



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2022년02월08일
(11) 등록번호 10-2355383
(24) 등록일자 2022년01월20일

(51) 국제특허분류(Int. Cl.)
H04B 7/0452 (2017.01) G06N 20/00 (2019.01)
G06N 3/08 (2006.01)
(52) CPC특허분류
H04B 7/0452 (2013.01)
G06N 20/00 (2021.08)
(21) 출원번호 10-2021-0175055
(22) 출원일자 2021년12월08일
심사청구일자 2021년12월08일
(56) 선행기술조사문헌
KR1020030096406 A*
KR1020130037118 A*
KR1020210000645 A*
*는 심사관에 의하여 인용된 문헌

(73) 특허권자
세종대학교산학협력단
서울특별시 광진구 능동로 209 (군자동, 세종대학교)
(72) 발명자
송형규
경기도 성남시 분당구 중앙공원로 17, 320-303(서현동, 한양아파트)
장준용
경기도 의정부시 오목로35번길 10, 102-102(용현동, 용현그랜드아파트)
(74) 대리인
이강민, 안준형, 남승희

전체 청구항 수 : 총 6 항

심사관 : 전용해

(54) 발명의 명칭 Massive MIMO 시스템에서 고 신뢰도를 위한 딥러닝 기반 신호 검출 기법


(57) 요약

본 발명은 딥러닝 알고리즘을 활용한 검출 성능 향상을 massive MIMO 시스템으로 확장하는 것으로 보다 낮은 구현 복잡도와 높은 신뢰도를 만족하는 딥러닝 기반 검출 기법에 관한 것이다.

본 발명에 따르면, 딥러닝 알고리즘을 활용하여 검출 정확도를 높을 수 있다. 학습 알고리즘을 통해 SOR 기법에 DNN 기반 비선형 추정기를 결합하는 것으로 높은 정확도로 신호를 검출하는 반복적인 구조의 검출 기법을 제안한다.

본 발명의 제안된 검출기는 선형 추정기로 저 복잡도의 SOR 기법을 사용하며 massive MIMO 시스템에서 OAMPNet 보다 낮은 복잡도로 구현될 수 있다.

대표도 - 도1



(52) CPC특허분류
G06N 3/08 (2013.01)

이영룡

서울특별시 광진구 면목로5길 30-8, 304호(군자동)

(72) 발명자

박찬엽

서울특별시 노원구 덕릉로 459-18, 103-1209(상계동, 미도아파트)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711139205
과제번호	2021-0-01816-001
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송혁신인재양성(R&D)
연구과제명	메타버스 자율트윈 핵심기술 연구
기여율	1/2
과제수행기관명	세종대학교 산학협력단
연구기간	2021.07.01 ~ 2021.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	1345331679
과제번호	2020R1A6A1A03038540
부처명	교육부
과제관리(전문)기관명	한국연구재단
연구사업명	이공학학술연구기반구축(R&D)
연구과제명	자율지능무인비행체연구소
기여율	1/2
과제수행기관명	세종대학교
연구기간	2021.03.01 ~ 2022.02.28

공지예외적용 : 있음

명세서

청구범위

청구항 1

업링크 Massive MIMO 시스템에서 고 신뢰도를 위한 딥러닝 기반 신호 검출 장치에 있어서,

단말기로부터 수신되는 신호를 입력받아 선형 추정(SOR기법)을 통해 추정된 신호를 출력하는 선형 추정 모듈;

상기 선형 추정모듈에서 출력된 상기 추정 신호를 입력받아 검출 신호를 비선형 추정하여 출력하는 DNN 모델 기반의 비선형 추정 모듈;

상기 비선형 추정 모듈의 출력을 상기 선형 추정 모듈의 입력으로 소정 횟수 귀환하여, 상기 선형 추정 모듈과 상기 비선형 추정 모듈이 연결된, 묶음 구성을 포함하는 신호 검출 블록 모듈에서의 연산이 소정 횟수 반복되도록 구성된 귀환 모듈;

을 포함하여 구성되며,

상기 선형 추정모듈은 SOR 기법을 적용한 연산을 반복하는 모듈이고;

상기 비선형 추정모듈은 상기 선형 추정모듈의 출력을 입력 받아, 적응적 기계 학습을 수행하는 모듈이며;

상기 SOR 기법은 상기 비선형 추정 모듈에 대한 기계 학습 변수를 출력하고 아래의 (수학식 1) 내지 (수학식 3)을 만족하는 연산을 수행하는 것;

을 특징으로 하는 신호 검출 장치.

(수학식 1)

$$\mathbf{x}_k^{(n+1)} = \mathbf{x}_k^{(n)} + \theta_k^{(n)} \mathbf{w}_k (\mathbf{w}_k L + A \text{diag})^{-1} (\mathbf{v} - A \mathbf{x}_k^{(n)})$$

(수학식 2)

$$\mathbf{r}_k = \mathbf{x}_k^{(n+1)}$$

(수학식 3)

$$\mathbf{x}_{k+1}^{(1)} = \eta_k(\mathbf{r}_k)$$

(\mathbf{v} 는 $\mathbf{v} = \mathbf{H}\mathbf{y}$, n 은 선형 추정기로 사용되는 SOR 기법의 반복횟수, k 는 선형 추정기와 비선형 추정기를 결합한 블록의 반복횟수, $\theta_k^{(n)} \in$ 는 SOR 기법의 각 반복에 적용되는 서로 다른 가중치, $\mathbf{w}_k \in$ 는 기존 SOR 기법의 완화 변수, \mathbf{r}_k 는 n 번 반복하여 얻은 SOR 기법의 결과로 k 번째 레이어의 비선형 추정 모듈로의 입력, $\eta_k(\cdot)$ 는 비선형 추정기의 연산을 기호로 표현한 것이며, $\mathbf{x}_{k+1}^{(1)}$ 는 $k+1$ 번째 레이어의 SOR 기법의 초기 벡터임)

청구항 2

삭제

청구항 3

삭제

청구항 4

삭제

청구항 5

제 1 항에 있어서,

상기 비선형 추정 모듈은 단일 입출력 구조를 가지며 아래의 (수학식 4) 내지 (수학식 7)를 만족하는 연산을 수행하는 것;

을 특징으로 하는 신호 검출 장치.

