(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0143447
(43) 공개일자 2024년10월02일

(51) 국제특허분류(Int. Cl.)
H04B 7/08 (2017.01) *G06N 3/08* (2023.01)
H04B 7/0413 (2017.01) *H04L 27/18* (2006.01)
(52) CPC특허분류
H04B 7/0857 (2013.01)
G06N 3/08 (2023.01)
(21) 출원번호 10-2023-0038762
(22) 출원일자 2023년03월24일
심사청구일자 2023년03월24일

(71) 출원인
인하대학교 산학협력단
인천광역시 미추홀구 인하로 100(용현동, 인하대학교)
(72) 발명자
박대영
인천광역시 연수구 송도문화로84번길 24, 208동 3104호(송도동, 송도 에듀포레 푸르지오)
김민우
경기도 파주시 책향기로 441, 1014동 702호(동패동, 책향기마을10단지동문굿모닝힐)
김민식
경기도 수원시 영통구 동수원로 448, 105동 402호(매탄동, 현대아파트)
(74) 대리인
양성보

전체 청구항 수 : 총 8 항

(54) 발명의 명칭 **깊은 신경망을 이용한 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 신호 검출 방법 및 시스템**

(57) 요 약

깊은 신경망을 이용한 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 신호 검출 방법 및 시스템이 제시된다. 본 발명에서 제안하는 깊은 신경망을 이용한 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 신호 검출 방법은 ML 탐지부를 통해 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 허수로 되어있는 가우시안 노이즈가 존재하는 채널을 통과한 QPSK 신호를 수신하고 실수로 나타내기 위하여 기존 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터를 두배의 크기를 갖는 BPSK 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터로 변환한다. 그리고 ML(Maximal Likelihood)를 탐지하는 단계 및 이진 MIMO 탐지부를 통해 네거티브 페널티(negative penalty)를 적용하고 ADMM(Alternating Direction Methods of Multipliers)을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 단계를 포함한다.

대 표 도 - 도1

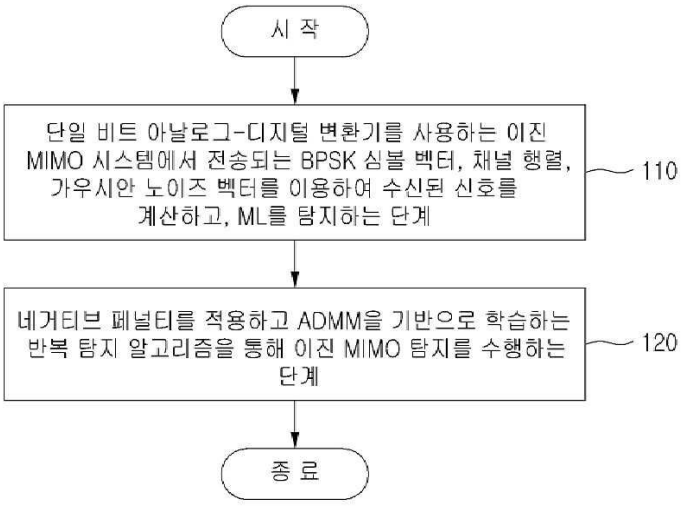

(52) CPC특허분류
H04B 7/0413 (2013.01)
H04L 27/18 (2021.01)

이 발명을 지원한 국가연구개발사업
과제고유번호 1711174241
과제번호 2022R1H1A2092541
부처명 과학기술정보통신부
과제관리(전문)기관명 한국연구재단
연구사업명 재도약연구(중견연구)
연구과제명 [Ezbaro] 대규모 연결을 위한 사물인터넷 시스템 최적화 연구
기 여 율 90/100
과제수행기관명 인하대학교
연구기간 2022.09.01 ~ 2023.08.31
이 발명을 지원한 국가연구개발사업
과제고유번호 1711179347
과제번호 00155915
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 정보통신인재양성(교육운영수익)
연구과제명 [Ezbaro][정부+민간] 인공지능융합혁신인재양성(2차년도)
기 여 율 10/100
과제수행기관명 인하대학교 산학협력단
연구기간 2023.01.01 ~ 2023.12.31

명 세 서

청구범위

청구항 1

ML 탐지부를 통해 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 허수로 되어있는 가우시안 노이즈가 존재하는 채널을 통과한 QPSK 신호를 수신하고 실수로 나타내기 위하여 기존 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터보다 더 큰 크기를 갖는 BPSK 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터로 변환하고 ML(Maximal Likelihood)를 탐지하는 단계; 및

이진 MIMO 탐지부를 통해 네거티브 페널티(negative penalty)를 적용하고 ADMM(Alternating Direction Methods of Multipliers)을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 단계

를 포함하는 신호 검출 방법.

청구항 2

제1항에 있어서,

상기 이진 MIMO 탐지부를 통해 네거티브 페널티를 적용하고 ADMM을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 단계는,

상기 반복 탐지 알고리즘에 대한 빠른 수렴을 위해 이완 파라미터 및 운동량 가속 파라미터를 이용하는 R-A-ADMM(Relaxed and Accelerated Alternating Direction Methods of Multipliers)을 적용하는

신호 검출 방법.

청구항 3

제2항에 있어서,

상기 이진 MIMO 탐지부를 통해 네거티브 페널티를 적용하고 ADMM을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 단계는,

계산 복잡성을 줄이기 위해 MM(majorization-minimization)방법을 사용하여 박스 제약 조건에 대한 투영을 요소별로 수행하고, BPSK 심볼 벡터의 업데이트의 복잡도를 감소시키는 저복잡도의(inexact) 업데이트를 반복 수행하는

신호 검출 방법.

청구항 4

제2항에 있어서,

상기 이진 MIMO 탐지부를 통해 네거티브 페널티를 적용하고 ADMM을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 단계는,

잔여 오류 및 가속 누적 오류를 이용하여 상기 R-A-ADMM을 알고리즘을 단순화하고, 이완 파라미터에 대해 계층별로 구별되는 하이퍼 파라미터를 허용하며, 저복잡도의(inexact) R-A-ADMM에 기반한 네거티브 페널티를 갖는 MIMO 탐지를 위한 심층 신경망 알고리즘을 수행하는

신호 검출 방법.

청구항 5

단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 허수로 되어있는 가우시안 노이즈가 존재하는 채널을 통과한 QPSK 신호를 수신하고 실수로 나타내기 위하여 기존 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터보다 더 큰 크기를 갖는 BPSK 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터로 변환하고 ML(Maximal Likelihood)를 탐지하는 ML 탐지부; 및

네거티브 페널티(negative penalty)를 적용하고 ADMM(Alternating Direction Methods of Multipliers)을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 이진 MIMO 탐지부

를 포함하는 신호 검출 시스템.

청구항 6

제5항에 있어서,

상기 이진 MIMO 탐지부는,

상기 반복 탐지 알고리즘에 대한 빠른 수렴을 위해 이완 파라미터 및 운동량 가속 파라미터를 이용하는 R-A-ADMM(Relaxed and Accelerated Alternating Direction Methods of Multipliers)을 적용하는

신호 검출 시스템.

청구항 7

제6항에 있어서,

상기 이진 MIMO 탐지부는,

계산 복잡성을 줄이기 위해 MM(majorization-minimization)방법을 사용하여 박스 제약 조건에 대한 투영을 요소별로 수행하고, BPSK 심볼 벡터의 업데이트의 복잡도를 감소시키는 저복잡도의(inexact) 업데이트를 반복 수행하는

신호 검출 시스템.

청구항 8

제6항에 있어서,

상기 이진 MIMO 탐지부는,

잔여 오류 및 가속 누적 오류를 이용하여 상기 R-A-ADMM을 알고리즘을 단순화하고, 이완 파라미터에 대해 계층별로 구별되는 하이퍼 파라미터를 허용하며, 저복잡도의(inexact) R-A-ADMM에 기반한 네거티브 페널티를 갖는 MIMO 탐지를 위한 심층 신경망 알고리즘을 수행하는

신호 검출 시스템.

