

Lightweight Data Processing Scheme based on Machine Learning for 5G DMRS Index Classification

5G DMRS 인덱스 분류를 위한 머신 러닝 기반의 경량 데이터 처리 기술

Jongseok Kim¹, Seungwoo Kang², Ohyun Jo³

김종석¹, 강승우², 조오현³

¹ Graduate Student, Department of Computer Science, Chungbuk National University, Republic of Korea, kjseok@chungbuk.ac.kr

² Graduate Student, Department of Computer Science, Chungbuk National University, Republic of Korea, swkang@chungbuk.ac.kr

³ Associate Professor, Department of Computer Science, Chungbuk National University, Republic of Korea, ohyunjo@chungbuk.ac.kr

Corresponding author: Ohyun Jo

Abstract: In this paper, we propose a new data imaging technique for DMRS(Demodulation Reference Signal) index classification in a real-world 5G network environment. The proposed imaging technique utilizes the amplitude values obtained from these two data while maintaining the original values of the In-phase and Quadrature-phase parts of the signal. This approach forms a structure similar to the RGB(Red-Green-Blue) color model used in conventional images, using these three pieces of data. As a classification model, a light-weight CNN(Convolutional Neural Network) model was constructed, which is a well-fitted neural network model for image processing. The data is collected in a real 5G environment to confirm the feasibility and applicability in the real 5G system. The performance of the proposed scheme is evaluated in terms of the index classification accuracy, the imaging time, and the model learning time while comparing with the benchmark methods in literature such as GASF(Gramian Angular Summation Field), GADF(Gramian Angular Difference Field), and MTF(Markov Transition Field). The proposed imaging technique showed a higher accuracy of at least 24% in all SNR(Signal-to-Noise Ratio) levels. In terms of imaging time, while the existing imaging methods of the same dimensions took around 1.5 seconds for two GAFs and approximately 95 seconds for MTF preprocessing, the proposed imaging technique demonstrated a faster preprocessing speed of about 0.7 seconds. Additionally, when considering model training time, the conventional imaging methods that achieved the best classification accuracy required approximately 212 seconds to complete training. On the other hand, the proposed imaging technique significantly improved time efficiency with a training time of approximately 133 seconds. This accelerated training speed led to a substantial enhancement in time efficiency while maintaining a high level of accuracy.

Keywords: 5G, Deep Learning, Classification, DMRS, Imaging

요약: 본 논문에서는 실제 5G 네트워크 환경에서 DMRS 인덱스 분류를 위해 새로운 데이터

Received: July 13, 2023; 1st Review Result: August 18, 2023; 2nd Review Result: September 21, 2023
Accepted: October 25, 2023

이미지화 기법을 제안하였다. 제안된 이미지화 기법은 신호가 갖고 있는 실수부와 허수부의 원래 값을 유지하면서 이 두 데이터로부터 얻은 진폭 값을 활용한다. 세 개의 데이터를 통해 기존 이미지에서 사용되던 RGB 색상 모델과 같은 구조를 형성한다. 분류 모델로는 이미지 분류 신경망 중 하나인 CNN을 활용하여 간단한 모델을 구성하였다. 데이터는 실제 5G 환경에서 수집된 데이터이며 이를 통해서 실제 시스템에서 적용 가능성 또한 확인할 수 있다. 제안된 이미지화 기법의 성능 비교를 위하여 기존 이미지화 기법인 GASF, GADF, MTF의 인덱스 분류 정확도, 이미지화 시간, 모델 학습 시간을 비교하였다. 제안된 이미지화 기법은 모든 SNR에서 최소 약 24% 이상의 높은 정확도를 보였다. 이미지화 시간 또한 같은 사이즈의 기존 이미지화 기법 중 두 개의 GAF가 약 1.5초, MTF가 약 95초에 전처리가 이루어지는 반면, 제안된 이미지화 기법이 약 0.7초로 더 빠른 전처리 속도를 보였다. 모델 학습 시간은 분류 정확도가 가장 잘 나오는 기존 이미지화 기법들이 약 212초에 학습을 완료하는 반면, 제안된 이미지화 기법은 약 133초로 더 빠른 학습 속도로 시간 효율성을 크게 향상시키며 높은 정확도를 유지하는 것을 확인하였다.

