

딥러닝 기반 지능형 재구성 표면 통신 채널 추정 기법

전정원, 최가은, 서경식, 노송[‡]
인천대학교

{jungwon1702, gaeun1884, ksseo, songnoh}@inu.ac.kr

요 약

통신용량 개선을 위해 기존의 송·수신기 위주의 시스템 최적화 연구와 달리, 지능형 재구성 표면 (Reconfigurable intelligent surface, RIS)을 사용한 무선 통신환경 최적화 연구 및 저전력·저복잡도 RIS 운용 기법이 활발히 연구되고 있다. 실제환경에서 이러한 RIS 기반 통신성능을 실현하기 위해, 본 논문은 지능형 재구성 표면 기반 시스템에서 딥러닝 기반 다수 채널 경로의 추정 기법을 제안한다. 또한, 제안된 딥러닝 RIS 채널 추정 모델의 성능 검증을 위해 신호 대 잡음비 및 안테나 개수 변화에 따른 채널 추정 성능을 분석하였다.

I. 서 론

밀리미터파(millimeter-wave) 및 테라헤르츠(terahertz) 대역 기반 통신은 광대역 대역폭과 대규모 안테나 배열을 사용해 대용량 무선 데이터 트래픽 지원이 가능하다. 그러나, 초고주파 대역은 파장의 길이가 매우 짧아 전파가 도달하는 거리에 장애물이 있는 환경(Non-line-of-sight, NLoS) 또는 실외 기지국에서 실내로 들어오는 상황(Outdoor-to-indoor, O2I)에서 손실이 발생하는 특성 또한 갖는다. 이를 보완하기 위해 지능형 재구성 표면(Reconfigurable intelligent surface, RIS)을 적용해 NLoS 환경에서 추가 통신 전달경로를 제공하고, O2I 환경에서 투과 감소를 완화하여 통신 음영지역을 개선할 수 있다[1-2]. 이를 위해서는 송수신기와 RIS 사이의 정확한 채널 정보를 확보해야 하기에 다양한 딥러닝 기법들이 적용되고 있다[3-5].

따라서 본 논문은 딥러닝 기법을 적용해 RIS 기반 통신 시스템에서 수신 안테나 개수에 따라 신경망을 학습시키고 채널 추정 성능을 비교하고 분석한다.

II. 시스템 모델

본 논문에서는 단일 송신 안테나, N 개의 RIS 선형 배열 소자, M 개의 선형 배열 수신 안테나로 구성된 통신 시스템을 고려한다. 이때 송신기와 RIS 사이의 채널의 수식은 다음과 같다.

$$\mathbf{h} = \sum_{l=1}^{L_h} \alpha_{h,l} \mathbf{u}_N(\theta_{h,l}) = \mathbf{U}_N(\boldsymbol{\theta}_h) \text{diag}(\boldsymbol{\alpha}_h) \in \mathbb{C}^N \quad (1)$$

L_h 는 송신기와 RIS 사이 경로 수를 의미하고, $\alpha_{h,l}$ 은 경로 별 채널 이득, $\theta_{h,l}$ 은 경로 별 송신기와 RIS 사이의 각이다. \mathbf{u}_N 은 조향 벡터를 의미하며 수식은 다음과 같다.

$$\mathbf{u}_P(\boldsymbol{\vartheta}) = [1, e^{j\pi\vartheta}, \dots, e^{j\pi\vartheta(P-1)}]^T \quad (2)$$

$$\mathbf{U}_P(\boldsymbol{\vartheta}) = [\mathbf{u}_P(\vartheta_1), \dots, \mathbf{u}_P(\vartheta_L)] \quad (3)$$

그리고 RIS 와 수신기 사이의 채널은 다음과 같다.

