

대규모 사물 통신에서 신호 검출을 위한 Consensus ADMM 기반 네트워크

김민우*, 김민식*, 박대영^o

Signal Detection Network Based on Consensus ADMM in mMTC

Minwoo Kim*, Minsik Kim*, Daeyoung Park^o

요약

대규모 사물 통신 시스템에서 일부 디바이스만 신호를 전송하는 경우 압축 센싱 기법으로 스케줄링 없이 수많은 디바이스의 신호를 검출할 수 있다. 본 레터에서는 consensus-ADMM 기반으로 송신 신호와 채널정보로 학습하는 검출 신경망을 제안한다. 제안하는 학습 모델은 기존 방식보다 활성/비활성 디바이스를 잘 구분하며 높은 신호 검출 성능을 달성하는 것을 확인한다.

Key Words : Consensus Alternating Direction Method of Multipliers, mMTC, multi-user detection

ABSTRACT

When only some devices transmit signals in massive machine-type communications, compressive sensing techniques can detect signals without scheduling. In this letter, we propose a detection network based on consensus-ADMM that is learnable from the transmitted signal and channel information. From simulation results, we confirm that the

proposed learning model achieves better classification accuracy and signal detection performance.

I. 서론

차세대 통신 시스템에서는 수백~수천 개의 IoT 디바이스가 동시에 신호를 전송할 수 있어야 한다. 대규모 사물 통신(Massive machine type communication, mMTC)은 인간의 무선 통신과 다르게 업 링크가 대부분이다. 또한 활성화된 디바이스만 패킷을 전송하므로 희소 벡터로 모델링하여 활성 디바이스의 신호를 검출할 수 있다.

그러나 mMTC 시스템에서 신호를 검출하는 문제는 NP-hard 문제여서 동시에 접속하는 디바이스가 많아지면 신호를 검출할 수 없게 된다. 이 문제를 해결하기 위하여 낮은 복잡도로 해를 구할 수 있는 consensus-ADMM (cADMM)으로 신호를 검출하는 기법이 제안되었다.^[1] 본 레터는 cADMM을 응용하여 학습 데이터를 이용해 하이퍼 파라미터를 학습하여 성능을 개선하는 모델을 제안한다.

II. 시스템 모델

M 개의 디바이스가 N 개의 안테나를 갖는 기지국으로 신호를 보내는 mMTC 시스템 모델은

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{w}, \tag{1}$$

와 같으며^[1], $\mathbf{y} \in \mathbb{C}^N$ 는 수신 신호 벡터, $\mathbf{x} \in \mathbb{S}_0^M$ 는 송신 신호 벡터, $\mathbf{w} \in \mathbb{C}^N$ 는 가산성 백색 가우시안 잡음(AWGN) 벡터이다. $\mathbf{H} \in \mathbb{C}^{N \times M}$ 는 가우시안 분포를 갖고 디바이스와 기지국간의 채널 행렬로써 수신 측에서 알고 있다고 가정한다. 각각의 디바이스는 p_m 의 확률로 활성화되며, 비활성화 디바이스는 신호를 보내지 않으므로 송신 신호 \mathbf{x} 는 성긴(sparse) 신호이다. 비활성화 디바이스를 고려하면, QPSK의 경우 \mathbb{S}_0 은

※ 이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원(2020-0-01389, 인공지능융합연구센터지원(인하대학교)과 RS-2022-00155915, 인공지능융합혁신인재양성사업(인하대학교))을 받아 수행된 연구임. 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2019R1A2C1005512, 2022R1H1A2092541).

• First Author : (ORCID:0000-0001-7856-1199) Department of Electrical and Computer Engineering, Inha University, kmw9167@gmail.com, 학생(석사과정), 학생회원

o Corresponding Author : (ORCID:0000-0001-8573-3526) Department of Information and Communication, Inha University, dpark@inha.ac.kr, 정교수, 중신회원

* (ORCID:0000-0002-0502-5464) Department of Information and Communication, Inha University, minsik92@gmail.com, 학생(박사과정), 학생회원

논문번호 : 202207-144-A-LU, Received July 19, 2022; Revised July 21, 2022; Accepted July 21, 2022

QPSK의 성좌도에 0을 추가한 $\{0, 1+1i, 1-1i, -1+1i, -1-1i\}$ 이다.

