

수신된 전파신호의 자동 변조 인식을 위한 딥러닝 방법론

김한진¹ · 김혁진² · 제준호¹ · 김경섭^{3*}

A deep learning method for the automatic modulation recognition of received radio signals

Hanjin Kim¹ · Hyeockjin Kim² · Junho Je¹ · Kyungsup Kim^{3*}

¹Undergraduate Student, Department of Computer Engineering, Chungnam National University, Daejeon, Korea, 34134

²Graduate Student, Department of Computer Engineering, Chungnam National University, Daejeon, Korea, 34134

^{3*}Professor, Department of Computer Engineering, Chungnam National University, Daejeon, Korea, 34134

요약

무선 신호의 자동 변조 인식은 지능형 수신기의 주요한 작업으로 다양한 민간 및 군대 응용분야가 있다. 본 논문에서는 딥 뉴럴 네트워크 모델을 기반한 무선통신에서 전파신호의 변조 방식을 식별하는 방법을 제안한다. 순차적인 데이터에 대해 장기적인 패턴을 잡아내는데 용이한 LSTM 모델을 통과하여 얻은 연속적인 신호의 특징값을 딥 뉴럴 네트워크의 입력 데이터로 사용하여 신호의 변조 패턴을 분류한다. 변조된 신호의 진폭 및 위상, 동상(In-phase) 반송파, 직각 위상(Quadrature-phase) 반송파의 값을 LSTM 모델의 입력 데이터로 사용하여 분류한다. 제안된 학습 방법의 성능을 검증하기 위해, 다양한 신호 대 잡음비로 10 가지 유형의 변조 신호를 포함하는 대형 데이터 세트를 사용하여 학습하고 테스트한다. 본 논문의 변조 인식 프로그램은 신호의 사전 정보가 없는 환경에서 변조방식을 예측하는데 적용될 수 있다.

ABSTRACT

The automatic modulation recognition of a radio signal is a major task of an intelligent receiver, with various civilian and military applications. In this paper, we propose a method to recognize the modulation of radio signals in wireless communication based on the deep neural network. We classify the modulation pattern of radio signal by using the LSTM model, which can catch the long-term pattern for the sequential data as the input data of the deep neural network. The amplitude and phase of the modulated signal, the in-phase carrier, and the quadrature-phase carrier are used as input data in the LSTM model. In order to verify the performance of the proposed learning method, we use a large dataset for training and test, including the ten types of modulation signal under various signal-to-noise ratios.

키워드 : 자동변조인식(AMC), 딥러닝, 장단기기억(LSTM), 신경망, 무선통신

Keywords : Automatic modulation classification(AMC), Deep learning, Long-short term memory(LSTM), Neural network, Wireless communication

Received 13 June 2019, Revised 23 June 2019, Accepted 12 July 2019

*Corresponding Author Kyungsup Kim(E-mail:sclkim@cnu.ac.kr, Tel:+82-42-821-5440)

Professor, Department of Computer Engineering, Chungnam National University, Daejeon, Korea, 34134

Open Access <http://doi.org/10.6109/jkiice.2019.23.10.1275>

print ISSN: 2234-4772 online ISSN: 2288-4165

©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.
Copyright © The Korea Institute of Information and Communication Engineering.

I. 서 론

다양한 신호의 변조 기술들이 무선 통신 시스템에서 사용되고 있다. 주파수, 시간 및 공간 차원에 대한 무선 스펙트럼 모니터링 및 신호 분류는 여전히 활발한 연구 문제이다. 신호 변조 방식의 종류가 늘어남으로써 해당 신호를 올바르게 복조하기 위해 신호의 변조 방식 식별의 중요성이 커지고 있다. 일반적으로 신호의 변조 방식에 대한 정보를 알려주지만, 특수한 경우에는 정보를 알리지 않는 경우가 존재한다. 통신 신호의 변조 인식 기술은 사업자 규제, 통신 전파 방해 방지 및 사용자 식별 등 여러 가지 응용 기술로 중요한 의미를 가지고 있다 [1,2].

