

ResNet과 GAF 기반 자동변조인식 성능 향상 연구

이 상 호*, 임 완 수°

Enhanced Automatic Modulation Recognition Performance Using ResNet and GAF

Sangho Lee*, Wansu Lim°

요 약

자동변조인식(AMR, Automatic Modulation Recognition)은 무선 통신에서 신뢰성과 효율성을 높이는 중요한 기술이다. 최근 AMR 연구는 딥러닝을 활용하여 성능을 개선하는 데 중점을 두고 있으며, 특히 IQ(In-phase and Quadrature) 성상도를 학습 데이터로 사용하는 다양한 딥러닝 모델이 제안되고 있다. 그러나 성상도는 신호의 시간적 특징을 포함하지 못하므로 시계열 데이터 처리가 필수인 AMR에서는 성능 향상에 한계가 있다. 이러한 문제를 해결하기 위해 본 논문은 시계열 데이터의 시간적 특징을 반영할 수 있는 GAF(Gramian Angular Field) 방식을 적용했다. GAF는 신호의 시간적 변화와 패턴을 효과적으로 나타내므로 기존 성상도 기법보다 더 다양한 정보를 제공한다. ResNet(Residual Neural Network) 모델에 GAF를 적용하여 변조를 인식한 결과, 기존 자동변조인식 기법보다 SNR -10dB에서 5dB에서 최소 5%에서 최대 15% 더 높은 정확도를 달성했다.

키워드 : 자동변조인식, 그라미안 각도 변환, 잔차 네트워크 모델

Key Words : Automatic Modulation Recognition(AMR), Gramian Angular Field(GAF), Residual Neural Network(ResNet)

ABSTRACT

Automatic Modulation Recognition (AMR) is a crucial technology for enhancing the reliability and efficiency of wireless communication. Recent AMR research has focused on improving performance by utilizing deep learning, with various models being proposed that use IQ constellations as training data. However, since constellations are tools for visualizing the signal state at a specific time, they fail to capture the temporal characteristics of the signal, which can lead to performance degradation. To address this issue, this paper proposes a novel visualization method called GAF that incorporates the temporal features of time-series data, along with the application of PCA for channel reduction and noise removal. The proposed GAF method effectively captures the temporal variations and patterns in the signal, providing more diverse information than traditional visualization techniques. Furthermore, applying this approach to a ResNet model resulted in 5% to 15% higher accuracy in the SNR range of -10dB to 5dB compared to other visualization techniques such as IQ constellations, GCC algorithms, and the traditional GAF method used in AMR.

* 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2024-00349885).

• First Author : Kumoh National Institute of Technology, Department of Computer Software Engineering, 20190826@kumoh.ac.kr, 정회원

° Corresponding Author : Sungkyunkwan University, Department of Electrical and Computer Engineering, wansu.lim@skku.edu, 정회원

논문번호 : 202409-197-B-RN, Received September 5, 2024; Revised November 17, 2024; Accepted December 3, 2024

I. 서 론

자동변조인식(AMR, Automatic Modulation Recognition)은 신호의 주파수, 진폭, 위상 등을 분석하여 송신부에서 사용한 변조 방식을 자동으로 판별하는 기술이다. AMR은 데이터 전송의 신뢰성을 높이고 대역폭 사용을 최적화함으로써 통신 시스템에서 중요한 기능을 수행한다^[1-3]. 특히, 가장 효율적인 복조 알고리즘을 실시간으로 선택할 수 있어, 전반적인 시스템 성능과 자원 사용률을 최적화할 수 있다. 이를 통해 통신 시스템의 자원을 더 효율적으로 활용하고, 데이터 품질을 향상시킨다. 더불어, 이 기술은 통신 보안을 강화하고, 다양한 시스템과의 호환성을 높여 유연성을 제공하며, 실시간 작동이 가능하므로 빠른 의사결정과 적응성이 가능하다^[4]. 이러한 장점으로 인해 AMR 연구가 활발하게 진행되고 있으며, 최근에는 딥러닝 기술을 AMR에 적용하여 변조 인식 성능이 계속 향상되고 있다. 딥러닝에서 데이터 전처리는 모델의 성능을 결정짓는 핵심적인 단계로, AMR 분야에서 중요한 역할을 한다. 효율적인 데이터 전처리는 딥러닝 모델이 신호의 중요한 특징을 효과적으로 학습하도록 하여 성능을 극대화할 수 있으며, 과적합을 방지하고 일반화 성능을 높인다^[5].

