

# 간략화된 구조의 DBPN 기반 RIS 시스템의 채널 추정

서정빈, 김석찬\*

부산대학교, \*부산대학교

sjb9612@pusan.ac.kr, \*sckim@pusa.ac.kr

## Channel Estimation for RIS System Based on DBPN with Simplified Structure

Jeongbin Seo, Suk Chan Kim\*

Pusan Univ., \*Pusan Univ.

### 요약

본 논문은 간략화된 구조의 deep back-projection networks(DBPN)을 사용한 reconfigurable intelligent surfaces(RIS)시스템의 채널 추정 기법을 제안한다. 제안하는 채널 추정 기법은 기존 DBPN의 적층 연산을 가중화된 덧셈과 가중화된 적층연산으로 변경하여 채널을 추정한다. 제안하는 채널 추정 기법은 기존 DBPN을 이용하여 채널을 추정했을 때 보다, 일정 신호 대 잡음비 구간에서 우수한 채널 추정 정확도를 가진다.

### I. 서론

본 논문에서는 딥러닝 기반 초해상화 기술 중 deep back projection networks (DBPN)을 사용한 RIS 시스템의 채널 추정 기술을 제안한다. DBPN은 반복적인 상향 및 하향 프로젝션으로 인해 타 모델 대비 우수한 정확도로 초해상화를 수행하는 딥 러닝 모델이다[2]. DBPN은 이전 계층에서 계산된 정보를 다음 계층에 전달할 때 적층(concatenation) 연산을 이용한다. DBPN은 모듈형 구조로 모델이 사용하는 계층 수를 조절할 수 있는 장점이 있다. 그러나 모델이 많은 계층을 사용할수록, 적층 연산에 의해 모델의 연산량이 증가하게 된다. 또한 앞쪽 계층에서 계산된 정보를 그대로 뒤쪽 계층에 전달할 경우, 낮은 정확도로 연산된 결과가 그대로 전달될 수 있기 때문에 정확도가 저하될 수 있다. 본 연구에선 DBPN의 사전 계산 정보를 전달하는 방식을 덧셈, 가중화된 적층 연산, 덧셈과 배치 정규화(batch normalization, BN) 적용 방법으로 변경하여 RIS시스템의 채널을 추정했다. 결과적으로 제안한 기술이 기존 DBPN보다 우수한 채널 추정 성능을 가진다.

### II. 본론

본 논문에서는 다중사용자가 존재하는 단일 입력 단일 출력 RIS 시스템을 가정한다. 단일 안테나를 사용하는  $K$ 명의 사용자가 존재하고, 단일 안테나를 가진 기지국이 하나 배치되어 있으며, RIS는  $N_x \times N_y (= N)$  구조의  $N$ 개의 수동소자를 가진다. 각 사용자는 시간 분할 다중화 방식으로 통신한다. 또한 채널의 시간상호성을 활용하여 상향 링크 상황에서 사용자들이 송신하는 파일럿 신호로 기지국에서 채널을 추정한다.

$k \in \{1, 2, \dots, K\}$  번째 사용자가 파일럿 신호( $x_k \in \mathbb{C}^{1 \times 1}$ )를 송신했을 때, 기지국에서 수신된 신호( $y_k \in \mathbb{C}^{1 \times 1}$ )는 아래와 같다.

$$y_k = h_{BR} \Phi h_{RU,k} x_k + h_{d,k} x_k + w \quad (1)$$

이 때,  $h_{BR} \in \mathbb{C}^{1 \times N}$ ,  $h_{RU,k} \in \mathbb{C}^{N \times 1}$ ,  $h_{d,k} \in \mathbb{C}^{1 \times 1}$ 는 각각 기지국과 RIS, RIS와  $k$  번째 사용자, 사용자와 기지국 간의 채널이며,  $w \sim \mathcal{N}(0, \sigma^2)$ 는 백색 가우시안 잡음이다.  $\Phi \in \mathbb{C}^{N \times N}$ 는 RIS의 반사 계수행렬이다.

$$\Phi = \text{diag}(\beta_1 e^{j\theta_1}, \beta_2 e^{j\theta_2}, \dots, \beta_N e^{j\theta_N}) \quad (2)$$

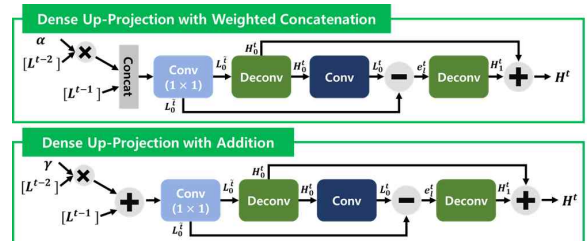
이 때,  $\beta_n \in [0, 1]$ 은  $n$  번째 RIS 수동소자 반사 계수의 진폭이며,  $\theta_n \in \{0, 2\pi\}$ 은  $n$  번째 수동소자 반사 계수의 위상이다. 우리는 채널 추정 기술의 성능을 분석하기 위해  $\beta_n = 1$ 로 가정한다. 본 연구에선 장애물에 의해 경로가 막혀 기지국과 사용자 간의 직접적인 채널( $h_{d,k}$ )은 없다고 가정한다. 해당 가정에 따라 수신 신호는 아래와 같이 변경된다.