AMC (Automatic Modulation Classification)는 사용자가 작동 대역 내에서 변조 모드를 식별하여 통신 재구성 및 전파 환경 분석하는데 도움이 되므로 반드시 필요하다 [2]. AMC는 다중 경로 전파, 주파수 선택성 및 채널의 시변 특성과 더불어 들어오는 신호에 대한 사전 지식이 없는 비협조적 환경에서 특히 어려운 작업이다 [3]. AMC는 매개 변수에 대한 제한된 지식만 사용할 수 있는 경우 신호에서 디지털 기저 대역 정보를 얻는 데 필수적인 역할을 한다. 이러한 기술은 지난 수십 년 동안 연구자들로부터 많은 주목을 받아온 지능형인지 무선 및 이상 탐지와 같은 군사 및 민간 응용 분야에서 널리 사용된다 [1-5].

기존의 AMC에 대한 연구내용을 LB(likelihood based)와 FB(feature based), 두 가지 주요 범주로 나눌 수 있다 [3]. FB 접근법의 분류 서브 시스템은 데이터 세트로부터 추출된 이들 별개의 입력 특징에 기초하여 정확한 목표 그룹을 식별한다. 사전 정보가 없는 신호의 변조 방식을 예측하기 위하여 기계학습을 이용한 다양한 방법들이 시도되고 있다 [1-4].

본 논문에서는 현재 음성인식과 자연어 처리기술 등 연속적인 데이터를 분류하는 데에 성능이 좋다고 알려진 기계학습의 한 방법인 RNN(Recurrent Neural Network)이 확장된 LSTM(Long Short-Term Memory)을 이용하여 신호를 입력받아 레이블링 된 데이터의 분류를 서술했으며 신호의 특징을 추출하기 위하여 진폭과 위상, 동상(in-phase) 반송파와 직각 위상(quadrature) 반송파를 함께 입력으로 사용하여 신호의 변조방식을 식별하는 프로그램을 제안한다.

II. 변조인식 시스템

2.1. 문제정의




Fig. 1 Block diagram of Classification

변조 시스템의 블록 다이어그램은 그림 1과 같다. 기존에 일반적인 접근법의 AMC는 수신된 기저 대역 파형 또는 중간 주파수로부터 추출된 정보를 이용해서 변조 모드를 인식하는 N개의 클래스 분류 문제로 구성되어 있다 [3]. 문제를 정의하면, $s(t)$ 는 송신신호의 무잡음 복소 기저 대역 포락선이고 $n(t)$ 는 영 평균을 갖는 가산 백색 가우스 잡음(AWGN)이고, $c(t)$ 는 송신된 무선 채널의 시간 변화 임펄스 응답일 경우에, 수신신호 $r(t)$ 은 다음의 식(1)과 같이 모델링될 수 있다.

$$r(t) = s(t) * c(t) + n(t). \quad (1)$$

수신된 신호 $r(t)$ 는 일반적으로 수학적 연산 및 하드웨어 설계와 유연성 및 단순성을 위해 IQ 형식의 복소신호로 표현된다. 복소신호를 직교 좌표를 통해 나타내면 X축은 실수부, Y축은 허수부로 표현된다. 실수부는 동상위상 $I = A \cos(\theta)$ 으로, 허수부는 직교-성분 $Q = A \sin(\theta)$ 으로 표현된다. 여기서 A 는 수신 신호 $r(x)$ 의 순간 진폭이고 θ 는 수신신호의 위상이다.

송신기로부터의 디지털 변조 신호 $s(t)$ 는 다음과 같이 표현될 수 있다.

$$s(t) = (A_c + jA_s)e^{j2\pi ft + \theta} g(t - nT) \quad (2)$$

여기서, $0 \leq t \leq NT$ 이고, A_c 와 A_s 는 동상과 직각위상성분의 크기이다. $g(t - nT)$ 는 디지털 샘플링 펄스 신호를 나타낸다. ASK, FSK과 PSK에서는 A_s 는 영이다 [2].

우리의 연구 목적은 어떤 변조에 대응하는 구체적인 복조기능에 대한 정보 없이, 주어진 데이터 특징을 학습하여 자동으로 분류하는 알고리즘을 개발하는데 있다.

기계학습 모델의 학습과 평가를 위해 RadioML[6]에

서 제시하고 있는 공개된 변조 신호 데이터 세트의 일부를 이용하였다. 여기서 제시하는 데이터 세트인 RadioML은 GNU Radio[7]을 사용하여 생성된 신호 데이터로 주파수 편차, 초당 샘플 수 편차, 백색 가우시안 소음이 부가된 다중 경로 페이딩과 같은 실제 환경에 있는 통신 채널의 불완전한 특징을 포함한다. 또한 무선통신 신호는 실제로 합성해서 만들기 때문에 실제 신호와 같은 특성을 가진 매개변수를 포함하고 있는 데이터를 사용하여 학습하는 의미가 있다.