(수학식 4)

$$x_i^{(k+1)} = \zeta \circ \psi \circ \Lambda_l \circ \varphi \circ \Lambda_{l-1} \circ \varphi \circ \dots \circ \varphi \circ \Lambda_1 (r_i^{(k)})$$

(\circ 는 함수 연결을 의미하는 수학적인 기호이며, $x_i^{(k+1)}$ 는 $x_{k+1}^{(1)}$ 의 i 번째 성분을 나타내고, Ψ 는 딥러닝 알고리즘에서 주로 사용되는 활성화 함수인 Relu(Rectifier linear unit)의 성분 곱 연산의 기호)

(수학식 5)

$$\Lambda_l(r_i^{(k)}) = W_l r_i^{(k)} + b_l$$

(b_l 은 bias 벡터, $W_l \in N_o \times N_i$ 는 가중치 행렬)

(수학식 6)

$$\psi(z) = \left[\frac{\exp(z_1)}{\sum_{j=1}^{|S|} \exp(z_j)}, \dots, \frac{\exp(z_{|S|})}{\sum_{j=1}^{|S|} \exp(z_j)} \right]$$

(Ψ 는 딥러닝 활성화 함수의 소프트맥스 연산 기호, z_j 는 z 벡터의 j 번째 성분 값)

(수학식 7)

$$x_i^{(k+1)} = \zeta \circ \psi(z) = \psi(z) s = \frac{\sum_{i=1}^{|S|} s_i \exp(z_i)}{\sum_{j=1}^{|S|} \exp(z_j)}$$

(ζ 는 비선형 추정기의 마지막 연산, $s \in |S| \times 1$ 는 변조의 정상도를 표현하는 S의 모든 값을 나타내는 벡터,

s_j 는 s 벡터의 j 번째 성분 값, z_i 는 z 벡터의 i 번째 성분 값)

청구항 6

제 1 항에 있어서,

상기 적응적 기계학습은 오프라인 학습으로, 학습 알고리즘은 Adam(Adaptative moment estimation) 최적화 함수를 활용한 Tensor flow로 구현되며 최적화하려는 손실 함수는 아래의 (수학식 8) 을 만족하는 것;

을 특징으로 하는 신호 검출 장치.

(수학식 8)

$$L(\tilde{\mathbf{x}}, \tilde{\mathbf{x}}_K) = \frac{1}{M} \sum_{i=1}^M \left\| \tilde{\mathbf{x}}^{(i)} - \tilde{\mathbf{x}}_K^{(i)}(\tilde{\mathbf{y}}^{(i)}) \right\|^2$$

(L 은 손실함수, M 은 훈련 데이터의 수를 나타내고 K 는 제안된 검출기의 총 레이어 수)

청구항 7

제 6 항에 있어서,

상기 신호 검출장치의 학습 과정은 검증되는 서로 다른 채널 환경에 대해 다시 수행되며 500의 배치 크기로 2만 번 학습하며, 0.003의 learning rate와 천 번의 반복에 0.97의 decay rate가 적용되는 것;

을 특징으로 하는 신호 검출 장치.

청구항 8

업링크 Massive MIMO 시스템에서 고 신뢰도를 위한 딥러닝 기반 신호 검출 방법에 있어서,

단말기로부터 수신되는 신호를 입력받아 선형 추정(SOR기법)을 통해 추정된 신호를 출력하는 선형 추정 단계;

상기 선형 추정단계에서 출력된 상기 추정 신호를 입력받아 검출 신호를 비선형 추정하여 출력하는 비선형 추정 단계;

상기 비선형 추정 단계의의 출력을 상기 선형 추정 단계의 입력으로 소정 횟수 귀환하여, 상기 선형 추정 단계와 상기 비선형 추정 단계를 결합한 연산을 소정 횟수 반복하는 귀환 단계;를 포함하여 구성되며,

상기 선형 추정단계는 SOR 기법을 적용한 연산을 반복하는 것;이고,

상기 비선형 추정단계는 상기 선형 추정단계의 출력을 입력 받아, 적응적 기계 학습을 수행하는 것이며;

상기 SOR 기법은 상기 비선형 추정 단계에 대한 기계 학습 변수를 출력하고 아래의 (수학식 1) 내지 (수학식 3)을 만족하는 연산을 수행하는 것;

을 특징으로 하는 신호 검출 방법.

(수학식 1)

$$\mathbf{x}_k^{(n+1)} = \mathbf{x}_k^{(n)} + \theta_k^{(n)} \mathbf{w}_k (\mathbf{w}_k L + A_{diag})^{-1} (\mathbf{v} - A \mathbf{x}_k^{(n)})$$

(수학식 2)

$$\mathbf{r}_k = \mathbf{x}_k^{(n+1)}$$

(수학식 3)

$$\mathbf{x}_{k+1}^{(1)} = \eta_k(\mathbf{r}_k)$$

(\mathbf{v} 는 $\mathbf{v} = \mathbf{H}\mathbf{y}$, n 은 선형 추정단계에서 사용되는 SOR 기법의 반복횟수, k 는 선형 추정단계와 비선형 추정단계를 결합한 절차의 반복횟수, $\theta_k^{(n)} \in \mathbb{R}$ 는 SOR 기법의 각 반복에 적용되는 서로 다른 가중치, $\mathbf{w}_k \in \mathbb{R}^N$ 는 기존 SOR 기법의 완화 변수, \mathbf{r}_k^* 는 n 번 반복하여 얻은 SOR 기법의 결과로 k 번째 레이어의 비선형 추정 단계로의 입력, $\eta_k(\cdot)$

는 비선형 추정단계의 연산을 기호로 표현한 것이며, $x_{k+1}^{(1)}$ 는 $k+1$ 번째 레이어의 SOR 기법의 초기 벡터임)

청구항 9

제 8 항에 있어서,

상기 비선형 추정 단계는 단일 입출력을 수행하며, 아래의 (수학식 4) 내지 (수학식 7)를 만족하는 연산을 수행하는 것;

을 특징으로 하는 신호 검출 방법.