핵심어: 5G, 딥러닝, 분류, 복조참조신호, 이미지화

1. 서론

5G 네트워크 상에서 송신자가 수신자에게 신호를 보낼 때, 전송되는 매체에 따라 신호 변조(Modulation)를 진행한다. 하지만 전송 채널을 따라 신호가 전달되는 과정에서 데이터가 왜곡될 수 있으며, 이로 인한 성능 열화를 회피하기 위하여 수신자 측에서는 DMRS(Demodulation Reference Signal)를 이용하여 전송 채널의 상황을 예측하고 데이터 복조(Demodulation) 성능을 향상시킬 수 있다. 네트워크 내에는 다수의 사용자가 존재하기 때문에 여러 종류의 DMRS 신호를 사용하며, 각 사용자나 단말기에는 DMRS 인덱스가 할당된다. DMRS 인덱스는 해당 사용자의 특징 신호 패턴을 나타내고 DMRS를 효과적으로 관리할 수 있으며 이를 위해 DMRS 인덱스를 식별하는 과정을 인덱스 분류(Index Classification)라고 한다. 통신 네트워크에서의 신호 처리를 위한 연구는 지속적으로 활발히 진행되고 있으며 최근에는 인공지능의 지속적인 발전으로 딥러닝(Deep Learning)을 이용한 연구가 발표되고 있다 [1][2]. 특히 입력 데이터의 구조와 패턴을 효과적으로 인식하는 CNN(Convolutional Neural Network)을 이용하여 분류하는 연구 또한 활발히 이루어지고 있다[3-5]. 신호 분류와 같은 연구에서는 입력 데이터가 이미지로 구성된 CNN 기반의 분류 모델을 활용할 때, 신호를 이미지화하는 전처리 기법을 활용하여 분류 모델의 입력 데이터로 활용된다[6]. 하지만 시퀀스 구조를 갖는 신호 데이터가 기존 이미지화 기법을 사용하게 되었을 때, 데이터의 차원이 증가하면서 메모리 요구 사항과 이미지화하는 전처리 시간도 함께 증가한다. 따라서 신호 분류의 성능과 효율을 향상시키기 위해 효율적인 이미지화 기술에 대한 연구가 필요하다.

본 논문에서는 기존 이미지화 기법이 아닌 경량화된 이미지화 기법을 제안한다. 제안된 이미지화 기법은 기존 신호 데이터 값을 유지하면서 원본 데이터에서 추출할 수 있는 새로운 정보를 조합하여 사용하고 만들어진다. 생성된 이미지 데이터에 적합한 CNN 모델을 설계하여 기존 이미지화 기법과 성능을 비교 분석한다[7-9]. 제안된 이미지화 기법의 성능을 분석하기 위해 실제 5G 환경에서 생성된 DMRS 신호를 사용하였으며 8가지 SNR(Signal-to-Noise Ratio) 환경에서 신호를 수집하여 다양한 환경에서 실험을

진행한다.

본 논문의 구성은 다음과 같다. 2장에서는 관련 연구에 대해 소개하고, 3장에서는 사용된 신호의 세부사항과 제안하는 이미지화 기법, 사용된 CNN 구조에 대해 설명한다. 4장에서는 제안된 이미지화 기법에 대한 성능 분석 결과를 보이며, 5장에서는 결론과 향후 연구에 대하여 언급한다.

2. 관련 연구

본 연구에서는 원본 데이터에 포함된 정보를 유지하면서 데이터의 패턴을 분석하고 추출하기 위해 데이터를 이미지의 형태로 변환하는 접근을 수행한다. 제안하는 이미지화 기법의 성능과 효율성을 검증하기 위해 먼저 기존의 이미지화 기법과 이에 적용된 CNN 모델을 조사하고 요약정리한다.

2.1 시계열 이미지화

GAF(Gramian Angular Field) 방법은 시계열 데이터를 이미지로 변환하여 데이터를 효과적으로 분석하는 기법으로 시간적 상관관계를 나타내는 이미지를 얻는다. GAF는 1D 행렬 형태인 시계열 데이터를 데이터의 각 점 사이의 각도에 따라 2D 행렬 형태로 변환한다. 극 좌표계로 변환이 되는 GAF는 극 좌표계의 각도의 합과 차에 따라서 GASF(Gramian Angular Summation Field)와 GADF(Gramian Angular Difference Field)로 나누어진다[7-9]. 하지만 GAF는 데이터를 이미지로 변환하는 과정에서 데이터의 분포와 통계적 특성으로 인해 일부 정보가 훼손될 수 있다. 또한, 시계열 데이터의 길이가 길어질수록 이미지의 크기가 증가하여 데이터를 이미지로 변환하는 전처리 시간과 메모리 사용량이 증가할 수 있다.