발명의 설명

기 술 분 야

[0001] 본 발명은 깊은 신경망을 이용한 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 신호 검출 방법 및 시스템에 관한 것이다.

배 경 기 술

[0002] 대규모 MIMO 시스템은 강력한 하드웨어와 높은 계산 복잡성을 희생하면서 많은 수의 안테나로 전송 속도를 향상시킬 수 있다. 고해상도 ADC(Analog-to-Digital Converter)로 인한 하드웨어 장애를 완화하기 위해 대규모 MIMO 시스템에서 저해상도 ADC를 사용할 수 있다. 1비트 ADC는 낮은 전력 소비로 높은 샘플링 주파수에서 작동할 수 있다는 장점이 있다. 그러나 기존의 고전적인 MIMO 탐지 방법을 적용하여 1비트 양자화된 MIMO 수신 신호를 탐지할 수 없다. 최적의 ML(Maximal Likelihood) 탐지는 NP-hard이기 때문에, 1비트 양자화 대규모 MIMO 시스템에서 이진 MIMO 탐지를 수행하는 데 많은 차선의 접근법이 있었다. 완화된 구 제약 조건 집합을 사용하여 이진 MIMO 탐지를 위한 제로-포싱(zero-forcing) 탐지와 경사도 예측 기법(projected gradient methods)이 제안되었다. 또 다른 방법은 박스 완화(box relaxation)를 갖는 동위 최적화(homotopy optimization) 기법을 사용하는 것이다. 이러한 접근 방식에서는 오류 성능이 최적의 성능과 거리가 멀기 때문에 여전히 개선의 여지가 있다.

선행기술문헌

비특허문헌

[0003] (비특허문헌 0001) [1] M. Shao, W.-K. Ma, Binary mimo detection via homotopy optimization and its deep adaptation, IEEE Trans. Sig. Process. 69 (2021) 781-796.

(비특허문헌 0002) [2] M. Shao, Q. Li, W.-K. Ma, A. M.-C. So, A framework for one-bit and constant-envelope precoding over multiuser massive miso channels, IEEE Trans. Sig. Process. 67 (2019) 5309-5324. 165

(비특허문헌 0003) [3] G. Franca, D. P. Robinson, R. Vidal, A dynamical systems perspective on nonsmooth constrained optimization, arXiv:1808.04048.

(비특허문헌 0004) [4] S. Boyd, N. Parikh, E. Chu, B. Peleato, J. Eckstein, Distributed optimization and statistical learning via the alternating direction method of multipliers, Found. Trends Machine Learning 3 (2011) 1-122.

발명의 내용

해결하려는 과제

[0004] 본 발명이 이루고자 하는 기술적 과제는 이진 MIMO 탐지에 네거티브 페널티를 도입하고 ADMM을 기반으로 학습 가능한 깊은 신경망을 이용한 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 신호 검출 방법 및 시스템을 제공하는데 있다. 제안하는 반복 탐지 알고리즘을 통해 낮은 계산 복잡도 및 기존 탐지 방법보다 우수한 성능을 제공하고자 한다.

과제의 해결 수단

[0005] 일 측면에 있어서, 본 발명에서 제안하는 깊은 신경망을 이용한 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 신호 검출 방법은 ML 탐지부를 통해 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 전송된 BPSK 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터를 이용하여 수신된 신호를 계산하고, ML(Maximal Likelihood)를 탐지하는 단계 및 이진 MIMO 탐지부를 통해 네거티브 페널티(negative penalty)를 적용하고 ADMM(Alternating Direction Methods of Multipliers)을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 단계를 포함한다.

[0006] 상기 이진 MIMO 탐지부를 통해 네거티브 페널티를 적용하고 ADMM을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 단계는 상기 반복 탐지 알고리즘에 대한 빠른 수렴을 위해 이완 파라미터 및 운동량 가속 파라미터를 이용하는 R-A-ADMM(Relaxed and Accelerated Alternating Direction Methods of Multipliers)을 적용한다.

[0007] 상기 이진 MIMO 탐지부를 통해 네거티브 페널티를 적용하고 ADMM을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 단계는 계산 복잡성을 줄이기 위해 MM(majorization-minimization)방법을 사용하여 박스 제약 조건에 대한 투영을 요소별로 수행하고, BPSK 심볼 벡터의 업데이트의 복잡도를 감소시키는 저복잡도의(inexact) 업데이트를 반복 수행한다.

[0008] 상기 이진 MIMO 탐지부를 통해 네거티브 페널티를 적용하고 ADMM을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 단계는 잔여 오류 및 가속 누적 오류를 이용하여 상기 R-A-ADMM을 알고리즘을 단순화하고, 이완 파라미터에 대해 계층별로 구별되는 하이퍼 파라미터를 허용하며, 저복잡도의(inexact) R-A-ADMM에 기반한 네거티브 페널티를 갖는 MIMO 탐지를 위한 심층 신경망 알고리즘을 수행한다.

[0009] 또 다른 일 측면에 있어서, 본 발명에서 제안하는 깊은 신경망을 이용한 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 신호 검출 시스템은 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 허수로 되어있는 가우시안 노이즈가 존재하는 채널을 통과한 QPSK 신호를 수신하고 실수로 나타내기 위하여 기존 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터를 두배의 크기를 갖는 BPSK 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터로 변환한다. 그리고 ML(Maximal Likelihood)를 탐지하는 ML 탐지부 및 네거티브 페널티(negative penalty)를 적용하고 ADMM(Alternating Direction Methods of Multipliers)을 기반으로 학습하는 반

복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 이진 MIMO 탐지부를 포함한다.

발명의 효과

[0010] 본 발명의 실시예들에 따르면 이진 MIMO 탐지에 네거티브 페널티를 도입하고 ADMM을 기반으로 학습 가능한 깊은 신경망을 이용한 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 신호 검출 방법 및 시스템을 제공할 수 있다. 제안하는 반복 탐지 알고리즘을 통해 낮은 계산 복잡도 및 기존 탐지 방법보다 우수한 성능을 제공할 수 있다.

도면의 간단한 설명

[0011] 도 1은 본 발명의 일 실시예에 따른 깊은 신경망을 이용한 단일 비트 ADC를 사용하는 이진 MIMO 시스템에서 신호 검출 방법을 설명하기 위한 흐름도이다.

도 2는 본 발명의 일 실시예에 따른 깊은 신경망을 이용한 단일 비트 ADC를 사용하는 이진 MIMO 시스템에서 신호 검출 시스템의 구성을 나타내는 도면이다.

도 3은 본 발명의 일 실시예에 따른 BER 대 SNR을 나타내는 그래프이다.

도 4는 본 발명의 일 실시예에 따른 유효 장치의 수 대비 BER를 나타내는 그래프이다.

발명을 실시하기 위한 구체적인 내용

[0012] 본 발명에서는 이진 MIMO 탐지에 네거티브 페널티(negative penalty)를 도입하고 ADMM(Alternating Direction Methods of Multipliers)을 기반으로 학습 가능한 반복 탐지 알고리즘을 제안한다. 제안된 이진 MIMO 방법은 훨씬 낮은 계산 복잡성에서도 기존 탐지 방법보다 성능이 우수하다. 이하, 본 발명의 실시 예를 첨부된 도면을 참조하여 상세하게 설명한다.

[0014] 도 1은 본 발명의 일 실시예에 따른 깊은 신경망을 이용한 단일 비트 ADC를 사용하는 이진 MIMO 시스템에서 신호 검출 방법을 설명하기 위한 흐름도이다.

[0015] 제안하는 깊은 신경망을 이용한 단일 비트 ADC를 사용하는 이진 MIMO 시스템에서 신호 검출 방법은 ML 탐지부를 통해 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 허수로 되어있는 가우시안 노이즈가 존재하는 채널을 통과한 QPSK 신호를 수신하고 실수로 나타내기 위하여 기존 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터를 두배의 크기를 갖는 BPSK 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터로 변환한다. 그리고 ML(Maximal Likelihood)를 탐지하는 단계(110) 및 이진 MIMO 탐지부를 통해 네거티브 페널티(negative penalty)를 적용하고 ADMM(Alternating Direction Methods of Multipliers)을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 단계(120)를 포함한다.