[6]은 여러 딥러닝 모델에 원본 IQ(In-phase and Quadrature) 데이터를 입력데이터로 사용하여 학습 및 평가하였다. AMR 기술이 SISO(Single Input and Single Output) 환경과 MIMO(Multiple Input and Multiple Output) 환경에서 효율성 있다는 것을 증명하는 실험을 진행했다. CNN(Convolutional Neural Network), LSTM(Long Short-Term Memory), RNN(Recurrent Neural Network) 등과 성능을 비교했다. 실험 결과 CNN 모델이 전체적으로 성능이 가장 좋았고, SNR(Signal-to-Noise Ratio)이 낮은 환경에서는 RNN 모델이 높은 정확도를 보였다. MIMO 및 SISO 환경에서 딥러닝이 자동변조인식을 잘 수행함을 보였지만, 이미지 처리에 주로 사용하는 CNN 모델에 복소수 IQ 데이터를 실험으로 사용했다.

[7]은 AMR을 위해 이미지 기반 딥러닝 모델을 설계하였다. CNN 기반 딥러닝 네트워크를 사용하여 특징을 추출한 후, 이를 이미지로 변환하여 변조 유형을 학습하였다. 제안한 모델은 다양한 벤치마크 모델과 성능을 비교했으며, 비교 결과 우수한 성능을 보였다. 그러나 IQ 성상도를 학습데이터로 사용한 모델과 성능 비교가 제시되지 않으므로 특징 데이터를 이미지로 변환하는 방식 자체에 효율성을 판단할 수 없다.

[8]은 신경망을 AMR에 적용하여 그동안 AMR에서 사용하던 기법(최대 우도 추정법, 패턴 인식 기술)의 높은 복잡성을 해결했다. 신경망은 CNN과 CNN을 확장한 GCN(Graph Convolutional Network)으로 구성했고, 신호의 실수부와 허수부를 2차원 행렬로 구성하여 입력으로 사용했다. 또한, CNN을 사용하여 신호의 특징을 추출하고, 그래프 매핑을 사용하여 하위 집합을 node와 edge로 구성된 그래프로 변환했다. 마지막으로 그래픽 데이터를 처리하는 GCN을 통해 신호의 변조 방식을 예측했다. 그러나 해당 방법도 IQ 성상도를 학습 데이터로 한 모델과 실험 결과가 없어 특징 추출 CNN의 사용이 효과적인지에 대한 비교가 불가하다.

기존 딥러닝 기반 AMR 연구는 IQ 원본 데이터보다 IQ 성상도를 학습 데이터로 많이 사용했다. IQ 성상도는 I축과 Q축을 사용하여 신호를 복소평면에 표시하는 시각화 기법이고, 신호의 변조 체계를 시각화하는 데 유용하다. [9]는 IQ 성상도와 IQ 원본데이터를 동시에 학습 데이터로 사용하여 특징을 추출한 후 분류를 진행했다. IQ 신호를 입력하여 IQ 원본 데이터와 IQ 성상도로 분할하고, IQ 성상도를 선형, 로그, 지수 변환하여 IQ 성상도의 시각적인 특징을 강화했다. 논문에서 제안한 딥러닝 모델은 타 CNN 계열 모델들에 비하여 낮은 SNR 및 높은 주파수 오프셋 환경에서 분류 정확도가 높았다. 하지만 논문에서 제안한 선형, 로그, 지수 변환을 수행할 때의 변수에 대한 정보가 제공되고 있지 않아 구현이 불가하다.

[10]은 밀도 및 위치 정보를 정확히 반영하지 못하는 IQ 성상도 문제를 해결하기 위해 IQ 신호의 밀도를 측정하여 이미지를 생성하는 GCC(Gradient Color Constellation) 알고리즘을 제안했다. GCC 결과로 밀도 정보가 포함된 성상도를 생성한 후, CNN 모델의 입력 데이터로 사용했다. 실험 결과 제안한 기법은 낮은 SNR에서 IQ 성상도보다 높은 정확도를 보였다. 하지만 해당 논문의 데이터는 QAM 변조 방식만 사용하여 다양한 변조 방식이 섞인 환경에서는 정확도를 측정할 수 없다.

