

인공신경망 기반 가스 분류기의 설계

Design of Gas Classifier Based On Artificial Neural Network

정우재*, 김민우*, 조재찬*, 정윤호*

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

Abstract

In this paper, we propose the gas classifier based on restricted column energy neural network (RCE-NN) and present its hardware implementation results for real-time learning and classification. Since RCE-NN has a flexible network architecture with real-time learning process, it is suitable for gas classification applications. The proposed gas classifier showed 99.2% classification accuracy for the UCI gas dataset and was implemented with 26,702 logic elements with Intel-Altera cyclone IV FPGA. In addition, it was verified with FPGA test system at an operating frequency of 63MHz.

요약

본 논문에서는 restricted coulomb energy(RCE) 신경망 기반 가스 분류기를 제안하고, 이의 실시간 학습 및 분류를 위한 하드웨어 구현 결과를 제시한다. RCE 신경망은 네트워크 구조가 학습에 따라 유동적이며, 실시간 학습 및 분류가 가능하므로, 가스 분류 응용에 적합한 특징을 갖는다. 설계된 가스 분류기는 UCI gas dataset에 대해 99.2%의 분류 정확도를 보였으며, Intel-Altera cyclone IV FPGA 기반 구현 결과, 26,702개의 logic elements로 구현 가능함을 확인하였다. 또한, FPGA test system을 구성하여 63MHz의 동작 주파수로 실시간 검증을 수행하였다.

Key words : machine learning, artificial neural network, RCE-NN, gas classification, FPGA

1. 서론

최근 공장, 연구소 등의 다양한 산업 현장에서 뿐만 아니라 화재 현장, 가정에서도 황산, 일산화탄소 등의 유독가스에 노출되는 사례가 급증하고 있다. 인화성, 발암성을 갖는 무취의 가스에 노출되면 질병 혹은 죽음을 야기할 수 있기 때문에, 해당 가스를 감지 및 경고할 수 있는 실시간 감지 시스템을 설치하는 것은 필수적이다[1].

가스 감지 시스템에는 특정 가스를 정확히 검출하는 가스 분류 기술이 핵심적이며, 가스 분류를 위해 높은 분별력, 민감한 감도, 온도 제어 능력, on-chip 집적화 기능, 그리고 다양한 종류의 가스를 검출할 수 있는 장점이 있는 반도체 기반의 마이크로 가스 센서가 활용된다. 반도체 기반의 가스 센서는 특정 가스에 노출되면 전기적인 신호를 출력하므로, 특정 가스별 서로 다른 전기적인 신호의 특성을 파악하여 가스 분류를 수행한다. 하지만, 가스 센서는 시간,

* School of Electronics and Information Engineering, Korea Aerospace University

★ Corresponding author

E-mail : yjung@kau.ac.kr, Tel : +82-2-300-0133

※ Acknowledgment

This work was supported by the Technology Innovation Program, 10073122, funded by the Ministry of Trade, Industry and Energy (MOTIE, Korea) and CAD tools were supported by IDEC.

Manuscript received Sep. 5, 2018; revised Sep. 19, 2018; accepted, Sep. 20, 2018

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.

습도, 온도의 변화 및 특정 가스에 대한 과다노출 등으로 인하여 노화가 진행 된다[2]. 이에 따라, 동일한 환경에서도, 같은 가스를 다른 가스로 검출할 수 있는 문제점이 발생할 수 있다. 따라서, 센서의 상태 및 환경을 파악하여, 실시간으로 학습할 수 있는 기계학습 기반의 알고리즘이 필요하다.

가스 분류 기술에 활용되는 기계학습 기반 알고리즘에는 multiple layer perceptron (MLP), support vector machine (SVM) 등이 있다[3-6]. 그러나, MLP의 경우, 층 수, 뉴런 개수 등의 네트워크 구조에 대한 최적화 과정이 필요하고, SVM의 경우에도 다양한 학습 파라미터를 최적화해야 하는 문제가 존재한다. 또한, 두 알고리즘 모두 복잡한 학습 알고리즘을 필요로 하는 단점이 있다. 이와 달리, restricted coulomb energy(RCE) 신경망은 학습 방법이 비교적 간단하며, 학습에 따라 유동적으로 네트워크 구조를 가변 시킬 수 있기 때문에, 네트워크 구조에 대한 최적화 과정 없이 학습이 가능하다[7]. 따라서, MLP, SVM에 비해, 비교적 적은 학습시간이 소요되어 실시간 학습이 가능할 뿐만 아니라, 다양한 분야에서 낮은 복잡도로도 높은 분류 성능을 보이는 장점이 있다.