[0016] 단계(110)에서, ML 탐지부를 통해 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 허수로 되어있는 가우시안 노이즈가 존재하는 채널을 통과한 QPSK 신호를 수신하고 실수로 나타내기 위하여 기존 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터를 두배의 크기를 갖는 BPSK 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터로 변환한다. 그리고 ML(Maximal Likelihood)를 탐지한다.

[0017] 단계(120)에서, 이진 MIMO 탐지부를 통해 네거티브 페널티(negative penalty)를 적용하고 ADMM(Alternating Direction Methods of Multipliers)을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행한다.

[0018] 본 발명의 실시예에 따르면, 반복 탐지 알고리즘에 대한 빠른 수렴을 위해 이완 파라미터 및 운동량 가속 파라미터를 이용하는 R-A-ADMM(Relaxed and Accelerated Alternating Direction Methods of Multipliers)을 적용한다.

[0019] 본 발명의 실시예에 따르면, 계산 복잡성을 줄이기 위해 MM(majorization-minimization)방법을 사용하여 박스 제약 조건에 대한 투영을 요소별로 수행하고, BPSK 심볼 벡터의 업데이트의 복잡도를 감소시키는 저복잡도의(inexact) 업데이트를 반복 수행한다.

[0020] 본 발명의 실시예에 따르면, 잔여 오류 및 가속 누적 오류를 이용하여 상기 R-A-ADMM을 알고리즘을 단순화하고, 이완 파라미터에 대해 계층별로 구별되는 하이퍼 파라미터를 허용하며, 저복잡도의(inexact) R-A-ADMM에 기반한

네거티브 페널티를 갖는 MIMO 탐지를 위한 심층 신경망 알고리즘을 수행한다.

[0022] 도 2는 본 발명의 일 실시예에 따른 깊은 신경망을 이용한 단일 비트 ADC를 사용하는 이진 MIMO 시스템에서 신호 검출 시스템의 구성을 나타내는 도면이다.

[0023] 본 실시예에 따른 신호 검출 시스템(200)은 프로세서(210), 버스(220), 네트워크 인터페이스(230), 메모리(240) 및 데이터베이스(250)를 포함할 수 있다. 메모리(240)는 운영체제(241) 및 신경망을 이용한 단일 비트 ADC를 사용하는 이진 MIMO 시스템에서 신호 검출 루틴(242)을 포함할 수 있다. 프로세서(210)는 ML 탐지부(211) 및 이진 MIMO 탐지부(212)를 포함할 수 있다. 다른 실시예들에서 신호 검출 시스템(200)은 도 2의 구성요소들보다 더 많은 구성요소들을 포함할 수도 있다. 그러나, 대부분의 종래기술적 구성요소들을 명확하게 도시할 필요성은 없다. 예를 들어, 신호 검출 시스템(200)은 디스플레이나 트랜시버(transceiver)와 같은 다른 구성요소들을 포함할 수도 있다.

[0024] 메모리(240)는 컴퓨터에서 판독 가능한 기록 매체로서, RAM(random access memory), ROM(read only memory) 및 디스크 드라이브와 같은 비소멸성 대용량 기록장치(permanent mass storage device)를 포함할 수 있다. 또한, 메모리(240)에는 운영체제(241)와 신경망을 이용한 단일 비트 ADC를 사용하는 이진 MIMO 시스템에서 신호 검출 루틴(242)을 위한 프로그램 코드가 저장될 수 있다. 이러한 소프트웨어 구성요소들은 드라이브 메커니즘(drive mechanism, 미도시)을 이용하여 메모리(240)와는 별도의 컴퓨터에서 판독 가능한 기록 매체로부터 로딩될 수 있다. 이러한 별도의 컴퓨터에서 판독 가능한 기록 매체는 플로피 드라이브, 디스크, 테이프, DVD/CD-ROM 드라이브, 메모리 카드 등의 컴퓨터에서 판독 가능한 기록 매체(미도시)를 포함할 수 있다. 다른 실시예에서 소프트웨어 구성요소들은 컴퓨터에서 판독 가능한 기록 매체가 아닌 네트워크 인터페이스(230)를 통해 메모리(240)에 로딩될 수도 있다.

[0025] 버스(220)는 신호 검출 시스템(200)의 구성요소들간의 통신 및 데이터 전송을 가능하게 할 수 있다. 버스(220)는 고속 시리얼 버스(high-speed serial bus), 병렬 버스(parallel bus), SAN(Storage Area Network) 및/또는 다른 적절한 통신 기술을 이용하여 구성될 수 있다.

[0026] 네트워크 인터페이스(230)는 신호 검출 시스템(200)을 컴퓨터 네트워크에 연결하기 위한 컴퓨터 하드웨어 구성요소일 수 있다. 네트워크 인터페이스(230)는 신호 검출 시스템(200)을 무선 또는 유선 커넥션을 통해 컴퓨터 네트워크에 연결시킬 수 있다.

[0027] 데이터베이스(250)는 신경망을 이용한 단일 비트 ADC를 사용하는 이진 MIMO 시스템에서 신호 검출을 위해 필요한 모든 정보를 저장 및 유지하는 역할을 할 수 있다. 도 2에서는 신호 검출 시스템(200)의 내부에 데이터베이스(250)를 구축하여 포함하는 것으로 도시하고 있으나, 이에 한정되는 것은 아니며 시스템 구현 방식이나 환경 등에 따라 생략될 수 있고 혹은 전체 또는 일부의 데이터베이스가 별개의 다른 시스템 상에 구축된 외부 데이터베이스로서 존재하는 것 또한 가능하다.

[0028] 프로세서(210)는 기본적인 산술, 로직 및 신호 검출 시스템(200)의 입출력 연산을 수행함으로써, 컴퓨터 프로그램의 명령을 처리하도록 구성될 수 있다. 명령은 메모리(240) 또는 네트워크 인터페이스(230)에 의해, 그리고 버스(220)를 통해 프로세서(210)로 제공될 수 있다. 프로세서(210)는 ML 탐지부(211) 및 이진 MIMO 탐지부(212)를 위한 프로그램 코드를 실행하도록 구성될 수 있다. 이러한 프로그램 코드는 메모리(240)와 같은 기록 장치에 저장될 수 있다.

[0029] ML 탐지부(211) 및 이진 MIMO 탐지부(212)는 도 1의 단계들(110~120)을 수행하기 위해 구성될 수 있다.

[0030] 신호 검출 시스템(200)은 ML 탐지부(211) 및 이진 MIMO 탐지부(212)를 포함할 수 있다.

[0031] 본 발명의 실시예에 따른 ML 탐지부(211)는 단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 허수로 되어있는 가우시안 노이즈가 존재하는 채널을 통과한 QPSK 신호를 수신하고 실수로 나타내기 위하여 기존 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터를 두배의 크기를 갖는 BPSK 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터로 변환한다. 그리고 ML(Maximal Likelihood)를 탐지한다.

[0032] 본 발명의 실시예에 따른 이진 MIMO 탐지부(212)는 네거티브 페널티(negative penalty)를 적용하고 ADMM(Alternating Direction Methods of Multipliers)을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행한다.

[0033] 본 발명의 실시예에 따른 이진 MIMO 탐지부(212)는 반복 탐지 알고리즘에 대한 빠른 수렴을 위해 이완 파라미터 및 운동량 가속 파라미터를 이용하는 R-A-ADMM(Relaxed and Accelerated Alternating Direction Methods of Multipliers)을 적용한다.

[0034] 본 발명의 실시예에 따른 이진 MIMO 탐지부(212)는 계산 복잡성을 줄이기 위해 MM(majorization-minimization)방법을 사용하여 박스 제약 조건에 대한 투영을 요소별로 수행하고, BPSK 심볼 벡터의 업데이트의 복잡도를 감소시키는 저복잡도의(inexact) 업데이트를 반복 수행한다.