[11]은 GAF(Gramian Angular Field) 알고리즘을 AMR에 적용했다. GAF는 각 시점 간의 시간적 상관관계를 극좌표 기반으로 표현하는 알고리즘으로, 기존 IQ 성상도와 달리 시계열 데이터를 이미지화할 때 시간적 특성을 포함할 수 있다. [11]은 GAF의 2가지 방식인 GADF(Gramian Angular Difference Field)와 GASF(Gramian Angular Summation Field) 방법 중 GASF 성상도만 사용하여 성능을 평가했다.

이에 본 논문은 GASF와 GADF를 병합하여 시계열

데이터의 시간 특성을 더 많이 확보하고자 한다. 이를 통해 AMR 정확도를 높이고, 통신시스템의 전체적인 효율성과 신뢰성, 그리고 보안을 향상할 수 있다.

II. AMR 향상을 위한 기존 시각화 기법

2.1 통신 데이터 시각화

최근 자동변조인식 연구는 통신 데이터를 시각화하여 딥러닝 모델의 학습 데이터로 활용하고 있다. 변조 방식은 신호의 주파수, 위상, 진폭 등의 복잡한 변화를 포함하며, 이러한 변화를 시각화된 이미지 형태로 변환하면 딥러닝 모델이 신호 패턴을 더 효과적으로 인식할 수 있다. 또한, 변조 방식은 고유한 형태를 보이고 있으므로 시각화하면 변조 유형 간 차이를 직관적으로 파악할 수 있어 변조 방식 인식 성능을 향상에 기여한다. 본 논문에서는 IQ 성상도, GCC 알고리즘, GASF, GADF 기법을 사용하여 데이터를 시각화하고, 이를 딥러닝 모델의 학습 데이터로 사용하여 성능을 비교한다.

2.1.1 IQ 성상도 기반 시각화

IQ 성상도는 통신 신호의 변조 방식을 시각적으로 표현하는 대표적인 방법이다. IQ 성상도는 I축과 Q축을 사용하여 신호를 복소 2차원 평면에 매핑한다. 각 변조 신호가 시간에 따라 어떤 위상과 진폭을 가지는지를 직관적으로 보여주며, 변조 방식에 따른 신호 간의 차이를 시각적으로 확인할 수 있다. 변조 신호는 점(clusters)으로 표현되며, 이 점들의 위치와 분포는 변조 방식에 따라 고유한 패턴을 형성한다. 예를 들어, QPSK 변조는 성상도에서 4개의 분리된 점이 형성되고, QAM 변조는 더 많은 점이 성상도에 나타난다. IQ 성상도의 가장 큰 특징은 신호의 위상과 진폭 변화를 시각적으로 표현하여, 딥러닝 모델이 변조 방식의 패턴을 쉽게 학습할 수 있도록 돕는다는 점이다. 이를 통해 자동변조인식




그림 1. 변조 방식별 IQ 성상도
Fig. 1. IQ Constellation Diagram for Modulations

에서 각 변조 방식을 효과적으로 구분할 수 있다. 그림 1은 5가지 변조방식을 SNR 18dB에서 표현한 IQ 성상도이다.

2.1.2 GCC 기반 시각화

GCC는 기존 IQ 성상도와 비교하여 데이터 밀도 정보를 더욱 직관적으로 나타내는 새로운 유형의 성상도이다^[10]. 그림 2는 GCC를 적용하여 생성한 성상도이고, 색상으로 밀도 변화를 나타냈다. 밀도가 낮은 영역은 노란색으로, 다음은 초록색, 그다음은 파란색, 가장 높은 밀도는 빨간색으로 표현하여 시각적으로 밀도 차이를 명확히 구분할 수 있다.