이에, 본 논문에서는 RCE 신경망 기반 가스 분류기를 제안하고, UCI gas dataset [8-9]을 활용하여 가스 분류 성능 평가 결과를 제시한다. 또한, 이의 실시간 학습 및 분류를 지원하기 위해, 효율적인 하드웨어 구조를 제안하고, FPGA 기반 구현 및 검증 결과를 제시한다. 본 논문의 구성은 다음과 같다. II장에서는 RCE 신경망의 구조와 학습 알고리즘, 그리고 UCI gas dataset 기반 성능 분석 결과를 제시한다. III장에서는 제안된 RCE 신경망 기반 가스 분류기의 하드웨어 구조를 기술하며, IV장에서는 FPGA 기반 구현 결과를 제시한다. 마지막으로, V장에서는 본 논문의 결론을 맺는다.

II. Restricted Coulomb Energy(RCE) 신경망

1. RCE 신경망 구조

RCE 신경망은 입력된 특징 데이터들을 분류하기 위해서, 각 입력 데이터의 패턴별로 최적의 분류기를 생성하는 지도학습 기반의 알고리즘이다. RCE 신경망은 그림 1과 같이 input layer, prototype layer, 그리고 output layer로 구성된다.

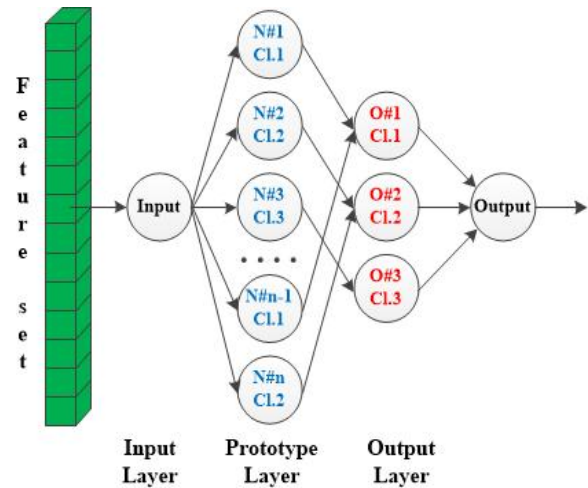


Fig. 1. Structure of RCE neural network.

그림 1. RCE 신경망 구조

Input layer는 특징 데이터를 입력받도록 구성되며, 입력받은 모든 특징 데이터는 prototype layer의 각 뉴런에 연결된다. Prototype layer는 임의로 선정한 모델의 중심점과 반경 (분산)을 보유한 뉴런들로 구성된다. 즉, 중심점은 원, 가우시안, 사각형 등의 모델의 중심 좌표 혹은 평균값을 의미하고, 반경은 모델의 분포 구간을 뜻한다. 각 뉴런은 입력되는 특징 데이터와 뉴런의 중심점 사이의 거리를 연산하고, 그 값을 뉴런의 반경과 비교하여 입력된 특징 데이터가 해당 뉴런에 포함되는지 판단한 후, output layer에 결과를 전달한다. 이후 output layer는 전달받은 정보들을 활용하여 입력된 특징 데이터와 가장 근접한 모델의 클래스 값을 출력한다.

Prototype layer를 구성하는 뉴런 n_j 는 식 (1)의 정보를 포함한다.

$$\mathbf{n}_j = [c_j^1, c_j^2, \dots, c_j^k, r_j] \quad (1)$$

여기서 $j \in \{1, 2, 3, \dots, l\}$ 은 각 뉴런의 인덱스를 의미하며, l 은 학습 과정에서 생성된 뉴런의 총 개수를 의미한다. 즉, 학습이 완료되었으면, 뉴런 집합은 $\mathbf{N} = [\mathbf{n}_1, \mathbf{n}_2, \dots, \mathbf{n}_l]$ 로 정의된다. 입력된 특징 벡터의 차원이 k 일 때, 각 뉴런 n_j 는 특징 벡터의 차원과 같은 k 차원의 중심점 $\mathbf{c}_j = [c_j^1, c_j^2, \dots, c_j^k]$ 와 반경 r_j 를 저장한다.

