(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0106987
(43) 공개일자 2024년07월08일

(51) 국제특허분류(Int. Cl.)
H04B 7/0417 (2017.01) *G06N 3/08* (2023.01)
H04B 7/06 (2017.01) *H04B 7/155* (2006.01)
(52) CPC특허분류
H04B 7/0417 (2013.01)
G06N 3/08 (2023.01)
(21) 출원번호 10-2023-0188084
(22) 출원일자 2023년12월21일
심사청구일자 2023년12월21일
(30) 우선권주장
1020220188935 2022년12월29일 대한민국(KR)

(71) 출원인
국립한밭대학교 산학협력단
대전광역시 유성구 동서대로 125 (덕명동)
(72) 발명자
콰두오 보아텡 오포리 아만포
대전광역시 유성구 동서대로 158-11, A동 103호(덕명동, HB학사)
이경재
대전광역시 유성구 노은동로 111, 1010동 701호(노은동, 열매마을10단지아파트)
(74) 대리인
이은철, 이우영

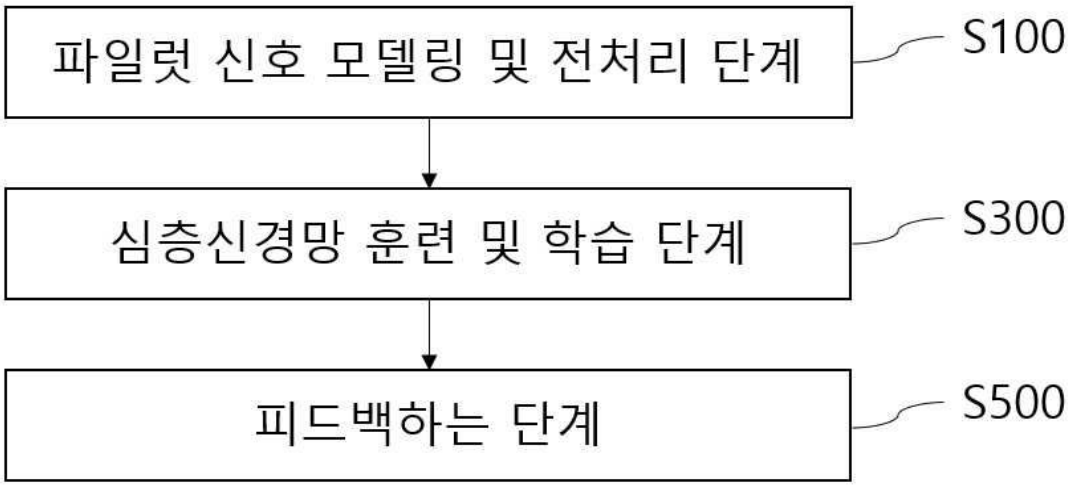
전체 청구항 수 : 총 6 항

(54) 발명의 명칭 **심화학습 기반 다중입출력 중계 전송 방법 및 시스템**

(57) 요 약

본 발명은, 파일럿 신호(pilot signal)를 소스 노드에서 릴레이 노드로 전송한 다음 릴레이 노드에서 목적지 노드로 전송하는 심화학습 기반 다중입출력 중계 전송 방법에 있어서, 수신된 신호를 수집하여 데이터 세트를 형성하는 파일럿 신호 모델링 및 전처리 단계; 전처리된 상기 데이터 세트를 심층신경망(DNN)에 입력하여 학습시키는 심층신경망(DNN) 훈련 및 학습 단계; 및 심층신경망(DNN)에서 출력된 유효 채널 이득을 최대화하는 프리코딩 행렬 인덱스(PMI)를 이전 노드로 피드백하는 단계;를 포함하는 것을 일 특징으로 한다.

대 표 도 - 도2



(52) CPC특허분류
H04B 7/0639 (2013.01)
H04B 7/0663 (2013.01)
H04B 7/155 (2020.08)

이 발명을 지원한 국가연구개발사업
과제고유번호 1711174097
과제번호 00156212
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 정보통신방송혁신인재양성(R&D)
연구과제명 ICT혁신인재4.0 (한밭대학교)
기 여 율 1/2
과제수행기관명 한밭대학교산학협력단
연구기간 2022.07.01 ~ 2022.12.31
이 발명을 지원한 국가연구개발사업
과제고유번호 1711152620
과제번호 2018-0-00812-005
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 방송통신산업기술개발
연구과제명 IoT 무선전력전송 인지무선통신을 위한 사용자중심 분산 Massive MIMO 시스템 연구
기 여 율 1/2
과제수행기관명 한밭대학교산학협력단
연구기간 2022.01.01 ~ 2022.12.31

명 세 서

청구범위

청구항 1

파일럿 신호(pilot signal)를 소스 노드에서 릴레이 노드로 전송한 다음 릴레이 노드에서 목적지 노드로 전송하는 심화학습 기반 다중입출력 중계 전송 방법에 있어서,

수신된 신호를 수집하여 데이터 세트를 형성하는 파일럿 신호 모델링 및 전처리 단계;

전처리된 상기 데이터 세트를 심층신경망(DNN)에 입력하여 학습시키는 심층신경망(DNN) 훈련 및 학습 단계; 및

심층신경망(DNN)에서 출력된 유효 채널 이득을 최대화하는 프리코딩 행렬 인덱스(PMI)를 이전 노드로 피드백하는 단계;

를 포함하는, 심화학습 기반 다중입출력 중계 전송 방법.

청구항 2

제1항에 있어서,

상기 파일럿 신호 모델링 및 전처리 단계는,

상기 릴레이 노드에서 수신된 신호(y_l^{train})의 인스턴스를 행렬($\mathbf{Y}^{train}$) 로 집계하여 데이터 세트를 형성하는 것인, 방법.