Maximum a posteriori 신호 검출은

$$\min_{\mathbf{x}} \|\mathbf{y} - \mathbf{H}\mathbf{x}\|_2^2 + \sigma_2 \sum_{m=1}^M \lambda_m \|x_{2,m}\|_0 + I_{S_0^M}(\mathbf{x}) \quad (2)$$

와 같으며^[1], 여기서 $\lambda_m = \ln((1-p_m)/(p_m/\|S_0\|))$, $\|\cdot\|_0$ 은 l_0 -norm, $I_{S_0^M}(\mathbf{x})$ 은 지지 함수로 $\mathbf{x} \in S_0^M$ 을 만족하면 0, 만족하지 못하면 ∞ 값을 갖는다.

III. 제안하는 consensus-ADMM 기반의 신호 검출 알고리즘

cADMM을 적용하기 위해 식 (2)에 보조 변수 (auxiliary variable) \mathbf{x}_i 를 도입하면

$$\min_{\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \mathbf{z}} \sum_{i=1}^3 f_i(\mathbf{x}_i) \quad (3)$$

s.t. $\mathbf{x}_i - \mathbf{z} = 0, \forall i$

이며, 각각의 $f_i(\cdot)$ 는 $f_1(\mathbf{x}_1) = \frac{1}{2} \|\mathbf{y} - \mathbf{H}\mathbf{x}_1\|_2^2$, $f_2(\mathbf{x}_2) = \sigma^2 \sum_{m=1}^M \lambda_m \|x_{2,m}\|_0$, $f_3(\mathbf{x}_3) = I_{S_0^M}(\mathbf{x}_3)$ 이다. 식 (3)으로부터 augmented Lagrangian을 얻은 후에 cADMM을 적용하면

$$\mathbf{x}_i^{(k+1)} = \arg \min_{\mathbf{x}_i} f_i(\mathbf{x}_i) + \frac{\rho}{2} \|\mathbf{x}_i - \mathbf{z}^{(k)} + \mathbf{u}_i\|_2^2, \forall i \quad (4)$$

$$\mathbf{z}^{(k+1)} = \frac{1}{3} \sum_{i=1}^3 (\mathbf{x}_i^{(k+1)} + \mathbf{u}_i^{(k)}) \quad (5)$$

$$\mathbf{u}_i^{(k+1)} = \mathbf{u}_i^{(k)} + \mathbf{x}_i^{(k+1)} - \mathbf{z}^{(k+1)}, \forall i \quad (6)$$

와 같으며^[2], $\rho \geq 0$ 는 페널티 파라미터, k 는 iteration 이다. $\bar{\mathbf{x}}^{(k)} = \frac{1}{3} \sum_{i=1}^3 \mathbf{x}_i^{(k)}$ 과 보조 변수로 $\zeta_i^{(k)} = \bar{\mathbf{x}}^{(k)} - \mathbf{u}_i^{(k)}$ 를 정의하면, cADMM에서 $\sum_{i=1}^3 \mathbf{u}_i^{(k)} = 0$ 이 되는 특징^[2]을 이용하여

$$\mathbf{x}_i^{(k+1)} = \arg \min_{\mathbf{x}_i} f_i(\mathbf{x}_i) + \frac{\rho}{2} \|\mathbf{x}_i - \zeta_i^{(k)}\|_2^2, \forall i \quad (7)$$

$$\zeta_i^{(k+1)} = \zeta_i^{(k)} + 2\bar{\mathbf{x}}^{(k+1)} - \bar{\mathbf{x}}^{(k)} - \mathbf{x}_i^{(k+1)}, \forall i \quad (8)$$

로 간단하게 정리할 수 있다.

최적해를 구하기 위해 수렴할 때까지 각각의 반복에서 \mathbf{x}_i 를 갱신해야 한다. \mathbf{x}_1 을 업데이트하는 식은

$$\mathbf{x}_1^{(k+1)} = \arg \min_{\mathbf{x}_1} \frac{1}{2} \|\mathbf{y} - \mathbf{H}\mathbf{x}_1\|_2^2 + \frac{\rho}{2} \|\mathbf{x}_1 - \zeta_1^{(k)}\|_2^2 \quad (9)$$

와 같다. 먼저 $f_1(\mathbf{x}_1)$ 은 smooth convex 함수이기 때문에

$$f_1(\mathbf{x}_1) \leq f_1(\mathbf{x}_1^{(k)}) + \nabla f_1(\mathbf{x}_1^{(k)})^T (\mathbf{x}_1 - \mathbf{x}_1^{(k)}) + \frac{1}{2\delta^{(k)}} \|\mathbf{x}_1 - \mathbf{x}_1^{(k)}\|_2^2 \quad (10)$$