2.2. AMC를 위한 딥러닝 모델

AMC에 대한 기존의 FB 접근법은 주기적 순간과 같은 전문가 기능을 사용한다[3,8]. 사전 정보가 없는 신호의 변조방식을 예측하기 위하여 기계학습을 이용한 다양한 방법들이 시도되고 있다. 최근에 제안된 AMC를 위한 딥러닝 기반 모델은 Convolutional Neural Network (CNN) 기반의 분류기를 사용했다 [4]. CNN 모델은 시간 도메인에서 IQ데이터에서 작동하고 다양한 신호 대 잡음비에 대해 서로 다른 정합필터를 학습했다. 이와 유사한 장기적인 시간 표현을 배울 수 있는 LSTM 기반의 딥러닝 분류 방법들이 제안되었다[1][2]. 또한 분류 결과를 향상시키기 위해 CNN과 LSTM 모듈을 결합한 복잡한 시작 모듈이 제안되었다[9]. 우리는 변조된 신호의 진폭 및 위상, 동상(In-phase) 반송파, 직각 위상(Quadrature-phase) 반송파의 값을 LSTM 모델의 입력 데이터로 사용하여 분류하는 방법을 제안한다.

III. 시스템 설계

3.1. 입력 데이터(Input)

우리는 RadioML[6]에 제시된 표준 변조 데이터 세트는 제안된 분류자의 성능을 훈련 및 평가하기 위한 기준선으로 사용한다. RadioML에서 제공된 여러 SNR (signal-to-noise ratio)에서 시뮬레이션된 아날로그 변조와 디지털 변조 신호를 데이터로 사용하였다. 아날로그와 디지털 변조 방식으로 변조된 10 종류의 신호를 0에서부터 18까지의 SNR에 따라 각각 6,000개의 데이터로 60만 개의 데이터 셋을 설정하였다. 각 데이터는 128개의 샘플을 포함하며, 이는 128 μ s 동안의 신호를 의미한다. 이 중 훈련 데이터를 70%로 설정하여 훈련 데이

터 420,000개, 검증 데이터 180,000개로 데이터 셋을 구성한다.

기존의 분류 방법들이 사용하는 통계적으로 최적화된 특징값 외에 신호의 진폭(A), 위상(θ), 동상 반송파(I)와 직각 위상 반송파(Q)의 값을 입력으로 사용한다. 사용한 신호에 대해서 전체 파라미터 목록과 포함된 변조 방식은 표 1에서 확인할 수 있다.

Table. 1 Dataset of various modulations

Modulation mode	8PSK, AM-DSB, BPSK, PFSK, GFSK, PAM4, QAM16, QAM64, QPSK, WBFM
Samples per symbol	4
Sample Length	128
SNR Range	0dB ~ +18dB
Number of training samples	420,000
Numer of test samples	180,000

3.2. 데이터 전처리

사용하는 데이터는 각 변조 방식과 신호 대 잡음비에 따라 시간 영역에서의 동상 반송파와 직각 위상 반송파 값으로 이루어져 있다. 이 데이터의 값인 동상 반송파(I)와 직각 위상 반송파(Q)만이 아니라 두 값을 각각 실수부와 허수부로 갖는 극좌표의 크기와 위상을 구해 얻은 신호의 진폭(A)과 위상(θ)을 계산하여 4차 채널의 데이터 집합을 LSTM에서의 특징 추출을 위해 사용하였다. 또한 효과적인 학습을 위해 신호의 데이터 값은 -1에서 1 사이의 범위로 정규화 하였다. 전체 데이터에 대해 임의적으로 선택하여 테스트 세트를 결정하고 그 외 나머지를 훈련 세트로 사용한다.