청구항 3

제1항에 있어서,

상기 파일럿 신호 모델링 및 전처리 단계는,

형성된 데이터 세트를 벡터화 함수를 사용하여 행렬에서 벡터 형식으로 변환하고, 변환된 데이터 세트를 실수 부분과 허수 부분으로 분할하는 전처리를 수행하는 것인, 방법.

청구항 4

제1항에 있어서,

상기 심층신경망(DNN)은 하나 이상의 레이어(layer)로 구성되고, 상기 하나 이상의 레이어 중 적어도 어느 하나는, 고밀도 입력 레이어(input layer), 배치 노멀라이저(batch normalizer) 및 활성화 함수(activation function)를 구비하는 것인, 방법.

청구항 5

제1항에 있어서,

하기 수학식 12를 이용하여 [-1,1]의 통일성 범위 사이에서 상기 심층신경망(SNN)의 출력을 제한하는 이진화 단계를 더 포함하는 것인, 방법.

[수학식 12]

$$\tanh(\zeta) = \frac{\exp(2\zeta) + 1}{\exp(2\zeta) - 1}$$

청구항 6

파일럿 신호(pilot signal)를 소스 노드에서 릴레이 노드로 전송한 다음 릴레이 노드에서 목적지 노드로 전송하는 심화학습 기반 다중입출력 중계 전송 시스템에 있어서,

수신된 신호를 수집하여 데이터 세트를 형성하는 파일럿 신호 모델링 및 전처리부;

전처리된 상기 데이터 세트를 심층신경망(DNN)에 입력하여 학습시키는 심층신경망(DNN) 학습부; 및

심층신경망(DNN)에서 출력된 유효 채널 이득을 최대화하는 프리코딩 행렬 인덱스(PMI)를 이전 노드로 피드백하는 피드백부;

를 포함하는, 심화학습 기반 다중입출력 중계 전송 시스템.

발명의 설명

기 술 분 야

[0001] 본 발명은 심화학습 기반 다중입출력 중계 전송 방법 및 시스템에 관한 것으로서, 특히 심층 신경망(DNN)이 기존 필터를 사용하여 훈련 데이터를 수집하고 양자화 및 피드백 문제를 공동으로 해결하는 하이브리드 딥러닝(DL)에 의존하는 제한된 피드백 릴레이 시스템의 구현을 위한 심화학습 기반 다중입출력 중계 전송 방법에 관한 것이다.

배 경 기 술

[0002] 제한된 피드백 시스템(Limited feedback system)은 주파수 분할 이중화(frequency-division duplexing, FDD) 하에서 폐쇄 루프 통신의 성능을 개선하기 위한 목적으로 널리 연구되어 왔다. 일반적인 모델은 파일럿 신호(pilot signal)를 통한 채널 추정(channel estimation)과 결과적으로 양자화(quantization) 및 추정된 채널의 코드북 파생 인덱스를 연속 전송에 사용하기 위해 송신기로 피드백하는 두 단계의 통신을 채택한다.

[0003] 폐쇄 루프 시스템에서 코드북(codebook)의 중요한 역할을 인식한 제한된 피드백 시스템에 대한 연구는 채널 추정, 양자화 및 인덱스 피드백 체인을 최적화하기 위해 코드북의 설계를 개선하는 데 중점을 두었다. 그래스마니안(Grassmanian), 로이드(Lloyd), 이산 푸리에 변환(Discrete Fourier Transform, DFT) 기반 코드북 설계는 이러한 시도의 결과물 중 하나이다. 여러 연구에서 목표로 삼은 최적화 매개변수 중 가장 중요한 것은 화음 거리 기준(chordal distance criterion)이었다.

[0004] 제한된 피드백 통신을 용이하게 하기 위해 그래스마니안(Grassmanian) 코드북의 다중 입력 다중 출력(multiple-input multiple-output, MIMO) 지점 간 시스템 설계를 사용하고 있다. 이 코드북의 핵심은 채널 상태 정보(channel state information, CSI) 오류를 추정하는 문제이다. 그러나 코드북 양자화와 함께 이 문제를 해결하는 것은 매우 비선형적이다.

[0005] 전송 범위를 확장하기 위해 MIMO 시스템은 릴레이를 사용한다. 예를 들어, Wiener 필터 인사이트에 의존하는 MIMO 릴레이 시스템은 최소평균제곱오차(minimum mean squared error MMSE)를 최적화하기 위해 기존의 단일값 분해(singular value decomposition, SVD) 기반 접근 방식에 대한 경쟁자로서 새로운 설계 전략을 제시한다. 한 연구에서는 채널 추정 및 양자화 시도에서 빔포밍 위상 파라미터(beamforming phase parameter)를 계산하기 위해 공간 보간(spatial interpolation) 방법을 사용하는 것을 조사했다.

[0006] 그러나 위에서 언급한 시스템에서도 동일한 비볼록 문제(non-convex problem)가 존재합니다. 채널 양자화(channel quantization) 및 채널 추정(channel estimation)은 각각 독립적으로 해결되므로 차선책이다. 또 다른 문제는 MIMO 릴레이 시스템이 단일 피드백 링크(single feedback link)만 사용한다는 것이다. 이 링크는 목적지-릴레이 또는 목적지-소스 형태로 존재한다. 릴레이 간(다중 릴레이의 경우) 또는 송신기-릴레이 간 링크에는 피드백 채널이 고려되지 않는다. 따라서 무시된 링크에서는 채널 추정과 양자화가 모두 수행되지 않는다. 따라서, 심층 신경망(deep neural network, DNN) 또는 심층 학습(deep learning, DL)을 사용하여 MIMO 릴레이 피드백 시스템의 공동 솔루션을 시도하려 하고 있다. 그러나 현재까지 진행된 연구에서는 이중 홉 피드백 경로(dual-hop feedback path)를 가진 릴레이에 대한 공동 채널 추정 문제를 고려하지 않고 있다는 문제점이 있다.