MTF(Markov Transition Field) 또한 GAF와 같이 시계열 데이터를 2차원 이미지로 변환하는 알고리즘이다. MTF는 시계열 데이터의 마르코프 상태 전이 확률을 행렬로 표현함으로써 시계열 데이터의 복잡한 패턴을 시각적으로 잘 드러낼 수 있다[7]. GAF와 MTF는 다양한 길이의 데이터를 동일한 방식으로 처리할 수 있으며 시계열 데이터의 패턴을 분석하고 비교하는 것이 매우 용이하다[8]. 변환된 이미지 데이터는 딥러닝 모델과 함께 사용하였을 때 분류 성능에도 용이하다. 하지만 MTF의 경우, 시계열 데이터의 전이 확률만을 이용하기 때문에 시간적인 패턴이나 주기성과 같은 시계열의 일부 정보가 손실될 수 있고 이로 인해 원래 특성을 완벽하게 보존하지 않을 수 있다.

2.2 Convolutional Neural Network

시계열 데이터를 2차원 이미지로 변환하는 시계열 이미지화는 CNN과 같이 이미지의 특징 추출과 이미지 인식에 강력한 성능을 보이는 딥러닝 모델의 입력 데이터로 사용되며 연구 또한 계속되고 있다. WANG and OATES (2015)은 딥러닝 모델을 시계열 데이터에 적용하여 이를 이미지로 인코딩하는 프레임워크를 제안하였다[7]. 이러한 프레임워크는 GASF와 GADF, MTF를 활용하여 시계열 데이터를 이미지와 유사한 형태로 변환하고 CNN 기반 모델을 통해 이미지에서 효과적인 특징 추출을 수행하였다. 또한, Garcia et al. (2022)은 6가지 인코딩 알고리즘을 비교하고 이미지로 변환된 시계열 데이터를 CNN 기반 모델을 이용해 산업 자산의 상태를 모니터링하는 방법을 제안하여 이미지

인코딩이 원시 시계열 데이터보다 성능이 개선되는 것을 보였다[8]. Wang et al. (2017)은 시계열 데이터 분류를 위한 딥러닝 기반 접근 방식을 제안하여 간단한 프로토콜로 우수한 성능을 보였다[9]. 하지만, 일반적으로 이미지 분류를 위해 CNN을 사용하여 이미지를 학습하게 된다면 이미지 사이즈가 큰 데이터가 학습 시간은 더 오래 걸리게 된다.

3. 경량 이미지 기술과 분류 모델

3.1 DMRS 데이터

본 논문에서는 DMRS 인덱스 분류를 위해 실제 5G 네트워크 환경에서 신호를 수집하여 데이터 셋으로 활용하였다. 이를 위해서 USRP(Universal Software Radio Peripheral) 2대를 활용하여 생성된 신호를 사용하였다[10][11]. [표 1]은 수집된 신호의 환경과 각 환경별 신호와 인덱스의 구조이다.

[표 1] 실험에 사용된 DMRS 신호 세부 사항

[Table 1] DMRS Signal Details used in the Experiment

	Details
SNR(dB)	-2.51dB, -2.74dB, -2.81dB, -2.99dB, -3.13dB, -3.42dB, -3.7dB, -4.11dB
Index	8 Integer Indexs
Complex Data (1-Sequence)	144(In-phase), 144(Quadrature-phase) 144 * 2 = 288(1-Sequence)
Sequence by Index	20000 (Data per Index)
Sequence by One SNR	20000(Sequence) * 8(Index) = 160,000

DMRS 신호는 8가지 SNR 환경에서 수집되었으며 한 인덱스마다 20,000개의 신호 데이터가 수집되었다. 또한, DMRS 신호는 복소수 신호(Complex Signal)이며, 실수부(In-phase)와 허수부(Quadrature-phase)로 구성된 2차원 좌표에 표현이 가능하다. 실수부와 허수부는 각각 144개의 요소들로 구성되어 있으며 인덱스를 포함한 하나의 시퀀스 데이터는 288개의 요소와 인덱스로 구성된다.

