
Frequency	70MHz

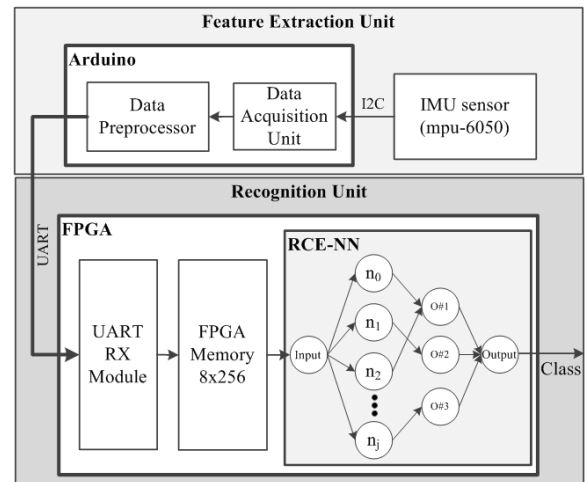


그림 5. 손동작 인식 검증 플랫폼의 블록도
 Fig. 5. Block diagram of the test platform for hand gesture recognition.



그림 6. 손동작 인식 검증 플랫폼의 실험 환경
 Fig. 6. Experiment environment of the test platform for hand gesture recognition.

제안된 RCE 신경망 프로세서에 대한 성능 평가를 위해 그림 5,6과 같이 관성 센서 기반 손동작 인식 검증 플랫폼을 구성하였다. 검증 플랫폼은 입력 데이터에 대해 전처리 과정을 수행하고 인식에 용이한 특징 데이터로 변환하는 특징 추출부와 입력된 특징 데이터를 통해 학습 및 인식을 수행하는 인식부로 나뉜다. 가속도계, 자이로스코프가 내장된 mpu-6050 센서 모듈을 통해 입력받은 센서 값은 I2C (inter-integrated circuit) 통신을 통해 아두이노 (Arduino)로 전송된다. 센서 값은 아두이노에서 전처리 과정을 통해 특징 데이터로 변환되며, 생성된 특징 데이터는 UART (universal asynchronous receiver-transmitter) 인터페이스를 통해 인식부의 FPGA 메모리에 전달된다. 학습 및 인식에 필요한 데이터가 준비되면 RCE 신경망 프로세서는 동작을 수행하며 클래스 및 학습된 뉴런 수를 출력한다.

그림 6의 검증 플랫폼으로 관성 센서 기반 3D 숫자 데이터셋을 생성하였으며, 생성된 데이터 셋으로 제안된 손동작 인식기의 성능 평가를 수행하였다. 학습된 뉴런 수 및 인식 정확도를 5-fold cross validation으로 평가하였고, 평균 100개의 뉴런으로 그림 7의 혼동 행렬과 같이 평균 98.8%의 인식 정확도를

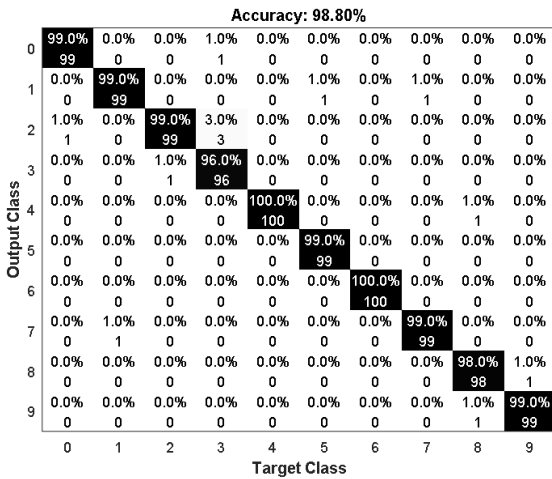


그림 7. 혼돈 행렬
Fig. 7. Confusion matrix.