[0007] 위에서 언급한 문제를 해결하기 위해 본 발명에서는 DNN을 이용한 MIMO 제한 피드백 릴레이 시스템을 제안한다. 특히, DNN을 사용하는 MIMO 릴레이 시스템의 듀얼 홉 제한 피드백 체인에서 공동 채널 추정 및 양자화 솔루션을 사용하는 시스템에 초점을 둔다. 결과적으로, 본 발명에서 제안하는 시스템은 채널이 끊임없이 변화하고 완벽한 CSI를 전제로 하는 것이 비현실적인 보다 동적인 실제 상황에서 더 잘 반응할 것으로 기대한다.

발명의 내용

해결하려는 과제

[0008] 본 발명은 DNN을 통한 AF MIMO 중계 시스템에서 양자화 및 제한된 피드백 단계에 대한 공동 솔루션을 도출할 수 있는 심화학습 기반 다중입출력 중계 전송 방법을 제공하는 것을 일 목적으로 한다.

[0009] 또한, 본 발명은 제한된 피드백 MIMO 중계 시스템에서 듀얼 홉 구동 DNN 체인을 도입하는 것을 다른 목적으로 한다.

과제의 해결 수단

[0010] 상기 목적을 달성하기 위하여 본 발명은, 파일럿 신호(pilot signal)를 소스 노드에서 릴레이 노드로 전송한 다음 릴레이 노드에서 목적지 노드로 전송하는 심화학습 기반 다중입출력 중계 전송 방법에 있어서, 수신된 신호를 수집하여 데이터 세트를 형성하는 파일럿 신호 모델링 및 전처리 단계; 전처리된 상기 데이터 세트를 심층신경망(DNN)에 입력하여 학습시키는 심층신경망(DNN) 훈련 및 학습 단계; 및 심층신경망(DNN)에서 출력된 유효 채널 이득을 최대화하는 프리코딩 행렬 인덱스(PMI)를 이전 노드로 피드백하는 단계;를 포함하는 것을 일 특징으로 한다.

[0011] 바람직하게는, 상기 파일럿 신호 모델링 및 전처리 단계는, 상기 릴레이 노드에서 수신된 신호(y_l^{train})의 인스턴스를 행렬($\mathbf{Y}^{train}$) 로 집계하여 데이터 세트를 형성할 수 있다.

[0012] 바람직하게는, 상기 파일럿 신호 모델링 및 전처리 단계는, 형성된 데이터 세트를 벡터화 함수를 사용하여 행렬에서 벡터 형식으로 변환하고, 변환된 데이터 세트를 실수 부분과 허수 부분으로 분할하는 전처리를 수행할 수 있다.

[0013] 바람직하게는, 상기 심층신경망(DNN)은 하나 이상의 레이어(layer)로 구성되고, 상기 하나 이상의 레이어 중 적어도 어느 하나는, 고밀도 입력 레이어(input layer), 배치 노멀라이저(batch normalizer) 및 활성화 함수(activation function)를 구비할 수 있다.

[0014] 바람직하게는, 하기 수학식 12를 이용하여 [-1,1]의 통일성 범위 사이에서 상기 심층신경망(SNN)의 출력을 제한하는 이진화 단계를 더 포함할 수 있다.

[0015] [수학식 12]

[0016] $$\tanh(\zeta) = \frac{\exp(2\zeta) + 1}{\exp(2\zeta) - 1}$$

[0017] 또한 본 발명은, 파일럿 신호(pilot signal)를 소스 노드에서 릴레이 노드로 전송한 다음 릴레이 노드에서 목적지 노드로 전송하는 심화학습 기반 다중입출력 중계 전송 시스템에 있어서, 수신된 신호를 수집하여 데이터 세트를 형성하는 파일럿 신호 모델링 및 전처리부; 전처리된 상기 데이터 세트를 심층신경망(DNN)에 입력하여 학습시키는 심층신경망(DNN) 학습부; 및 심층신경망(DNN)에서 출력된 유효 채널 이득을 최대화하는 프리코딩 행렬 인덱스(PMI)를 이전 노드로 피드백하는 피드백부;를 포함하는 것을 다른 특징으로 한다.

발명의 효과

[0018] 본 발명은 AF MIMO 중계 시스템에서 양자화 및 제한된 피드백 단계에 대한 공동 솔루션을 DNN 기반으로 도출하여, 유효 채널 이득을 극대화함으로써 심볼 오류율(SER)을 줄일 수 있다는 이점이 있다.

도면의 간단한 설명

[0019] 도 1은 본 발명의 실시예에 따른 듀얼 홉 제한 피드백 체인을 통해 통신하는 시스템을 나타낸다.

도 2는 본 발명의 실시예에 따른 심화학습 기반 다중입출력 중계 전송 방법의 흐름도를 나타낸다.

도 3는 안테나의 수에 따른 SNR에 대한 SER의 관계를 나타내는 그래프이다.

도 4는 t-value에 따른 SNR에 대한 SER의 관계를 나타내는 그래프이다.

도 5는 본 발명의 실시예에 따른 심화학습 기반 다중입출력 중계 전송 시스템의 구성도를 나타낸다.