그림 2. 변조 방식별 GCC 성상도
Fig. 2. GCC image for Modulations

2.1.3 GASF 기반 시각화

[11]과 [12]는 GASF를 이용하여 자동변조인식을 수행했다. I 데이터, Q 데이터, IQ 데이터를 각각 GASF로 계산한 후 3채널 이미지를 생성했다. 그림 3은 변조 방식을 GASF를 이용하여 표현한 예시이다.




그림 3. 변조방식별 GASF 이미지
Fig. 3. GASF Image for Modulations

III. AMR 향상을 위한 GAF 기법

그림 4는 본 논문에서 제안한 자동변조인식 연구 흐름도이다. 먼저 IQ 데이터를 GAF 기법으로 전처리한 후, ResNet(Residual Neural Network) 모델을 통해 학습 및 평가를 수행한다. 전처리에서는 IQ 데이터를 I 데이터와 Q 데이터로 분리한 후, 각각 GASF와 GADF 알고리즘을 적용한다. GADF와 GASF를 통해 전처리된 데이터를 결합하여 4채널 데이터를 만든 후, PCA(Principal Component Analysis) 기법을 활용하여 3채널 데이터로 변환한다. 이러한 전처리 과정을 거친 데이터를 ResNet50 모델에 입력하여 학습한다. 제안한 AMR은 기존 논문에서 사용한 IQ 성상도, GCC 이미지, GASF 기법기반 AMR과 정확도를 비교한다.




그림 4. 연구 흐름도
Fig. 4. Workflow of the Research

3.1 GAF 기반 시각화

GAF는 삼각함수를 이용하여 시계열 데이터의 시간적 특성을 시각화하는 방법이다. GAF는 데이터의 합과 차를 각각 코사인 함수와 사인 함수를 사용하여 시각화한다. GAF는 GASF와 GADF 두 가지 형태로 구분되며, 각각 시계열 데이터의 각도 합과 차를 나타낸다. GAF 기법은 세 단계로 진행되고, 첫 번째 단계는 식 (1)에 따라 데이터를 -1에서 1 범위로 정규화한다.

$$ScaledData_i = \frac{2 \cdot data_i - max - min}{max - min} \quad (1)$$

두 번째 단계는 극좌표계를 이용하여 시계열 데이터를 각도로 변환하고, 변환된 각도는 GAF 행렬을 구성하는 데 사용한다. 식 (2)는 시계열 데이터를 각도로

변환하는 방법이다.

$$\Phi_i = \arccos(ScaledData_i) \quad (2)$$

마지막 단계는 시계열 데이터 각도의 합과 차를 식 (3)과 식 (4)에 대입하여 GASF와 GADF를 각각 도출한다.

$$GASF_{ij} = \cos(\Phi_i + \Phi_j) \quad (3)$$

$$GADF_{ij} = \sin(\Phi_i - \Phi_j) \quad (4)$$

3.2 제안한 GAF 알고리즘

본 논문은 GASF와 GADF 알고리즘을 결합한 새로운 GAF 기법을 제안한다. 그림 5는 제안한 GAF 흐름도이고 IQ 데이터를 I 데이터와 Q 데이터로 분리한 후, 각각에 GASF와 GADF 알고리즘을 적용하여 다양한 특징을 학습한다. GAF로 전처리한 데이터는 4채널이므로 PCA 기법을 사용하여 3채널 이미지로 변환한다. PCA는 정보 손실을 최소화하고 중요한 특성을 보존하기 때문에 채널 축소에 사용했다^[13-14]. 이미지를 입력으로 사용하는 딥러닝 모델은 RGB 이미지를 처리하는데 최적화되어 있으므로, 입력 데이터를 3채널로 변환은 모델의 학습 성능과 처리 효율성을 향상할 수 있다.^[15,16]




그림 5. 제안한 GAF 알고리즘
Fig. 5. Proposed GAF Algorithm




그림 6. 변조방식별 제안한 GAF 이미지
Fig. 6. GAF Image for Modulations

그림 6은 본 논문에서 사용한 GAF 결과 예시이다. GAF 이미지에서 왼쪽 위 끝에서 오른쪽 아래로 이동하며 시간이 증가하고 시간의 흐름에 따른 종속성을 보존한다. 따라서 IQ 성상도는 시간 상관관계를 표현하지 못하지만, GAF는 시간적 정보를 시각적으로 반영할 수 있다. 또한, GAF 이미지는 원시 시계열 데이터의 값과 각도 정보도 포함하므로 원시 데이터를 복구할 수 있다.

