

5G 소프트웨어 모뎀을 위한 딥러닝 프레임워크 개발

민응규, 강승우, 조오현

충북대학교 컴퓨터과학전공

{minwg1021, swkang, ohyunjo}@chungbuk.ac.kr

Development of Deep Learning Framework for the Practical 5G Softwarized Modem

Woonggyu Min, Seungwoo Kang, Ohyun Jo

Chungbuk National University, Department of Computer Science

요약

본 논문에서는 5G 소프트웨어 기지국 모뎀에 딥러닝(Deep Learning) 모델을 적용하기 위한 C 기반의 학습 프레임워크(C 프레임워크)를 제안한다. 본 연구에서 고안하고 개발한 C 프레임워크는 CNN(Convolutional Neural Network) 기반의 경량 학습 모델과 함께 신호 분류 알고리즘을 구현하기 위한 기본적인 구조를 제공한다. 학습 모델의 경량화를 위하여 신호의 이미지화 기법(Imagification)을 적용하였으며 직접 개발한 5G 소프트웨어 모뎀 테스트베드를 이용하여 실제 채널 환경에서 DMRS(DeModulation Reference Signal)를 수집하였고, 실제 데이터를 사용하여 구현한 학습 모델의 성능 분석과 평가를 진행한다. 실험의 결과는 상대적으로 낮은 SNR(Signal Noise Ratio) 환경인 -4.11dB에서도 약 80%의 분류 정확도를 보이며 이는 C 프레임워크를 통한 CNN 모델의 실제 시스템에의 적용 가능성을 보인다. 또한 하이퍼 파라미터(Hyper Parameter) 최적화 실험을 통해 최적의 분류 정확도를 보이는 모델을 찾는 연구를 수행하였다.

I. 서론

최근 몇 년 동안 딥러닝 기술은 이미지 처리, 음성 인식, 자연어 처리 등 다양한 분야에서 괄목할만한 성과를 보여주고 있고, 통신 시스템 및 신호 처리 분야에 적용하기 위한 연구 또한 증가하고 있다 [1]. 하지만 높은 복잡도와 연산량으로 인하여 실제 5G 시스템에 적용에는 한계가 존재하였다. 본 연구에서는 5G 소프트웨어 모뎀에 적용을 위한 C 기반의 학습 프레임워크를 제안하며 이를 통하여 실제 채널 환경에서 딥러닝 모델을 구현하고 평가한다. 이를 위해 5G 소프트웨어 모뎀 테스트베드를 이용하여 수집된 DMRS 데이터를 사용하였으며, 레퍼런스 신호의 분류 정확도를 획기적으로 개선시킴으로써 Blind Decoding 기반으로 레퍼런스 신호를 Detection 하는 기존의 방법에 대비하여 시스템의 효율을 대폭 향상시킬 수 있는 학습 프레임워크를 개발하였다. 또한, 학습 모델의 하이퍼 파라미터 최적화를 통해 실제 시스템에 적용 가능한 최적의 학습 모델 구조를 찾을 수 있다.

II. 본론

1. 실제 5G 기지국 시스템 임베딩을 위한 C 프레임워크

1-1. C 프레임워크 구조

본 연구를 통해 개발한 학습 프레임워크는 실제 5G 소프트웨어 모뎀에 적용하고 시스템과의 연동하여 실시간 동작이 가능할 수 있도록 온전한 C 언어를 이용하여 구현하였다. 주요 특징으로서 합성곱(Convolution)층에서 다차원의 이미지를 1차원 행렬로 변환하는 Im2Col 함수와 Im2Col의 역기능을 하는 Col2Im 함수를 설계하여 데이터 변환의 효율성을 높였다. 또한, 합성곱을 위한 행렬곱 연산은 오픈소스 라이브러리인 OpenBLAS를 사용하여 구현하였으며 딥러닝 모델 설계의 범용성을 높이기 위해 모델에

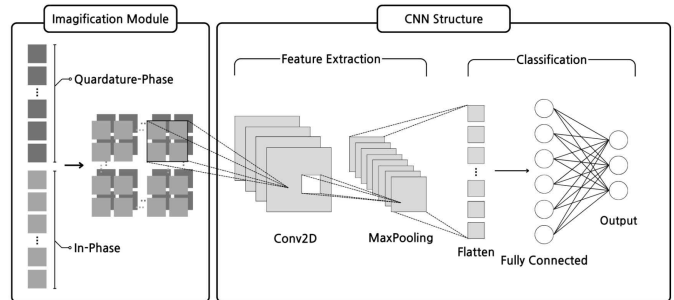


그림 1. C 프레임워크 기반으로 구현된 CNN 모델의 구조

사용되는 각 층을 모듈화하였다. 딥러닝 모델의 입력으로 사용되는 텐서는 1차원 배열로 구현하였고 여러 차원을 쌓아 입력의 형태를 변형할 수 있도록 구현하였다.