발명을 실시하기 위한 구체적인 내용

[0020] 이하, 첨부된 도면들에 기재된 내용들을 참조하여 본 발명을 상세히 설명한다. 다만, 본 발명이 예시적 실시 예들에 의해 제한되거나 한정되는 것은 아니다. 각 도면에 제시된 동일 참조부호는 실질적으로 동일한 기능을 수행하는 부재를 나타낸다.

[0021] 본 발명의 목적 및 효과는 하기의 설명에 의해서 자연스럽게 이해되거나 보다 분명해질 수 있으며, 하기의 기재만으로 본 발명의 목적 및 효과가 제한되는 것은 아니다. 또한, 본 발명을 설명함에 있어서 본 발명과 관련된 공지 기술에 대한 구체적인 설명이, 본 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명을 생략하기로 한다.

[0022] 본 발명에서 사용하는 용어는 단지 특정한 실시예들을 설명하기 위해 사용된 것으로, 본 발명을 한정하려는 의도가 아니다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 출원에서, "포함하다" 또는 "가지다" 등의 용어는 발명의 설명에 기재된 특징, 숫자, 단계, 동작, 구성 요소, 부분품 또는 이들을 조합한 것이 존재함을 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성 요소, 부분품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.

[0023] 제1, 제2 등의 용어는 다양한 구성 요소들을 설명하는데 사용될 수 있지만, 상기 구성 요소들은 상기 용어들에 의해 한정되어서는 안된다. 상기 용어들은 하나의 구성 요소를 다른 구성 요소로부터 구별하는 목적으로만 사용된다. 예를 들어, 본 발명의 권리 범위를 벗어나지 않으면서 제1 구성 요소는 제2 구성 요소로 명명될 수 있고, 유사하게 제2 구성 요소도 제1 구성 요소로 명명될 수 있다.

[0024] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 갖는다. 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥상 가지는 의미와 일치하는 의미를 갖는 것으로 해석되어야 하며, 본 발명에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.

[0025] 구성 요소를 해석함에 있어서, 별도의 명시적 기재가 없더라도 오차 범위를 포함하는 것으로 해석한다. 시간 관계에 대한 설명일 경우, 예를 들어, '~후에', '~에 이어서', '~다음에', '~전에' 등으로 시간 적 선후관계가 설명되는 경우, '바로' 또는 '직접'이 사용되지 않는 이상 연속적이지 않은 경우도 포함한다.

[0026] $\mathbf{A} \in \mathbb{C}^{N \times M}$는 차원 N에 M을 곱한 행렬을 나타낸다. $\mathrm{tr}\{\mathbf{A}\}$ 및 $\mathbf{A}^{\dagger}$는 각각 행렬 A의 트레이스(trace) 및 공액 전치(conjugate transpose)를 나타낸다. 행렬 $\mathbf{A}$와 벡터 a의 추정치는 각각 $\hat{\mathbf{A}}$와 $\hat{\mathbf{a}}$로 표시된다. 또한, $|\mathbf{A}|$와 $||\mathbf{A}||$는 각각 행렬 A의 행렬식 연산(determinant operation)과 행렬의 놈(norm)이다. $\mathbf{I}_N$은 $N \times N$ 단위행렬을 나타낸다. $n \sim \mathcal{CN}(0, \delta^2)$은 평균이 0이고 분산이 δ^2인 원형 대칭 복소 가우스 확률 변수 n을 나타낸다. $\mathbb{E}_X[f(X)]$는 무작위 변수 X에 대한 기대 연산(expectation operation)을 나타낸다. $\Re\{\cdot\}$와 $\Im\{\cdot\}$는 각각 실수 함수와 허수 함수에 해당하고, $\mathrm{vec}(\cdot)$와 $\mathrm{diag}(\cdot)$는 각각 벡터화 및 대각선화 연산을 반환한다.

[0027] 이하, 첨부한 도면들을 참조하여 본 발명의 기술적 구성을 상세하게 설명한다.

[0028] 도 1은 본 발명의 실시예에 따른 듀얼 홉 제한 피드백 체인을 통해 통신하는 시스템을 나타낸다. 도 1을 참조하면, 기존 접근 방식은 소스 노드(S)가 릴레이 노드(R)를 통해 목적지 노드(D)와 통신을 수행한다. 기존 접근 방식의 1단계(phase 1)는 모든 데이터 전송으로 구성되며, 기존 접근 방식의 2단계(phase 2)는 모든 피드백 프로세스가 해당된다. 소스 노드, 릴레이 노드, 및 목적지 노드에는 각각 N_t, N_r, 및 N_d 개의 안테나가 장착될 수 있다. 1단계(phase 1)에서 입력 신호 x의 첫 번째 전송 시퀀스, 즉 $\mathbb{E}[\mathbf{x}\mathbf{x}^{\dagger}] = \sigma_x \mathbf{I}_{N_s}$는 $\mathbf{F}_T$로 프리코딩되어 빔포밍된 심볼 s($\mathbf{s} = \mathbf{F}_T\mathbf{x} \in \mathbb{C}^{N_t \times 1}$)를 제공할 수 있다.

[0029] 결과 신호(resulting signal)는 S-to-R 채널 $\mathbf{H}_{RT} \in \mathbb{C}^{N_r \times N_t}$을 통해 전송될 수 있다. 릴레이 노드에서는, 선형 최소 평균 제곱 오차(minimum mean square error, MMSE) 수신 필터 L이 신호를 수신하는데 사용될 수 있다. 그런 다음 추정 채널(estimated channel) $\hat{\mathbf{H}}_{RT}$의 최적 프리코딩 행렬(optimal precoding matrix, PMI) 인덱스가

연속 전송을 위해 송신기로 다시 피드백될 수 있다.