IV. 실험

4.1 사용 데이터 및 모델

본 연구에서 사용한 데이터는 AMR 분야에서 많이 사용하는 RadioML 2016.10A^[17] 데이터이다. RadioML 데이터는 신호 분류 및 인식 문제를 해결하기 위해 만들어졌으며, 다양한 변조 방식과 SNR 조건에서의 신호 데이터를 제공한다. 또한, 실제 통신 환경을 모사하기 위해 가산성 백색 가우시안 잡음(AWGN)과 다중 경로 페이딩 등을 포함하고 있다. 본 연구는 BPSK, QPSK, 8PSK, 16QAM, 64QAM 등 다섯 가지 변조 방식을 사용한다. SNR은 -20dB에서 18dB까지 2dB마다 성능을 평가했으며, 각 변조 방식당 20,000개의 데이터가 포함되어 총 100,000개 데이터를 사용했다. 데이터는 학습 데이터, 검증 데이터, 테스트 데이터로 나누었으며, 비율은 각각 8:1:1이다. 학습에는 ResNet50 모델^[18]을 사용하였고, 학습률은 0.0001로 설정하였다. 최적화 알고리즘으로는 학습 속도를 높이고 모멘텀을 활용하여 학습 과정의 불안정성을 줄이는 동시에 학습률을 동적으로 조정함으로써 경사 하강 과

정의 과도한 진동을 방지하는 Adam(Adaptive Moment Estimation)을 사용하였다. ResNet50 모델의 구조는 그림 7에 제시되어 있다^[18]. ResNet50은 딥러닝 모델의 깊이를 증가시키면서도 성능 저하를 방지하기 위해 설계된 잔차 네트워크(Residual Network)로, 입력을 받는 Initial Block과 반복되는 ResNet Block으로 구성되어 있다. 각 ResNet Block은 1x1, 3x3, 1x1 컨볼루션 레이어를 포함하고, 분류를 위해 모델 끝에는 분류 레이어를 추가된다. Block 사이에는 잔차 연결(Residual Connection)이 적용되어 있어, 네트워크의 깊이가 증가할 때 발생할 수 있는 기울기 소실(Vanishing Gradient) 및 기울기 급증(Exploding Gradient) 문제를 효과적으로 해결할 수 있다. 이러한 구조 덕분에 ResNet50은 매우 깊은 네트워크 구조에서도 안정적인 학습이 가능하며, 성능이 향상될 수 있다.

4.2 실험 결과

그림 8은 다양한 데이터 시각화 기법의 정확도를 SNR에 따라 비교한 그래프이며, 표 1은 시각화 기법에 따른 변조 인식 정확도를 비교한 표이다. 제안한 GAF 방법은 SNR -10dB에서 5dB 범위에서 기존 IQ 성상도보다 약 5%에서 15% 더 높은 정확도를 보인다. 또한, 제안한 기법은 GASF 기법에 비해 대부분 SNR에서 5%에서 10% 높은 정확도를 나타낸다. GCC 기법에 비해서도 모든 SNR 구간에서 높은 정확도를 보인다. 특히, 0dB SNR에서 IQ 성상도와 GASF의 정확도는 각각 66.4%와 68.6%지만 제안한 방식의 정확도는 82.6%로 매우 높았다.

제안한 기법의 정확도는 높은 SNR에서 다른 기법들에 비해 다소 낮은 경향이 있다. 그러나 높은 SNR에서도 약 90%의 인식률을 달성하여 실제 변조 인식 운영에 충분히 효과적이다. 또한, 통신은 높은 SNR뿐 아니라




그림 7. ResNet50 모델 구조
Fig. 7. ResNet50 Model Architecture




그림 8. 데이터 시각화 방법별 정확도 비교
Fig. 8. Comparison of Accuracy by Data Visualization Methods

표 1. SNR에 따른 시각화 기법별 정확도

Table 1. Accuracy by Visualization Method According to SNR.

