

직렬 연결된 이미지 처리용 합성곱 신경망을 사용한 시간-주파수 채널 추정

김영찬, 장태준, 조준호
포항공과대학교

yckim321@postech.ac.kr, taejun8@postech.ac.kr, jcho@postech.ac.kr

Time-Frequency Channel Estimation Using Image Processing Convolutional Neural Networks

Youngchan Kim, Taejun Jang, Joon Ho Cho
POSTECH (Pohang University of Science and Technology)

요약

최근 기계학습을 이용해 시간-주파수 채널 행렬을 추정하는 방법에 대한 연구가 다수 진행되었다. 본 논문은 이러한 채널 추정에 이미지 처리용 초해상도 합성곱 신경망과 잡음제거 합성곱 신경망을 연결하여 사용하는 기존 방법을 재검토하였다. 기존 연구에서는 초해상도 신경망과 잡음제거 신경망 모두를 적용 대상 채널 모델에 훈련하여 사용하는 방식을 제안하였다. 반면에 본 논문은 초해상도 신경망을 적용 대상 채널 모델에 훈련하는 과정을 생략하여도 기존 연구와 유사한 채널 추정 성능을 달성할 수 있음을 보였다. 즉, 잡음제거 신경망의 훈련만으로도 기존 성능에 근접함을 보임으로써 학습 시간을 크게 감소시킬 수 있음을 확인하였다.

I. 서론

최근에 신경망을 이용한 기계학습이 크게 발달함에 따라 통신의 여러 분야에 기계학습을 적용하는 연구가 진행되었다. 채널 추정에도 기존의 통계적인 방법에서 탈피하여 기계학습을 이용하는 방법이 연구되었다 [1], [2]. 그 중에서 [1]에서는 이미지 처리용으로 개발된 기존의 신경망 2 개를 직렬 연결하여 채널 추정에 활용함으로써 인상적인 채널 추정 성능을 보여주었다.

[1]에서 사용하는 채널 추정 시스템은 파일럿 심볼을 이용하여 파일럿 위치에서의 채널을 추정한 후, 나머지 자원 요소(resource element)에서의 채널 추정값을 이미지 처리용 합성곱 신경망을 통해 구한다. 파일럿 위치만 추정된 시간-주파수 영역에서의 채널 행렬을 2차원 이미지와 유사하게 취급하여 이미지 처리용으로 만들어진 합성곱 신경망을 사용한다. 이 과정에서 저해상도 이미지를 고해상도 이미지로 변환하는 초해상도(super resolution)를 위한 합성곱 신경망인 SRCNN 과 함께 이미지의 잡음 제거(denoising)를 위한 합성곱 신경망인 DnCNN 을 사용한다.

본 논문은 이 시스템에서 첫 번째 신경망인 SRCNN 을 일반적인 이미지에 대해서만 학습시켜도 목표 채널 모델의 수많은 채널에 대해 학습시킬 때와 유사한 성능을 보임을 확인하였다. 이를 통해서 학습 시간을 단축시킬 수 있다.

II. 신호 및 시스템 모델

신호 모델은 다음과 같다. N_s 개의 부반송파와 N_D 개의 심볼이 있을 때, 시간-주파수 영역에서 채널을 통과한 수신 신호 행렬 $\mathbf{Y} \in \mathbb{C}^{N_s \times N_D}$ 의 i 행 k 열 원소는 다음과 같다.

$$Y_{i,k} = H_{i,k}X_{i,k} + W_{i,k}$$

여기에서 $\mathbf{H} \in \mathbb{C}^{N_s \times N_D}$ 는 채널 행렬, $\mathbf{X} \in \mathbb{C}^{N_s \times N_D}$ 는 송신 신호 행렬, $\mathbf{W} \in \mathbb{C}^{N_s \times N_D}$ 은 가산 백색 가우시안 잡음(additive white Gaussian noise) 신호를 뜻한다.

본 논문의 시스템에서는 파일럿 심볼을 이용한 채널 추정 기법을 사용한다. 파일럿 심볼의 위치가 정해져 있을 때, 시간 · 주파수 영역에서 파일럿 심볼 위치에 해당하는 채널의 값은 최소 제곱법(least squares)을 이용해서 다음과 같이 구할 수 있다.

$$\hat{\mathbf{H}}_p^{LS} = \arg \min_{\mathbf{H}_p} \|\mathbf{Y}_p - \mathbf{H}_p \circ \mathbf{X}_p\|_F^2$$

여기에서 $\mathbf{Y}_p$, $\mathbf{H}_p$, $\mathbf{X}_p$ 는 각각 $\mathbf{Y}$, $\mathbf{H}$, $\mathbf{X}$ 에서 파일럿 심볼 위치를 제외한 원소의 값이 0 인 행렬을 나타내며 $\circ$ 는 아다마르 곱(Hadamard product) 연산자를 나타낸다. 이를 풀면 다음과 같은 식으로 각 파일럿 심볼의 추정값을 구할 수 있다.

$$\hat{H}_{i,k} = \frac{Y_{i,k}}{X_{i,k}}$$

[1]에서 제안한 채널 추정 시스템인 ChannelNet 은 파일럿 심볼을 이용해 최소 제곱법으로 파일럿 심볼 위치에서만 추정된 채널을 입력받아 모든 심볼에서 높은 정확도로 추정된 채널을 출력한다. 이러한 과정에서 그림 1 과 같이 2 개의 합성곱 신경망을 사용한다.