3.2 경량 이미지화 기법

제안하는 데이터 이미지화는 RGB 색상 모델을 기반으로 이루어진다. RGB 색상 모델은 세 가지 색상 성분으로 구성되어 있으며 각 기본 색마다 색상의 강도가 들어가게 된다. 이러한 색상 모델을 수집된 데이터 셋에 적용했을 때, 실수부와 허수부는 각각 하나의 색상 성분에 들어가게 되고 남은 한 성분에는 실수부와 허수부를 통해 구할 수 있는 유의미한 데이터를 적용한다. 본 논문에서는 기존에 존재하던 데이터를 통하여 진폭 값을 구하고 남은 한 성분에 적용하여 RGB 색상 모델을 구성하는 신호 이미지를 만들었다. DMRS 이미지의 RGB 색상 모델은 다음과 같이 정의한다.

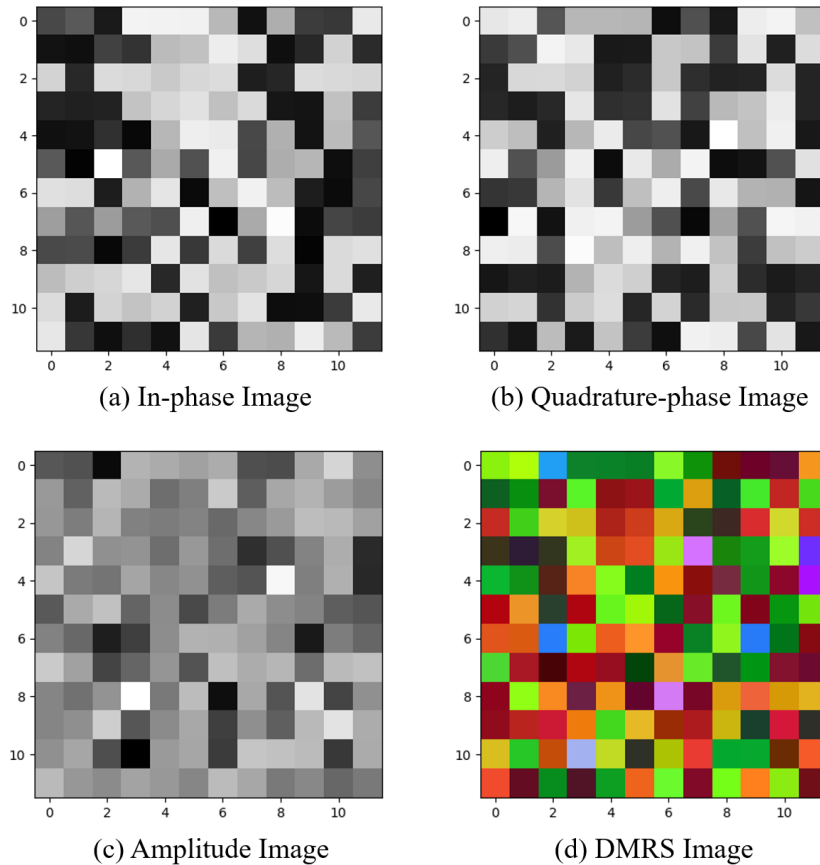
$$DMRS_RGB_i[n] = \begin{cases} R_i[n] = I_i[n] \\ B_i[n] = Q_i[n] \\ G_i[n] = \sqrt{(I_i[n])^2 + (Q_i[n])^2} \end{cases}, n \in [0, 143] \quad (1)$$

식(1)에서 i 는 SNR에 따른 데이터의 순서를 의미하며 수집된 데이터에서는 최대 160,000까지 존재한다. n 은 DMRS 신호를 구성하는 각 시퀀스 요소의 위치를 의미하며 실수부와 허수부는 각각 식(1)이 적용된다. RGB가 적용되었을 때, n 은 생성된 이미지가 갖는 전체 픽셀수를 의미하게 된다. 생성된 이미지는 $N \times N$ 의 형태의 이미지를 갖게 된다. 식(2)는 실험에서 사용된 DMRS 신호 이미지 사이즈를 결정하는 식이다. 또한, $DMRS_RGB_i[n]$ 의 각 색상 성분을 구성하는 신호 정보를 1차원에서 2차원 행렬로 변환하는 과정은 식(3)과 같이 정의한다.

