

다중경로 페이딩 환경에서 심층 학습을 이용한 채널 추정 기법

박정균*, 고경준*, 김희영**,
왕한호***, 최수용°

A Deep Learning Based Channel Estimation in Multipath Fading Environment

Junggyun Park*, Kyeongjun Ko*,
Heeyoung Kim**, Hanho Wang***,
Sooyong Choi°

요약

본 논문에서는 다중경로 페이딩 채널 환경에서 심층 학습을 이용한 채널 추정 기법을 제안하였다. 채널 추정을 위한 파일럿 신호는 다중 경로 채널을 통과하면서 크기와 위상이 변화하게 되는데 심층 학습을 이용하여 송신된 파일럿의 변화된 크기와 위상을 추정하였다. 실험을 통해 심층 학습 기반 채널 추정 기법이 기존의 선형 채널 추정 기법에 비해 잡음에 강인하며 추정 정확도가 우수함을 확인할 수 있다.

Key Words : multipath fading channel, channel estimation, deep learning, deep neural network, multi layer perceptron

ABSTRACT

In this paper, we propose a deep learning based channel estimation method in multipath fading

environment. If the pilot sequences for channel estimation are transmitted through the multipath fading channel, their amplitude and phase change in the channel. The deep learning algorithm is applied to estimate the channel. We compare the performance of the deep learning based channel estimator with the widely used linear channel estimator. The deep learning based channel estimator performs better than the conventional linear channel estimation scheme with respect to the mean squared error (MSE).

1. 서론

무선통신 시스템에서는 다중경로 페이딩으로 인해 수신 심볼의 크기와 위상이 왜곡된다. 이러한 신호의 왜곡을 추정하여 보상하기 위해 전송 신호가 수신 안테나에 도착하기까지의 무선 채널의 응답을 추정하는 채널 추정 기법이 사용된다. 다양한 채널 추정 기법 중 훈련 기반 채널 추정 방식은 파일럿과 같이 송수신 단에서 모두 알고 있는 훈련 신호를 사용하여 채널을 추정하는 기법으로, 최소자승 (LS, least squares) 또는 최소평균제곱오차 (MMSE, minimum mean square error) 등과 같은 선형 방식이 대표적으로 사용되고 있다¹⁾. 최소자승 기법은 구조가 간단하지만 잡음에 민감하다는 단점이 있으며, 최소평균제곱오차 기법은 잡음을 고려한 전체 추정 오차가 최소가 되도록 하므로 우수한 성능을 보이지만, 동작 SNR(signal-to-noise ratio)과 채널의 자기 상관과 같은 통계적 정보가 필요하다는 단점이 있다²⁾.

한편 기존 컴퓨터의 연산능력의 한계로 인해 이론으로만 존재하였던 인공 신경망(neural network) 기반의 심층 학습(deep learning) 알고리즘은 현대의 발전된 컴퓨터 하드웨어와 결합하여 다양한 분야에 적용되어 새로운 해결책을 제시해 주고 있다³⁾. 최근에는 채널 추정 등 무선통신 분야에도 심층 학습 알고리즘

* 본 연구는 한국철도기술연구원 주요사업의 연구비 지원으로 수행되었습니다.

• First Author : (ORCID:0000-0001-5192-9432) School of Electrical and Electronic Engineering, Yonsei University, pjgstar@yonsei.ac.kr, 학생회원

° Corresponding Author : (ORCID:0000-0001-7413-1765) School of Electrical and Electronic Engineering, Yonsei University, csyong@yonsei.ac.kr, 중신회원

* (ORCID:0000-0001-7575-864X) Smart Electrical & Signaling Division, Korea Railroad Research Institute, kkj8000@krii.re.kr, 정회원

** (ORCID:0000-0001-8552-7060) School of Electrical and Electronic Engineering, Yonsei University, khy93@yonsei.ac.kr, 학생회원

*** (ORCID:0000-0002-0672-7775), Smart Information and Telecommunication Engineering, Sangmyung University, hhwang@smu.ac.kr, 정회원

논문번호 : 201911-290-A-LU, Received November 8, 2020; Revised November 13, 2020; Accepted November 13, 2020;

을 적용이 활발히 진행되고 있다⁴⁾.

본 논문에서는 심층 학습을 이용한 채널 추정 기법을 제안한다. 심층 학습의 특성상 평균화 연산 과정에서 파생되는 잡음 감소 효과를 얻을 수 있어, 자기 상관과 같은 채널의 통계적 정보 없이도 잡음에 강인한 특성을 가질 것으로 예상된다.