3.3. LSTM (Long Short-Term memory)

RNN(Recurrent Neural Networks)은 반복적이고 순차적인 데이터를 학습하는데 특화된 인공지능의 한 종류로서 음성인식, 언어 모델링, 번역 등 여러 분야에서 성공적인 성과를 내고 있다[10]. 우리는 기존 RNN 알고리즘에서 적절한 정보와 그 정보를 사용하는 지점 사이가 멀 경우 학습을 위한 역전파시 경사 값이 점차 0에 수렴하는 장기 의존성 문제를 해결하기 위해 제안된 LSTM (Long-Short Term Memory)[10]으로 학습을 시켜보고자 한다. LSTM은 기존 RNN의 Hidden Layer를

Forget Gate, Input Gate, Output Gate라는 세 가지 게이트로 대체한 구조이다. Forget Gate는 셀 스테이트에서 어떤 정보를 버릴지 선택하는 역할을 하고 Input Gate는 어떤 값을 업데이트할 지를 결정하는 역할을 한다. 마지막으로 Output Gate는 어떤 값을 출력할지에 대한 결정을 해주는 역할을 한다.

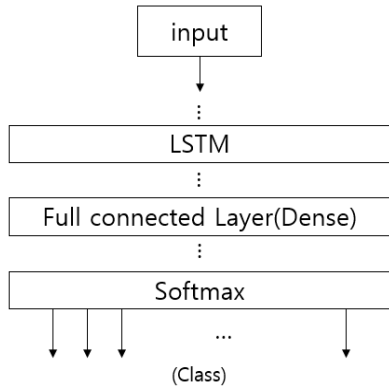


Fig. 2 LSTM for Classification

그림 2와 같이 LSTM 층과 Full connected Layer 층을 혼합한 학습 모델을 구성하였다. 본 논문에서는 이후 Full connected Layer를 Dense 라는 명칭으로 사용한다. 모든 타임스텝마다 128개의 셀로 이루어진 LSTM 층은 128개의 출력을 낸다. 그리고 이것은 Dense 구조를 통과한다. 최종 층인 Softmax 층은 분류된 특징들을 10개의 출력 클래스 중 하나에 대응한다.

3.4. 제안된 학습 모델

앞서 제시한 시스템의 자세한 학습 모델 구성은 그림 3와 같다. 연속된 128개씩의 동상 반송파, 직각 위상 반송파 그리고 이를 통해 계산된 진폭과 위상 값들의 1차원 벡터를 입력으로 한다.

입력은 먼저 2개의 LSTM 층을 지나게 되며, 각 LSTM 층은 hyperbolic tangent를 활성화 함수로 갖는다. LSTM 셀의 수와 레이어 깊이는 각각 64에서 256 및 1에서 3까지 실험해본 결과 셀의 수는 128일 때 레이어 깊이는 2일 때 최고 성능을 보이는 것을 확인하여 이를 적용한다.

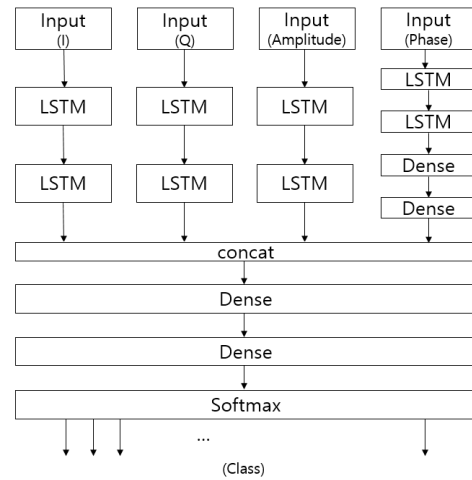


Fig. 3 Four channel Classifier with two layer LSTM

위상 입력에 대해서는 2개의 Dense 층을 더 통과하며, 이 때 Dense 층의 활성화 함수는 모두 ReLU (Rectified Linear Unit) 이다. 이 때 얻은 출력 값들을 연결하여 하나의 벡터를 만들며 2개의 Dense 층으로 이루어진 구조를 통과한다. 그리고 최종 층인 Softmax 층을 통과하여 10개 클래스 중 하나로 대응된다. 과적합을 방지하기 위해 Dropout[11] 비율은 0.5로 둔다. 또한 전반적인 데이터를 반영할 수 있으면서 학습의 각 반복의 소요 시간을 줄이기 위하여 배치 크기를 128로 설정한다. 손실함수는 Tensorflow에 있는 함수 softmax cross entropy with logits[12]를 사용한다. 그리고 최적화 함수로는 학습률은 0.001의 Adam optimizer[13]을 사용한다. 이를 통해 손실함수를 최소화하는 방향으로 학습한다.