[0035] 본 발명의 실시예에 따른 이진 MIMO 탐지부(212)는 잔여 오류 및 가속 누적 오류를 이용하여 상기 R-A-ADMM을 알고리즘을 단순화하고, 이완 파라미터에 대해 계층별로 구별되는 하이퍼 파라미터를 허용하며, 저복잡도의(inexact) R-A-ADMM에 기반한 네거티브 페널티를 갖는 MIMO 탐지를 위한 심층 신경망 알고리즘을 수행한다.

[0036] 본 발명에서는 기지국에 1비트 A/D 변환기(A/D converters; ADC)가 있는 업링크 대규모 MIMO 시스템을 고려한다. 1비트 ADC는 오류 성능 저하의 비용으로 수신기의 전력 소비를 줄이는 데 도움이 된다. 수신된 신호는 $\mathbf{y}_c = \mathbf{H}_c\mathbf{x}_c + \mathbf{n}_c$ 이며, 여기서 $\mathbf{H}_c \in \mathbb{C}^{N_c \times M_c}$ 는 채널 행렬, $\mathbf{x}_c \in \mathbb{C}^{M_c}$ 는 QPSK 심볼 벡터, $\mathbf{n}_c \in \mathbb{C}^{N_c}$ 이다. 본 발명의 실시예에 따르면, 복소 벡터를 실수 벡터로 변환할 수 있으며, 이는 $N = 2N_c$ 및 $M = 2M_c$ [1]와 같은 수의 안테나를 생성한다. 1비트 ADC가 있는 수신된 신호는 다음과 같이 나타낼 수 있다:

[0037] $$\mathbf{y} = \operatorname{sgn}(\mathbf{H}\mathbf{x} + \mathbf{n}), \tag{1}$$

[0038] 여기서, $\mathbf{x} \in \mathcal{S}^M = \{-1, +1\}^M$ 은 전송된 BPSK 심볼 벡터이고, $\mathbf{H} = [\mathbf{h}_1 \cdots \mathbf{h}_N]^T \in \mathbb{R}^{N \times M}$ 은 채널 행렬이며, $\mathbf{n} \sim \mathcal{N}(0, \sigma^2)$ 은 가우스 노이즈 벡터이다. 최적의 ML(Maximal Likelihood) 탐지는 식(2)와 같이 나타낼 수 있다:

[0039] $$\text{(P1)} \quad \min_{\mathbf{x} \in \mathcal{S}^M} -\sum_{i=1}^{N} \log \Phi\left(\frac{y_i \mathbf{h}_i^T \mathbf{x}}{\sigma}\right), \tag{2}$$

[0040] 여기서 $\Phi(x) = \int_{-\infty}^{x} \frac{1}{\sqrt{2\pi}} e^{-t^2/2} dt$ 는 표준 가우스 분포의 CDF이다.

[0041] 문제(P1)에서 가능한 모든 이진 벡터에 대한 철저한 검색은 계산적으로 금지된다. 따라서, 1비트 ADC를 사용한 차선의 MIMO 탐지를 위한 많은 접근법이 있었다. $-\log \Phi(x)$ 가 볼록이므로, 볼록 최적화 문제를 도출하기 위해 $\mathbf{x} \in \mathcal{S}^M$ 을 구 제약(sphere constraint) $\|\mathbf{x}\|^2 \le M$ 으로 완화할 수 있다. 이 볼록한 구 완화(sphere relaxation)에 기초한 투영된 경사도 예측 기법은 수신 안테나의 수가 그렇게 많지 않을 때 최적의 ML 탐지 성능과 거리가 멀다. 또 다른 접근법은 $\mathbf{x} \in \mathcal{S}^M$ 을 박스 제약(box constraint) $\mathbf{x} \in \bar{\mathcal{S}}^M = \{x | -1 \le x \le 1\}^M$ 으로 완화하면서 네거티브 페널티(negative penalty)를 도입했다:

[0042] $$\text{(P2)} \quad \min_{\mathbf{x} \in \mathcal{S}^M} -\sum_{i=1}^{N} \log \Phi\left(\frac{y_i \mathbf{h}_i^T \mathbf{x}}{\sigma}\right) - \lambda r(\mathbf{x}), \tag{3}$$

[0043] 여기서 $r(\mathbf{x}) = \frac{1}{2}\|\mathbf{x}\|^2$ [4] 이다. 문제(P1)와 (P2) 사이의 등가(equivalence)가 도출되었다[1][2].

[0044] **정리 1** ((P1)과 (P2)[1][2]의 솔루션). 모든 $\lambda > \bar{\lambda}$, 에 대해 문제(P2)에 대한 글로벌 최적 솔루션이 문제(P1)에 대한 전역 최적 솔루션이 되는 $\bar{\lambda}$ 가 존재한다. 그 반대도 참이다. 또한 문제(P2)에 대한 로컬 최적 솔루션은 문제(P1)에 대한 실현 가능한 솔루션이다.

[0045] 문제(P2)는 네거티브 페널티가 있는 박스 완화 이진 MIMO 탐지이며, 이는 좋은 속성을 가지고 있다. 정리 1에 따르면, 충분히 큰 λ 의 경우, 문제(P2)에 대한 모든 글로벌 최적 솔루션은 문제(P1)에도 해당되며, 문제(P2)에 대한 모든 로컬 최적 솔루션은 S^M[2]에 있다. 비볼록 문제를 해결하기 위해 더 어려운 문제를 근사치가 있는 더

쉬운 문제로 변환하고 솔루션 시퀀스를 더 쉬운 것에서 더 어려운 것으로 추적하는 동위 최적화(homotopy optimization) 기법을 적용할 수 있다. 문제(P2)의 경우, 네거티브 페널티가 있는 박스 완화 이진 MIMO 탐지에 GEMM(the gradient extrapolated majorization-minimization)이 적용되었다[1].

[0046] 본 발명에서는 문제를 더 잘 해결하기 위한 다른 알고리즘을 제안한다. 본 발명에서는 R-A-ADMM(Relaxed and Accelerated Alternating Direction Methods of Multipliers)[3]을 문제(P2)에 적용하고 수신된 신호 데이터를 사용하여 하이퍼 파라미터를 학습하여 최적의 성능을 달성한다.

[0047] 본 발명의 실시예에 따른 MIMO 탐지를 위한 학습 가능한 ADMM에 있어서, z를 도입하여 ADMM 친화적인 형태로 문제(P2)를 재구성한다.

$$\min_{\mathbf{x}\in\bar{\mathcal{S}}^M,\mathbf{z}\in\mathbb{R}^N} \; -\sum_{i=1}^{M}\log\Phi\left(\frac{z_i}{\sigma}\right)-\lambda r(\mathbf{x}).$$

[0048] $$\text{s.t.} \quad \mathbf{z}=\text{diag}(\mathbf{y})\mathbf{H}\mathbf{x}, \tag{4}$$

[0049] 이는 네거티브 ℓ_2 페널티 r(x) = $\frac{1}{2}\|\mathbf{x}\|^2$이기 때문에 계산되지 않는다. 증강 스케일 라그랑지안(Lagrangian)은 다음과 같이 주어진다.

[0050] $$L(\mathbf{x},\mathbf{z},\mathbf{u}) = -\sum_{i=1}^{N}\log\Phi\left(\frac{z_i}{\sigma}\right)-\lambda r(\mathbf{x}) + \rho\mathbf{u}^T(\text{diag}(\mathbf{y})\mathbf{H}\mathbf{x}-\mathbf{z})+\frac{\rho}{2}\|\text{diag}(\mathbf{y})\mathbf{H}\mathbf{x}-\mathbf{z}\|_2^2, \tag{5}$$

[0051] 여기서 $\rho>0$이다. 가우시안 자이델(Gauss-Seidel) 방식으로 (x, z)에 대해 L(x, z, u)를 최소화하고 u에 대해 L(x, z, u)을 최대화한다. 그러면, (정확한) ADMM [4]은 다음과 같이 주어진다.