	SNR (dB)	-20	-10	0	10	18
Acc	IQ Constellation	0.188	0.246	0.664	0.91	0.912
	GCC ^[11]	0.196	0.226	0.602	0.898	0.902
	GASF ^[12]	0.182	0.288	0.686	0.834	0.812
	Proposed	0.192	0.286	0.826	0.9	0.896

중간 SNR 상황에서도 빈번히 발생한다. 제안한 방법은 중간 SNR 범위에서 다른 기법들보다 월등히 높은 성능을 보여주며, 다양한 SNR 조건에서도 안정적이고 효율적인 성능을 제공한다.

그림 9는 변조 방식별 정확도를 SNR에 따라 비교한 결과를 보여준다. PSK 계열의 신호는 잘 분류되지만, QAM64은 상대적으로 분류 성능이 낮았다. 그림 10은 제안한 방식의 SNR에 따른 혼동 행렬이고, 낮은 SNR에서는 거의 모든 변조 방식의 분류가 어려웠지만, SNR 0dB 이상에서는 효과적으로 분류됐다. 그러나 64QAM을 16QAM으로 잘못 분류하는 경우가 지속해




그림 9. 변조 방식별 정확도

Fig. 9. Accuracy by Modulation Type

서 발생했다. 이는 QAM 변조 방식이 잡음에 취약한 특징을 가지고 있기 때문이다. 특히, 위상 잡음이나 진폭 왜곡과 같은 신호 왜곡이 발생할 경우 성상도가 왜곡되면서 두 변조 방식이 혼동될 가능성이 높아진다. 이러한 결과들은 제안한 GAF 알고리즘이 기존의 IQ 성상도, GCC 및 GASF를 사용한 GAF 시각화 기법들에 비해 통신 데이터에서 더 많은 특징을 추출하여 높은 정확도를 달성할 수 있음을 입증한다.




그림 10. SNR에 따른 혼동 행렬. (a) 전체 SNR에 대한 혼동행렬. (b) -20dB에 대한 혼동행렬. (c) -10dB에 대한 혼동행렬. (d) 0dB에 대한 혼동행렬. (e) 10dB에 대한 혼동행렬. (f) 18dB에 대한 혼동행렬.

Fig. 10. Confusion matrices for different SNRs. (a) Confusion matrix for all SNRs. (b) Confusion matrix for -20dB. (c) Confusion matrix for -10dB. (d) Confusion matrix for 0dB. (e) Confusion matrix for 10dB. (f) Confusion matrix for 18dB.

V. 결 론

본 논문은 IQ 데이터를 분할 후 I와 Q 신호에 GASF와 GADF 기법을 각각 적용하고, PCA를 통하여 채널을 축소시키는 새로운 데이터 전처리 기법을 제안하고 이를 자동변조인식 기술에 적용했다. 변조 유형은 RadioML 2016 데이터의 BPSK, QPSK, 8PSK, 16QAM, 64QAM 등을 이용했다. 제안한 전처리 기법의 우수성을 검증하기 위해 IQ 성상도, GCC 알고리즘, 그리고 GASF 기반 GAF 방법과 성능을 비교했다. 시뮬레이션 결과, 제안된 기법은 -10dB에서 5dB의 SNR 구간에서 기존 자동변조인식 기법에 비해 최소 5%에서 최대 15% 더 높은 정확도를 나타냈으며, GASF 한 가지만 사용한 기존 GAF 기법에 비해서도 SNR 대부분 구간에서 더 높은 정확도를 보였다. 이를 통해 제안한 GAF 알고리즘이 기존 GAF 기법 및 IQ 성상도를 사용하는 방법보다 우수한 성능을 발휘하며, 특히 낮은 SNR 환경에서 더욱더 효과적임을 입증했다. 통신시스템은 single carrier뿐 아니라 multi carrier도 많이 사용하고 있다. 자동 변조 인식 기법도 multi carrier 환경에 대응할 수 있도록 확장돼야 하며, 향후 연구에 multi carrier를 포함한 다양한 통신 환경과 시나리오를 반영할 계획이다.