$$y_k = h_{BR} \Phi h_{RU,k} x_k + w \quad (3)$$

RIS에는 RF chain이 없기 때문에  $h_{BR}$ 과  $h_{RU,k}$ 를 개별적으로 추정하는 것은 불가능하다. 따라서 간단한 행렬 연산을 통해 채널의 형태를 아래와 같이 변경한다.

$$h_{BR} \Phi h_{RU,k} = h_{BR} \text{diag}(h_{RU,k}) \phi = h_k \phi \quad (4)$$

이 때,  $\phi \in \mathbb{C}^{N \times 1}$ 은  $\Phi$ 가 벡터화된 형태이다. 본 논문에선 DBPN을 활용하여  $h_k$ 를 추정하는 것을 목표로 한다.



[ 그림 1 ] 제안하는 밀집된 상향 및 하향 프로젝션 블록의 구조

### III. 제안하는 채널 추정 기법

본 논문에서는 초해상화용 딥 러닝 모델인 DBPN을 활용한 채널 추정 방법을 제안한다. DBPN은 반복적인 상향 프로젝션과 하향 프로젝션을 통해 높은 정확도로 초해상화를 수행한다. DBPN은 3단계(특징 추출, 백-

프로젝션, 재건설)의 동작으로 초해상화를 수행한다. 특징 추출과 재건설 단계는 합성곱 계층으로 수행된다.

백-프로젝션 단계는 4종류의 building block, 상향 프로젝트, 하향 프로젝트, 밀집된 상향 프로젝트(dense up-projection), 밀집된 하향 프로젝트(dense down-projection),을 겹겹이 쌓아 진행된다. 백-프로젝션은 2개의 상향 프로젝트 블록과 1개의 하향 프로젝트 블록, 그리고 여러 쌍의 밀집된 상향 및 하향 프로젝트 블록으로 구성된다. 4종의 building block엔 같은 크기의 이미지끼리 더하고 빼는 과정이 들어가 있는데, 이를 자가 검증(self-correction)이라고 하며, 해당 과정으로 인해 DBPN이 다른 초해상화 모델보다 우수한 성능을 가진다[2]. 기존의 DBPN은 밀집된 상향 및 하향 프로젝트 블록에서 적층 연산을 통해 이전 모든 블록의 연산 결과를 전달받는다. 따라서 DBPN은 모델이 깊어질수록 filter의 수가 증가되게 설계되었다. 본 연구에서는 밀집된 상향 및 하향 프로젝트 블록이 이전 블록의 연산 결과를 전달받을 때, 덧셈과 가중화된 적층을 적용한 구조를 제안한다. 모델 초반 블록에서의 연산 결과를 그대로 전달하는 것은 모델 성능을 열화시킬 수 있다. 그에 따라 우리는 밀집된 상향 및 하향 프로젝트 블록에서 이전 프로젝트 블록 결과의 영향을 감소시키기 위해 가중치( $\alpha$ -가중화된 적층 연산,  $\gamma$ -덧셈)를 적용했다. 덧셈을 적용할 경우, 적층 연산을 적용할 때와 달리 모델이 깊어져도 각 블록 입력의 filter 수가 증가하지 않기 때문에 모델 연산량이 줄어든다. 그림 1은 제안하는 밀집된 상향 프로젝트 블록의 구조이며, 하향 프로젝트 블록도 동일한 방식으로 설계했다.

DBPN을 활용하여 RIS 시스템의 채널을 추정하기 위해 채널 벡터의 형태를 변경했다. 우선 채널을 RIS의 구조와 동일한 형태인  $N_x \times N_y$  구조의 2차원 행렬 변경하고 정규화했다. 또한 DBPN의 활성화 함수가 실수영역에만 정의되어 있기 때문에 채널 행렬을 실수부와 허수부로 나누어  $N_x \times N_y \times 2$  구조의 3차원 행렬로 변경했다. 변경된 채널을 하향 샘플링하여 DBPN 훈련 및 검증에 사용될 입력 데이터를 생성했다. 손실함수로는 정규화된 평균 자승 오류(normalized mean square error, NMSE)를 사용했으며 식은 아래와 같다.