[0052] $$\begin{aligned}\mathbf{x}_{k+1} &= \arg\min_{\mathbf{x}\in\bar{\mathcal{S}}^M} -\lambda r(\mathbf{x})+\frac{\rho}{2}\|\text{diag}(\mathbf{y})\mathbf{H}\mathbf{x}-\mathbf{z}_k+\mathbf{u}_k\|_2^2\\ \mathbf{z}_{k+1} &= \arg\min_{\mathbf{z}\in\mathbb{R}^N} -\sum_{i=1}^{N}\log\Phi\left(\frac{z_i}{\sigma}\right)\\ &\quad +\frac{\rho}{2}\|\text{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_{k+1}-\mathbf{z}+\mathbf{u}_k\|_2^2\\ \mathbf{u}_{k+1} &= \mathbf{u}_k+\text{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_{k+1}-\mathbf{z}_{k+1},\end{aligned} \tag{6}$$

[0053] 여기서 k는 반복 지수이다. 더 빠른 수렴을 위해 몇 가지 모멘텀을 도입할 수 있다. 본 발명의 실시예에 따르면, R-A-ADMM(Relaxed and Accelerated Alternating Direction Methods of Multipliers)을 문제에 적용할 수 있다[4].

[0055] $$\begin{aligned}\mathbf{x}_{k+1} &= \arg\min_{\mathbf{x}\in\bar{\mathcal{S}}^M} -\lambda r(\mathbf{x})+\frac{\rho}{2}\|\text{diag}(\mathbf{y})\mathbf{H}\mathbf{x}-\hat{\mathbf{z}}_k+\hat{\mathbf{u}}_k\|_2^2\\ \mathbf{z}_{k+1} &= \arg\min_{\mathbf{z}\in\mathbb{R}^N} \sum_{i=1}^{N} g(z_i)\\ &\quad +\frac{\rho}{2}\|\alpha\text{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_{k+1}+(1-\alpha)\hat{\mathbf{z}}_k-\mathbf{z}+\hat{\mathbf{u}}_k\|_2^2\\ \mathbf{u}_{k+1} &= \hat{\mathbf{u}}_k+\alpha\text{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_{k+1}+(1-\alpha)\hat{\mathbf{z}}_k-\mathbf{z}_{k+1}\end{aligned}$$

$$\mathbf{u}_{k+1} = \hat{\mathbf{u}}_k + \alpha \mathrm{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_{k+1} + (1-\alpha)\hat{\mathbf{z}}_k - \mathbf{z}_{k+1}$$
$$\hat{\mathbf{z}}_{k+1} = \mathbf{z}_{k+1} + \gamma_k(\mathbf{z}_{k+1} - \mathbf{z}_k)$$
$$\hat{\mathbf{u}}_{k+1} = \mathbf{u}_{k+1} + \gamma_k(\mathbf{u}_{k+1} - \mathbf{u}_k),$$

[0056] (7)

[0057] 여기서 $g(z) = -\log\Phi\left(\frac{z}{\sigma}\right)$, $\xi > 0$인 $\gamma_k = k/(k+\xi)$, $\alpha \in (0,2)$이다. (7)의 알고리즘은 이완 파라미터 α와 운동량 가속 파라미터 γ_k의 도입으로 기존의 ADMM보다 더 일반적이다. 예를 들어, α = 1이고 γ_k= 0인 알고리즘은 (6)이고 α = 1이고 γ_k= k/(k + 5)인 알고리즘은 A-ADMM(Accelerated ADMM)이다.

[0058] 본 발명의 실시예에 따르면, 계산 복잡성을 줄이기 위해 정확한 x-업데이트를 대체하는 정확한 저복잡도의 해결 방안을 설계해야 한다. 본 발명은 저복잡도의 최적화를 도출하기 위해 MM(majorization-minimization) 방법을 적용하고, $\delta_k \le 1/L_f$에 대해 다음 식을 취하는 매끄러운 볼록 함수 $h(\mathbf{x}) = \frac{1}{2}\|\mathrm{diag}(\mathbf{y})\mathbf{H}\mathbf{x} - \hat{\mathbf{z}}_k + \hat{\mathbf{u}}_k\|_2^2$를 정의한다:

$$h(\mathbf{x}) \le h(\mathbf{x}_k) + \nabla h(\mathbf{x}_k)^T(\mathbf{x}-\mathbf{x}_k) + \frac{1}{2\delta_k}\|\mathbf{x}-\mathbf{x}_k\|_2^2$$

[0059] (2)

[0060] 여기서 Lf는 $\mathbf{H}^T\mathbf{H}$의 가장 큰 고유값이다. MM 방법을 사용하면 다음과 같이 정확하지 않은 x-업데이트가 제공된다.

$$\arg\min_{\mathbf{x}\in\bar{\mathcal{S}}^M} -\lambda r(\mathbf{x}) + \rho\nabla h(\mathbf{x}_k)^T(\mathbf{x}-\mathbf{x}_k) + \frac{\rho}{2\delta_k}\|\mathbf{x}-\mathbf{x}_k\|_2^2$$
$$= \arg\min_{\mathbf{x}\in\bar{\mathcal{S}}^M} -\lambda r(\mathbf{x}) + \frac{\rho}{2\delta_k}\|\mathbf{x}-\mathbf{x}_k + \delta_k\nabla h(\mathbf{x}_k)\|_2^2.$$

[0061] (9)

[0062] $r(\mathbf{x}) = \frac{1}{2}\|\mathbf{x}\|_2^2 \ge (\mathbf{x}_k)^T(\mathbf{x}-\mathbf{x}_k) - \frac{1}{2}\|\mathbf{x}_k\|^2$이기 때문에, MM 방법은 다시 한 번 정확하지 않은 x-업데이트를 제공한다.

$$\mathbf{x}_{k+1} = \arg\min_{\mathbf{x}\in\bar{\mathcal{S}}^M} -\lambda\left((\mathbf{x}_k)^T(\mathbf{x}-\mathbf{x}_k) - \frac{1}{2}\|\mathbf{x}_k\|^2\right) + \frac{\rho}{2\delta_k}\|\mathbf{x}-\mathbf{x}_k + \delta_k\nabla h(\mathbf{x}_k)\|_2^2$$
$$= \Pi_{\bar{\mathcal{S}}^M}\left(\left(1+\frac{\lambda\delta_k}{\rho}\right)\mathbf{x}_k - \delta_k\mathbf{H}^T\mathrm{diag}(\mathbf{y})(\mathrm{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_k - \hat{\mathbf{z}}_k + \hat{\mathbf{u}}_k)\right),$$

[0063] (10)

[0064] 여기서 $\Pi_{\bar{\mathcal{S}}^M}(\mathbf{v}) = \arg\min_{x\in\bar{\mathcal{S}}^M}\|\mathbf{x}-\mathbf{v}\|_2^2$은 벡터 v 집합 $\bar{\mathcal{S}}^M$의 유클리드 투영이다. x = xk일 때 h(x)와 r(x)의 두 부등식이 팽팽해지기 때문에, 이 저복잡도의업데이트는 반복이 진행되며 솔루션이 수렴할 때 정확해진다. 박스 제약 조건 $\Pi_{\bar{\mathcal{S}}^M}(\mathbf{v})$에 대한 투영은 요소별로 수행될 수 있으며, 여기서 $\Pi_{\bar{\mathcal{S}}}(v)$는 다음과 같이 주어진다.

$$\Pi_{\bar{\mathcal{S}}}(v) = \begin{cases} -1, & \text{if } v \le -1 \\ v, & \text{if } -1 < v < 1 \\ 1, & \text{if } v \ge 1 \end{cases}$$

[0065] (11)

[0066] 식(7)의 z-업데이트는 각 구성 요소에서 분리할 수 있다.