IV. 실험 결과

언급한 데이터세트에 대한 모델의 분류 정확도는 다음 절에서 설명한다. 위에서 제시된 IQ 데이터 세트에 대한 두층 LSTM 모델은 비교를 위한 기준 모델로 사용한다. 신호의 변조방식을 식별하기 위하여 일반적으로 신호를 표현하는 특징인 진폭과 위상, 혹은 동상 반송파와 직각 위상 반송파의 값만으로 학습할 경우와 모든 특징을 함께 사용하여 학습할 경우의 결과 비교는 아래 그림 4의 그래프와 같다.




Fig. 4 Classification accuracy comparison of IQ, AP and IQAP

동상 반송파와 직각 위상 반송파만을 사용할 경우 평균적인 정확도는 62.31%로 저조하다. 하지만 진폭과 위상값을 이용해 구분하게 될 경우 평균 73.63%로 더 정확도가 높다. 그러나 동상 반송파, 직각 위상 반송파와 진폭과 위상을 모두 사용하여 구분할 경우에는 평균 77.03%의 정확도로 위의 두 경우보다 높은 정확도로 변조 방식을 구분한다.

위 결과를 보았을 때 위상의 값이 신호의 변조 방식을 구분하는 데에 영향력이 높다고 생각하여 위상에 대하여 추가로 Dense 층을 적용하였으며 가장 높은 정확도인 평균 79.78%의 정확도로 변조 방식을 구분할 수 있었다. 위 그래프에서 PDense는 이 층을 의미한다. 위 그래프에서 PDense의 계수는 이 층의 수를 의미하며 Dense의 계수는 Dense 층의 수를 의미한다. 위 실험의 결과 전반적인 우리의 제안된 모델의 성능은 [1]에서 제시한 IQ 데이터에 적용된 LSTM 모델보다 훨씬 더 나은 것으로 나타났다.

우리는 학습기의 성능을 개선하기 위해서 몇 가지 중요한 변수 값을 조절해서 그것에 따라 정확도 얼마나 개선이 되는지 확인하는 추가적인 실험을 수행했다. 그림 5에서는 각각의 SNR에 대해서 Dense, PDense에 따라 정확도가 얼마나 향상되는지를 보여준다. 각각의 SNR에 대해서 Dense 층의 수를 늘여가면서 정확도 향상을 확인한 결과 3개의 Dense에서 최대치를 보이는 것을 확인할 수 있다. 그리고 위상 값에 대해 부공간을 더 나누기 위해 위상에 대한 Dense를 늘려보았고, 그 결과 2개

의 dense에서 최대의 정확도를 보이는 것을 확인 할 수 있었다.




Fig. 5 Classification accuracy comparison of PDense(P) and Dense(D)




Fig. 6 Confusion Matrix (CM) of the optimal case.

실험 결과를 더 잘 이해하기 위해, 제안된 LSTM 모델에 대한 CM을 추가적으로 살펴보자. 그림 6에서는 신호의 네 가지 특성을 모두 사용하고 위상에 대하여 Dense층을 적용하였을 때의 신호 대 잡음 비 0dB에서 18dB 범위 신호의 CM를 보여준다. y축은 실제 신호의 변조방식이고 x축은 예측한 변조방식을 보여준다. AM-DSB와 WBFM의 경우 신호를 128 길이로 볼 경우 신호의 특징이 비슷하여 구분하는 데 어려움이 있다. 또한 QAM16과 QAM64도 신호의 특징을 통해 쉽게 구분하지 못한다. 하지만, 그림 4의 실험의 결과를 보면 전반적

으로 제안된 모델의 성능은 IQ데이터에 적용된 LSTM 모델보다 훨씬 더 정확도가 증가함을 알 수 있다.

V. 결론

본 논문에서는 RNN 기법 중 LSTM을 이용하여 신호의 변조 방식을 분류하는 방법을 제안하였다. LSTM에 레이블링 된 신호의 진폭, 위상, 동상 반송파, 직각 위상 반송파를 각각 통과시켜 학습할 때 신호의 진폭과 위상만을 이용하여 학습하였을 때보다 성능이 개선되었다. 또한 신호의 네 가지 값들이 LSTM을 통과한 이후 위상에 대하여 Dense를 통과시킬 경우 위의 네 가지 값에 대해서만 Dense를 적용했을 때보다 분류 성능이 개선됨을 알 수 있었다.