그림 1. 합성곱 신경망을 사용한 채널 추정 시스템 구조

첫 번째 합성곱 신경망인 SRCNN 은 본래 저해상도 이미지를 고해상도 이미지로 변환하기 위해 설계되었다 [3]. 이 신경망은 보간된 저해상도 이미지를 입력받아 같은 크기의 고해상도 이미지를 출력한다.

그러나 우리는 이미지가 아닌 채널을 다루고 있으므로, 이를 이미지와 유사한 형식으로 변환하는 과정을 거쳐야 한다. 채널은 복소수 행렬로 표현할 수 있고 그레이스케일 이미지는 [0,1] 범위의 실수 행렬로 표현할 수 있기 때문에 전처리 과정으로 채널을 실수부와 허수부로 나누어 리스케일링하는 과정이 필요하다. 또한, [3]에서는 이미지를 보간하기 위해 쌍입방 보간법을 사용하였으나, 채널을 다룰 때에는 파일렛 심볼 위치가 격자점 모양으로 배치되지 않아도 처리할 수 있어야 하므로 보간 데이터점 위치를 임의로 지정할 수 있도록 가우시안 커널을 사용한 방사형 기저 함수(radial basis function) 보간법을 사용한다.

두 번째 합성곱 신경망인 DnCNN 은 본래 잡음이 있는 이미지에서 잡음을 제거하기 위해 설계되었다[4]. 이 신경망은 잡음이 있는 이미지를 입력받아 최대한 잡음과 동일한 이미지를 출력한다. 따라서 신경망의 입력에서 출력을 빼면 잡음이 제거된 이미지를 구할 수 있다.

기존의 논문 [1]에서는 SRCNN 과 DnCNN 을 모두 적용하려는 채널 모델의 수많은 채널에 대해 학습시켰다. 그러나 본 논문에서는 SRCNN 은 일반적인 이미지에 대해 사전 학습된 것을 그대로 사용하고 DnCNN 만 채널에 대해 따로 학습하여도 시스템이 상당히 양호한 채널 추정 성능을 보임을 확인하였다.

III. 시뮬레이션 결과

기본적인 시뮬레이션 매개 변수는 $N_S = 72$, $N_D = 14$ 를 사용하는 등 기존 논문[1]과 동일하게 설정하였다. 학습 및 성능 평가에 사용된 채널들은 채널 시뮬레이터를 이용해 생성되었으며, VehA 채널 모델과 SUI5 채널 모델의 두 가지 경우로 나뉘었다. 학습 데이터셋, 테스트 데이터셋은 각각 32000 개, 10000 개를 사용하였다. 또한 낮은 SNR 과 높은 SNR 의 경우로 나누어, 하나의 채널 모델 및 SRCNN 의 채널 추가 학습 여부에 따라 각각 DnCNN 을 2 개 학습하였다. 낮은 SNR 용 신경망은 SNR 12 dB 인 채널을 이용하여 학습하였고, 높은 SNR 용 신경망은 SNR 22 dB 에 맞추어 학습하였다.

그림 2 와 3 은 이렇게 학습시킨 시스템의 시뮬레이션 결과를 나타낸다.




그림 2. VehA 채널 모델에서의 채널 추정값 MSE 비교

VehA 과 SUI5 채널 모두에서 낮은 SNR 을 목표로 학습한 신경망을 사용하는 경우, 채널에 대해 학습한 SRCNN 과 일반적인 이미지에 대해 학습한 SRCNN 의

MSE 차이가 1 dB 이내로 매우 작았다. 또한 높은 SNR 을 목표로 학습한 신경망을 사용하는 경우에도 마찬가지로 두 경우의 MSE 차이가 1.1 dB 이내로 매우 작은 것




그림 3. SUI5 채널 모델에서의 채널 추정값 MSE 비교

을 확인할 수 있었다.

IV. 결론

본 논문에서는 채널 추정에 이미지 처리용 합성곱 신경망을 사용하는 기존 시스템을 재구현하고 분석하였다. 이를 통해 사용된 합성곱 신경망의 일부만을 채널에 대해 추가 학습시킴으로써 기존의 시스템과 유사한 채널 추정 성능을 보임으로써 학습에 필요한 시간을 크게 감소시킬 수 있음을 확인하였다.

ACKNOWLEDGMENT

이 논문은 부분적으로 2020 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구이며 [No. 2016-0-00123, 5G & Beyond 이동통신 시스템을 위한 정수 한정 MIMO 송/수신기 개발], 부분적으로 2020 년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 [No. 2018R1D1A1A02086169, QAM-FBMC: 6G & Beyond 이동통신 표준을 위한 새로운 파형 설계 연구].

참고 문헌

- [1] M. Soltani, V. Pourahmadi, A. Mirzaei and H. Sheikhzadeh, "Deep learning-based channel estimation," in IEEE Communications Letters, vol. 23, no. 4, pp. 652-655, April 2019.
- [2] H. He, C. Wen, S. Jin and G. Y. Li, "Deep learning-based channel estimation for beamspace mmWave massive MIMO systems," in IEEE Wireless Communications Letters, vol. 7, no. 5, pp. 852-855, Oct. 2018.
- [3] C. Dong, C. C. Loy, K. He and X. Tang, "Image super-resolution using deep convolutional networks," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 38, no. 2, pp. 295-307, 1 Feb. 2016.
- [4] K. Zhang, W. Zuo, Y. Chen, D. Meng and L. Zhang, "Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising," in IEEE Transactions on Image Processing, vol. 26, no. 7, pp. 3142-3155, July 2017.