$$\mathbf{z}_{k+1} = \arg\min_{\mathbf{z}\in\mathbb{R}^N} \sum_{i=1}^{N} g(z_i) + \frac{\rho}{2}\|\mathbf{z} - \mathbf{v}_{k+1}\|_2^2$$
$$= \arg\min_{\mathbf{z}\in\mathbb{R}^N} \sum_{i=1}^{N} \left(g(z_i) + \frac{\rho}{2}|z_i - [\mathbf{v}_{k+1}]_i|^2 \right),$$

[0067] (12)

[0068] 여기서 $\mathbf{v}_{k+1} = \alpha\mathrm{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_{k+1} + (1-\alpha)\hat{\mathbf{z}}_k + \hat{\mathbf{u}}_k$ 이고 $[\mathbf{v}]_i$ 는 v의 i번째 항목을 나타낸다. 이는 g(z)의 proximal 연산자와 관련이 있다.

$$z^\star = \arg\min_{z\in\mathbb{R}} g(z) + \frac{\rho}{2}|z - v|^2,$$

[0069] (13)

[0070] 닫힌 형태의 솔루션을 도출하기는 어렵다. 1차 근사 $g(z) \approx g(v) + g'(v)(z-v)$ 를 사용하면 (13)의 업데이트는 $z^\star \approx v - \frac{1}{\rho}g'(v)$ 로 근사된다. 따라서 1단계 경사도 기법을 사용하고 적절한 조건을 위해 충분히 작은 $\mu \equiv 1/\rho$ 을 선택해야 한다. 이때 μ 는 근사된 경사 하강법의 스텝의 크기를 나타낸다.

$$[\mathbf{z}_{k+1}]_i = [\mathbf{v}_{k+1}]_i - \mu g'([\mathbf{v}_{k+1}]_i),\ \forall i,$$

[0071] (14)

[0072] 여기서 $g'(z) = -\frac{1}{\sqrt{2\pi}\sigma\Phi(z/\sigma)} e^{-\frac{z^2}{2\sigma^2}}$ 이다.

[0073] 본 발명의 실시예에 따른 이진 MIMO 탐지를 위한 학습 가능한 ADMM 네트워크에 있어서, 반복 알고리즘은 각 반복을 펼치고 학습 가능한 파라미터를 도입하여 심층 신경망을 설계하는 데 사용될 수 있다.

[0074] 본 발명에서는 알고리즘 언롤링 기술을 도출된 R-A-ADMM 알고리즘에 적용한다.

$$\begin{aligned}
\mathbf{x}_{k+1} &= \Pi_{\tilde{\mathcal{S}}^M}((1+\zeta_k)\mathbf{x}_k - \delta_k\mathbf{H}^T\mathrm{diag}(\mathbf{y})(\mathrm{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_{k+1} \\
&\quad - \hat{\mathbf{z}}_k + \hat{\mathbf{u}}_k)) \\
\mathbf{v}_{k+1} &= \alpha\mathrm{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_{k+1} + (1-\alpha)\hat{\mathbf{z}}_k + \hat{\mathbf{u}}_k \\
[\mathbf{z}_{k+1}]_i &= [\mathbf{v}_{k+1}]_i - \mu g'([\mathbf{v}_{k+1}]_i),\ \forall i, \\
\mathbf{u}_{k+1} &= \hat{\mathbf{u}}_k + \alpha\mathrm{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_{k+1} + (1-\alpha)\hat{\mathbf{z}}_k - \mathbf{z}_{k+1} \\
\hat{\mathbf{z}}_{k+1} &= \mathbf{z}_{k+1} + \gamma_k(\mathbf{z}_{k+1} - \mathbf{z}_k) \\
\hat{\mathbf{u}}_{k+1} &= \mathbf{u}_{k+1} + \gamma_k(\mathbf{u}_{k+1} - \mathbf{u}_k),
\end{aligned}$$

[0075] (15)

[0076] 여기서 $\zeta_k = \lambda\delta_k/\rho$ 이다. 먼저 일부 보조 변수(잔여 오류 $\mathbf{e}_{k+1} = \mathrm{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_{k+1}$ 및 가속 누적 오류 $\hat{\mathbf{v}}_{k+1} = \mathbf{v}_{k+1} + \gamma_k(\mathbf{v}_{k+1} - \mathbf{v}_k)$)를 도입하여 제안된 ADMM 알고리즘을 단순화한다. 이러한 도입된 변수를 사용하여, 보여주는 것은 어렵지 않다

$$\begin{aligned}
\mathbf{u}_{k+1} &= \mathbf{v}_{k+1} - \mathbf{z}_{k+1} \\
\hat{\mathbf{u}}_{k+1} &= \hat{\mathbf{v}}_{k+1} - \hat{\mathbf{z}}_{k+1} \\
\mathbf{v}_{k+1} &= \alpha\mathbf{e}_{k+1} - \alpha\hat{\mathbf{z}}_k + \hat{\mathbf{v}}_k.
\end{aligned}$$

[0077] (16)

[0078] 본 발명의 실시예에 따르면, α, μ에 대해 계층별로 구별되는 하이퍼 파라미터를 허용하고, 이는 심층 신경망에 더 많은 표현력을 제공할 수 있기 때문이다.

[0079] 요약하자면, 저복잡도의 R-A-ADMM에 기반한 네거티브 페널티를 갖는 MIMO 탐지 알고리즘인 DeepADMM 알고리즘을 제안한다.

$$\begin{aligned}
\mathbf{x}_{k+1} &= \Pi_{\mathcal{S}^M}((1+\zeta_k)\mathbf{x}_k - \delta_k \mathbf{H}^T \mathrm{diag}(\mathbf{y})(\mathbf{e}_k - 2\hat{\mathbf{z}}_k + \hat{\mathbf{v}}_k)) \\
\mathbf{e}_{k+1} &= \mathrm{diag}(\mathbf{y})\mathbf{H}\mathbf{x}_{k+1} \\
\mathbf{v}_{k+1} &= \alpha_k \mathbf{e}_{k+1} - \alpha_k \hat{\mathbf{z}}_k + \hat{\mathbf{v}}_k \\
[\mathbf{z}_{k+1}]_i &= [\mathbf{v}_{k+1}]_i - \mu_k g'([\mathbf{v}_{k+1}]_i),\ \forall i, \\
\hat{\mathbf{v}}_{k+1} &= \mathbf{v}_{k+1} + \gamma_k(\mathbf{v}_{k+1} - \mathbf{v}_k) \\
\hat{\mathbf{z}}_{k+1} &= \mathbf{z}_{k+1} + \gamma_k(\mathbf{z}_{k+1} - \mathbf{z}_k). \qquad (17)
\end{aligned}$$

[0080]

[0081] 휴리스틱하게 최적의 파라미터를 검색하는 대신, 데이터를 사용하여 신경망을 훈련시켜 얻을 수 있다. 도출된 반복 알고리즘(17)의 각 반복은 신경망의 각 계층 역할을 할 수 있다. L 신경망 계층을 가질 때, 제안된 DeepADMM의 학습 가능한 파라미터 집합은 $\Omega = \{\zeta_k, \delta_k, \alpha_k, \mu_k, \gamma_k\}_{k=0}^{L-1}$ 이고 학습 가능한 파라미터의 총 개수는 5L이다. 손실 함수를 마지막 계층의 출력과 실제 전송된 심볼 사이의 유클리드 거리로 간주한다.

[0082] 신경망 훈련의 관점에서 제안된 DeepADMM을 DeepHOTML과 비교한다. 안테나 수가 다른 경우, DeepHOTML은 학습 가능한 파라미터가 안테나 수에 따라 크기가 조정되는 가중치와 편향을 가지기 때문에 별도의 학습이 필요하다. 그러나 DeepADMM에는 안테나 수와 무관한 스칼라 파라미터만 있다. 따라서 학습된 파라미터를 다른 안테나 구성에 적용할 수 있기 때문에 다양한 안테나 구성에서 더 유연하다.

[0084] 도 3은 본 발명의 일 실시예에 따른 BER 대 SNR을 나타내는 그래프이다.