[0030] 수신 시, 해당 전송은 $\mathbf{B}$로 릴레이 프리코딩되고, 그 후 결과 신호는 증폭되어 채널 $\mathbf{H}_{DR} \in \mathbb{C}^{N_d \times N_r}$를 통해 행렬 $\mathbf{K}_D$와 함께 신호를 수신하는 목적지 노드(D)로 전달될 수 있다. 목적지 노드(D)에서 채널 추정이 다시 수행되어 코드북에서 $\hat{\mathbf{H}}_{DR}$의 인덱스를 획득할 수 있고, 상기 인덱스는 연속 전송을 위해 릴레이로 전송될 수 있다. 이것으로 첫 번째 전송 시퀀스가 완료될 수 있다.

[0031] 본 발명은 채널 추정과 양자화된 코드북 인덱스 피드백 프로세스를 모두 심층신경망(DNN)으로 대체할 수 있다. 본 발명은 기존에는 개별적으로 수행되고 최적화되던 두 프로세스를 하나의 원활한 프로세스로 통합하여 공동의 문제로 해결할 수 있다. 본 발명은 심층신경망(DNN)을 기반으로 하는 2단계 훈련/머신러닝(ML) 리드 체인을 제공하며, 이는 제한된 피드백 시스템을 공동으로 최적화하는 접근 방식을 제공할 수 있다.

[0032] 도 1을 참조하면, 점선 프레임은 본 발명의 MIMO 제한 피드백 구조에 통합된 심층신경망(DNN) 레이어를 나타낸다.

[0033] 기존 접근 방식에서는 신호 전송에 필요한 신호 모델링을 1단계로 간주하고, 모든 양자화된 코드북의 피드백을 2단계로 간주한다.

[0034] 파일럿 신호(pilot signal)를 모델링 단계(phase 1a)는 릴레이 노드에서 소스 노드로부터 수신된 신호를 하기 수학식 1로 나타낼 수 있다.

[0035] [수학식 1]

[0036] $$\mathbf{y}_R = \sqrt{E_S}\mathbf{F}_R\mathbf{H}_{RT}\mathbf{s} + \mathbf{n}_R$$

[0037] 여기에서, $\mathbf{F}_R \triangleq \mathbf{B}\mathbf{L}_R$은 릴레이 결합 행렬(relay combining matrix)이고, $\mathbf{n}_R \in \mathbb{C}^{N_r \times 1} \sim \mathcal{CN}(\mathbf{0}, \sigma_n^2\mathbf{I}_{N_r})$은 릴레이에서의 가우스 잡음 벡터 신호(Guassian noise vector signal)를 나타낸다.

[0038] 이어서, 릴레이 노드는 수신된 신호를 목적지 노드로 전달하기 전에 증폭할 수 있다. 목적지 노드에서 수신된 신호는 수학식 2로 나타낼 수 있다.

[0039] [수학식 2]

[0040] $$\mathbf{y}_D = \mathbf{H}_{DR}\sqrt{E_S}\left(\sqrt{E_R}\mathbf{F}_R\mathbf{H}_{RT}\mathbf{s} + \mathbf{F}_R\mathbf{n}_R\right) + \mathbf{n}_D$$

[0041] 여기에서, 벡터 $\mathbf{n}_D \in \mathbb{C}^{N_d \times 1} \sim \mathcal{CN}(\mathbf{0}, \sigma_n^2\mathbf{I}_{N_d})$는 목적지 노드에서의 잡음을 나타낸다.

[0042] 채널 추정 과정을 기반으로 최적화 문제에서 최적의 프리코딩 행렬 인덱스(PMI)가 선택될 수 있고, 최적의 프리코딩 행렬 인덱스를 하기 수학식 3과 같이 정의될 수 있다. 이는 B 피드백 비트로 변환되며, 전송 체인의 각 노드에 존재하는 C의 크기도 결정한다.

[0043] [수학식 3]

[0044] $$i^* = \underset{i \in \{1,\ldots,2^B\}}{\operatorname{argmax}} ||\hat{\mathbf{H}}\mathbf{c}_i||_2^2$$

[0045] 여기에서, $\hat{\mathbf{H}} \in \left\{\hat{\mathbf{H}}_{RT}, \hat{\mathbf{H}}_{DR}\right\}$ 및 $\mathbf{c}_i$는 미리 정의된 코드북 $\mathrm{C} = \{\mathbf{c}_1, \mathbf{c}_2, \ldots, \mathbf{c}_{2^B}\}$을 빔포머로 사용할 수 있다.

[0046] 프리코딩 필터 및 수신기를 모델링하는 단계(phase 1b)는 소스 노드의 프리코더와 1단계의 목적지 노드에서 사용되는 릴레이 노드 및 수신 노드의 필터를 하기 수학식 4로 정의될 수 있다.

[0047] [수학식 4]

[0048] $$\mathbf{B} = \mathbf{H}_{DR}^{\dagger}\mathbf{W}_D^{\dagger}[\mathbf{W}_D\mathbf{H}_{DR}\mathbf{H}_{DR}^{\dagger}\mathbf{W}_D + \frac{\operatorname{tr}\left(\sigma_{n_D}^2\mathbf{W}_D\mathbf{W}_D^{\dagger}\right)}{P_R}\mathbf{I}_{N_s}]^{-1}$$

[0049] 여기에서, $\mathbf{W}_D$는 하기 수학식 5로 정의될 수 있다.