(수학식 4)

$$x_i^{(k+1)} = \zeta \circ \psi \circ \Lambda_l \circ \varphi \circ \Lambda_{l-1} \circ \varphi \circ \dots \circ \varphi \circ \Lambda_1 (r_i^{(k)})$$

(\circ 는 함수 연결을 의미하는 수학적 기호이며, $x_i^{(k+1)}$ 는 $x_{k+1}^{(1)}$ 의 i 번째 성분을 나타내고, Ψ 는 딥러닝 알고리즘에서 주로 사용되는 활성화 함수인 Relu(Rectifier linear unit)의 성분 곱 연산의 기호)

(수학식 5)

$$\Lambda_l(r_i^{(k)}) = W_l r_i^{(k)} + b_l$$

(b_l 은 bias 벡터, $W_l \in N_o \times N_i$ 는 가중치 행렬)

(수학식 6)

$$\psi(z) = \left[\frac{\exp(z_1)}{\sum_{j=1}^{|S|} \exp(z_j)}, \dots, \frac{\exp(z_{|S|})}{\sum_{j=1}^{|S|} \exp(z_j)} \right]$$

(Ψ 는 딥러닝 활성화 함수의 소프트맥스 연산 기호, z_j 는 z 벡터의 j 번째 성분 값)

(수학식 7)

$$x_i^{(k+1)} = \zeta \circ \psi(z) = \psi(z) \mathbf{s} = \frac{\sum_{i=1}^{|S|} s_i \exp(z_i)}{\sum_{j=1}^{|S|} \exp(z_j)}$$

(ζ 는 비선형 추정단계의 마지막 연산, $\mathbf{s} \in |S| \times 1$ 는 변조의 정상도를 표현하는 S의 모든 값을 나타내는 벡터,

s_j 는 s 벡터의 j 번째 성분 값, z_i 는 z 벡터의 i 번째 성분 값)

청구항 10

삭제

발명의 설명

기술 분야

본 발명은 massive MIMO 시스템에서 높은 신뢰도를 위한 딥러닝 기반 신호 검출 장치 및 그 방법에 관한 것으로서, 보다 상세하게는 업 링크 대용량 MIMO 시스템에서 딥러닝 알고리즘을 이용하여 오류 성능을 향상시키기 위

[0001]

한 효율적인 검출 장치 및 그 방법에 관한 것이다.

배경 기술

- [0003] 무선통신 시스템에서 다중 안테나의 기지국으로 활용되는 MIMO 시스템은 신뢰도 및 데이터 전송 효율을 향상시키는 다이버시티 이득과 독립적인 데이터의 다중 스트림을 지원하기 위한 필수적인 기술로 여겨진다. MIMO 시스템을 사용하여 기대되는 이득을 얻기 위해 송신 단으로부터 전송된 기존 데이터를 정확하게 복구해야 하며 이는 잘 설계된 신호 검출 기법을 요구한다.
- [0004] 신호 검출을 위한 MLD(Maximum Likelihood Detection) 기법은 최적의 검출 성능을 얻을 수 있으나, 매우 높은 구현 복잡도로 인하여 이를 대체하는 다양한 선형 및 비선형 검출 기법이 개발되었다. 최근 무선통신 시스템에서 인공지능을 활용하여 통신 시스템을 최적화하려는 연구가 진행되어왔으며, 이는 신호 검출 기법에 학습 가능한 변수를 적용하여 다양한 채널 환경에서 높은 정확도로 신호를 검출하기 위한 연구가 존재한다. 딥러닝 기반의 검출 기법은 크게 데이터 기반 검출 기법과 모델 기반 검출 기법으로 두 가지로 구분할 수 있다. 데이터 기반 검출 기법은 학습 알고리즘으로 얻을 수 있는 성능 향상을 최대화하기 위해 기존 수학적으로 설계된 검출 기법을 NN(Neural Network)의 구조로 대체한다. 모델 기반 검출 기법은 기존 수학적 모델을 유지하며 학습 가능한 변수를 통해 딥러닝 알고리즘의 장점을 활용한다. 반복적인 구조의 OAMP(Orthogonal approximate message passing)에 학습 가능한 변수를 포함하여 한 번의 반복을 딥러닝 네트워크의 한 레이어로 구조화한 OAMPNet(OAMP Network)의 모델 기반 검출 기법은 오프라인 학습을 통해 OAMP보다 높은 성능을 기대할 수 있다. 또한 높은 차수의 변조 방식과 공간적 상관성이 존재하는 채널에 대해서도 신호 검출의 높은 신뢰도를 얻을 수 있다. 하지만, 기지국의 안테나 수가 최소 64개 이상을 가정하는 massive MIMO 시스템에서 안테나 수에 비례하는 OAMPNet의 구현 복잡도가 매우 높아진다.

선행기술문헌

특허문헌

- [0006] (특허문헌 0001) 한국 공개특허 10-2020-0024072호
- (특허문헌 0002) 한국 공개특허 10-2010-0125593호

발명의 내용

해결하려는 과제

- [0007] 본 발명은 딥러닝 알고리즘을 활용한 검출 성능 향상을 massive MIMO 시스템으로 확장하는 것으로 보다 낮은 구현 복잡도와 높은 신뢰도를 만족하는 딥러닝 기반 검출 기법을 제공하는데 목적이 있다.

과제의 해결 수단

- [0009] 본 발명은, 업 링크 massive MIMO 시스템에서 딥러닝 알고리즘을 활용한 높은 신뢰도를 얻을 수 있는 새로운 검출 기법을 개발하는 것으로, 반복적인 구조의 선형 추정기로 SOR(Successive over relaxation)의 근사화 기법을 이용하고 비선형 추정기로는 DNN(Deep neural network) 기반의 추정기를 이용한다.
- [0010] 반복적인 구조를 저 복잡도로 설계하기 위해 선형 추정기로 SOR 기법을 고려하며, DNN 기반의 비선형 추정기는 신호 검출을 위해 지도 학습으로 최적화되어 SOR 기법과 결합된다.
- [0011] 반복적인 구조의 신호 검출 기법은 선형 추정기의 출력에서 정확한 신호를 검출하기 위해 수학적으로 최적화된 비선형 추정기를 설계한다. 하지만, 기존의 비선형 추정기는 채널의 통계적 특성을 분석하는 것으로 설계되며 채널의 통계적 특성이 예측과 환경에서 비선형 추정기를 이용한 성능 향상을 기대하기 어렵다. 또한, 선형 ZF(Zero-forcing)와 MMSE(Minimum mean square error)의 신호 검출 결과를 반복적으로 연산하는 SOR 기법의 정확도는 반복횟수에 영향을 받아 결과 값이 달라지며 다양한 반복횟수를 가지는 SOR 기법을 고려하여 비선형 추정기를 설계하는 것은 매우 복잡하다. 이는 특정 채널 환경에 적응적으로 최적화되는 딥러닝 기반 비선형 추정기를 설계하는 것으로 문제를 해결할 수 있다. DNN 기반의 비선형 추정기는 수학적 연산 없이도 채널의 통계적 특성을 데이터 기반으로 분석하여 주어진 반복횟수에 따라 반복적인 구조의 검출 기법을 최적화한다. 따

라서, 제안된 검출기는 역 행렬 연산을 요구하는 선형 추정기와 비교하여 저 복잡도로 선형 추정기를 설계하며 딥러닝 알고리즘을 통해 높은 정확도로 신호를 검출할 수 있다.