$$\begin{aligned} \mathbf{G} &= \sum_{l=1}^{L_g} \alpha_{g,l} \mathbf{u}_M(\phi_{g,l}) \mathbf{u}_N^H(\theta_{g,l}) \\ &= \mathbf{U}_M(\boldsymbol{\phi}_g) \text{diag}(\boldsymbol{\alpha}_g) \mathbf{U}_N^H(\boldsymbol{\theta}_g) \in \mathbb{C}^{M \times N} \end{aligned} \quad (4)$$




그림 1. 심볼 시간 i 에서의 시스템 구조

L_g 는 RIS 와 수신기 사이 경로 수를 의미하고, $\alpha_{g,l}$ 은 경로 별 채널 이득, $\phi_{g,l}$ 은 경로 별 RIS 의 각이다. $\mathbf{u}_M, \mathbf{u}_N$ 은 조향 벡터를 의미한다.

$$\boldsymbol{\psi} = [e^{j\psi_1}, \dots, e^{j\psi_N}]^T \quad (5)$$

수식 (5)의 $\boldsymbol{\psi}$ 는 각 RIS 요소의 조향 벡터이다.

채널 (1), (4), (5)을 거쳐 심볼시간 i 에서 수신된 신호는 다음과 같다.

$$\mathbf{y}_i = \mathbf{G} \cdot \text{diag}(\boldsymbol{\psi}_i) \cdot \mathbf{h} \cdot \mathbf{x}_i + \mathbf{n}_i \quad (6)$$

$$= \sum_{l=1}^L \alpha_l \mathbf{u}_M(\phi_l) \mathbf{u}_N^H(\theta_l) \boldsymbol{\psi}_i \mathbf{x}_i + \mathbf{n}_i \quad (7)$$

$$\begin{aligned} L &\triangleq L_g L_h, \alpha_l \triangleq \alpha_{g,m} \alpha_{h,n}, \phi_l \triangleq \phi_{g,m}, \theta_l = \theta_{g,m} - \theta_{h,n}, \\ l &= (m-1)L_h + n, 1 \leq m \leq L_g, 1 \leq n \leq L_h. \end{aligned} \quad (7-1)$$

심볼시간 i 에서 \mathbf{x}_i 는 전력이 1 인 송신 신호이며, \mathbf{n}_i 은 가산 백색 잡음을 나타낸다 ($\mathbf{n}_i \sim \mathcal{CN}(\mathbf{0}_M, \sigma_n^2)$).

수식 (6)은 조건 (7-1)에 의해 수식 (7)로 전개할 수 있고, 이런 수식 (7)에 대해 심볼 시간 $1 \leq i \leq N_p$ 동안 받은 총 신호의 수식은 다음과 같으며 N_p 는 전체 심볼 시간을 나타낸다.

$$\mathbf{Y} = [\mathbf{y}_1 \cdots \mathbf{y}_{N_p}] \quad (8)$$

$$= \mathbf{U}_M(\boldsymbol{\phi}) \cdot \text{diag}(\boldsymbol{\alpha}) \cdot \mathbf{U}_N^H(\boldsymbol{\theta}) \cdot \boldsymbol{\Psi} \cdot \text{diag}(\mathbf{x}) + \mathbf{N}$$

$$\begin{aligned} \mathbf{x} &= [x_1, \dots, x_{N_p}]^T, \quad \mathbf{N} = [\mathbf{n}_1, \dots, \mathbf{n}_{N_p}], \quad \boldsymbol{\Psi} = [\boldsymbol{\psi}_1, \dots, \boldsymbol{\psi}_{N_p}] = \\ &= [\mathbf{I}_{N_p}; \mathbf{0}_{(N-N_p) \times N_p}]. \end{aligned}$$

III. 제안된 딥러닝 기반 채널 추정 방법




그림 2. 학습 딥러닝 구조

본 논문에서 시행한 모델은 그림 2로 ϕ , θ 를 추정하기 위해 입력 값은 복소수 연산이 제한되는 텐서플로우를 극복 하기위해 $[Re\{Y\} \quad Im\{Y\}]$, $\in \mathbb{R}^{M \times 2N_p}$ 로 구성하고 출력 값은 다음과 같이 구성한다 $\hat{\rho} := [\hat{\phi}^T, \hat{\theta}^T]^T \in \mathbb{R}^{2L}$.