II. 시스템 모델

본 논문에서는 최대 L 개의 다중경로 지연 확산을 갖는 채널 임펄스 응답 (CIR, channel impulse response) $\mathbf{h} = [h_0 \ h_1 \ \dots \ h_L]^T$ 에 대해 송신 단과 수신 단에서 모두 알고 있는 길이 P 의 파일럿 신호 $\mathbf{s} = [s_1 \ s_2 \ \dots \ s_P]^T$ 를 사용하는 훈련 기반 채널 추정 환경을 고려한다. 수신 단에서 t 시간에 수신하는 신호 y_t 는 아래의 식 (1)과 같이 표현된다.

$$y_t = s_t h_0 + s_{t-1} h_1 + \dots + s_{t-L} h_L + n_t$$

$$= \sum_{i=0}^{L-1} s_{t-i} h_i + n_t \tag{1}$$

여기서 h_i 는 단위 크기의 복소 가우시안(Complex Gaussian) 확률 분포를 따르며, 이와 같은 채널 모델을 레일리(Rayleigh) 페이딩 채널이라고 한다. n_t 는 백색잡음으로 평균이 0이고 분산이 σ_n^2 인 복소 가우시안 분포를 따르는 랜덤 변수이다.

III. 선형 채널 추정 기법

훈련 기반 선형 채널 추정 기법은 수신 단에서 파일럿의 왜곡을 통해 채널의 상태를 알아내는 방식이다. 채널 추정에 사용되는 파일럿 신호와 파일럿 수신 신호, CIR을 행렬 형태로 나타내면 다음과 같다.

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{P+L} \end{bmatrix} = \begin{bmatrix} s_1 & 0 & 0 & \dots & 0 \\ s_2 & s_1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ s_{L+1} & s_L & s_{L-1} & \dots & s_1 \\ s_{L+2} & s_{L+1} & s_L & \dots & s_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ s_P & s_{P-1} & s_{P-2} & \dots & s_{P-L} \\ 0 & s_P & s_{P-1} & \dots & s_{P-L+1} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & S_P \end{bmatrix} \begin{bmatrix} h_0 \\ h_1 \\ \vdots \\ h_L \end{bmatrix} + \begin{bmatrix} n_1 \\ n_2 \\ \vdots \\ n_{P=L} \end{bmatrix} \tag{2}$$

$$= \mathbf{S}^T \mathbf{h} + \mathbf{n}.$$

최소자승 채널 추정은 다음과 같이 구할 수 있다.

$$\hat{\mathbf{h}}_{LS} = (\mathbf{S}^T)^\dagger \mathbf{y}. \tag{3}$$

여기서 $(\cdot)^\dagger$ 는 무어-펜로즈 의사 역행렬(Moore - Penrose pseudo inverse matrix)을 나타낸다.

또한, 최소평균제곱오차 채널 추정은 다음 식과 같이 이루어진다.

$$\hat{\mathbf{h}}_{MMSE} = \mathbf{R}_h \mathbf{S}^H (\mathbf{S}^T \mathbf{R}_h \mathbf{S}^H + \sigma_n^2 \mathbf{I})^{-1} \mathbf{y}. \tag{4}$$

여기서 $\mathbf{R}_h = \mathbf{h} \mathbf{h}^H$ 는 CIR의 자기 상관을 의미하고, $(\cdot)^H$ 는 행렬의 쥘레 전치(conjugate transpose)를 의미한다.

최소자승 기법은 구현이 쉬운 반면 잡음의 영향을 크게 받기 때문에 낮은 SNR 영역에서는 채널 추정 성능이 떨어진다. 최소평균제곱오차 방법은 식 (4)에서 볼 수 있듯이 잡음의 전력 및 CIR의 자기 상관을 고려하기 때문에 최소자승 방법보다 추정 성능은 좋지만, 추가적인 정보가 필요하다는 단점이 있다.

IV. 심층 학습 기반 채널 추정 기법

심층 학습의 기반이 되는 인공 신경망은 생물학적 뉴런의 구조 및 기능을 수학적으로 표현한 것으로, 신경망의 입력으로부터 가중치를 자동으로 학습하는 능력을 가지는 모델 전반을 가리킨다. 다층 퍼셉트론은 이러한 인공 신경망을 구현하는 알고리즘의 한 종류이며⁵⁾, 그림 1과 같이 입력층과 출력층 사이에 은닉층(hidden layer)이라 불리는 중간층이 하나 이상으로 구성된 구조를 갖는다. 이러한 심층 신경망을 학습하기 위해 고안된 알고리즘을 심층 학습이라 한다.

본 논문에서 제안하는 심층 학습 기반 채널 추정 기법은 그림 2와 같이 학습 단계와 추정 단계로 구분된다. 학습 단계에서는 다층 퍼셉트론을 이용하여 파일럿 신호와 파일럿 수신 신호 사이의 관계를 모델링

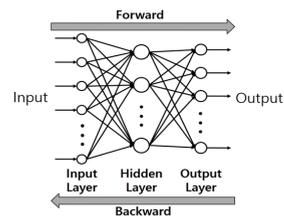


그림 1. 은닉층이 하나인 다층 퍼셉트론 구조
Fig. 1. The structure of multi layer perceptron with 1 hidden layer.

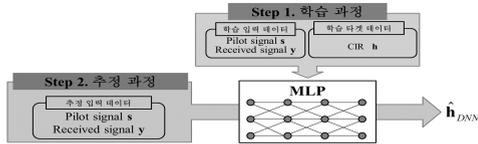


그림 2. 심층 학습 기반 채널 추정 기법.
Fig. 2. Deep learning based channel estimation method.