[0012] 상술한 신호 검출방법을 구현하기 위하여, 본 발명은 업링크 Massive MIMO 시스템에서 고 신뢰도를 위한 딥러닝 기반 신호 검출 장치에 있어서, 단말기로부터 수신되는 신호를 입력받아 선형 추정(SOR기법)을 통해 추정된 신호를 출력하는 선형 추정 모듈; 상기 선형 추정모듈에서 출력된 상기 추정 신호를 입력받아 검출 신호를 비선형 추정하여 출력하는 DNN 모델 기반의 비선형 추정 모듈; 상기 비선형 추정 모듈의 출력을 상기 선형 추정 모듈의 입력으로 소정 횟수 귀환하여, 상기 선형 추정 모듈과 상기 비선형 추정 모듈이 연결된, 묶음 구성을 포함하는 신호 검출 블록 모듈에서의 연산이 소정 횟수 반복되도록 구성된 귀환 모듈;을 포함하는 신호 검출 장치를 제공한다.

[0013] 이때, 상기 선형 추정모듈은 SOR 기법을 적용한 연산을 반복하는 모듈일 수 있으며, 상기 비선형 추정모듈은 상기 선형 추정모듈의 출력을 입력 받아, 적응적 기계 학습을 수행하는 모듈인 것;을 특징으로 한다.

[0014] 또한, 본 발명은 업링크 Massive MIMO 시스템에서 고 신뢰도를 위한 딥러닝 기반 신호 검출 방법에 있어서, 단말기로부터 수신되는 신호를 입력받아 선형 추정(SOR기법)을 통해 추정된 신호를 출력하는 선형 추정 단계; 상기 선형 추정단계에서 출력된 상기 추정 신호를 입력받아 검출 신호를 비선형 추정하여 출력하는 비선형 추정 단계; 상기 비선형 추정 단계의 출력을 상기 선형 추정 단계의 입력으로 소정 횟수 귀환하여, 상기 선형 추정 단계와 상기 비선형 추정 단계를 결합한 연산을 소정 횟수 반복하는 귀환 단계;를 포함하는 신호 검출 방법을 제공하며, 상기 비선형 추정단계는 상기 선형 추정단계의 출력을 입력 받아, 적응적 기계 학습을 수행하도록 구성된다.

발명의 효과

[0016] 본 발명에 따르면, 딥러닝 알고리즘을 신호 검출에 적용하는 것으로 검출 정확도를 향상시킬 수 있다. 이러한 본 발명은 채널의 통계적 특성을 기반으로 설계된 기존의 신호 검출 기법과 비교하여 서로 다른 통계적 특성을 가지는 채널 환경에 대해 적응적으로 학습하여 높은 정확도로 신호를 검출할 수 있는 이점이 있다.

도면의 간단한 설명

[0018] [도 1]은 본 발명에서 제안하는 신호 검출 기법에 대한 선형 추정기와 비선형 추정기의 반복적인 구조를 나타내며 두 가지 변조 기법에 대해 서로 다른 비선형 추정기의 DNN을 그림으로 표현한 것이다.

[도 2]는 본 발명에서 제안된 기법의 수렴율을 레이어 수에 따른 SER 성능으로 보여준다.

[도 3]는 본 발명에서 제안된 기법의 수렴율을 반복 추정 알고리즘의 반복 수에 따른 SER 성능으로 보여준다.

[도 4]은 이상적인 통계적 특성을 가지는 독립항등분포의 Rayleigh fading 채널에서 검출 성능을 비교하기 위해 제안된 검출기를 포함한 다양한 검출 기법의 수신 SNR 따른 SER 성능을 보여준다.

[도 5]는 [도 4]와 비교하여 보다 현실적인 통계적 특성을 가지는 3차원 채널에 대해 제안된 검출기를 포함한 다양한 검출 기법의 수신 SNR 따른 SER 성능을 보여준다.

발명을 실시하기 위한 구체적인 내용

[0019] 첨부한 도면을 참고로 하여 본 발명의 실시 예에 대하여 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 상세히 설명한다.

[0020] 본 발명에서는 N_b 개의 안테나를 가진 기지국에서 단일 안테나를 가진 N_u 개의 USs(User Equipments)와 동시에 송수신하는 단일 셀의 업 링크 massive MIMO 시스템을 고려한다. 복소수의 집합을 표현하기 위하여 기호 \in 를 사용하며, 기지국의 수신신호 $\mathbf{y} \in N_b \times 1$ 는 아래의 수학식으로 나타낼 수 있다.

수학식 1

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{n}$$

[0021]

[0022] 여기서, $\mathbf{H} \in \mathbb{C}^{N_b \times N_u}$ 는 채널 행렬을 나타내며, $\mathbf{n} \in \mathbb{C}^{N_b \times 1}$ 은 독립항등분포의 평균이 0이고 분산이 σ^2

인 가우시안 복소 잡음 벡터를 나타낸다. $\mathbf{x} \in \mathbb{S}^{N_u \times 1}$ 는 N_u 개의 송신 신호 벡터로 QAM(Quadrature amplitude modulation) 변조의 정상도 상의 값을 표현하는 S의 벡터로 표현되며 S의 모든 값은 정규화 된다. 본 발명에서 신호 검출을 위한 정확한 채널의 정보는 기지국에 알려져 있다고 가정한다.

[0023] 신호 검출을 위한 선형 기법은 아래의 수학식을 해결하는 것으로 massive MIMO 시스템에서 채널 경화 성질로 인해 높은 검출 성능을 얻을 수 있다.