$$N = \text{ceil}[\sqrt{\max(n)}] \quad (2)$$

$$DMRS_{1D-array}Seq[n] \rightarrow DMRS_{2D-array}Seq[n/N][n\%N] \quad (3)$$

식(3)은 색상 성분에 포함된 모든 데이터에 각각 적용되며 1차원 행렬을 갖는 데이터가 2차원 행렬을 갖게 되면서 픽셀의 위치가 2차원 행렬에 맞게 변환되는 것을 볼 수 있다. [그림 1]은 하나의 시퀀스 데이터가 이미지화가 적용된 그림이다.



[그림 1] 요소별 DMRS 이미지화 결과

[Fig. 1] DMRS Imaging Results by Element

[그림 1]의 (a), (b), (c)는 각각 실수부와 허수부, 진폭을 식(3)까지의 과정을 통해 이미지화한 결과이며 하나의 정보만 갖고 있으므로 그레이 스케일(Gray-Scale) 이미지가 생성된다. [그림 1]의 (d)는 (a), (b), (c) 이미지를 RGB 모델을 구성하는 세 개의 성분에 순차적으로 들어가게 되는 식(3)까지 적용된 이미지이다. 생성된 이미지는 정규화를 거치지 않고 원래 데이터 값을 유지한 상태로 DMRS 인덱스 분류 모델의 입력 데이터로 사용하게 된다.

3.3 DMRS 인덱스 분류 모델

본 논문에서는 DMRS 인덱스 분류를 위해 신경망을 활용한 딥러닝을 사용한다. CNN은 입력 데이터의 지역적인 구조와 패턴을 잘 인식하고 이미지의 중요한 특징들을 추출하여 이미지 분류에도 적합한 딥러닝의 아키텍처이다. [표 2]는 실험에 사용된 CNN 모델 구조이다.

[표 2] 실험에 사용된 CNN 모델 구조

[Table 2] CNN Model Structure used in Experiment

Layer	Filter Size	Output Size
Input	-	$12 \times 12 \times 3$
Conv	$2 \times 2 \times 16$	$11 \times 11 \times 16$
Conv	$2 \times 2 \times 8$	$10 \times 10 \times 8$
Batch Normalization	-	$10 \times 10 \times 8$
FC	-	1024
Softmax	-	8

입력층은 이미지화된 시퀀스 데이터의 크기를 가지며 다음 합성곱(Convolution) 층에서 16개의 2×2 필터와 8개의 같은 사이즈 필터를 연속적으로 사용하고 신경망의 빠르고 안정적인 학습을 하기 위해 배치 정규화(Batch Normalization)[12]를 사용한다. 배치 정규화가 끝난 이후에는 FC(Fully Connected) 층을 구성하고 학습하여 분류를 진행한다. 이때, 최종 분류를 진행하는 Softmax 층의 Output Size는 최종 인덱스의 개수와 같다.

본 논문에서는 인덱스 분류 모델을 위해 각 SNR에 따라 모델을 학습하였으며 데이터는 8 : 2의 비율로 학습 데이터(Train Data)와 테스트 데이터(Test Data)를 나누고 나뉜 학습 데이터 중 다시 8 : 2의 비율로 최종 학습 데이터와 검증 데이터(Validation Data)를 나누었다. 학습이 진행될 때, 모델의 설정은 [표 3]과 같다.

[표 3] 학습에 사용된 모델 파라미터 설정

[Table 3] Model Parameter Settings used for Training

Type	Value
Loss Function	Sparse Categorical Cross Entropy
Optimizer Function	Adam(Adaptive Moment Estimation)
Epoch	100
Batch	256

4. 성능 평가

제안하는 이미지화 기법의 성능을 비교하기 위해 GASF, GADF, MTF와 비교하여 SNR에 따른 인덱스 분류의 성능을 나타내었으며 기존 이미지화 기법들의 이미지 사이즈를 일정 크기까지 증가시키면서 성능을 비교하였다. 이미지 사이즈는 수신기 측에서 인덱스 분류가 이루어진다는 점과 함께 메모리 사용량 (Memory Usage) 측면을 고려하여 최대 36 × 36 까지만 증가하였다. [표 4]는 8바이트의 float64를 사용했을 때 하나의 SNR에서 생성된 전체 이미지의 메모리 사용량이다.


