

# OFDM 시스템에서 ESRGAN을 활용한 딥러닝 기반 채널 추정

이나영, 조은우, 박호성\*

전남대학교 컴퓨터정보통신공학과, \*지능전자컴퓨터공학과

[eao3116@naver.com](mailto:eao3116@naver.com), [twins2937@naver.com](mailto:twins2937@naver.com), \*[hpark1@jnu.ac.kr](mailto:hpark1@jnu.ac.kr)

## Deep Learning-Based channel estimation with ESRGAN in OFDM systems

Nayoung Lee, Eunwoo Jo, Hosung Park\*

Chonnam National University

### 요약

본 논문에서는 직교 주파수 분할 다중화(Orthogonal frequency division multiplexing: OFDM) 시스템에서 딥러닝 기반의 채널 추정 기법을 제안한다. 무선 채널에서 시간-주파수 응답은 2차원 이미지로 간주되며 파일럿 신호의 일부 알려진 값을 활용하여 나머지 알려지지 않은 채널 응답을 찾는다. 이를 위해 이미지 초해상도 생성적 적대 신경망(Super Resolution Generative Adversarial Network: SRGAN)을 적용한 채널 추정 기법이 연구된 바 있다. 본 논문에서는 SRGAN에 잔차 내 잔차 밀집 블록(Residual in Residual Dense Block: RRDB)을 추가한 향상된 초해상도 생성적 적대 신경망(Enhanced SRGAN: ESRGAN)을 채널 추정에 적용하여 성능을 비교 및 분석하였다.

### I. 서론

OFDM은 무선 채널에서 주파수 선택적 페이딩을 다루기 위해 널리 사용되는 변조 방법이다. OFDM 시스템에서 정확한 채널 추정을 하는 것은 필수적으로, 수신기에서 파일럿을 사용하여 채널을 추정한다. 전통적인 파일럿 기반 추정 방법인 최소 제곱(Least Square: LS) 및 최소 평균 제곱 오차(Minimum Mean Square Error: MMSE)는 시간-주파수 그리드에서 파일럿 값을 활용하여 채널 추정을 한다. LS 방법은 관찰 값과 추정 값 사이의 오차 합을 최소화하는 방식이다. MMSE 방법은 채널 및 잡음 분산의 2차 통계를 활용하여 LS 방법보다 훨씬 뛰어난 성능을 보여주었다. MMSE의 복잡도는 매우 높기 때문에 이를 줄이기 위해 선형 최소 평균제곱 오차(Linear MMSE: LMMSE)가 유도되었다.

최근 딥러닝은 무선 통신 시스템에서 우수한 성능을 보여주고 있다. ChannelNet은 합성곱 신경망(Convolutional Neural Network: CNN) 기반 알고리즘인 초해상도 합성곱 신경망(Super Resolution CNN: SRCNN) 및 잡음 감소 합성곱 신경망(Denoising CNN: DnCNN)을 활용한 채널 추정을 통해 MMSE 방법과 매우 경쟁력 있는 결과를 보였다. SRGAN을 활용한 채널 추정 방법에서는 생성자 및 판별자 구조를 사용해 LMMSE와 유사한 성능을 얻었다.

본 논문에서는 ESRGAN을 활용한 채널 추정을 통해 SRGAN 채널 추정 방법보다 향상된 평균 제곱 오차(Mean Square Error: MSE) 성능을 보이고자 한다.

### II. 본론

#### 2.1. 전통적인 파일럿 기반 채널 추정 방법

LS 방법은 파일럿 위치에서 채널을 추정한다. LS 추정된 채널을 대각 행렬로 간주한다면,  $H_p^{LS} \in C^{N_p \times N_p}$ 로 나타낼 수 있고, 다음과 같이 해결할 수 있다:

$$\hat{H}_p^{LS} = \arg \min_{H_p} \|y_p - H_p x_p\|_2^2$$

$\|\cdot\|_2$ 는 유클리드 거리이며  $x_p$ 는 알려진 파일럿 값이 포함되어 있고,  $y_p$ 는 해당 관측값이다. 위 식의 최적화는 다음 식을 결과로 한다.