와 같으며, $\delta^{(k)} \leq 1/L_f$ 이고 L_f 는 $\mathbf{H}^T\mathbf{H}$ 의 가장 큰 고유 값이다. Majorization-minimization (MM)기법을 적용하여 근사화한 \mathbf{x}_1 에 대한 업데이트는

$$\begin{aligned} \mathbf{x}_1^{(k+1)} &= \arg \min_{\mathbf{x}_1} \nabla f_1(\mathbf{x}_1^{(k)})^T (\mathbf{x}_1 - \mathbf{x}_1^{(k)}) \\ &\quad + \frac{1}{2\delta^{(k)}} \|\mathbf{x}_1 - \mathbf{x}_1^{(k)}\|_2^2 + \frac{\rho}{2} \|\mathbf{x}_1 - \zeta_1^{(k)}\|_2^2 \\ &= \beta^{(k)} (\mathbf{x}_1^{(k)} - \delta^{(k)} \mathbf{H}^T (\mathbf{H}\mathbf{x}_1^{(k)} - \mathbf{y})) + (1 - \beta^{(k)}) \zeta_1^{(k)} \end{aligned} \quad (11)$$

이며, 여기에서 $\beta^{(k)} = 1/(\rho\delta^{(k)} + 1)$ 로 정의한다.

다음으로 \mathbf{x}_2 에 대한 업데이트는

$$\mathbf{x}_2^{(k+1)} = \arg \min_{\mathbf{x}_2} \sigma^2 \sum_{m=1}^M \lambda_m |x_{2,m}| + \frac{\rho}{2} \|\mathbf{x}_2 - \zeta_2^{(k)}\|_2^2 \quad (12)$$

와 같다. 실수부와 허수부의 크기는 0 또는 1이므로 l_0 -norm 대신 절댓값의 합을 최소화 할 수 있다. 복소 신호를 2차원 실수로 바꿔서 식을 작성한 뒤 해를 구하면

$$x_{2,m}^{(k+1)} = \left(|c_{2,m}^{(k)}| - \Gamma_m \right)_+ \frac{\zeta_{2,m}^{(k)}}{|c_{2,m}^{(k)}|}, \forall m \quad (13)$$

이고^[11], $\Gamma_m = \sigma^2 \lambda_m / \rho$ 는 문턱값(threshold) 역할을 한다. 식 (13)은 신호의 크기를 감소시키지만 하기 때문

에 반복이 진행될수록 신호가 sparse해지는 문제가 발생할 수 있다. 이 문제를 해결하기 위해 $\zeta_{2,m}^{(k)}$ 에 따라 커지거나 작아지도록 모든 m 에 대해서

$$x_{2,m}^{(k+1)} = (|\zeta_{2,m}^{(k)}| + \Gamma_m \tanh(\psi(|\zeta_{2,m}^{(k)}| - \kappa_m))) + \frac{\zeta_{2,m}^{(k)}}{|\zeta_{2,m}^{(k)}|} \quad (14)$$

와 같이 업데이트한다. 이때 ψ, κ 는 문턱값 Γ_m 의 크기와 부호에 영향을 준다.

마지막으로 \mathbf{x}_3 는

$$\mathbf{x}_3^{(k+1)} = \underset{\mathbf{x}_3 \in \mathbb{S}_3}{\operatorname{argmin}} \frac{\rho}{2} \|\mathbf{x}_3 - \zeta_3^{(k)}\|_2^2 = \Pi_{\mathbb{S}_3}(\zeta_3^{(k)}) \quad (15)$$

와 같이 계산하는데, 미분 불가능한 사영(Projection) 연산자 Π 를 대신하여 벡터의 각 원소별로 hyperbolic tangent를 사용한다.^[3]

$$\eta_{\mathbb{S}_0}(x; \theta) = \sum_{i=1}^{|\mathbb{S}_0|-1} \xi_i \tanh(\theta(x - \tau_i)) \quad (16)$$

여기에서 θ 는 입력값의 연관정(soft decision)에 영향을 주고 $c_i, c_{i+1} \in \mathbb{S}_0$ 일 때 $c_i < c_{i+1}$ 라 하면, $\tau_i = (c_{i+1} + c_i)/2, \xi_i = (c_{i+1} - c_i)/2$ 로 정의한다.

제안 알고리즘은 식 (11), (14), (15), (8)을 수렴할 때까지 반복한다. 알고리즘의 각 반복을 한 개의 레이어에 해당하는 뉴럴 네트워크로 학습 데이터로부터 하이퍼 파라미터 $\{\beta^{(k)}, \delta^{(k)}, \Gamma_m^{(k)}, \psi^{(k)}, \kappa^{(k)}, \theta^{(k)}\}_{k=0}^{L-1}$ 를 학습하는 알고리즘으로 Learnable Consensus-ADMM (Learnable cADMM)을 제안한다. 이때 학습 데이터는 랜덤으로 생성한 채널 행렬과 수신 신호, 송신 신호이며 손실 함수는 최종 레이어의 출력 값과 송신 신호의 평균 제곱 오차 (MSE)를 사용한다.