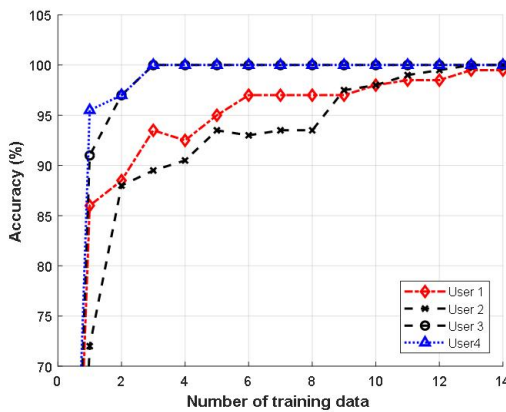


그림 8. 학습 데이터의 수에 따른 인식 정확도
Fig. 8. Recognition accuracy for the number of learning data.

보였다. 이는 동일한 3D 숫자 데이터 셋에 대해 학습 및 성능 평가를 수행한 기존 DTW 기반 손동작 분류기의 94.6% 인식 정확도에 비해 4.2% 우수한 결과임을 의미 한다 [10]. 인식 정확도는 입력된 총 샘플 수에서 오차를 뺀 값을 총 샘플 수로 나눈 값을 의미하며, 여기서 오차는 예측된 클래스가 실제 클래스와 다른 경우로 정의된다. 그림 8은 4명의 참여자에 대해 성능 평가를 수행한 결과로, 학습 데이터 수에 따른 인식 정확도 향상을 나타낸다. 제안된 손동작 인식기는 2개의 데이터로 학습하였을 때 평균 92.6%의 인식 정확도를 보여 적은 수의 데이터로 학습하더라도 높은 인식 정확도를 얻는 것을 확인하였다.

V. 결론

본 논문에서는 손동작 인식을 위한 RCE 신경망 기반 손동작 인식 알고리즘을 제안하고, 이의 실시간 학습 및 인식을 위한

하드웨어 구조 설계 결과를 제시하였다. 제안된 손동작 인식기는 3D 숫자 데이터 셋을 사용하여 5-fold cross validation으로 평가하였으며, 98.6%의 인식 정확도를 나타내어 손동작 인식 응용에 적합함을 보였다. 제안된 손동작 인식기는 FPGA 기반 구현 결과, 총 26,702개의 logic elements, 13,906개의 registers, 258,048 bit의 memory로 구현 가능함을 확인하였고, 70MHz의 동작 주파수에서 실시간 동작을 검증하였다.

Acknowledgments

본 논문은 산업통상자원부 및 한국산업기술평가관리원의 산업원천기술개발사업 (10079634)의 일환으로 수행되었음.

References

- [1] S. Seneviratne, Y. Hu, T. Nguyen, G. Lan, and S. khalifa, "A survey of wearable devices and challenges," *IEEE Communications Survey & Tutorials*, Vol. 19, No. 4, pp. 2573-2620, Jul. 2017.
- [2] J. Yu and Z. Fu Wang, "A video, text, and speech-driven realistic 3-D virtual head for human-machine interface," *IEEE Transactions on Cybernetics*, Vol. 45, No. 5, pp. 977-988, May 2015.
- [3] Z. Lu, X. Chen, Q. Li, X. Zhang, and P. Zhou, "A hand gesture recognition framework and wearable gesture-based interaction prototype for mobile devices," *IEEE Transactions on Human-Machine Systems*, Vol. 44, No. 2, pp. 293-299, Apr. 2014.
- [4] H. Cheng, L. Yang, and Z. Liu, "Survey on 3D hand gesture recognition," *IEEE Transactions on Circuits and Systems for Video Technology*, Vol. 26, No. 9, pp. 1659-1673, Sep. 2016.
- [5] Z. Chaohui, D. Xiaohui, X. shuoyu, and S. Zheng, "Tiny hand gesture recognition without localization via a deep convolutional network," *IEEE Transactions on Consumer Electronics*, Vol. 63, No. 3, pp. 251-257, Aug. 2017.
- [6] E. Ohn-Bar, and M. M. Trivedi, "Hand gesture recognition in real time for automotive interfaces: a multimodal vision-based approach and evaluations," *IEEE Transactions on Intelligent Transportation Systems*, Vol. 15, No. 6, pp. 2368-2377, Dec. 2014.
- [7] R. Xie and J. Cao, "Accelerometer-based hand gesture recognition by neural network and similarity matching," *IEEE Sensors Journal*, Vol. 16, No. 11, pp. 4537-4535, Jun. 2016.
- [8] 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 Transactions on Industrial Informatics, Vol. 14, No. 8, pp. 3376-3385, Aug. 2018.