2. RCE 신경망 학습 알고리즘

k 차원의 특징 벡터 수를 m 이라 할 때, 특징 벡터

집합은 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_i, \dots, \mathbf{x}_m\}$ 로 표현할 수 있다. 여기서, \mathbf{x}_i 는 특징 벡터를 나타내며, 특징 벡터는 $\mathbf{x}_i = [x_i^1, x_i^2, \dots, x_i^k]$ 와 같이 구성된다. x_i^k 는 특징 벡터 \mathbf{x}_i 를 구성하는 k 번째 특징 데이터를 의미한다. 특징 데이터는 각 뉴런 \mathbf{n}_j 에 순차적으로 입력되며, 식 (2)와 같이, 특징 벡터 \mathbf{x}_i 와 각 뉴런의 중심점 \mathbf{c}_j 와의 거리 정보 $d(\mathbf{x}_i, \mathbf{c}_j)$ 를 연산한 후, 식 (3)과 같이 반경 r_j 와 거리 정보를 비교하여, 특징 벡터가 각 뉴런 \mathbf{n}_j 영역에 활성화되는지 여부를 판단한다.

$$d(\mathbf{x}_i, \mathbf{c}_j) = \sqrt{(x_i^1 - c_j^1)^2 + (x_i^2 - c_j^2)^2 + \dots + (x_i^k - c_j^k)^2} \quad (2)$$

$$d(\mathbf{x}_i, \mathbf{c}_j) \leq r_j \quad (3)$$

특정 뉴런 \mathbf{n}_j 에서 식 (3)을 만족하는 경우, 해당 뉴런이 활성화되었다고 판단하는 반면, 특징 벡터 \mathbf{x}_i 에 대해 모든 뉴런이 식 (3)을 만족하지 못하는 경우, 중심점 $[x_i^1, x_i^2, \dots, x_i^k]$ 를 갖는 새로운 뉴런 \mathbf{n}_{l+1} 이 생성되고, 총 뉴런 개수 l 을 1 증가시킨다.

3. UCI gas dataset 기반 성능 평가 결과

제안된 RCE 신경망의 성능 평가를 위해 UCI gas dataset을 활용하였다. UCI gas dataset은 6종류의 가스를 검출하기 위해, 36개월간 16개의 gas sensor array에서 추출된 13,910개의 샘플을 포함한다. 가스는 암모니아, 아세트알데히드, 아세톤, 에틸렌, 에탄올, 톨루엔으로 구성되어 있으며, 각각의 가스는 다양한 농도로 수집되었다[9]. 모든 샘플은 총 10개의 batch로 나뉘며, 각 batch는 시간 순으로 6종류의 가스가 균일하게 분포되도록 구성되어 있다. 각 샘플들은 특징별로 분포가 상이하기 때문에, 식 (4)와 같이 normalization하여 분포를 동일하게 맞춰준 다음, 8bit로 양자화 하여 전처리 과정을 진행하였다. 이후 전처리 과정을 통해 추출된 특징 데이터를 RCE 신경망의 입력 데이터로 활용한다.

$$Normalization = \frac{(data - \text{mean}(data))}{(\text{max}(data) - \text{min}(data))} \quad (4)$$

그림 2는 제안된 RCE 신경망을 바탕으로 UCI gas dataset을 사용하여 학습한 결과를 나타내며, 평균적으로 67개의 뉴런이 생성되었다. 학습된 뉴런 수에 따라 RCE 신경망의 구현 복잡도가 증가하므로 적절한 크기의 학습 샘플로 학습을 진행해야 한다. Batch 10에서 평균보다 더 많은 뉴런이 생성

된 이유는 batch 10의 샘플 수가 다른 batch보다 비교적 많기 때문이다.




Fig. 2. Learning results of the proposed RCE neural network with UCI gas dataset batch.

그림 2. Batch별 RCE 신경망의 학습 결과

그림 3은 제안된 RCE 신경망의 시뮬레이션 결과를 나타내며, 평균 99.2%의 분류 성능을 보였다. 정확도(accuracy)는 예측된 클래스가 실제 클래스와 다른 경우를 오차로 정의하고, 입력된 총 샘플 수에서 오차를 뺀 값을 총 샘플 수로 나눈 값을 의미한다.