$$\hat{h}_p^{LS} = \text{diag}(\hat{H}_p^{LS}) = y_p / x_p$$

LMMSE 채널 추정의 표현은 다음과 같다:

$$\hat{h}_n^{lmmse} = A_{lmmse} \hat{h}_p^{LS}$$

여기서,  $A_{lmmse} \in C^{N_L \times N_p}$  ( $N_L = N_f * N_p$ )은 파일럿 위치에서의 필터 행렬이다.  $\hat{h}_n^{lmmse} \in C^{N_L \times 1}$ 은 n번째 서브프레임에서 채널  $H$ 의 추정값을 벡터화한 것이고,  $\hat{h}_p^{LS} \in C^{N_p \times 1}$ 은 추정된 채널  $H_p$ 의 벡터화된 추정값이다.  $A_{lmmse}$ 는 다음과 같이 유도될 수 있다:

$$A_{lmmse} = R_{h_n, h_p} (R_{h_p, h_p} + \sigma_w^2 I)^{-1}$$

서브프레임 채널  $h_n$ 과 파일럿 위치의  $h_p$ 간의 교차 상관 행렬은  $R_{h_n, h_p} = E\{h_n h_p^H\}$ 로 표기되며, 이는 채널 자기 상관 행렬을 나타낸다.  $\sigma_w^2$ 는 잡음 분산을 나타낸다.

#### 2.2. SRGAN 기반 채널 추정 방법

SRGAN 기반 채널 추정 방법에서는 파일럿 위치에서 추정된 채널을 저해상도 채널  $H_p$ 로 취급한다. 저해상도 채널을 사용하여 전체 채널  $\hat{H}$ 을 추정하기 위해 일반적으로 컴퓨터 비전 분야에서 사용되는 초고해상도 기술을 적용하였다. SRGAN 기반 채널 추정 방법에서는 파일럿 위치에서 추정된 채널  $H_p$ 가 생성기의 입력으로 사용되고, 그 후 생성된 채널  $\hat{H}$ 은 실제 채널  $H$ 와 함께 판별기를 통과하여 입력이 실제인지 가짜인지를 판단한다. 네트워크 구조는 그림 1[2]과 같다.

지각 손실  $l^{SR}$ 은 두 가지 손실 요소의 가중 조합으로 설계되었다.

$$l^{SR} = l_X^{SR} + 10^{-3} l_{Gen}^{SR}$$

$l_X^{SR}$ 와  $l_{Gen}^{SR}$ 은 각각 콘텐츠 손실과 적대적 손실을 나타낸다. 콘텐츠 손실은 생성기 손실을 의미하며, MSE를 사용하여 추정된 채널과 실제 채널의 성능을 평가한다. 콘텐츠 손실은 다음과 같이 나타낼 수 있다:

$$l_X^{SR} = \frac{1}{N_f N_s} \sum_{x=1}^{N_f} \sum_{y=1}^{N_s} (H_{x,y} - G_{\theta_G}(H^{LR})_{x,y})^2$$

$G_{\theta_G}$ 는  $\theta_G$ 로 매개변수화된 feed-forward CNN이고  $\theta_G$ 는 생성자 G의 네

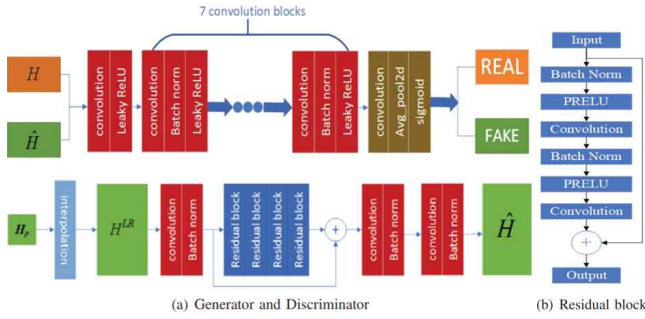


그림 1. SRGAN 기반 채널 추정 네트워크 구조

트위크 매개변수 집합이다. 콘텐츠 손실에 추가로, 훈련 샘플에서 판별자의 확률  $D_{\theta_D}(G_{\theta_G}(H^{LR}))$ 을 기반으로 적대적 손실  $l_{Gen}^{SR}$ 이 정의된다:

$$l_{Gen}^{SR} = \sum_{n=1}^N -\log D_{\theta_D}(G_{\theta_G}(H^{LR}))$$

$D_{\theta_D}(G_{\theta_G}(H^{LR}))$ 는 추정된 채널  $G_{\theta_G}(H^{LR})$ 이 실제 채널인 확률을 나타낸다. 더 나은 성능을 얻기 위해,  $[1 - \log D_{\theta_D}(G_{\theta_G}(H^{LR}))]$ 이 아닌  $1 - \log D_{\theta_D}(G_{\theta_G}(H^{LR}))$ 를 최소화한다.