AMC관련 주파수, 시간 및 공간 차원에 대한 무선 스펙트럼 모니터링 및 신호와 관련한 데이터 분석은 활발한 연구 문제이다[1,5]. 이와 관련해 채널 모델을 실제 배포 조건에 맞추고, 큰 양의 레이블이 붙은 데이터 세트를 만드는 것은 어렵지만 학습의 정확도를 높이는 데 중요한 작업이다. 이후 연구에서 실제 무선 통신 시스템이 잘 반영된 빅데이터를 수집하고 이 데이터에 딥러닝을 적용해 속도와 성능 면에서 개선된 알고리즘을 개발할 계획이다.

ACKNOWLEDGEMENT

This work was supported by research fund of Chungnam National University.

REFERENCES

- [1] S. Rajendran, W. Meert, D. Giustiniano, V. Lenders, and S. Pollin, "Deep learning models for wireless signal classification with distributed low-cost spectrum sensors," *IEEE Transactions on Cognitive Communications and Networking*, vol. 4, no. 3, pp. 433-445, Sep. 2018.
- [2] D. Zhang, W. Ding, B. Zhang, C. Xie, H. Li, , C. Liu, and J. Han, "Automatic modulation classification based on deep learning for unmanned aerial vehicles," *Sensors*, vol.18, no. 3, pii: E924, 2018.
- [3] O. A. Dobre, A. Abdi, Y. Bar-Ness, and W. Su, "Survey of automatic modulation classification techniques: classical approaches and new trends," *IET Communications*, vol. 1, no. 2, pp. 137-156, Apr. 2007.
- [4] T. J. O'Shea, J. Corgan, and T. C. Clancy, "Convolutional radio modulation recognition networks," in *International Conference on Engineering Applications of Neural Networks*, Communications in Computer and Information Science, Springer, pp. 213-226, 2016.
- [5] T. J. O'Shea, T. Roy, and T. C. Clancy, "Over-the-air deep learning based radio signal classification," *IEEE Journal of Selected Topics in Signal Processing*, vol. 12, no. 1, pp. 168-179, Feb. 2018.
- [6] T. J. O'Shea, and N. West, "Radio machine learning dataset generation with GNU radio," in *Proceedings of the GNU Radio Conference*, vol. 1, no. 1, 2016.
- [7] GNU radio: tools for exploring the radio frequency spectrum [Internet]. Available: <http://www.gnuradio.org>.
- [8] W. A. Gardner, "Signal interception: a unifying theoretical framework for feature detection," *IEEE Transactions on Communications*, vol. 36, no. 8, pp. 897-906, Aug. 1988.
- [9] N. E. West, and T. O'Shea, "Deep architectures for modulation recognition," in *IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN)*, pp. 1-6, 2017.
- [10] S. Hochreiter, and J. U. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8, pp. 1735 - 1780, 1997.
- [11] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A simple way to prevent neural networks from overfitting," *The Journal of Machine Learning Research*, vol. 15, no. 1, pp. 1929-1958, 2014.
- [12] TensorFlow: A system for large-scale machine learning [Internet]. Available: <https://www.tensorflow.org/>.
- [13] D. P. Kingma, and J. Ba, "Adam: A method for stochastic optimization," in *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*, abs/1412.6980, 2014.



김한진(Hanjin Kim)

충남대학교 컴퓨터공학과 학사과정
※관심분야: 기계학습, 인공지능, 신호처리 등



김혁진(Hyeockjin Kim)

충남대학교 컴퓨터공학과, 학사(2019)
충남대학교 컴퓨터공학과, 석사과정
※관심분야: 기계학습, 인공지능, 신호처리 등



제준호(Junho Je)

충남대학교 컴퓨터공학과, 학사과정
※관심분야: 기계학습, 인공지능, 신호처리 등



김경섭(Kyungsup Kim)

서울대학교 수학과, 석사(1994)
KAIST 전기 및 전자공학과, 공학박사(2000)
현재 충남대학교 컴퓨터 공학과 교수(2004 -현재)
※관심분야: 기계학습, 인공지능, 신호처리 등