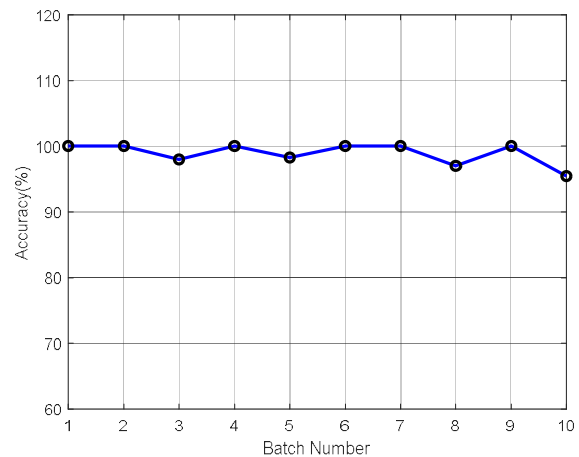


Fig. 3. Performance evaluation results of the proposed RCE neural network.

그림 3. 제안된 RCE 신경망의 성능 평가 결과

III. 하드웨어 구조 설계

제안된 RCE 신경망 기반 가스 분류기는 그림 4와 같이, 마이크로프로세서(MCU)와 통신하기 위한

버스 인터페이스 제어기(bus interface controller), 하드웨어 동작을 위해 필요한 학습 파라미터를 저장하는 입력 레지스터 집합(input register set), 출력값들을 저장하기 위한 출력 레지스터 집합(output register set), 마이크로프로세서로부터 입력된 특징 데이터를 저장하고 하드웨어에 특징 데이터를 전송하기 위한 특징 메모리(feature memory), 그리고 신경망과 이를 제어하는 네트워크 제어기(network control unit)으로 구성된다.

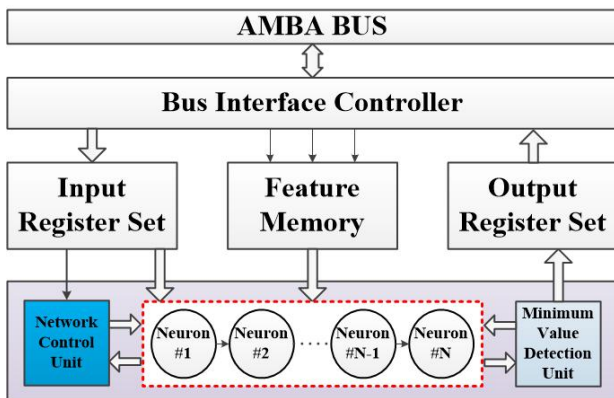


Fig. 4. Block diagram of the proposed gas classifier.
그림 4. 제안된 가스 분류기의 블록도

마이크로프로세서가 버스 인터페이스 제어기를 통해 각 동작에 필요한 값들을 입력 레지스터 집합과 특징 메모리에 설정하면, 네트워크 제어기에서 해당 값을 읽으며 동작을 실행한다. 동작이 완료되면 완료 신호를 마이크로프로세서에 전송하며, 이후 마이크로프로세서는 입력 레지스터 집합을 초기화하고, 다음 동작에 필요한 레지스터 및 특징 메모리를 설정한다.

그림 5는 네트워크 제어기와 신경망간의 인터페이스를 나타낸다. 네트워크 제어기는 뉴런들의 정

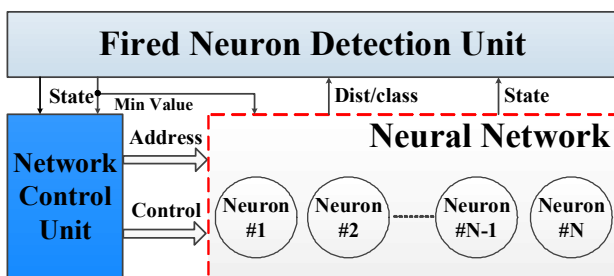


Fig. 5. Interface between network control unit and neural network.
그림 5. 네트워크 제어기와 신경망 간의 인터페이스

보를 활성화된 뉴런 검출기(fired neuron detection unit)을 통해 수신하고, 각 동작 및 네트워크 상태에 따라 뉴런들을 제어하는 제어 신호를 신경망에 전송한다.

그림 6과 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. 모든 뉴런의 출력 값은 활성화된 뉴런 검출기를 통해 네트워크 제어기 혹은 출력 레지스터 집합으로 전송된다.