수학식 2

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x} \in \mathbb{S}^{N_u \times 1}} \|\mathbf{y} - \mathbf{H}\mathbf{x}\| \approx \mathbf{A}^{-1} \mathbf{H}^H \mathbf{y}$$

[0024]

[0025] 여기서, 선형 검출 기법인 ZF, MMSE는 각각 $\mathbf{A} = \mathbf{H}^H \mathbf{H}$, $\mathbf{A} = \mathbf{H}^H + \sigma^2 \mathbf{I}_{N_u}$ 을 사용하며, \mathbf{I}_{N_u} 는 N_u 크기의 단위 행렬을 의미한다. 선형 MMSE 기법의 검출 성능을 역 행렬의 연산 과정 없이 달성하는 것으로 복잡도를 감소시키는 반복적인 추정 알고리즘은 A 행렬을 아래의 수학식과 같이 3가지 부분으로 나누어 연산 식에 활용한다.

수학식 3

$$\mathbf{A} = \mathbf{L} + \mathbf{A}_{\text{diag}} + \mathbf{L}^H$$

[0026]

[0027] 여기서, \mathbf{L}^H 와 \mathbf{L} 은 각각 \mathbf{A} 행렬의 대각 성분을 제외한 상 삼각 행렬과 하 삼각 행렬을 나타내며 \mathbf{A}_{diag} 는 대각 행렬을 나타낸다.

[0028] 본 발명에서 제안된 검출기를 설명하기 앞서 송 수신 신호를 복소수로 표현하는 것은 신호 검출을 위한 딥러닝 알고리즘을 구현하는데 어려움이 있다. 이를 해결하기 위해 복소수 표현에서 수학적으로 동일한 연산 결과를 얻을 수 있는 실수 표현으로 대체하며 기존보다 2배 크기의 행렬과 벡터로 표현된다. 이는 복소수 값을 가지는 임의의 열 벡터 \mathbf{a} 와 행렬 \mathbf{A} 에 대해 아래의 수학식으로 나타낼 수 있다.

수학식 4

$$\tilde{\mathbf{A}} = \begin{bmatrix} \Re(\mathbf{A}) & \Im(\mathbf{A}) \\ -\Im(\mathbf{A}) & \Re(\mathbf{A}) \end{bmatrix}, \tilde{\mathbf{a}} = \begin{bmatrix} \Re(\mathbf{a}) \\ \Im(\mathbf{a}) \end{bmatrix}$$

[0029]

[0030] 여기서, $\Re(\cdot)$ 은 복소수의 실수 값을 나타내며, $\Im(\cdot)$ 은 복소수의 허수 값을 나타낸다. 이와 같이 [수학식 1]의

실수 표현은 아래의 수학적식으로 나타낼 수 있다.

수학식 5

$$\tilde{\mathbf{y}} = \tilde{\mathbf{H}}\tilde{\mathbf{x}} + \tilde{\mathbf{n}}$$

[0031]

[0033]

본 발명에서 제안된 검출기는 3차원의 채널 환경을 수학적으로 모델링하여 생성된 무작위의 채널 행렬과 송수신 데이터를 이용하여 지도 학습의 중단 간 학습 알고리즘으로 신호를 정확하게 검출할 수 있도록 최적화된다. 제안된 검출기의 구조는 선형 추정기와 비선형 추정기의 반복적인 블록 구조를 기반으로 설계되어 반복하는 횟수에 따라 복잡도와 검출 정확도가 결정된다. 본 발명에서 제안된 반복적인 구조의 신호 검출 기법은 선형 추정기와 비선형 추정기로 나누어 설명한다.

[0034]

첫째, 반복적인 구조의 선형 추정기는 낮은 복잡도를 위해 MMSE 기반 반복 추정 알고리즘인 SOR 기법을 고려한다. 본 발명에서는 딥러닝 알고리즘을 활용하여 얻을 수 있는 성능 향상을 극대화하기 위해 학습 가능한 변수를 포함하는 SOR 기법을 제안하며 반복적인 구조의 제안된 검출 기법은 아래의 수학적식으로 나타낼 수 있다.

수학식 6

$$\mathbf{x}_k^{(n+1)} = \mathbf{x}_k^{(n)} + \theta_k^{(n)} \mathbf{w}_k (\mathbf{w}_k L + A_{diag})^{-1} (\mathbf{v} - A \mathbf{x}_k^{(n)})$$

[0035]

수학식 7

$$\mathbf{r}_k = \mathbf{x}_k^{(n+1)}$$

[0036]

수학식 8

$$\mathbf{x}_{k+1}^{(1)} = \eta_k (\mathbf{r}_k)$$

[0037]

[0039]

여기서, \mathbf{v} 는 $\mathbf{v} = \mathbf{H}^H \mathbf{y}$, n 은 선형 추정기로 사용되는 SOR 기법의 반복을 나타내며 k 는 선형 추정기와 비선형 추정기를 결합한 블록의 반복을 나타낸다. 이와 같이 제안된 검출기를 설명하기 위한 반복 용어의 혼란을 방지하기 위해 기존의 반복 용어는 SOR 기법의 반복 추정 알고리즘에 대해서만 사용한다. 이에 반복되는 구조의 한 블록은 딥러닝 네트워크의 한 레이어로 지칭한다.

[0040]

[수학식 6]은 본 발명에서 제안하는 변형된 SOR 기법의 수식으로 제안된 검출기의 k 번째 레이어에 대해 $\theta_k^{(n)} \in$ 는 SOR 기법의 각 반복에 적용되는 서로 다른 가중치를 나타내고, $\mathbf{w}_k \in$ 는 기존 SOR 기법의 완화 변수를 나타내며 두 변수 모두 검출 성능을 향상시키기 위해 학습 알고리즘을 통해 최적화된다. 기호 \in 는 실수 집합을 표현한다. 반복 추정 알고리즘에서 추정 성능을 향상시키기 위한 초기 벡터를 따로 고려하지 않으며, $\mathbf{x}_1^{(1)}$ 을 영 벡터로 설정한다. 이에 k 번째 레이어에 대한 SOR 기법의 초기 벡터 $\mathbf{x}_k^{(1)}$ 은 $k-1$ 번째 비선형 추정기의 결과값으로 사용된다.

[0041]

[수학식 7]은 n 번 반복하여 얻은 SOR 기법의 결과를 k 번째 레이어에 대한 비선형 추정기의 입력인 \mathbf{r}_k 벡터로 나

타낸다.

