

하드웨어 왜곡이 있는 다중입출력 시스템을 위한 조건부 생성적 적대 신경망 기반 데이터 검출 기법

강유진, 전요셉*
포항공과대학교

{yujiinkang, yoseb.jeon}@postech.ac.kr

Conditional GAN-based Data Detection Method for MIMO Systems with Hardware Impairments

Yujin Kang, Yo-Seb Jeon
Pohang Univ. of Science and Technology (POSTECH)

요약

본 논문은 하드웨어 왜곡을 겪는 다중입출력 시스템의 데이터 검출 성능을 향상시키기 위한 조건부 생성적 적대 신경망(Conditional generative adversarial networks, CGAN) 기반 검출 기법을 제안한다. 제안된 기법은 기존 데이터 검출 기법을 통해 확보한 온라인 학습 데이터에 대해 CGAN을 이용한 데이터 증강으로 학습 데이터의 신뢰도 및 양을 증가시킨다. CGAN으로 생성된 데이터로 심층 신경망을 학습하여 데이터 검출을 수행한다. 모의 실험을 통해, 제안된 기법이 하드웨어 왜곡이 있는 다중입출력 시스템에서 데이터 검출 성능을 향상시킬 수 있음을 보인다.

I. 서론

초고주파 광대역 다중입출력(Multiple-input multiple-output, MIMO) 시스템은 스펙트럼 효율성을 높일 수 있어 차세대 통신 시스템의 핵심 요소 기술로 주목받고 있다. 그러나, 주파수 대역과 대역폭이 높아짐에 따라 소자 및 설계의 한계로 이상적인 RF 하드웨어 구성 요소들의 사용이 어려워지고 있다. 대표적인 예로, 높은 주파수 및 넓은 대역폭에서 전력 증폭기와 DAC/ADC의 성능 저하가 일어날 수 있으며, 이로 인해 전력 증폭기의 비선형 포화화 ADCs의 양자화 오류와 같은 하드웨어 왜곡이 발생하게 된다. 하드웨어 왜곡은 비선형성을 띄는 추가적인 잡음 신호를 발생시키며, 이는 채널 추정 및 데이터 검출 과정에서 심각한 성능 저하로 이어진다. 하드웨어 왜곡이 존재하는 MIMO 시스템의 데이터 검출 성능을 향상시키기 위해, 하드웨어 왜곡으로 인한 잡음 신호를 통계적으로 모델링하는 기법들이 제안된 바 있다 [1]. 하지만, RF 요소들의 하드웨어 왜곡은 각 하드웨어 스펙에 따라 크게 바뀔 수 있으므로, 이러한 모델링 기법은 모델링 오류를 피할 수 없게 된다.

본 논문에서는 하드웨어 왜곡이 존재하는 MIMO 시스템에 대해 기존 모델링 기법들의 한계를 극복할 수 있는 학습 기반 데이터 검출 기법을 제안한다. 가장 먼저, 기존의 채널 추정 및 데이터 검출을 통해 현재 시스템의 입출력 관계를 나타낼 수 있는 온라인 학습 데이터를 확보한다. 이렇게 확보한 학습 데이터는 데이터 검출 오류로 인해 잘못된 라벨을 포함하고 있을 뿐만 아니라, 매우 제한적인 양을 가지고 있다. 이 문제를 해결하기 위해, 제안된 기법은 잘못된 라벨의 효과를 완화하기 위한 프로토타입(prototype) 데이터를 추출한 뒤, 프로토타입 데이터에 조건부 생성적 적대 신경망(Conditional generative adversarial networks,

CGAN)을 활용하여 학습 데이터를 증강시킨다. 이렇게 확보한 학습 데이터를 활용하여 데이터 검출을 위한 심층 신경망을 학습시킨다. 모의 실험을 통해, 제안된 기법이 하드웨어 왜곡이 있는 다중입출력 시스템에서 정확한 데이터 검출을 수행할 수 있음을 입증한다.

II. 본론

본 논문에서는 N_t 개의 송신 안테나와 N_r 개의 수신 안테나로 구성된 MIMO 통신 시스템을 고려한다. 이 때, 각 송신기와 수신기는 비선형 무선 구성요소를 장착한다고 가정한다. 채널 상관 시간 T 동안 각 송신 안테나에서 송신 신호 $\mathbf{x}_i[n] \in \mathcal{X}$ 를 송신하였을 때, 데이터 심볼 벡터 $\mathbf{x}[n] = [x_1[n], \dots, x_{N_t}[n]]^T$ 에 대한 수신 신호 벡터 $\mathbf{y}[n]$ 은 다음과 같이 나타낼 수 있다.

$$\mathbf{y}[n] = f_{rx}(\mathbf{H}[n]f_{tx}(\mathbf{x}[n]) + \mathbf{z}[n]), n \in \{1, 2, \dots, T\},$$
 (1)
위 식에서, f_{rx} 와 f_{tx} 는 수신기와 송신기의 하드웨어 왜곡에 의한 비선형 함수를, $\mathbf{H}[n]$ 은 n 번째 시간 슬롯에서의 채널 행렬을, $\mathbf{z}[n] \sim \mathcal{CN}(\mathbf{0}_{N_r}, \sigma^2 \mathbf{I}_{N_r})$ 은 가우시안 잡음 벡터를 나타낸다.