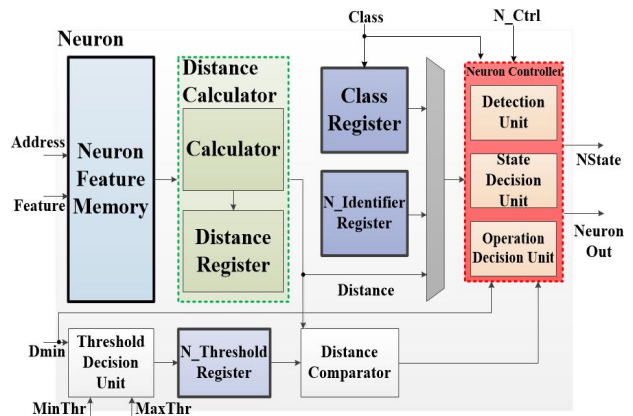


Fig. 6. Block diagram of the neuron.
그림 6. 뉴런의 블록도

활성화된 뉴런 검출기를 통해 뉴런 블록과 네트워크 제어기 간의 통신이 이루어지며, 네트워크 제어기의 제어 신호를 통해 각 동작을 수행한다.

IV. FPGA 기반 구현 결과

제안된 RCE 신경망 기반 가스 분류기는 Verilog HDL을 이용하여 RTL 설계 후, Altera cyclone IV (EP4CE115) FPGA 디바이스에서 구현 및 검증되었다. 표 1은 RCE 신경망 기반 가스 분류기를 Altera cyclone IV FPGA 디바이스에 구현한 결과를 나타낸다. 구현 결과, 제안된 하드웨어는 총 26,702개의 logic elements(23%), 13,906개의 레지스터(29%), 131,072 bit의 메모리(3%)로 구현 가능함을 확인하였다. 또한, 63MHz의 동작 주파수로 구현 및 검증하여 실시간 학습 및 분류가 가능함을 확인하였다.

Table 1. Implementation results of the proposed gas classifier with Cyclone IV FPGA.

표 1. Cyclone IV FPGA 기반 가스 분류기의 구현 결과

	Proposed gas classifier
FPGA device	Cyclone IV EP4CE115
Logic elements	26,702 / 114,480 (23%)
Embedded memory	131K / 3,388K (3%)
Frequency	63 MHz

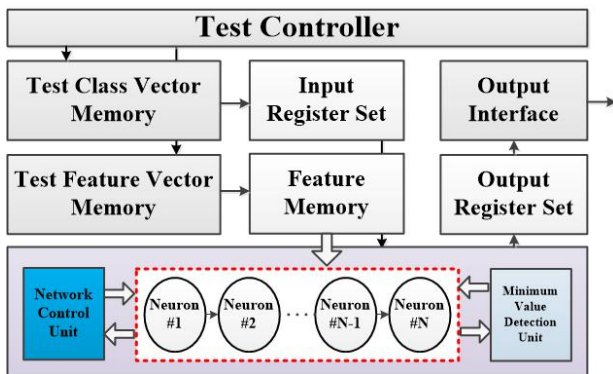


Fig. 7. FPGA test platform.

그림 7. FPGA 기반 검증 플랫폼

제안된 가스 분류기에 대한 실시간 검증을 위해 그림 7과 같이 FPGA 기반 검증 환경을 구성하였다. RCE 신경망에 대한 알고리즘 성능 평가 결과와 비교 검증을 수행하기 위해 UCI gas dataset의 각 batch별 특징 데이터를 검증 특징 벡터 메모리(test feature vector memory)에, 클래스 데이터는 검증 클래스 벡터 메모리(test class vector memory)에 초기화 한다. 이후 검증 제어기(test controller)를 통해 초기화 된 검증 벡터를 입력 레지스터 집




Fig. 8. FPGA test results.

그림 8. FPGA 기반 검증 결과

합과 특징 메모리에 입력하고, 학습 및 분류를 수행하도록 제어한다. 최종적으로 출력되는 클래스를 출력 레지스터 집합에 전송하고, 그림 8과 같이 출력 인터페이스를 통해서 7-세그먼트 디바이스에 출력하여, 알고리즘 분석 결과와 비교함으로써 검증을 완료하였다.