[0050] [수학식 5]

[0051] $$\mathbf{W}_D = \gamma \mathbf{R}_x \mathbf{F}_T^{\dagger} \mathbf{H}_{RT}^{\dagger} \mathbf{F}_R^{\dagger} \mathbf{H}_{DR}^{\dagger} (\mathbf{H}_{DR} \mathbf{F}_R \mathbf{H}_{RT} \mathbf{F}_T \mathbf{R}_x \times \mathbf{F}_T^{\dagger} \mathbf{H}_{RT}^{\dagger} \mathbf{F}_R^{\dagger} \mathbf{H}_{DR}^{\dagger} + \mathbf{R}_n)^{-1}$$

[0052] 여기에서, $\mathbf{R}_n$은 하기 수학식 6으로 정의될 수 있다.

[0053] [수학식 6]

[0054] $$\mathbf{R}_n = \sigma_{n_1}^2 \mathbf{H}_{DR} \mathbf{F}_R \mathbf{F}_R^{\dagger} \mathbf{H}_{DR}^{\dagger} + \mathbf{I}_{N_d}$$

[0055] 따라서, 릴레이 노드에서 가능한 MMSE 필터는 하기 수학식 7과 같이 정의될 수 있다.

[0056] [수학식 7]

[0057] $$\mathbf{L}_R = \left(\mathbf{F}_T^{\dagger} \mathbf{H}^{\dagger} \mathbf{H} \mathbf{F}_T + \left(\frac{\sigma_{n_R}^2}{\sigma_s^2} \right) \mathbf{I}_{N_s} \right)^{-1} \mathbf{F}_T^{\dagger} \mathbf{H}^{\dagger}$$

[0058] 여기에서, $\gamma = \sqrt{P_R / \mathrm{tr}\left(\bar{\mathbf{F}}_R \left(\mathbf{H} \mathbf{F}_T \mathbf{F}_T^{\dagger} + \sigma_{n_1}^2 \mathbf{I}_{N_r} \right) \bar{\mathbf{F}}_R^{\dagger} \right)}$이고, σ_{n_R}과 σ_s^2는 각각 수신기의 잡음과 신호 전력을 의미한다. 또한, $\mathbf{R}_x$와 $\mathbf{R}_s$는 각각 전송된 심볼 x와 s의 공분산 행렬(covariance matrix)을 나타낸다.

[0059] 목적지 노드의 이퀄라이저(equalizer)는 $\mathbf{R}_{n_{R0}}$(하기 수학식 8)에 대한 $\mathbf{K_D} = (\mathbf{R}_s^{-1} + \mathbf{H}_{RT}^{\dagger} \mathbf{F}_R^{\dagger} \mathbf{H}_{DR}^{\dagger} \mathbf{R}_{n_{R0}}^{-1} \mathbf{H}_{DR} \mathbf{F}_R \mathbf{H}_{RT}) \mathbf{H}_{RT}^{\dagger} \mathbf{F}_R^{\dagger} \mathbf{H}_{DR}^{\dagger} \mathbf{R}_{n_{R0}}$로 정의될 수 있다.

[0060] [수학식 8]

[0061] $$\mathbf{R}_{n_{R0}} = \mathbf{H}_{DR} \mathbf{F}_R \mathbf{R}_{n_R} \mathbf{F}_R^{\dagger} \mathbf{H}_{DR}^{\dagger} + \mathbf{R}_{n_D}$$

[0062] 여기에서, $\mathbf{R}_{n_R}$ 및 $\mathbf{R}_{n_D}$는 각각 릴레이 노드와 목적지 노드의 노이즈 공분산 행렬을 나타낸다.

[0063] 최적 PMI 선택 및 피드백 단계(phase 2)는 코드북을 활용하여 현재 노드의 최적 PMI를 이전 노드에 피드백하는 모든 피드백 프로세스로 구성될 수 있다. 최적 PMI 선택 및 피드백 단계(phase 2)는 벤치마크 체계 중 하나로 DFT 코드북을 사용할 수 있다.

[0064] 지금까지의 설명은 기존의 접근 방식에 대한 것이었다. 이하에서는 기존의 접근 방식에서 개선된 DNN 접근 방식이 적용된 심화학습 기반 다중입출력 중계 전송 방법에 대해 설명한다.

[0065] 도 2는 본 발명의 실시예에 따른 심화학습 기반 다중입출력 중계 전송 방법의 흐름도를 나타낸다. 도 2를 참조하면, 심화학습 기반 다중입출력 중계 전송 방법은 파일럿 신호 모델링 및 전처리 단계(S100), 심층신경망 훈련 및 학습 단계(S300), 및 피드백하는 단계(S500)를 포함할 수 있다. 심화학습 기반 다중입출력 중계 전송 방법은 이진화 단계(S700)를 더 포함할 수 있다.

[0066] 본 발명에 따른 심화학습 기반 다중입출력 중계 전송 방법에서 1단계는 기존의 접근 방식과 유사하나, DNN 학습을 위한 데이터 세트로 파일럿 신호를 수집하는 결과를 가져온다. DNN 접근 방식에서 2단계는 공동 채널 추정 및 양자화에 DNN을 사용한다는 점에서 차이가 있다.

[0067] 파일럿 신호 모델링 및 전처리 단계(S100, phase 1)는 수신된 신호를 수집하여 데이터 세트를 형성할 수 있다. 파일럿 신호 모델링 및 전처리 단계(S100)는 도 1과 같이 제한된 피드백 시스템을 위한 딥러닝(DL) 구조를 가질 수 있다. 파일럿 신호는 기존의 접근 방식에서 사용한 방식으로 소스 노드에서 릴레이 노드로 전송된 다음 릴레이 노드에서 목적지 노드로 전송된다. 따라서, 릴레이 노드에서 수신된 신호는 상기 수학식 1을 재정의하여 하기 수학식 9로 정의될 수 있다.