하드웨어 왜곡이 존재하는 MIMO 시스템의 입출력 관계를 학습하기 위해, 제안 기법은 기존 채널 추정 및 데이터 검출 기법을 이용하여 온라인 학습 데이터를 확보한다. 채널 추정치 $\hat{\mathbf{H}}_{LS}$ 를 기반으로 기존의 최대 우도 검출 기법을 수행하면 각 수신 신호 $\mathbf{y}[n]$ 에 대해 검출 데이터가 다음과 같이 결정된다.

$$\hat{k}[n] = \underset{i \in \{1, \dots, M\}}{\operatorname{argmin}} \|\mathbf{y}[n] - \hat{\mathbf{H}}_{LS} \mathbf{x}_i[n]\|^2, \quad (2)$$

위 식에서, N 은 데이터 심볼 벡터의 가짓수를 나타낸다. 식 (2)로 추정된 검출 데이터 $\hat{k}[n]$ 을 수신 신호에 대한 라벨로 이용하면, $(\mathbf{y}[n], \hat{k}[n])$ 으로 구성된 T 개의 학습 데이터를 확보할 수 있다. 그러나, 검출 데이터는 검출 오류로 인해 실제로 송신된 데이터와 다를 수 있으며,

이로 인해 위 방식으로 확보된 학습 데이터는 잘못된 라벨을 일부 포함하게 된다. 또한, 학습 데이터 수는 전송 데이터 개수인 T 개로 제한되므로, 심층 신경망 학습에 충분한 수의 데이터를 확보할 수 없게 된다.

앞서 언급한 학습 데이터 부족 문제를 해결하기 위해, 제안 기법은 CGAN 을 활용하여 학습 데이터를 증강시킨다. 식 (2)로 얻어진 온라인 학습 데이터를 그대로 CGAN 에 활용할 경우, 잘못된 라벨로 인해 생성된 데이터의 신뢰도가 떨어지게 된다. 이 문제를 해결하기 위해, 온라인 학습 데이터에 대해 프로토타입을 추출한 뒤, 프로토타입을 CGAN 의 학습 데이터로 활용한다. 프로토타입 형성 과정은 다음과 같다. 먼저, 식 (2)로부터 동일한 심볼이 검출된 수신 신호들을 하나의 그룹으로 묶는다. 다음으로, 각 그룹에서 무작위로 n 개의 수신 신호들을 선택한 뒤, 선택된 수신 신호들을 평균하여 $\bar{y}_{i,1}$ 를 계산한다. 이 과정을 M 번 반복하여 각 그룹에 대한 평균 수신 신호 집합 $\{\bar{y}_{i,1}, \dots, \bar{y}_{i,M}\}$ 을 얻을 수 있다. 위 과정으로 얻어진 프로토타입 학습 데이터 셋은 다음과 같이 나타낼 수 있다.

$$\mathcal{D}_a = \{(i, \bar{y}_{i,j}) | i \in \{1, \dots, N\}, j \in \{1, \dots, M\}\}. \quad (3)$$

평균화 과정을 거친 프로토타입 수신 신호들은 검출 과정에서 오류가 일부 발생하더라도, 해당 데이터의 영향을 줄여 신뢰성 있는 학습 데이터 형성을 가능하게 한다.

다음으로, 충분한 수의 학습 데이터를 확보하기 위해 위 과정으로 추출한 프로토타입 데이터들을 이용하여 CGAN 을 훈련시킨다. CGAN 은 ‘생성자’와 ‘판별자’가 적대적인 관계를 가지며, 보다 실제적인 샘플을 생성하는 것을 목표로 한다. 생성자는 조건 $i^g[l]$ 와 잡음 \mathbf{z} 를 입력으로 받아 샘플 $\mathbf{y}^g[l]$ 을 생성하고, 판별자는 생성자에서 생성된 샘플 $\mathbf{y}^g[l]$ 또는 실제 샘플 $\mathbf{y}^r[n]$ 을 입력으로 받아 입력 받은 데이터가 실제 데이터일 확률을 출력한다. CGAN 의 손실함수는 다음과 같다.

$$L_{CGAN}(\theta) = E[\log(D(\mathbf{y}^r, i^r))] + E[\log(1 - D(G(\mathbf{z}, i^g), i^g))]. \quad (4)$$

‘생성자’는 손실함수를 최소화하는 방향, ‘판별자’는 최대화하는 방향으로 조건부 생성적 적대 신경망의 매개변수 θ 를 업데이트한다. 이처럼 매개변수 업데이트를 적대적으로 구성함으로써 생성자는 더욱 실제적인 샘플을 만들고 판별자는 실제와 생성 샘플을 구분하게 된다. 조건부 생성적 적대 신경망은 평균화 과정을 거친 \mathcal{D}_a 로 학습한 후, 검증 단계에서 조건 $i^g[l]$ 를 입력으로 넣어 신뢰도 있는 데이터라 볼 수 있는 $\mathbf{y}^g[l]$ 을 T 보다 많이 생성한다.