[0042] [수학식 8]의 $\eta_k(\cdot)$ 는 비선형 추정기의 연산을 기호로 표현한 것이며 $k+1$ 번째 레이어의 SOR 기법의 초기 벡터 $x_{k+1}^{(1)}$ 을 도출한다.

[0043] 둘째, 본 발명에서는 [수학식 8]의 비선형 추정기에 대한 연산을 단일 입출력 구조의 DNN로 설계하며 비선형 추정기의 r^k 벡터의 i 번째 성분 $r_i^{(k)}$ 에 대하여 아래의 수학식으로 나타낼 수 있다.

수학식 9

[0044]
$$x_i^{(k+1)} = \zeta \circ \psi \circ \Lambda_l \circ \varphi \circ \Lambda_{l-1} \circ \varphi \circ \dots \circ \varphi \circ \Lambda_1 (r_i^{(k)})$$

[0045] 여기서, \circ 는 함수 연결을 의미하는 수학적 기호이며, $x_i^{(k+1)}$ 는 $x_{k+1}^{(1)}$ 의 i 번째 성분을 나타내고, Φ 는 딥러닝 알고리즘에서 주로 사용되는 활성화 함수인 Relu(Rectifier linear unit)의 성분 곱 연산의 기호를 나타낸다. 이에 Λ_l 는 N_o 의 출력 크기와 N_i 의 입력 크기를 가지는 DNN의 l 번째 FC(Fully connected layer)를 나타내며 $W_l \in N_o \times N_i$ 의 가중치 행렬과 $b_l \in N_o$ 의 bias 벡터의 선형대수의 연산으로 아래의 수학식으로 나타낼 수 있다.

수학식 10

[0046]
$$\Lambda_l(r_i^{(k)}) = W_l r_i^{(k)} + b_l$$

[0047] (b_l 은 bias를 의미함)

[0049] S 집합의 성분 개수를 $|S|$ 라 할 때, 제안된 비선형 추정기를 구성하는 DNN은 마지막 FC에 대해 $|S|$ 의 출력 크기를 가지며, $z \in |S|$ 를 출력 값을 나타내는 벡터라 할 때 수학식 [9]의 딥러닝 활성화 함수의 소프트맥스 연산 기호 Ψ 를 아래의 수학식으로 나타낼 수 있다.

수학식 11

[0050]
$$\psi(z) = \left[\frac{\exp(z_1)}{\sum_{j=1}^{|S|} \exp(z_j)}, \dots, \frac{\exp(z_{|S|})}{\sum_{j=1}^{|S|} \exp(z_j)} \right]$$

[0051] 여기서, z_j 는 z 벡터의 j 번째 성분 값을 나타낸다. 이에 비선형 추정기의 마지막 연산을 나타내는 ζ 는 단일 입력 값에 대한 단일 출력 값을 얻기 위해 본 발명에서 아래와 같은 수학식으로 계산하는 것을 제안한다.

수학식 12

$$x_i^{(k+1)} = \zeta \circ \psi(\mathbf{z}) = \psi(\mathbf{z})\mathbf{s} = \frac{\sum_{i=1}^{|\mathbf{s}|} s_i \exp(z_i)}{\sum_{j=1}^{|\mathbf{s}|} \exp(z_j)}$$

[0052]

[0053] 여기서, $\mathbf{s} \in |\mathbf{s}| \times \mathbf{1}$ 는 변조의 성상도를 표현하는 S의 모든 값을 나타내는 벡터이며, s_j 는 s 벡터의 j 번째 성분 값, z_i 는 z 벡터의 i번째 성분 값을 나타낸다.

[0054] 비선형 추정기로 제안된 DNN의 크기는 제안된 검출기의 계산 복잡도를 결정하며 적절한 크기의 DNN을 설계하는 것이 중요하다. 본 발명에서는 16QAM과 64QAM의 두 변조에 대해 각각 다른 크기의 DNN을 제안하며 16QAM 변조에 대해 1×30 의 첫번째 FC와 30×20 의 두번째 FC를 사용한다. 이에 64QAM 변조에는 30×30 의 FC를 추가하는 것으로 반복적인 구조의 검출기를 표현하는 [도 1]에서 16QAM과 64QAM을 비교하여 비선형 추정기에 대해 다른 깊이의 FC를 가지는 DNN를 표현한다.

[0055] 기존 반복적인 구조의 비선형 추정기는 선형 추정기의 결과로부터 높은 정확도로 신호를 검출하기 위해 수학적으로 설계되었다. 하지만, SOR 기법은 반복 수에 따라 달라지는 결과 값에 대해 수학적으로 비선형 추정기를 설계하는 것은 매우 어렵다. 본 발명에서 제안하는 DNN 기반의 비선형 추정기는 데이터를 기반으로 최적화되어 SOR 기법과 결합될 수 있으며 학습된 채널 환경에 대해 높은 정확도로 신호를 검출할 수 있다.

[0056] 본 발명에서 제안된 검출기는 오프라인 학습을 통해 최적화된다. 학습 알고리즘은 Adam(Adaptative moment estimation) 최적화 함수를 활용한 Tensor flow로 구현되며 최적화하려는 손실 함수는 아래의 수학식으로 나타낼 수 있다.

수학식 13

$$L(\tilde{\mathbf{x}}, \tilde{\mathbf{x}}_K) = \frac{1}{M} \sum_{i=1}^M \left\| \tilde{\mathbf{x}}^{(i)} - \tilde{\mathbf{x}}_K^{(i)}(\tilde{\mathbf{y}}^{(i)}) \right\|^2$$

[0057]

[0058] 여기서, M은 훈련 데이터의 수를 나타내고 K는 제안된 검출기의 총 레이어 수를 나타내며 모든 값은 [수학식 4]의 실수 표현으로 변환되어 사용된다. 학습 알고리즘을 위한 데이터 집합 $(\tilde{\mathbf{x}}, \tilde{\mathbf{y}})$ 은 검증되어지는 수신 SNR(Signal to noise ratio) 범위 안에서 [수학식 5]의 변조된 신호 벡터 $\tilde{\mathbf{x}}$, 채널행렬 $\tilde{\mathbf{H}}$, 그리고 수신 잡음 벡터 $\tilde{\mathbf{n}}$ 을 통해 무작위로 생성된다. 본 발명에서 제안된 검출기를 검증하기 위한 성능 지표로는 수신 SNR에 따른 SER(Symbol error rate)를 사용하며 기지국의 수신 SNR은 아래의 수학식으로 나타낼 수 있다.