V. 결론

본 논문에서는 가스 분류를 위한 RCE 신경망 기반 가스 분류기를 제안하고, 이의 하드웨어 구조 설계 결과를 제시하였다. 제안된 가스 분류기는 UCI gas dataset 기반으로 검증을 수행하였으며, 검증 결과, 99.2%의 분류 정확도를 보임을 확인하였다. 또한, 이의 실시간 학습 및 검증을 위해 하드웨어 구조 설계를 진행하였으며, FPGA 기반 구현 결과, 26,702개의 logic slice로 구현 가능함을 확인하였고, 63MHz의 동작 주파수에서 실시간 동작 가능성이 확인되었다.

References

- [1] Duk-Dong Lee, Dae-Sik Lee, "Environmental Gas Sensors," *IEEE SENSORS*, vol.1, no.3, pp. 214-224, October. 2011. DOI:10.1109/JSEN.2001.954834
- [2] Chengxiang Wang, Longwei Yin, Luyuan Zhang, Dong Xiang, Rui Gao, "Metal Oxide Gas Sensors: Sensitivity and Influencing Factors," *Sensors*, vol.10, pp.2088-2106, March. 2010. DOI:10.3390/s100302088
- [3] Xiaojun Zhai, Amine Ait Si Ali, Abbes Amira, Faycal Bensaali, "MLP Neural Network Based Gas Classification System on Zynq SoC," *IEEE Access*, vol.4, pp.8138-8146, October. 2016. DOI:10.1109/ACCESS.2016.2619181
- [4] F. Benrekia, M. Attari, M. Bouhedda, "Gas sensors characterization and multilayer perceptron (MLP) hardware implementation for gas identification using a field programmable gate array (FPGA)," *Sensors*, vol.13, no.3, pp.2967-2985, March, 2013. DOI:10.3390/s130302967

- [5] Pai Peng, Xiaojin Zhao, Xiaofang Pan, Wenbin Ye, "Gas Classification Using Deep Convolutional Neural Networks," *Sensors*, vol.18, no.1, pp.1-11, January, 2018. DOI:10.3390/s18010157
- [6] Kun Wang, Wenbin Ye, Xiaojin Zhao, Xiaofang Pan, "A Support Vector Machine-Based Genetic Algorithm Method for Gas Classification," in *Proc. of the 2017 2nd international Conference on Frontiers of Sensors Technologies*, 2017, pp. 363-366. DOI:10.1109/ICFST.2017.8210537
- [7] G.Dong, M.Xie, "Color Clustering and Learning for Image Segmentation Based on Neural Networks," *IEEE Transactions on Neural Network*, vol.16, ISSUE 4, pp.925-936, July. 2005. DOI:10.1109/TNN.2005.849822
- [8] Alexander Vergara, "UCI Machine Learning Repository," <https://archive.ics.uci.edu/ml/datasets/gas+sensor+array+drift+dataset>
- [9] Alexander Vergara, Shankar Vembu, Tuba Ayhan, Margaret A.Ryan, Margie L. Homer, Ramon Huerta, "Chemical Gas Sensor Drift Compensation Using Classifier Ensembles," *Sensors and Actuators B: Chemical*, Vol.166-17, No.20, pp. 320-329, May 2012. DOI:10.1016/j.snb.2012.01.074

BIOGRAPHY

Woojae Jeong (Student Member)



2018 : BS degree in School of Electronics and Information Engineering, Korea Aerospace University.

2018~present : MS degree in School of Electronics and Information Engineering, Korea Aerospace University.

Minwoo Kim (Student Member)



2018 : BS degree in School of Electronics and Information Engineering, Korea Aerospace University.

2018~present : MS degree in School of Electronics and Information Engineering, Korea Aerospace University.

Jaechan Cho (Student Member)



2015 : BS degree in School of Electronics and Information Engineering, Korea Aerospace University.

2017 : MS degree in School of Electronics and Information Engineering, Korea Aerospace University.

2017~present : Ph.D degree in School of Electronics and Information Engineering, Korea Aerospace University.

Yunho Jung (Member)



1998 : BS degree in Department of Electrical and Electronic Engineering, Yonsei University.

2000 : MS degree in Department of Electrical and Electronic Engineering, Yonsei University.

2005 : Ph.D degree in Department of Electrical and Electronic Engineering, Yonsei University.

2005~2008 : Senior, Samsung Electronics

2008~present : Professor, School of Electronics and Information Engineering, Korea Aerospace University