데이터 검출 과정에서는 조건부 생성적 적대 신경망의 출력 $\mathbf{y}^g[l]$ 을 학습 데이터로 활용하여 DNN 분류기를 학습한다. 다음은 DNN 분류기의 학습 데이터를 나타낸다.

$$\mathcal{D}_g = \{(\mathbf{y}^g[l], i^g[l]) | l \in \{1, \dots, 2T\}\}. \quad (5)$$

검증 단계에서는 학습된 DNN 분류기에 실제 수신 신호 $\mathbf{y}^r[n]$, $n \in \{1, 2, \dots, T\}$ 를 입력하여 출력된 $i^r[n]$ 에 대응되는 송신 심볼 벡터 $\hat{\mathbf{x}}[n]$ 을 최종 검출 데이터로 확정한다.

본 논문에서 제안된 기법의 성능을 비교하기 위해 모의 실험을 진행하였다. 상관 시간 $T = 500$, 파일럿 신호의 수 $T_p = 4$ 와 $N_t = 2$, $N_r = 8$ 개의 안테나를 가진 다중 입출력 시스템을 가정하였다. 시간에 따라 변화하는 시변 채널을 가정한다. 이때, n 번째 시간 슬롯에서의 채널 행렬 $\mathbf{H}[n]$ 은 다음과 같이 변화한다.

$$\mathbf{H}[n] = \zeta \mathbf{H}[n-1] + \sqrt{1-\zeta^2} \mathbf{G}[n], \quad (6)$$

위 식에서, $\mathbf{G}[n]$ 은 n 번째 시간 슬롯에서의 진화 행렬로, 각 요소들이 독립적으로 $\mathcal{CN}(0,1)$ 에서 추출된다고

가정한다. 또한, 초기 채널 $\mathbf{H}[1]$ 의 요소들도 $\mathcal{CN}(0,1)$ 에서 독립적으로 추출되며 $\zeta = 0.98$ 로 가정한다. 프로토타입 추출을 위해 $n = 10$, $M = 100$ 을 설정하였다. 하드웨어 왜곡에 의한 영향을 확인하기 위해 송신기에서는 비선형 전력증폭기, 수신기에서는 저해상도 ADC 를 각각 f_{tx} f_{rx} 로 설정하였다. 또한, 데이터 검출 과정에서 사용되는 DNN 분류기로는 2 개의 은닉층으로 구성된 네트워크를 사용하였다.




그림 1. 다양한 기법의 심볼 검출 오류율 비교

그림 1 은 다양한 기법의 심볼 검출 오류율을 비교한 결과이다. 여기서 Avg DNN 기법은 데이터 증강 과정 없이 프로토타입을 이용하여 심층신경망을 훈련시킨 딥러닝 기반 검출 기법이고, Approx MLD 기법은 추정된 채널을 이용한 최대 우도 검출 기법이며, Optimal 기법은 하드웨어 왜곡 모델을 완벽하게 알고 있다는 가정 하에서, 최적의 최대 우도 검출을 수행한 기법이다. 그림 1 은 제안된 DNN 분류기가 하드웨어 왜곡 시스템을 효과적으로 모델링하여 낮은 오류율로 데이터 검출을 수행할 수 있음을 보인다. 특히, 비교 기법인 Avg DNN 과 제안하는 기법의 이득 차이는 파일럿 신호가 제한된 통신 환경에서 적절한 학습 데이터 생성의 필요성을 나타낸다.

III. 결론

본 논문에서는 하드웨어 왜곡이 존재하는 MIMO 통신 시스템의 데이터 검출 문제를 해결하기 위해 CGAN 기반 데이터 검출 기법을 제안하였다. 제안 기법은 기존 채널 추정 및 데이터 검출을 통해 온라인 학습 데이터를 확보한 뒤, CGAN 을 이용하여 데이터의 신뢰도 및 양을 획기적으로 증강시킨다. 모의 실험을 통해 제안하는 기법이 기존의 검출 기법들보다 우수한 검출 성능을 나타냄을 입증하는 한편, CGAN 을 이용한 데이터 증강이 효과적임을 입증하였다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임. (No. 2022R1C1C1010074)

참고 문헌

[1] E. Björnson, J. Hoydis, M. Kountouris and M. Debbah, "Massive MIMO Systems with Non-Ideal Hardware: Energy Efficiency, Estimation, and Capacity Limits," *IEEE Trans. Info. Theory*, vol. 60, no. 11, pp. 7112-7139, Nov. 2014.