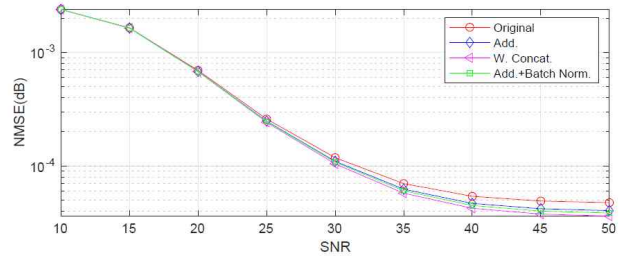
$$NMSE = \sum_{d=1}^D (F(\bar{h}_k) - h_k)^2 \quad (5)$$

이 때,  $F(\bar{h}_k)$ 는 DBPN의 출력이며,  $D$ 는 전체 데이터 수이다.

### III. 모의 실험 결과

본 장에선 DBPN의 밀집된 프로젝트 블록의 구조에 따른 RIS 시스템의 채널 추정 성능과 모델 연산량을 비교 분석한다. RIS 시스템의 채널 데이터를 생성하기 위해 Deep-MIMO 데이터셋 생성기를 사용했다[3]. DeepMIMO 데이터셋 생성기는 특정 환경에서 ray-tracing을 사용하여 채널 데이터를 생성한다. 본 연구에선 60GHz대역의 mmWave를 사용하는 'O160'환경을 사용했다. 'O160' 환경의 BS2 위치에 기지국을 배치하고 BS3위치에  $32 \times 32$  구조의 RIS를 배치했다. 사용자는 한 row당 90명이 있으며 [1650, 2300]의 row범위에 배치했다. 총 234,000개의 데이터를 생성했으며, 이 중 60%는 훈련 및 검증데이터, 40%를 평가데이터로 사용했다. DBPN은  $16 \times 16$  크기의 하향 샘플링 된 채널 데이터로  $32 \times 32$  크기의 전체 채널을 추정하도록 훈련되었다. 모든 모델은 ADAM 최적화 알고리즘으로 훈련했으며, 초기 학습률은 0.001이고 10 epoch마다 5%씩 감소시켜서 총 200 epoch동안 훈련했다. 훈련데이터의 SNR은 [-5dB, 35dB]의 범위에 균등하게 분포시켰다. 활성화 함수로는 hyperbolic tangent와 ReLU(rectified linear unit)를 사용했다.

그림 2는 SNR대비 채널 추정의 NMSE를 비교한 그래프이다. 'Original'은 기존의 DBPN을 의미하고, 'Add', 'W. Concat.'은 순서대로 밀집된 프로젝트 블록에 덧셈, 가중화된 적층연산을 적용한 모델이고, 'Addition+Batch norm.'은 밀집된 프로젝트 블록에 덧셈을 적용하고 모든 계층에 배치정규화를 적용한 모델을 의미한다.  $\alpha$ 는 0.2,  $\beta$ 는 0.5를 사용했다. 제안하는 구조가 변경된 DBPN은 기존의 DBPN보다 일부 SNR 구간에서 우수한 채널 추정 정확도를 가진다. 또한 이전 계층의 연산 결과를 전달 시 스케일을 줄인 가중화된 적층 연산을 적용한 DBPN도 기존 DBPN대비 우수한 채널 정확도를 보인다.



[ 그림 2 ] 채널 추정 기술의 정규화된 평균 자승 오차 비교

### III. 결론

본 논문에선 딥러닝 기반 초해상화 기술인 DBPN을 사용한 채널 추정 기술을 제안했다. 제안된 채널 추정 기술은 DBPN의 밀집된 프로젝트 블록의 구조를 변경하여 이전 계층에서 계산된 결과 값을 이후 계층에 전달하는 방식을 변경했다. 제안된 채널 추정 기법은 기존 DBPN을 채널 추정에 적용했을 때보다 일정 SNR 구간에서 낮은 NMSE 성능을 가진다.

### ACKNOWLEDGMENT

이 논문은 2022년도 정부(교육부)의 재원으로 한국연구재단 기초연구사업의 지원을 받아 수행된 연구임(No. 2022R1A2C1092737)

### 참 고 문 헌

- [1] Y. Liu, X. Liu, X. Mu, T. Hou, J. Xu, M. Di Renzo, and N. Al-Dhahir, "Reconfigurable intelligent surfaces: Principles and opportunities," *IEEE Communications Surveys Tutorials*, vol. 23, no. 3, pp. 1546 - 1577, 2021.
- [2] M. Haris, G. Shakhnarovich, and N. Ukita, "Deep back projection networks for super-resolution," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2018.
- [3] A. Alkhateeb, "Deepmimo: A generic deep learning dataset for millimeter wave and massive mimo applications," arXiv preprint arXiv:1902.06435, 2019.