1-2. 이미지화(Imagification) 기법 적용을 통한 딥러닝 모델 경량화

효율적인 DMRS 데이터의 인덱스 분류와 학습 모델의 경량화를 위하여 최초로 고안한 신호 데이터의 이미지화 기법을 적용하였다 [2-3]. 인덱스 분류를 위한 딥러닝 모델로는 CNN 모델을 사용한다. CNN 모델의 전반적인 구조는 그림 1과 같이 표현할 수 있다. 특징 추출(Feature Extraction)과 인덱스 분류를 위한 분류(Classification)로 이루어진다. 특징 추출은 합성곱층과 풀링(Pooling) 층으로 구성되며 하이퍼 파라미터의 변경에 따라 구조가 유동적으로 변경된다. 분류 부분은 하나의 완전 연결(Fully Connected) 층과 출력(Output) 층으로 구성되어 있으며 구조는 변하지 않는다. 각 층의 활성화 함수는 ReLU가 적용되고 층을 지날 때마다 정규화(Normalization)를 거친다. 손실 함수로는 Sparse Categorical Cross Entropy가 사용되고, 최적화 함수로는 Adam을 사용한다.[4]

2. 하이퍼 파라미터 최적화 실험

2-1. 실험 환경

모델의 학습에는 2대의 USRP(Universal Software Radio Peripheral)을 이용하여 구현한 소프트웨어 모뎀에서 실제 수집된 5G 신호 데이터를 사용한다. 데이터는 -4.66dB ~ 23.37dB까지 총 12가지의 SNR 환경에서 수집했고 각 데이터는 8개의 Index를 가지며 인덱스 당 데이터 개수는 20,000개이다. 수집된 DMRS 데이터는 실수부와 허수부로 나뉘며 각각 144개의 샘플로 구성된다. 최적화 모델을 찾기 위한 하이퍼 파라미터의 목록은 표 1과 같다. Filter Num은 합성곱층의 개수와 그에 따른 필터(Filter)의 개수이며 Filter Size는 합성곱층에서 특징 추출을 위해 사용되는 Filter의 크기이다. 또한 MaxPooling은 풀링층의 사용 유무, Data Shape은 이미지를 거친 데이터의 형태이다. 실험은 표 1의 하이퍼 파라미터 순서에 따라 순차적으로 진행되며 최적의 정확도를 보이는 값으로 고정된 후 다음 하이퍼 파라미터 실험을 진행한다.

Hyper Parameter	Conv2D Layer Num	Value
Filter Num	1	4, 8, 16
	2	(4, 4), (4, 8), (8, 8), (8, 16), (16, 16)
Filter Size		(2, 2), (3, 3), (4, 4)
MaxPooling		O, X
Data Shape		(6, 24), (8, 18), (9,16), (12, 12), (16, 9), (18, 8), (24, 6)

표 1. 최적화 실험에 사용된 하이퍼 파라미터 목록

2-2. 실험 결과

모든 모델에서 학습 이전에 이미지화, 데이터 정규화를 거친 후 학습이 진행되며 30번의 에포크(Epoch)동안 학습시키며 정확도를 지표로 모델의 성능을 평가한다. 실험의 결과는 정확도의 차이가 0.1% 이상의 차이를 보이는 하이퍼 파라미터에 대한 결과만을 기재하였다.