[0085] 도 3을 참조하여 제안된 DeepADMM을 최적의 최대우도(Maximum Likelihood; ML) 탐지 및 ZF(zero-forcing), SR(Sphere Relaxation), DeepHOTML과 같은 기존 이진 MIMO 탐지 알고리즘과 비교한다. 본 발명의 실시예에 따른 N_c 안테나와 M_c 단일 안테나 장치가 장착된 단일 BS로 구성된 업링크 대규모 MIMO 시스템을 고려한다. MIMO 채널 매트릭스의 각 항목은 가우스 분포 CN(0, 1)에서 추출된다. 모든 시뮬레이션 결과는 (N_c, M_c)가 아니라 장치 및 안테나의 유효 수(N, M)로 표시된다.

[0086] 도 3은 (N, M) = (20, 16)의 경우의 BER(Bit Error Rate) 대 SNR을 나타낸 것이다. 본 발명의 실시예에 따르면, 학습 기반 탐지 알고리즘인 DeepHOTM과 DeepADMM을 관찰하며 이는 학습되지 않은 알고리즘인 ZF와 SR을 능가한다. 제안된 DeepADMM은 DeepHOTML을 능가하며 BER 성능은 최적의 ML 탐지기 성능에 가깝다.

[0088] 도 4는 본 발명의 일 실시예에 따른 유효 장치의 수 대비 BER를 나타내는 그래프이다.

[0089] 도 4는 N = 120 및 SNR 20 dB의 경우에 유효 장치의 수 대비 BER를 나타낸 것이다. 본 발명의 실시예에 따라 다음을 관찰한다: 1) 장치 수가 많을수록 업링크 채널의 사용자 간 간섭으로 인한 모든 알고리즘의 비트 오류가 증가한다. 2) ZF 탐지기는 최악의 BER 성능을 보여주며, 제안된 DeepADMM은 최고의 성능을 달성한다. 3) 목표 BER이 10^{-5}일 때 제안된 DeepADMM은 DeepHOTML보다 2개 더 많은 장치를 수용할 수 있다. 따라서 DeepADMM은 업링크 채널에 더 많은 장치를 수용할 수 있다는 장점이 있다.

[0090] 표 1은 이진 MIMO 탐지에서 다양한 알고리즘의 평균 실행 시간을 보여준다.

[0091] <표 1>

(N, M)	(120, 20)	(120, 40)	(120, 60)
ZF	3.16 μsec	5.85 μsec	6.30 μsec
DeepADMM	0.312 msec	0.348 msec	0.371 msec
DeepHOTML	0.385 msec	0.449 msec	0.471 msec
SR	33.2 msec	81.7 msec	93.4 msec

[0092]

[0093] 공정한 비교를 위해 Intel Core i9-11900 프로세서와 32GB RAM을 탑재한 동일한 Matlab 프로그램과 PC를 사용했다. ZF는 채널 행렬의 슈도(pseudo) 역방향만 계산하기 때문에 가장 빠른 알고리즘인 반면 SR은 가장 느리다.

DeepHOTML 및 DeepADMM은 실행 시간이 비슷하지만, DeepADMM이 더 빠르다. 그러므로, 제안된 DeepADMM은 성능이 가장 좋지 않은 ZF를 제외하고 테스트된 알고리즘 중에서 가장 빠르다.

[0094] 본 발명의 실시예에 따르면, 기지국에서 1비트 ADC를 사용하여 정확하지 않은 ADMM을 기반으로 하는 새로운 학습 가능한 이진 MIMO 탐지 네트워크를 제안했다. 본 발명의 실시예에 따르면, 최적의 오류 성능을 달성하기 위해 심층 알고리즘 언롤링을 사용하여 ℓ_2 네거티브 페널티를 가진 박스 완화 이진 MIMO 탐지를 R-A-ADMM 형태로 변환했다. 제안된 알고리즘은 바람직한 특성을 많이 가지고 있다: 1) 본 발명의 실시예에 따른 수치 결과는 그것이 구 이완 및 DeepHOTML보다 더 나은 탐지 성능을 가지고 있음을 보여주며 BER은 최적 ML 탐지기의 BER에 가깝다. 2) 또한, 다른 알고리즘에 비해 계산 복잡도가 낮으며 3) DeepHOTML은 안테나 구성이 다를 때 별도의 학습이 필요한 반면 제안된 알고리즘은 학습된 파라미터를 다른 안테나 구성에 적용할 수 있기 때문에 다른 안테나 구성에서 더 유연하다.

[0096] 이상에서 설명된 장치는 하드웨어 구성요소, 소프트웨어 구성요소, 및/또는 하드웨어 구성요소 및 소프트웨어 구성요소의 조합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치 및 구성요소는, 예를 들어, 프로세서, 콘트롤러, ALU(arithmetic logic unit), 디지털 신호 프로세서(digital signal processor), 마이크로컴퓨터, FPGA(field programmable gate array), PLU(programmable logic unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 하나 이상의 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(OS) 및 상기 운영 체제 상에서 수행되는 하나 이상의 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로 설명된 경우도 있지만, 해당 기술분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(processing element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 콘트롤러를 포함할 수 있다. 또한, 병렬 프로세서(parallel processor)와 같은, 다른 처리 구성(processing configuration)도 가능하다.

[0097] 소프트웨어는 컴퓨터 프로그램(computer program), 코드(code), 명령(instruction), 또는 이들 중 하나 이상의 조합을 포함할 수 있으며, 원하는 대로 동작하도록 처리 장치를 구성하거나 독립적으로 또는 결합적으로(collectively) 처리 장치를 명령할 수 있다. 소프트웨어 및/또는 데이터는, 처리 장치에 의하여 해석되거나 처리 장치에 명령 또는 데이터를 제공하기 위하여, 어떤 유형의 기계, 구성요소(component), 물리적 장치, 가상 장치(virtual equipment), 컴퓨터 저장 매체 또는 장치에 구체화(embody)될 수 있다. 소프트웨어는 네트워크로 연결된 컴퓨터 시스템 상에 분산되어서, 분산된 방법으로 저장되거나 실행될 수도 있다. 소프트웨어 및 데이터는 하나 이상의 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.

[0098] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.

[0099] 이상과 같이 실시예들이 비록 한정된 실시예와 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가진 자라면 상기의 기재로부터 다양한 수정 및 변형이 가능하다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다.

[0100] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.

도면

도면1

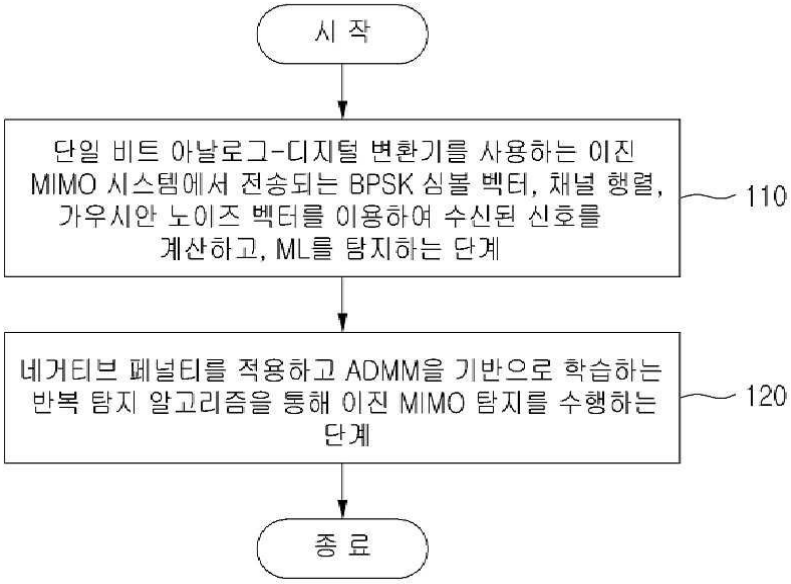
시 작
단일 비트 아날로그-디지털 변환기를 사용하는 이진 MIMO 시스템에서 전송되는 BPSK 심볼 벡터, 채널 행렬, 가우시안 노이즈 벡터를 이용하여 수신된 신호를 계산하고, ML를 탐지하는 단계
110
네거티브 페널티를 적용하고 ADMM을 기반으로 학습하는 반복 탐지 알고리즘을 통해 이진 MIMO 탐지를 수행하는 단계
120
종 료