[0068] [수학식 9]

[0069] $$\mathbf{y}_l^{train} = \sqrt{E_S} \mathbf{H}_{DR} \left(\sqrt{E_R} \mathbf{B} \mathbf{L}_R \mathbf{H}_{RT} \mathbf{p}_l + \mathbf{B} \mathbf{L}_R \mathbf{n}_{R_l} \right) + \mathbf{n}_{D_l}$$

[0070] 여기에서, $\forall l = \{1, 2, \cdots, L\}$이고, L은 총 파일럿 인스턴스 수를 나타낸다.

[0071] 행렬 $\mathbf{P} \triangleq [\mathbf{p}_1, \mathbf{p}_2, \ldots, \mathbf{p}_L] \in \mathbb{C}^{N_t \times L}$는 파일럿 전송에 사용되는 모든 신호 벡터를 $\mathbf{p}_l \triangleq \mathbf{F}_T \tilde{\mathbf{s}}^{\,l}$과 함께 제공할 수 있다. 이러한, y_l^{train} 파일럿 트레인 전송(pilot train transmission)의 L 인스턴스는 $\mathbf{Y}^{train}$ 행렬로 집계되어 데이터 세트를 형성할 수 있다. 즉, 파일럿 신호 모델링 및 전처리 단계(S100)는 릴레이 노드에서 수신된 신호(y_l^{train})의 인스턴스를 행렬($\mathbf{Y}^{train}$)로 집계하여 데이터 세트를 형성할 수 있다.

[0072] 형성된 새로운 데이터 세트는 $\mathrm{vec}(\cdot)$ 함수를 사용하여 행렬에서 벡터 형식으로 변환될 수 있다. 그 후, 복소수 벡터 데이터 세트의 실수 부분과 허수 부분이 $\mathrm{split}(\cdot)$ 함수를 통해 분할 될 수 있다. 즉, 파일럿 신호 모델링 및 전처리 단계(S100)는 형성된 데이터 세트를 벡터화 함수를 사용하여 행렬에서 벡터 형식으로 변환하고, 변환된 데이터 세트를 실수 부분과 허수 부분으로 분할하는 전처리를 수행할 수 있다. 이 두 가지 연산을 합하면 하기 수학식 10으로 표현되는 새로운 학습 집합이 생성된다. 이 단계까지 거치면, 데이터는 성공적으로 전처리되어 2단계 훈련 및 DNN을 통한 피드백을 받을 준비가 완료된다.

[0073] [수학식 10]

[0074]
$$\mathrm{split}\left(\mathrm{vec}(\mathbf{Y}^{train})\right) = \tilde{\mathbf{Y}}^{train}$$
$$\tilde{\mathbf{Y}}^{train} = [\Re\{\mathbf{Y}^{train}\}, \Im\{\mathbf{Y}^{train}\}]$$

[0075] 심층신경망(DNN) 훈련 및 학습 단계(S300)는 전처리된 상기 데이터 세트를 심층신경망(DNN)에 입력하여 학습시킬 수 있다. 심층신경망(DNN) 훈련 및 학습 단계(S300, phase 2a)는 전처리된 $\hat{\mathbf{Y}}_{train}$ 데이터 세트가 DNN에 입력된다. 심층신경망(DNN) 훈련 및 학습 단계(phase 2a)는 세 가지 주요 기능에 관여한다. 도 1에서 소스 노드, 릴레이 노드, 및 목적지 노드에 대해 각각 $f_S(\cdot)$, $f_R(\cdot)$, 및 $f_D(\cdot)$로 정의될 수 있다. $f_S(\cdot)$는 소스 노드에서의 DNN을 모델링한다. 심층신경망(DNN)은 50^{N_T}, 30^{N_T}, 및 20^{N_T} 크기의 3가지 레이어로 구성될 수 있다. 각 레이어에는 고밀도 입력 레이어(input layer), 배치 노멀라이저(batch normalizer) 및 활성화 함수(activation function)가 있다.

[0076] 본 발명에 따른 심층신경망(DNN)은 하나 이상의 레이어(layer)로 구성되고, 상기 하나 이상의 레이어 중 적어도 어느 하나는, 고밀도 입력 레이어(input layer), 배치 노멀라이저(batch normalizer) 및 활성화 함수(activation function)를 구비할 수 있다.

[0077] 본 발명에 따른 심층신경망(DNN)은 Tensorflow 프레임워크를 사용하여 모델링될 수 있다. 치수가 20^{N_T}인 첫 번째 레이어는 출력이 인스턴스화된 "BatchNormalization" 클래스에 공급되고 마지막으로 출력을 얻기 위해 "relu" 활성기에 공급되는 "Dense" 레이어로 구성된 세트를 사용하여 모델링된다. 상기 출력은 입력 치수가 30NT인 유사한 모듈 세트에 입력으로 공급되고, 상기 출력은 치수가 50NT인 최종 세트에 공급된다. 마찬가지로 $f_R(\cdot)$에 의해 주어진 릴레이 노드는 단일 레이어 세트로 구성되며 치수는 6^{N_R}이다. 마지막으로, 송신 노드는 심층신경망(DNN) 모델링된 제한된 피드백 링크의 최종 링크를 완성한다. 송신 노드는 수신기와 유사한 모듈 세트로 구성된 모델이다. 그러나 그 크기는 수신기의 크기와 역순이다. 즉, 세트 1은 50 ^{N_D}, 세트 2는 30 ^{N_D}, 마지막 세트는 20 ^{N_D}이다.