[표 4] 이미지 사이즈 별 메모리 사용량

[Table 4] Memory Usage by Image Size

Input Shape	Existing Imaging			Proposed Imaging
	12 × 12 × 2	24 × 24 × 2	36 × 36 × 2	12 × 12 × 3
Memory Usage(Byte)	368,640,000	1,474,560,000	3,317,760,000	552,960,000

또한, 기존 이미지화 기법들도 실수부와 허수부 각각에 대해서 전처리가 이루어지기 때문에 생성된 각 요소들에 대한 이미지들은 제안된 이미지화 기법과 유사한 형태로 생성된다. [그림 2]는 이미지화된 데이터에 대해 SNR에 따른 인덱스 분류 정확도를 나타낸 그래프이다.

같은 분류 모델의 구조를 사용했을 때 제안하는 이미지화 기법은 기존의 이미지화 기법보다 전 구간에서 우수한 성능을 가졌다. 특히 기존 이미지화 기법들은 이미지의 크기가 커질수록 성능이 높아지는 것을 볼 수 있었고 실험 중 가장 큰 이미지 사이즈인 36 × 36의 형태를 갖는 기존 방법들과 비교했을 때, 가장 높은 SNR인 -2.51dB에서 GASF 63.75%, GADF 71.36%, MTF 22.41% 그리고 제안된 이미지화 기법이 99.42%로 최소 28% 이상 높은 성능을 갖는다. 가장 낮은 SNR인 -4.11dB에서도 제안된 이미지화 기법은 80% 이상 정확도를 보이지만 다른 이미지화 기법들은 40% 이하로 성능 차이를 보였다.



[그림 2] SNR에 따른 이미지화된 DMRS 인덱스 분류 정확도 성능 비교

[Fig. 2] Imaged DMRS Index Classification Accuracy Performance Comparison according to SNR

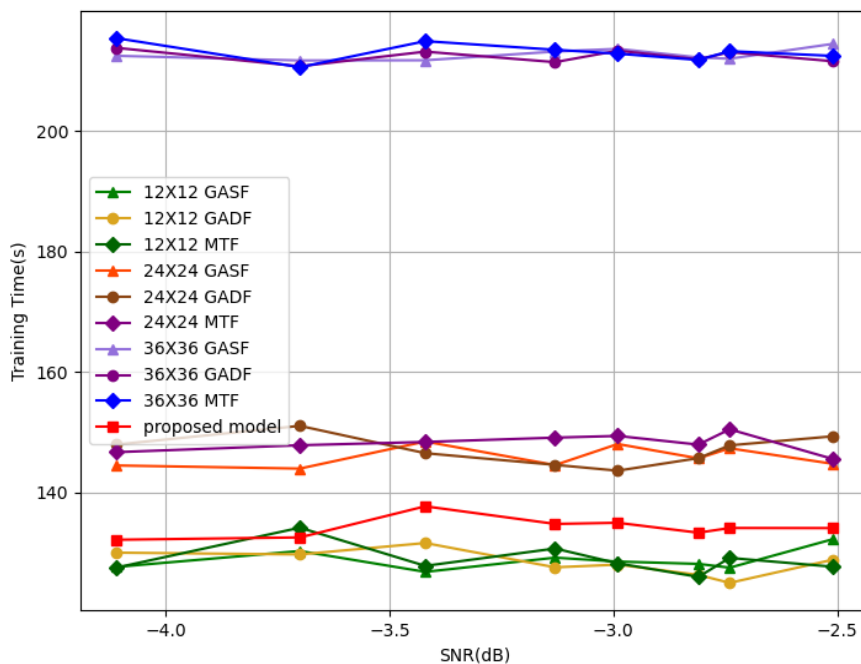
[표 5]는 전체 데이터에 대해서 이미지화가 생성되기 위한 이미지 전처리 시간을 나타내었으며 8개의 모든 SNR에서 제안하는 이미지화 기법이 가장 좋은 성능을 보였다. 또한, [그림 2]에서 볼 수 있듯이 이미지 사이즈가 증가하면서 인덱스 분류 정확도의 성능도 함께 향상되는 기존 이미지화 기법들은 이미지 전처리 시간도 함께 증가하는 반면 제안하는 이미지화 기법은 기존 방법보다 낮은 이미지화 전처리 시간과 높은 인덱스 분류 정확도를 갖고 있어 경량화된 이미지화 기법으로 볼 수 있다.