도면2

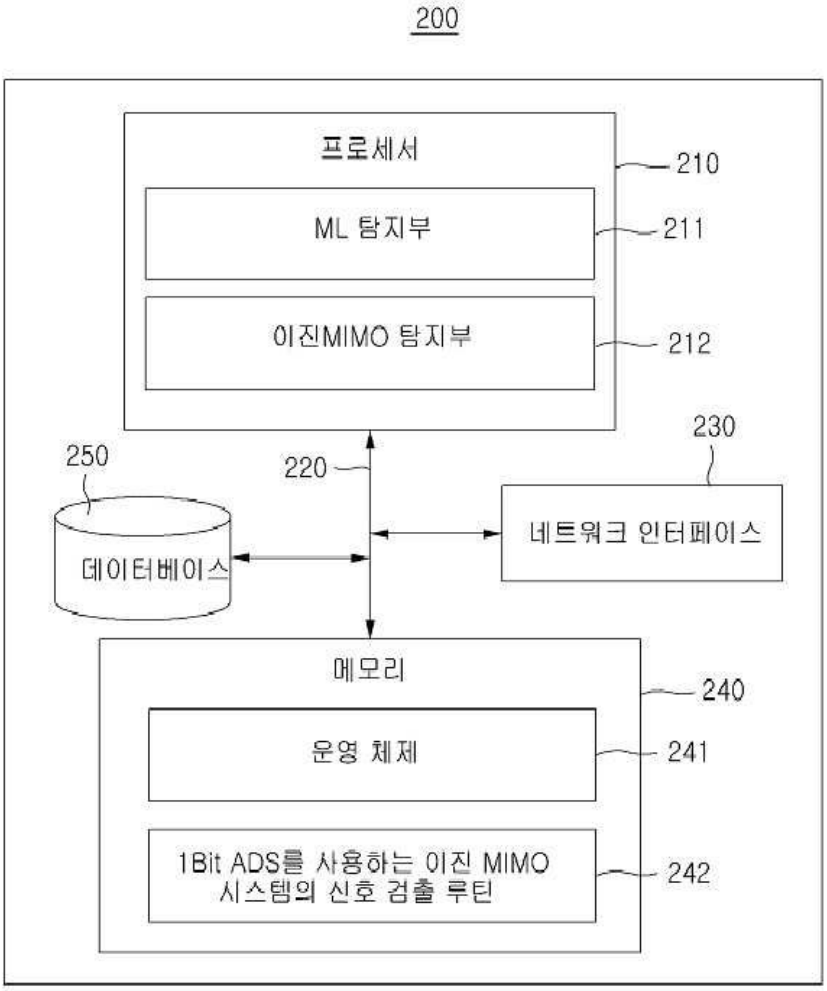
200
프로세서
210
ML 탐지부
211
이진MIMO 탐지부
212
230
250
220
네트워크 인터페이스
데이터베이스
메모리
240
운영 체제
241
1Bit ADS를 사용하는 이진 MIMO 시스템의 신호 검출 루틴
242

도면3

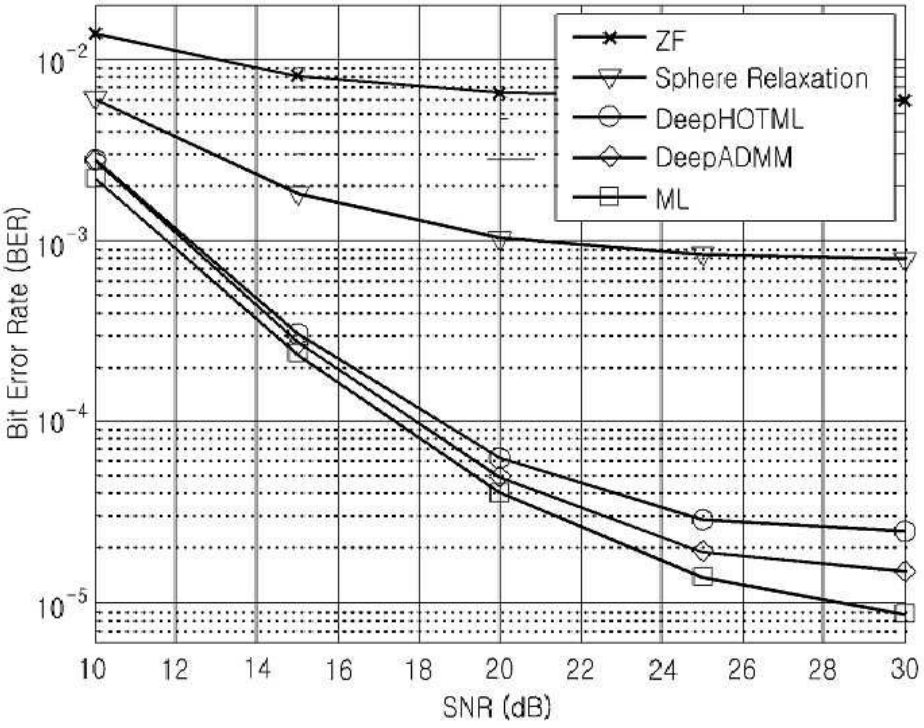
ZF
Sphere Relaxation
DeepHOTML
DeepADMM
ML
Bit Error Rate (BER)
SNR (dB)

도면4

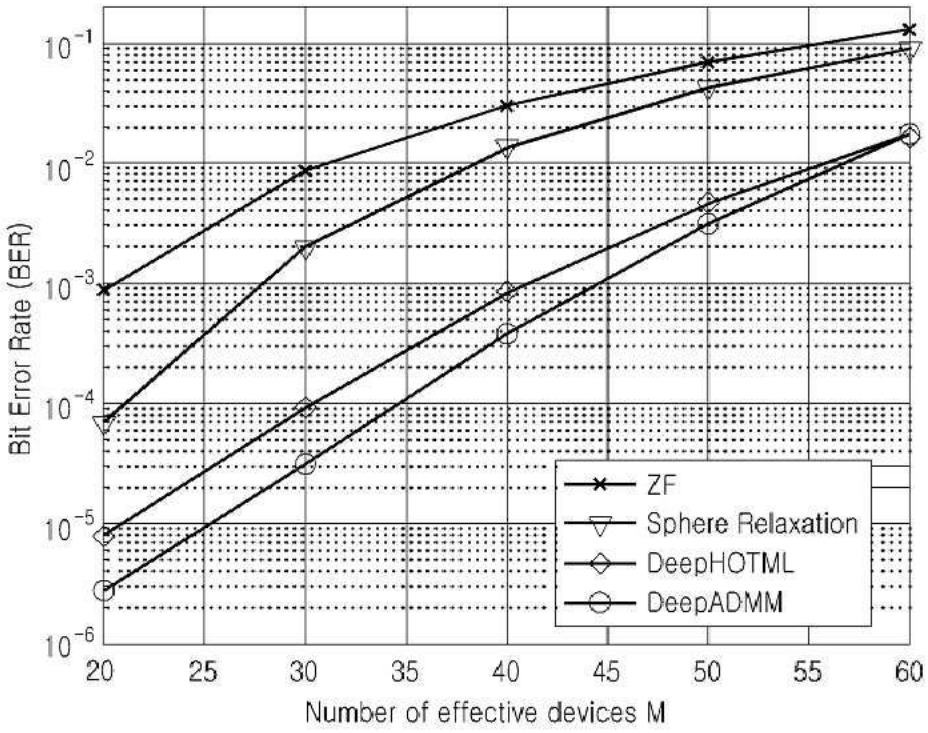
ZF
Sphere Relaxation
DeepHOTML
DeepADMM
Bit Error Rate (BER)
Number of effective devices M