### 2.3 ESRGAN을 활용한 채널 추정




그림 2. ESRGAN 생성자 네트워크 구조

본 논문은 SRGAN을 활용한 채널 추정 모델에 성능을 향상시키기 위해 생성자 구조에 RRDB를 적용하였다. RRDB는 다중 잔차 학습과 밀집 연결을 결합한 형태로 기존 SRGAN을 활용한 채널 추정에서 사용하는 잔차 블록 (Residual Block: RB)보다 더 깊고 복잡한 구조를 사용한다. 매우 깊은 네트워크를 효율적으로 학습시키기 위해 잔차 스케일링과 작은 값으로 초기화하는 기법을 사용한다. 잔차 스케일링은 네트워크의 주요 경로에 잔차 연결을 하기 전에 0과 1 사이의 값을 곱하는 것으로 부적절한 초기화를 보정하여 네트워크가 불안정해지는 것을 방지한다. 또한, 작은 값으로 초기값을 설정할 경우 잘못된 극소점에 빠지는 위험을 방지할 수 있다.




그림 3. RRDB 구조

ESRGAN의 RRDB와는 다르게 Convolution layer 뒤에 배치 정규화를 추가하였다. 배치 정규화는 잔차 스케일링과는 다르게 배치 전체의 분포를 고려하여 데이터의 크기를 조절하고 특정 범위로 정규화하기 때문에 딥러닝에서 발생할 수 있는 내부 공변량을 줄인다. 이는 네트워크의 전체적인 성능을 향상시켰다.

### 2.4 실험 결과

채널 추정의 성능을 평가하기 위해 48개 파일럿 신호를 사용할 때 추정된 채널의 MSE로 성능을 비교하였다. 각각의 신호대잡음비 환경에서 LS, ChannelNet[1], SRGAN 기반 채널 추정[2]과의 MSE값을 그래프로 비교할 수 있다. VehA 채널[1]을 이용하여 학습 및 실험을 진행하였으며




그림 4. 채널 추정 모델에 따른 MSE 성능 비교

ESRGAN과 SRGAN을 활용한 채널 추정은 12dB, 22dB에서 학습을 진행하였다.

GAN을 사용하기 때문에 기존 딥러닝 기반 채널 추정 모델인 ChannelNet보다 좋은 성능을 보이는 것을 확인할 수 있다. 또한 SRGAN에서의 생성자보다 더 깊은 네트워크 구조를 사용하기 때문에 보다 좋은 성능이 나타나지만 잔차 스케일링과 작은 값으로 초기화하는 기법을 사용하여 네트워크가 빠르게 학습할 수 있도록 하였다.

### III. 결론

본 논문에서는 파일럿 위치에서의 시간-주파수 응답을 저해상도 이미지로 간주하고, 컴퓨터 비전에서의 이미지 초해상도 기법을 사용하여 모델링 분석을 수행한다. 기존의 SRGAN을 활용한 채널 추정 모델도 우수한 성능을 보이지만 RB보다 더 깊은 네트워크 구조인 RRDB를 생성자에 적용하여 보다 우수한 성능을 보였다. 추후 연구에서는 MIMO 상황을 고려한 다중 안테나로 확장하는 것이 필요해 보인다. 또한 무선 채널에 알맞게 모델을 세부 조정하여 더 나은 성능을 얻을 수 있다.

### ACKNOWLEDGMENT

이 논문은 2024년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원(No. 2021001016004, 6G/B5G xURLLC를 위한 유연한 신뢰도의 채널코딩), (No.RS-2021-II212068, 인공지능 혁신 허브 연구 개발)과 교육부와 한국연구재단의 재원으로 지원을 받아 수행된 첨단분야 혁신융합대학사업(차세대통신)의 연구 결과입니다.

### 참고 문헌

- [1] M. Soltani, V. Pourahmadi, A. Mirzaei and H. Sheikhzadeh, "Deep learning-based channel estimation," IEEE Commun. Lett., vol. 23, no. 4, pp. 652-655, 2019.
- [2] S. Zhao, Y. Fang, L. Qiu, "Deep Learning-Based channel estimation with SRGAN in OFDM System." IEEE Wireless Communications and Networking conference, 2021.
- [3] WANG, Xintao, et al. "ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks", Computer Vision - ECCV 2018 Workshops, pp 63 - 79, 2018.