[표 5] 제안된 이미지화의 SNR에 따른 데이터 이미지화 시간 성능 비교

[Table 5] Comparison of Data Imaging Time Performance according to SNR of Proposed Imaging

Pre-processing Time(s)		SNR (dB)							
Input Shape	Image	-2.51	-2.74	-2.81	-2.99	-3.13	-3.42	-3.7	-4.11
12 × 12 × 2	GASF	1.51	1.52	1.51	1.51	1.53	1.52	1.51	1.51
	GADF	1.52	1.53	1.52	1.53	1.52	1.53	1.51	1.51
	MTF	94.74	96.45	95.47	94.88	94.95	95.42	94.32	97.48
24 × 24 × 2	GASF	4.01	4.20	4.15	4.00	3.96	4.21	4.14	3.99
	GADF	4.44	4.39	4.40	4.38	4.39	4.39	4.49	4.40
	MTF	104.19	104.11	103.56	104.12	104.32	103.03	102.96	103.58
36 × 36 × 2	GASF	8.70	8.68	8.77	8.80	8.75	8.92	8.83	8.80
	GADF	8.62	8.71	8.65	8.67	8.70	8.68	8.73	8.78
	MTF	115.70	115.28	115.00	114.54	114.70	115.35	114.91	115.75
12 × 12 × 3	Proposed	0.77	0.77	0.78	0.77	0.77	0.77	0.77	0.78

실시간 처리가 가능하고 경량화된 이미지화 기법을 위해서 짧은 학습 시간 또한 중요한 조건 중 하나이다. [그림 3]은 같은 모델을 학습하였을 때 이미지화 기법에 따른 분류 모델 학습 시간이다. [표 3]과 같이 모델의 설정이 모두 같을 때 모델의 학습 시간은 데이터의 크기의 영향을 크게 받게 되며 이미지의 사이즈에 따라 학습 시간 또한 달라지는 것을 볼 수 있다. 기존 이미지화 기법이 작은 사이즈로 생성이 되는 경우에는 전체적으로 제안하는 이미지화 기법이 학습 시간 측면에서 조금 오래 걸리는 경향이 있다. 하지만 기존 방법 중 분류 정확도의 성능이 가장 높았던 $36 \times 36 \times 2$ 의 형태를 가진 이미지화 기법을 비교하면 약 80초 정도의 큰 차이를 보였다. 따라서 전체적인 성능 측면에서 제안하는 이미지화 기법이 다른 기존 방법보다 성능 측면과 경량화 측면에서 성능이 우수함을 볼 수 있다.



[그림 3] SNR에 따른 이미지화된 인덱스 분류 모델 학습 시간 비교

[Fig. 3] Comparison of the Training time of the Imaged Index Classification Model according to SNR

5. 결론 및 향후연구

본 논문에서는 DMRS 인덱스 분류를 위한 데이터 이미지화 기법에 대해 제안하였다. 제안된 이미지화 기법은 실제 값을 유지하면서 값을 통해 새로운 데이터를 추가하여 이미지를 생성한다. 생성된 이미지는 실제 이미지가 갖고 있는 RGB 색상 모델의 구조와 같으며 이를 통해 기존 이미지 학습 신경망인 CNN을 통해 인덱스 분류 모델을 구성하고 학습하였다. 제안된 이미지화의 성능 평가를 위해 기존 이미지화 기법인 GASF, GADF, MTF의 사이즈를 증가시키면서 분류 정확도와 이미지화 시간, 학습 시간을 비교하였다. 실험을 통해 제안된 이미지화 기법이 모든 SNR에서 인덱스 분류 정확도와 이미지화 시간 측면에서 우수한 성능을 보였고 모델 학습 시간 또한 제안하는 이미지화 기법보다 Input Shape가 작은 $12 \times 12 \times 2$ 이미지를 제외하고는 모두 큰 차이로 높은 성능을 보였다.