수학식 14

$$\text{SNR}(\text{dB}) = 10 \log \left(\frac{\mathbb{E} \left[\|\mathbf{H}\mathbf{x}\|^2 \right]}{\mathbb{E} \left[\|\mathbf{n}\|^2 \right]} \right)$$

[0059]

[0060] 제안된 검출기의 학습 과정은 검증되는 서로 다른 채널 환경에 대해 다시 수행되며 500의 배치 크기로 2만번 학습한다. 이에 0.003의 learning rate과 천 번의 반복에 0.97의 decay rate이 적용된다.

[0061] 본 발명은 제안된 검출기의 성능 비교에 대해 ML 성능을 보다 낮은 복잡도로 달성할 수 있는 트리 구조의

QRDM(QR decomposition-based M) 검출 기법으로 최적의 검출 성능 기준치를 보여주고 선형 기법의 검출 성능을 비교하기 위해 선형 MMSE 기법의 성능을 제공한다. 또한 이상적인 통계적 특성을 가지는 Rayleigh fading 채널에 대해서는 MMSE 기반 DFE(Decision feedback equalizer)와 AMP의 검출 성능을 추가적으로 비교한다. 본 발명에서 딥러닝 알고리즘으로 검출 성능을 향상시키는 것과 같은 맥락에서 딥러닝 알고리즘을 활용한 30개의 레이어를 가진 DetNet(Detection Network)과 10개의 레이어를 가진 OAMPNet의 두 가지 검출 기법의 성능 비교는 제안된 검출기의 우수성을 검증하기 위해 제공된다.

[0062] 본 발명은 이상적인 Rayleigh fading 채널 환경 이외에도 3차원의 채널 환경을 수학적으로 모델링하여 제안된 검출기를 검증한다. 3차원 채널의 모델링은 3GPP 표준의 Release 16 TR(Technical report) 38.901 V16.1.0을 참고하였으며 본 발명은 채널의 상관도와 반비례하는 ASD(Angular spread deviation)로 채널의 공간적 상관도를 조절한다. 또한 64개의 안테나에 대해 ULA(Uniform linear array)와 8×8 의 UPA(Uniform planar array) 두 가지의 기지국 안테나 배치를 가정한다.

[0063] 제안된 검출기의 수렴율은 SOR 기법의 반복횟수에 따라 달라진다. 본 발명에서는 단일 ULA 기지국의 10° ASD를 가정하여 채널의 공간적 상관도가 높은 3차원 채널에 대해 수렴율을 분석한다. 제안된 검출기의 학습 알고리즘은 16QAM에서는 6에서 16dB SNR 범위에서 64QAM에서는 12에서 22dB SNR 범위에서 무작위로 생성된 데이터로 수행된다.

[0064] [도 2]는 제안된 검출기의 SER 성능을 16QAM 변조에 대해 레이어의 수에 따라 보여준다. 반복 수가 수렴율에 미치는 영향을 평가하기 위해 1에서 5까지의 반복을 가지는 제안된 검출기를 제시한다. 1번의 반복을 가진 제안된 검출기는 5개의 레이어 이상에서 매우 낮은 수렴율을 보여준다. 이는 채널 상관도가 높은 채널에서 1번의 반복이 제안된 검출기가 얻을 수 있는 최적의 성능을 달성하는데 매우 비효율적이라는 것을 의미한다. 반면에 5번의 반복을 사용한 제안된 검출기는 5개의 레이어에 SER 성능의 최적에 수렴하는 것을 확인할 수 있다.

[0065] [도 3]은 제안된 검출기의 SER 성능을 64QAM 변조에 대해 반복 수에 따라 보여준다. 이 결과는 반복 수에 따라 달성할 수 있는 제안된 검출기 성능의 최대 한계를 확인하기 위해 1에서 5까지의 레이어를 가지는 제안된 검출기를 제시한다. 단일 레이어의 제안된 검출기는 반복수가 증가함에 따라 낮은 SER 성능을 보여준다. 이는 제안된 검출기의 적절한 반복수가 선택되어야 함을 의미한다. 제안된 검출기의 성능 한계는 레이어의 수가 증가함에 따라 점차 감소하고 제안된 검출기는 4에서 5의 레이어에 대해 최대 수렴가능한 성능을 얻을 수 있다. [도 2]와 [도 3]의 결과는 제안된 검출기가 높은 변조 차수와 상관 채널에 대해서도 반복 수와 레이어 수를 조절하여 높은 성능을 달성할 수 있다는 사실을 보여준다.


[0066] 5개의 레이어를 가진 제안된 검출기와 다양한 검출 기법의 성능 비교는 16QAM과 64QAM 그리고 16개의 UE를 가정하는 Rayleigh fading 채널과 단일 UPA 기지국이 존재하는 30° ASD의 3차원 채널에 대해 제시된다.

[0067] [도 4]는 Rayleigh fading 채널에서 성능 비교가 수행되며 16QAM에서는 1번의 반복을 64QAM에서는 3번의 반복을 가지는 제안된 검출기의 성능을 보여준다. Rayleigh fading 채널은 SOR 기법과 같은 반복 추정 알고리즘의 추정 성능에 영향을 주는 채널 경화 특성에 이상적이기 때문에 적은 반복으로도 높은 성능을 달성할 수 있다. 제안된 검출기가 ML 성능을 제시하는 QRDM의 SER과 거의 일치함을 보여준다. 이는 제안된 검출기의 DNN 기반 비선형 추정기가 SOR 기법과 성공적으로 결합되었다는 사실을 증명한다. 이외 64QAM의 DetNet을 제외한 나머지 기법들도 제시된 SNR 범위에서 2dB SNR 차이 안으로 QRDM의 성능을 달성하는 것을 보여준다.