IV. 모의실험 결과

활성 디바이스를 모두 알고 있다고 가정하는 Oracle-ZF^[1], orthogonal matching pursuit (OMP)를 사용하여 활성 디바이스를 찾은 후 zero forcing을 사용한 OMP, 학습을 하지 않는 기존의 cADMM^[2]과 레터에서 제안하는 Learnable cADMM의 성능을 비교한다. 모의실험에서 $N=64, M=96, p_m=0.1$, 변

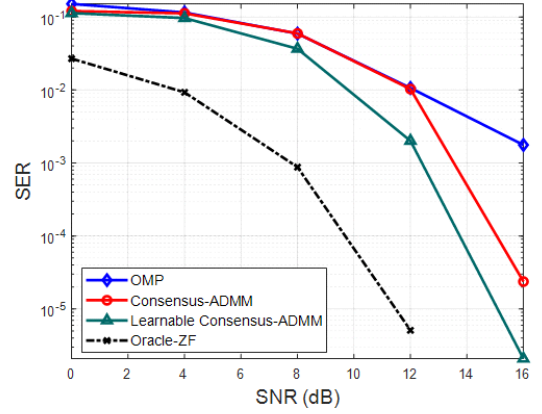


그림 1. 신호 대 잡음비에 따른 심볼 오류율.
Fig. 1. Symbol error rate versus SNR.

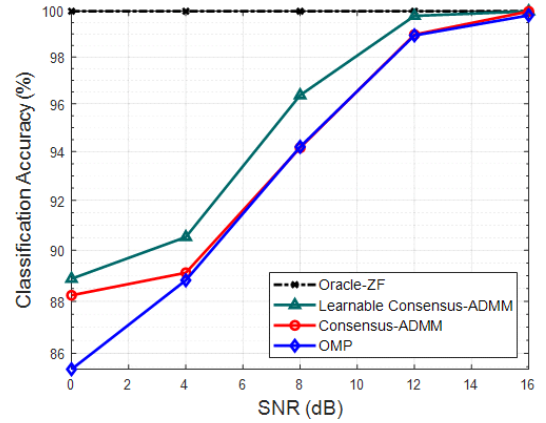


그림 2. 신호 대 잡음비에 따른 분류 정확도.
Fig. 2. Classification accuracy according to SNR

조방식은 QPSK를 사용하였다.

그림 1은 SNR에 따른 심볼 오류율을 보여주는 그래프이다. Oracle-ZF는 활성 디바이스를 알고 있어서 과소결정 시스템이 아니므로 가장 좋은 성능을 가진다.^[1] Learnable cADMM은 SNR이 증가함에 따라 OMP와 cADMM보다 좋은 성능을 달성한다. 또한 Learnable cADMM은 심볼 오류율 10^{-4} 에서 cADMM보다 1dB 이상의 성능 향상이 있다.

그림 2는 장비의 활성여부를 맞춘 개수를 전체 디바이스 수로 나눈 Classification accuracy를 나타낸다. Oracle-ZF는 모든 디바이스의 활성 여부를 알고 있어 100%의 성능을 갖는다. 제안하는 Learnable cADMM은 다른 방법 보다 우수하며, 4dB에서 90% 이상의 정확도를 달성하고 12dB부터 100%에 가까운 정확도를 달성한다.

V. 결 론

본 레터에서는 대규모 사물 통신 시스템에서 송신 신호 검출을 위한 학습 모델을 제안한다. MM을 적용하여 기존보다 복잡도를 줄이고 cADMM의 파라미터를 학습하는 모델을 제안하였다. 제안하는 네트워크가 기존보다 활성/비활성 디바이스를 잘 구분하고 신호 검출 성능을 향상시키는 것을 확인하였다.

References

- [1] M. Kim, et al., "Iterative detection based on consensus alternating direction method of multipliers in massive machine-type communications," *Wireless Pers. Commun.*, vol. 110, no. 4, pp. 2253-2264, Feb. 2020. (<https://doi.org/10.1007/s11277-020-07082-y>)
- [2] S. Boyd, et al., "Distributed optimization and statistical learning via the alternating direction method of multipliers," *Found. Trends*, vol. 3, no. 1, pp. 1-122, 2011. (<https://doi.org/10.1561/22000000016>)
- [3] M. Kim and D. Park, "Learnable MIMO detection networks based on inexact ADMM," *IEEE Trans. Wireless Commun.*, vol. 20, no. 1, pp. 565-576, Jan. 2021. (<https://doi.org/10.1109/TWC.2020.3026471>)