하고, 파일럿 신호와 파일럿 수신신호를 입력으로 하여 다층 퍼셉트론의 출력을 산출하는 전방향처리(feed forward) 과정과, 입력한 파일럿 수신 신호에 대응되는 CIR을 목표값으로 하여 다층 퍼셉트론 출력값과 목표값 사이의 오차가 최소가 되도록 은닉층의 가중치를 변환, 조절하는 역방향처리(feed backward) 과정이 반복 수행된다. 채널 추정 단계에서는 학습 단계에서 최종적으로 획득한 다층 퍼셉트론 모델과 추정하려는 CIR에 대한 파일럿 신호 및 파일럿 수신 신호를 이용하여 추정된 채널을 구할 수 있다.

V. 채널 추정 성능 검증

본 논문에서 제안하고 있는 심층 학습 기반 채널 추정 기법과 기존의 선형 채널 추정 기법의 성능을 검증하였다. 일반적으로 채널 추정 시 채널 추정의 정확도는 추정된 채널이 실제 채널과 유사한 정도를 나타내는 평균제곱오차 (MSE, mean square error)로 측정한다.

$$MSE = E[|\mathbf{h} - \hat{\mathbf{h}}|^2]. \quad (5)$$

채널 추정을 위한 파일럿 신호는 길이가 10인 유사 잡음(PN, pseudo noise) 코드를 BPSK(binary phase shift keying) 변조하여 전송하며, 채널은 다중경로 지연확산의 개수가 4~9개가 되도록 임의의 레일리 페이딩 채널을 생성하였다. 다층 퍼셉트론은 은닉층 수를 2개 또는 5개로, 은닉층 당 뉴런 수는 100개 또는 500개로 구성하였으며, 서로 다른 200,000개의 파일럿 신호와 파일럿 수신신호, 다중경로 페이딩 채널을 사용하여 학습하였다.

그림 3에는 각각의 채널 추정기법의 SNR에 따른 MSE 결과가 도시되어 있다. 다층 퍼셉트론의 구조가 간단한 경우(은닉층의 수가 2개) 제안한 채널 추정기의 성능은 최소자승 기법과 최소평균제곱오차 기법의 사이에 존재하지만, 다층 퍼셉트론의 구조가 복잡해질수록(은닉층의 수가 5개, 은닉층당 뉴런 수가 500개) 제안한 채널 추정기의 MSE 성능이 선형 채널 추정기

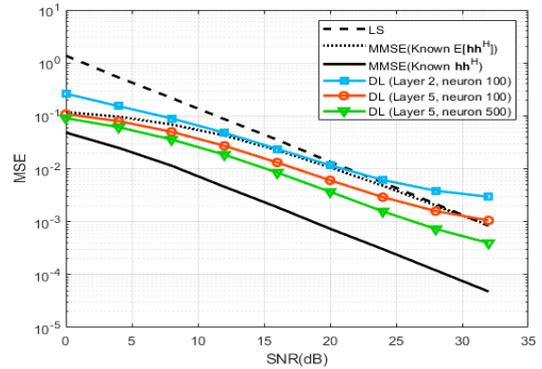


그림 3. 심층 학습 기반의 채널 추정 MSE.
Fig. 3. MSE of deep learning based channel estimation.

보다 우수함을 알 수 있다.

VI. 결론

본 논문에서는 심층 학습을 활용한 채널 추정 기법을 제안하고 기존의 선형 기법들과 채널 추정 성능을 비교하였다. 실험 결과 심층 신경망 기반 채널 추정 기법은 동일한 정보를 사용하는 최소자승 채널 추정과, 추가적인 정보를 사용하는 최소평균제곱오차 채널 추정보다 높은 추정 성능을 보이는 것을 확인할 수 있었다. 하지만 학습의 복잡도가 높다는 문제가 있으며, 성능 향상의 한계에 대한 분석이 전무한 상황이다. 추후 신경망 구조를 최적화하고, 학습 복잡도를 줄이는 방안에 대한 연구가 필요하다.

References

- [1] M. X. Chang and Y. T. Su, "Model-based channel estimation for OFDM signals in Rayleigh fading," *IEEE Trans. Commun.*, vol. 50, pp. 540-544, Apr. 2002.
- [2] M. Lorelli and U. Mengali, "A comparison of pilot-aided channel estimation method for OFDM systems," *IEEE Trans. Signal Process.*, vol. 49, no. 12, pp. 3065-3073, Dec. 2001.
- [3] D. Jeong, "Trend on artificial intelligence technology and its related industry," *Korea Inst. Inf. Technol. Mag.*, vol. 15, no. 2, pp. 21-28, Dec. 2017.
- [4] H. Ye, G. Y. Li, and B. H. Juang, "Power of

deep learning for channel estimation and signal detection in OFDM systems,” *IEEE Wirel. Commun. Lett.*, vol. 7, no. 1, pp. 114-117, Jan. 2018.

- [5] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, MIT Press, 2016.