손실함수는 평균 제곱오차(Mean Squared Error, MSE) 함수를 적용하며, 입력 값을 모델에 입력해 출력 값에 대해 이 함수를 최소화하는 방향으로 학습시키고 수식은 다음과 같다.

$$MSE = \frac{1}{2L} \sum_{l=1}^L \|\rho - \hat{\rho}\|_2 \quad (9)$$

IV. 성능 분석 및 결론

수신 안테나 개수에 따른 딥러닝 기반 채널 추정 성능을 비교하기 위해 다음과 같은 시뮬레이션 환경을 고려한다. RIS 소자 개수 $N = 16$, 심볼 시간 $N_p = 5$, 채널 경로 수 $L = 1$ 로 설정하고, 신호 대 잡음비 (Signal-to-Noise ratio, SNR)로 정의하고 $SNR = \frac{|x_i|^2}{\sigma_n^2} = 30\text{dB}$ 환경에서 수신 안테나 개수 $M = 4, 8, 16, 32$ 의 값들로 각각 학습시킨다.

그림 3은 $M = 4$ 에 대해 학습시킨 모델에 대해 SNR 에 따른 MSE 의 성능을 나타내고 있다. 학습한 모델은 SNR 이 증가할수록 MSE 의 성능이 더욱 향상되는 모습을 보이고 있다.

그림 4는 $SNR=15\text{dB}$ 환경에서 서로 다른 M 에 대해 학습한 모델들 간 M 에 따른 MSE 의 성능을 나타내고 있다. M 이 증가할수록 M 이 적은 모델보다 MSE 에 대해 더 향상된 성능을 보이고 있다.

본 논문에서는 딥러닝 모델의 하이퍼 파라미터가 아닌 시스템 모델의 파라미터의 변화로 인한 딥러닝 모델의 성능 차이를 확인했다. 이후 추가적인 연구로는 시스템 모델의 파라미터 또한 고려하여 통신용 심층 신경망 연구에 적용하고자 한다.




그림 3. SNR(dB)에 따른 MSE 성능 비교




그림 4. SNR=15dB 환경에서 수신 안테나 개수에 따른 MSE 성능 비교

ACKNOWLEDGMENT

본 연구는 2022년도 정부(산업통상자원부)의 재원으로 한국산업기술평화원의 지원과, 2022년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (과제번호: P0022557, NRF-2022R1F1A1074612).

참고 문헌

- [1] Samsung, "6G The Next Hyper-Connected Experience for All," Dec. 2020.
- [2] C. Huang, A. Zappone, G. C. Alexandropoulos, M. Debbah and C. Yuen, "Reconfigurable intelligent surfaces for energy efficiency in wireless communications," *IEEE Transactions on Wireless Communications*, vol. 18, no. 8, pp. 4157-4170, Aug. 2019.
- [3] 서경식, 노승. (2021), "딥러닝을 이용한 지능형 반사 표면 기반 통신 시스템 채널 추정 및 신호 검출 성능 분석," 『한국통신학회 학술대회 논문집,』 112-113.
- [4] N. Ginige, K. B. Shashika Manosha, N. Rajatheve and M. Latva-aho, "Untrained DNN for channel estimation of RIS-assisted multi-user OFDM system with hardware impairments," *2021 IEEE 32nd Annual International Symposium on Personal Indoor and Mobile Radio Communications (PIMRC)*, pp. 561-566, 2021.
- [5] A. M. Elbir, A. Papazafeiropoulos, P. Kourtessis, and S. Chatzinotas, "Deep channel learning for large intelligent surfaces aided mm-WAVE massive MIMO systems," *IEEE Wireless Communications Letters*, vol. 9, no. 9, pp. 1447-1451, Sep. 2020.