향후 연구로는 기존 데이터를 유지하면서 높은 성능을 보이는 데이터 경량화와 학습하는 모델의 경량화에 대한 연구를 진행할 예정이다. 이를 통해 신호 데이터 처리 기술에 학습 신경망 기술을 적용함으로써 지능형 기지국 연구에 기여하기를 기대한다.

6. 감사의 글

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구이며(No. 2021R1A2C2095289), 2021년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. 2021-0-00165, 5G+ 지능형 기지국 소프트웨어 모델 개발). 또한, 2022학년도 충북대학교 연구년제 지원에 의하여 연구되었음.

References

- [1] Vaibhav TIWARI, Girish Chandra Tripathi, Meenakshi Rawat, Deep Learning-Based Modulation Classification of Communication Signals, Recent Trends in Electronics and Communication: Select Proceedings of VCAS 2020, Springer Singapore, (2022), pp.747-759.
DOI: https://doi.org/10.1007/978-981-16-2761-3_66
- [2] Weiwei JIANG, Graph-based deep learning for communication networks: A survey, Computer Communications, (2022), Vol.185, pp.40-54.
DOI: <https://doi.org/10.1016/j.comcom.2021.12.015>
- [3] A. Sharma, E. Vans, D. Shigemizu, K. A. Boroevich, T. Tsunoda, DeepInsight: A methodology to transform a non-image data to an image for convolution neural network architecture, Scientific reports, (2019), Vol.9, 11399.
DOI: <https://doi.org/10.1038/s41598-019-47765-6>
- [4] Z. Zhang, C. Wang, C. Gan, S. Sun and M. Wang, Automatic Modulation Classification Using Convolutional Neural Network With Features Fusion of SPWVD and BJD, IEEE Transactions on Signal and Information Processing over Networks, (2019), Vol.5, No.3, pp.469-478.
DOI: <http://doi.org/10.1109/TSIPN.2019.2900201>
- [5] Qian MAO, Fei Hu, Qi HAO, Deep learning for intelligent wireless networks: A comprehensive survey, IEEE Communications Surveys & Tutorials, (2018), Vol.20, No.4, pp.2595-2621.
DOI: <http://doi.org/10.1109/COMST.2018.2846401>
- [6] Park Ji-Yeon, Seo Dong-Ho, Nam Hae-Woon. Deep-Learning-Based Automatic Modulation Classification Using Imaging Algorithm, The Journal Of Korean Institute of Electromagnetic Engineering and Science, (2021), Vol.32, No.4, pp.328-333.
DOI: <https://doi.org/10.5515/KJKIEES.2021.32.4.328>
- [7] Zhiguang Wang, Tim Oates, Imaging time-series to improve classification and imputation, arXiv preprint arXiv:1506.00327, (2015)
DOI: <https://doi.org/10.48550/arXiv.1506.00327>
- [8] G. R. Garcia, G. Michau, M. Ducoffe, J. S. Gupta, O. FinkM Temporal signals to images: Monitoring the condition of industrial assets with deep learning image processing algorithms, Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability, (2022), Vol.236, No.4, pp.617-627.
DOI: <https://doi.org/10.1177/1748006X2199444>
- [9] Zhiguang Wang, Weizhong Yan, Tim Oates, Time series classification from scratch with deep neural networks: A strong baseline, 2017 International joint conference on neural networks (IJCNN), IEEE, (2017), pp.1578-1585.
DOI: <http://doi.org/10.1109/IJCNN.2017.7966039>

- [10] Ji Yoon Han, Ohyun Jo, Juyeop Kim, Exploitation of Channel-Learning for Enhancing 5G Blind Beam Index Detection, IEEE Transactions on Vehicular Technology, (2022), Vol.71, No.3, pp.2925-2938.
DOI: <http://doi.org/10.1109/TVT.2021.3140019>
- [11] S. Kang, T. Lee, J. Kim, A. -R. -S. Lee, J. Kim, O. Jo, Intelligent Index Classification Method Based on Machine Learning for Detection of Reference Signal in 5G Networks, IEEE Access, (2023), Vol.11, pp.100810-100822.
DOI: <https://doi.org/10.1109/ACCESS.2023.3314167>
- [12] Sergey Ioffe, Christian Szegedy, Batch normalization: Accelerating deep network training by reducing internal covariate shift, arXiv:1502.03167, (2015), pp.448-456.
DOI: <https://doi.org/10.48550/arXiv.1502.03167>