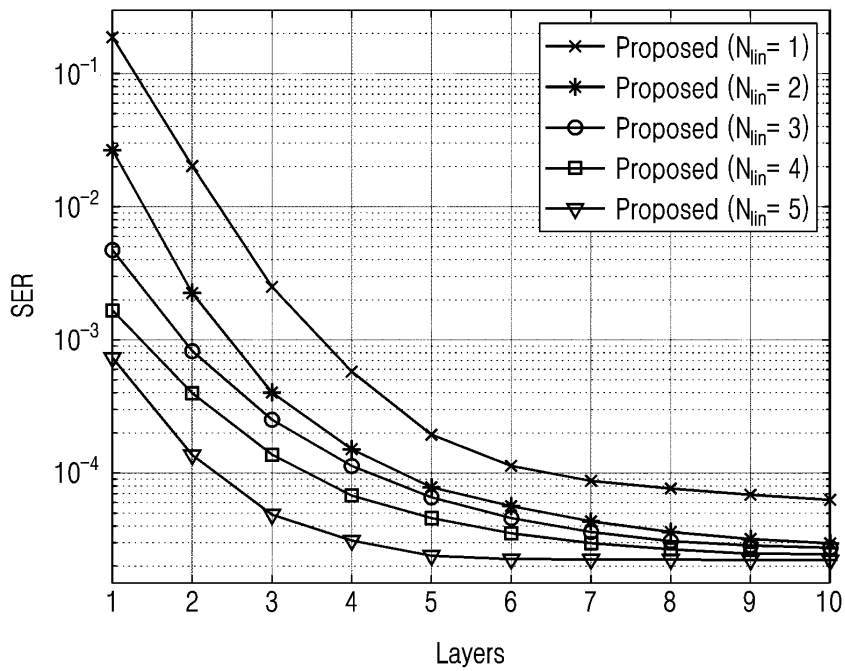
[0068] [도 5]는 3차원 채널에 대해 수렴율 분석을 기반으로 5번의 반복 수를 가지는 제안된 검출기의 성능을 보여주며 딥러닝 알고리즘 기반 DetNet과 OAMPNet의 주된 성능 비교를 제시한다. DetNet은 공간적 상관도가 높은 채널과 높은 변조 차수에 대해 성능이 매우 낮은 것을 확인할 수 있으며 16QAM의 16dB SNR에 대해 선형 MMSE 기법보다도 SER 성능이 낮은 것을 볼 수 있다. 제안된 검출기는 OAMPNet 보다 SER 성능이 높으며 약 1dB SNR 범위에서 QRDM의 성능을 달성할 수 있다. 이는 제안된 검출기는 높은 공간적 상관도와 변조 차수에 대해 강건성을 가지며 높은 성능을 제공하는 것을 알 수 있다. 이러한 결과는 제안된 검출기가 더 적은 레이어의 낮은 복잡도로 OAMPNet 보다 높은 성능을 달성할 수 있다는 것을 보여준다.

도면

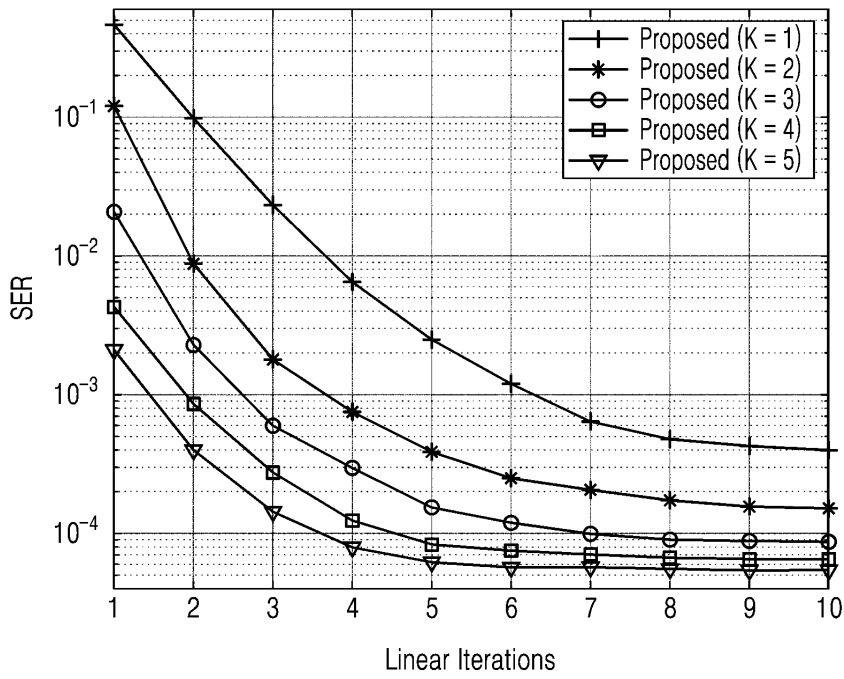
도면1



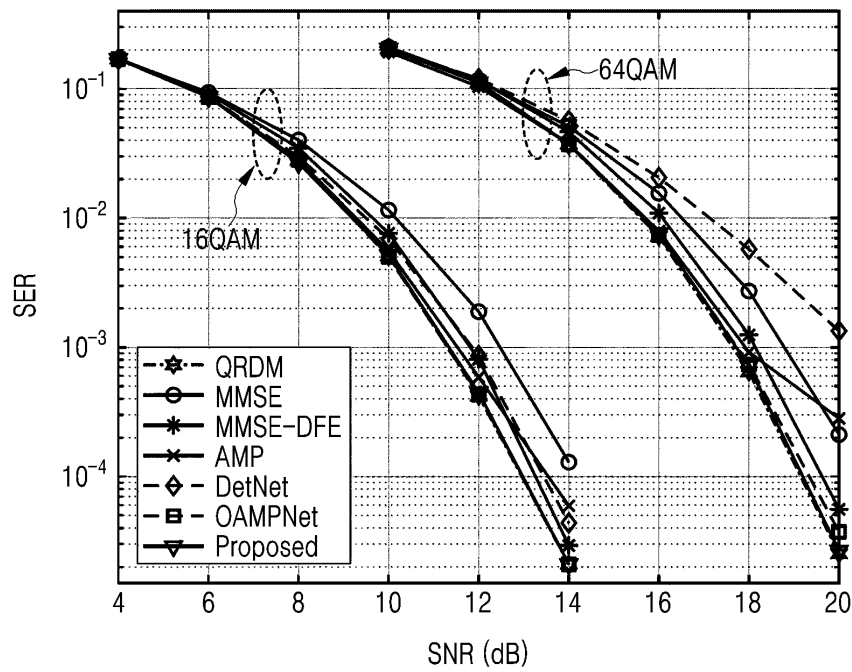
도면2



도면3



도면4



도면5