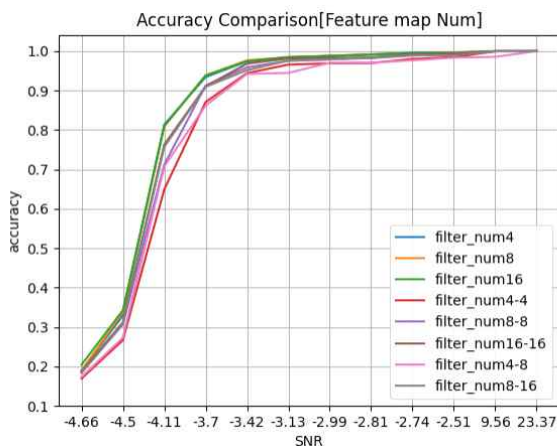


그림 3. Filter Num 변화에 따른 CNN 모델의 정확도 비교

그림 2는 Filter Num의 변화에 따른 모델의 정확도 비교 그래프를 나타낸다. 모든 SNR에서 합성곱층의 개수가 1개일 때가 2개인 경우보다 평균 약 4% 높은 정확도를 보이며 -4.11dB에서는 최대 약 16.4% 높은 정확도 차이를 보인다. 합성곱층의 수가 1개이며 Filter의 수가 4, 8, 16개인 경우는 평균 0.1%의 근소한 차이를 보인다. 위의 결과로 미루어 보았을 때, CNN 모델은 분류 정확도는 Filter의 개수보다는 합성곱층의 개수에 더

큰 영향을 받음을 알 수 있다.

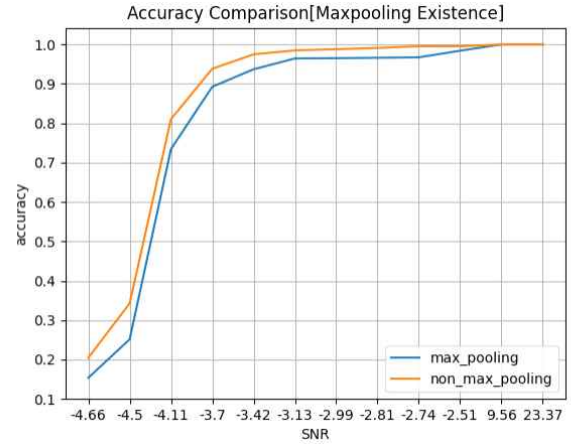


그림 2. MaxPooling 변화에 따른 CNN 모델의 정확도 비교

그림 3은 풀링층의 유무에 따른 모델의 정확도 비교 그래프를 나타낸다. 모든 SNR에서 풀링층이 없는 경우가 평균 3.4%의 높은 정확도를 보인다. 위의 결과의 이유는 CNN 모델의 입력으로 사용되는 DMRS 데이터의 크기가 작아 데이터의 크기를 줄이는 풀링층 통과 시 데이터의 특징이 사라지기 때문이다. 따라서 그림 3에서 풀링층이 없는 경우가 더 높은 정확도를 보임을 알 수 있다.

III. 결론

본 논문에서는 학습 가능한 딥러닝 모델을 5G 기지국 시스템에 적용하기 위한 C 프레임워크를 제안하고 이를 구현하여 실제 5G 데이터를 이용하여 성능을 평가하였다. 또한, 구현한 모델의 하이퍼 파라미터 최적화를 통해 최적의 5G DMRS 인덱스 추정 모델을 고안하였다.

ACKNOWLEDGMENT

이 논문은 2021년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. 2021-0-00165, 5G+ 지능형 기지국 소프트웨어 모뎀 개발). 또한, 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2021R1A2C2095289)

참고 문헌

- [1] Huang, Hongji, et al. "Deep learning for physical-layer 5G wireless techniques: Opportunities, challenges and solutions." IEEE Wireless Communications 27.1 (2019): 214-222.
- [2] Kim, J. S., Kang, S. W., Jo, O. (2023). Lightweight Data Processing Scheme based on Machine Learning for 5G DMRS Index Classification. Asia-pacific Journal of Convergent Research Interchange (APJCRD), ISSN: 2508-9080 (Print); 2671-5325 (Online), KCTRS, 9(11), 91-101. doi: 10.47116/apjcri.2023.11.09.
- [3] 김종석, 강승우, 김주엽, & 조오현. (2023). 다중 채널 기반 이미지화를 이용한 5G DMRS 신호 인덱스 분류 성능 향상. 한국통신학회 학술대회논문집, 1541-1542.
- [4] 강승우, 이태겸, 김주엽, & 조오현. (2022). 5G DMRS 데이터 전처리를 통한 딥러닝 기반 인덱스 분류 모델 성능 향상. 한국통신학회 학술대회논문집, 175-176.