References

- [1] M. Lee, M. Chae, and W. Lim, "Research on automatic modulation recognition using Vision Transformer," *J. KICS*, vol. 49, no. 8, pp. 1074-1081, 2024.
- [2] S. Lee, E. Cha, M. Chae, and W. Lim, "Research on automatic modulation recognition technology based on TimeSformer," in *Proc. KICS*, Gyeongsangbuk-do, South Korea, Nov. 2023.
- [3] H. Cho, J. Park, M. Chae, H. Lee, and W. Lim, "Protocol structure and sequence detection method for multi-protocol analysis," *J. KICS*, vol. 49, no. 4, pp. 556-566, 2024.
- [4] K. Ma, Y. Zhou, and J. Chen, "CNN-based automatic modulation recognition of wireless signal," *2020 IEEE 3rd ICISCAE*, pp. 654-659, Dalian, China, 2020.
- [5] Z. Mundargi, S. Bhatti, and A. Chandra, "PrePy-A customize library for data pre-

- processing in Python," *2023 Int. Conf. Advancement in Technol. (ICONAT)*, Goa, India, 2023.
- [6] F. Zhang, C. Luo, J. Xu, Y. Luo, and F.-C. Zheng, "Deep learning-based automatic modulation recognition: Models, datasets, and challenges," *Digital Signal Process.*, vol. 129, no. 103650, 2022.
(Available: <https://arxiv.org/abs/2207.09647>)
- [7] S.-H. Kim, C.-B. Moon, K.-H. Kwon, and D.-S. Kim, "Design of the image-based deep learning model using a pre-training deep learning network," *J. KICS*, vol. 47, no. 4, pp. 615-624, 2022.
- [8] Y. Liu, Y. Liu, and C. Yang, "Modulation recognition with graph convolutional network," *IEEE Wireless Commun. Lett.*, vol. 9, no. 5, pp. 624-627, May 2020.
- [9] H. Han, et al., "Automatic modulation recognition based on deep-learning features fusion of signal and constellation diagram," *Electr.*, vol. 12, no. 3, Article 552, Jan. 2023.
(<https://doi.org/10.3390/electronics12030552>)
- [10] G. Huang, et al., "Modulation classification of MQAM signals based on gradient color constellation and deep learning," *2021 IWCMC*, IEEE, 2021.
- [11] J.-Y. Park, D.-H. Seo, and H.-W. Nam, "Deep-learning-based automatic modulation classification using imaging algorithm," *J. KIEES*, vol. 32, no. 4, pp. 328-333, 2021.
- [12] Y. Shi, et al., "GAF-MAE: A self-supervised automatic modulation classification method based on Gramian angular field and masked autoencoder," *IEEE Trans. Cognitive Commun. and Netw.*, 2023.
- [13] K.-M. Lee and C.-H. Lin, "A new image analysis method based on regression manifold 3-D PCA," *J. Inst. Internet, Broadcasting and Commun.*, vol. 22, no. 2, pp. 103-108, Apr. 2022.
(<http://doi.org/10.7236/JIIBC.2022.22.2.103>)
- [14] S. Ko and M. Park, "Image classification algorithm combining principal component analysis and complex valued neural network," *J.*

- KICS*, vol. 48, no. 8, pp. 1012-1022, 2023.
- [15] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," in *Proc. ICLR*, 2015.
- [16] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," in *Proc. 25th Int. Conf. Neural Inf. Process. Syst.*, pp. 1097-1105, 2017.
- [17] T. J. O'Shea and N. West, "Radio machine learning dataset generation with GNU Radio," in *Proc. GNU Radio Conf.*, vol. 1, no. 1, Sep. 2016.
(Available: <https://pubs.gnuradio.org/index.php/grcon/article/view/11>)
- [18] K. He, et al., "Deep residual learning for image recognition," in *Proc. IEEE Conf. Comput. Vision and Pattern Recognition*, 2016.

이 상 호 (Sangho Lee)

2019년 3월~현재 : 금오공과대학교 컴퓨터소프트웨어
공학과

<관심분야> 자동변조인식, 머신러닝

[ORCID:0009-0007-9164-8265]

임 완 수 (Wansu Lim)

2024년 3월~현재 : 성균관대학교 전자전기공학부 교수

<관심분야> 통신 프로토콜, 기계학습, 자동채널코딩인
식

[ORCID:0000-0003-2533-3496]