[9] Z. Zhang, Z. Tian, and M. Zhou, "Latern: dynamic continuous hand gesture recognition using FMCW radar sensor," *IEEE Sensors Journal*, Vol. 18, No. 8, pp. 3278-3289, Apr. 2018.

[10] Y. Hsu, C. Chu, Y. Tsai, and J. Wang, "An inertial pen with dynamic time warping recognizer for handwriting and gesture recognition," *IEEE Sensors Journal*, Vol. 15, No. 1, pp. 154-163, Jan. 2015.

[11] R. Srivastava, and P. Sinha, "Hand movements and gestures characterization using quaternion dynamic time warping technique," *IEEE Sensors Journal*, Vol. 16, No. 5, pp. 1333-1341, March 2016.

[12] Z. Ji, Z. Li, P. Li, and M. An, "A new effective wearable hand gesture recognition algorithm with 3-axis

accelerometer," in *2015 12th International Conference on Fuzzy Systems and Knowledge Discovery (FSKD)*, Zhangjiajie: China, pp. 1243-1247, Jan. 2016.

[13] R. Xie and J. Cao, "Accelerometer-based hand gesture recognition by neural network and similarity matching," *IEEE Sensors Journal*, Vol. 16, No. 11, pp. 4537-4545, Jun. 2016.

[14] E. Akan, H. Tora, and B. Uslu, "Hand gesture classification using inertial based sensors via a neural network," in *2017 24th IEEE International Conference on Electronics, Circuits and Systems (ICECS)*, Batumi: Georgia, pp. 140-143, Feb. 2017.

[15] G. Dong and M. Xie, "Color clustering and learning for image segmentation based on neural networks," *IEEE Transactions on Neural Networks*, Vol. 16, No. 4, pp. 925-936, Jul. 2005.



김민우 (Minwoo Kim)

2018년 2월 : 한국항공대학교 항공전자정보공학부 (공학사)
2018년 3월 ~ 현재 : 한국항공대학교 항공전자정보공학부 석사과정
※관심분야 : 센서 신호처리 시스템, 인공지능 시스템, 인공지능 SoC



정우재 (Woojae Jeong)

2018년 2월 : 한국항공대학교 항공전자정보공학부 (공학사)
2018년 3월 ~ 현재 : 한국항공대학교 항공전자정보공학부 석사과정
※관심분야 : 센서 신호처리 시스템, 인공지능 시스템, 인공지능 SoC



조재찬 (Jaechan Cho)

2015년 8월 : 한국항공대학교 전자 및 항공전자공학과 (공학사)
2017년 2월 : 한국항공대학교 항공전자정보공학부 (공학석사)
2017년 3월 ~ 현재 : 한국항공대학교 항공전자정보공학부 박사과정
※관심분야 : 센서 신호처리 시스템, 영상처리 시스템, 인공지능 시스템, 영상처리 SoC, 인공지능 SoC



정운호 (Yunho Jung)

1998년 2월 : 연세대학교 전자공학과 (공학사),
2005년 2월 : 연세대학교 전기전자공학과 (공학박사),
2007년 ~ 2008년 : 연세대학교 연구교수,
※관심분야 : 무선 통신 시스템, 항공통신 시스템, 영상처리 시스템, 모뎀 SoC, 영상처리 SoC, 인공지능 SoC
2000년 2월 : 연세대학교 전기전자공학과 (공학석사)
2005년 ~ 2007년 : 삼성전자 책임연구원
2008년 ~ 현재 : 한국항공대학교 교수