[0078] 제한된 피드백 시스템의 다양한 매핑은 다음과 같이 설명된다.

[0079] 목적지 노드에서 상기 수학식 3에 의해 주어진 $\hat{\mathbf{H}}_{RT}$와 $\hat{\mathbf{H}}_{DR}$에 대한 유효 채널 이득을 최대화하는 최적의 PMI는 DNN에서 $i^* = f_D(\mathbf{Y}^{train}) \rightarrow g_D(\tilde{\mathbf{y}}^{train}; \theta_D)$로 정의될 수 있다. 이와 동일하게, 릴레이 노드에서는 피드백 정보 i^*의 빔포밍 벡터를 식 $\mathbf{w_1} = f_R(i^*) \rightarrow g_R(i^*; \theta_R)$에 통합하여 릴레이 노드에서 최적화된 파라미터를 산출할 수 있다. 결국 송신기 측에서 실현되는 제한된 피드백 체인의 최종단은 식 $\mathbf{w_2} = f_S(w_1) \rightarrow g_T(w_1; \theta_T)$로 표현될 수 있다. 이를 통해, 완전히 최적화된 피드백 정보를 얻기 위한 완전한 피드백 체인 매핑을 하기 수학식 11과 $\mathbf{w}_2^* = f_S f_R((i^*))$로 표현될 수 있다.

[0080] [수학식 11]

[0081] $$\mathbf{w_2} = f_S(f_R(f_D(\mathbf{Y}^{train})))$$

[0082] 도 1에 도시된 입력 $\mathbf{Y}^{train}$ 데이터의 경우, 완전히 연결된 중간 레이어(fully-connected middle layer)에서 출력 o가 주어지며, 이후 활성화를 위해 해당 레이어 정류 선형 장치(ReLU)를 통과한다. 아담 옵티마이저(Adam optimizer)와 같은 경사 하강(gradient descent, GD) 기반 DNN 옵티마이저는 경사 업데이트가 실패하여 결과적으로 솔루션에 대한 수렴이 제대로 이루어지지 않는 소실 경사 문제로 인해 활성화 후 완화 장치로 다른 두 단계의 활성화가 사용된다.

[0083] 이진화 단계(S700)는 하기 수학식 12를 이용하여 [-1,1]의 통일성 범위 사이에서 상기 심층신경망(SNN)의 출력을 제한할 수 있다. 확률적 이진화 단계(S700, phase 2b)는 두 개의 순차적 활성화 함수를 사용하여 DNN과 관련된 소실 그라데이션 문제(vanishing gradient problem)를 개선한다. 첫 번째는 하기 수학식 12로 표현되는 tanh(z) 함수 활성화이다. 확률적 이진화 단계(S700)는 [-1,1]의 통일성 범위 사이에서 출력을 제한하는 역할을 한다. 그 후, 노이즈 분포 η에 대해 하기 수학식 12으로 정의된 $b(z)$에 확률적 활성화(stochastic activation)가 사용된다.

[0084] [수학식 12]

[0085] $$\tanh(\zeta) = \frac{\exp(2\zeta)+1}{\exp(2\zeta)-1}$$

[0086] [수학식 13]

[0087] $$b(\zeta) = \zeta + \eta \text{ for } \zeta \in [-1,1] \left(\eta = \begin{cases} 1-\zeta & (\text{ with probability } \frac{1+\zeta}{2}) \\ -1-\zeta & (\text{ with probability } \frac{1-\zeta}{2}) \end{cases}\right)$$

[0088] 확률적 이진화 단계에 의해 상기 수학식 11에 주어진 함수 연산의 연쇄로 인해 발생하는 최적화 문제의 조합적 한계(다른 방법이었다면, 하기 수학식 13, 14로 표현되었을)를 이제 하기 수학식 16으로 표현하여 훈련 문제를 나타낼 수 있다.

[0089] [수학식 14]

[0090] $$\max_{f_R, f_T} \mathbb{E}_{\mathbf{H},\mathbf{N}} \left[||\mathbf{H} f_T(f_R((i^*)))||_2^2 \right]$$

[0091] [수학식 15]

[0092] $$\text{s.t.} \quad i^* = f_R\left(\mathbf{Y}^{train}\right) \in \{1, \ldots, 2^B\}$$

[0093] [수학식 16]

[0094] $$\max_{\theta_T, \theta_R, \theta_D} \mathbb{E}_{\mathbf{H},\mathbf{N}} \left[||g_T(g_R(g_D(\mathbf{y}^{train}; \theta_R); \theta_R); \theta_T)||_2^2 \right]$$

[0095] 여기에서, θ_D, θ_R, 및 θ_T는 최적화할 변수이다. 수학식 16을 통해 훈련 단계는 이전에 사전 처리된 훈련 세트에서 추출한 샘플을 반복하는 확률적 경사 하강(stochastic gradient descent, SGD)의 여러 배치로 구성된다. 시뮬레이션을 위한 훈련 세트는 채널 데이터와 노이즈 데이터 모음에서 생성된다. SGD는 상기 수학식 11에 주어진 파라미터 세트에 대해 동일한 업데이터 규칙을 따르며, 훈련은 오프라인으로 수행된다. 훈련 후 학습된 파라미터 θ_D, θ_R, 및 θ_T를 각각 목적지 노드, 릴레이 노드, 송신기의 메모리 유닛에 저장할 수 있다. 이러한 파라미터는 실시간 제한 피드백에 사용되며, 기존 방식에서 사용되는 PMI 코드북을 대체하는 것으로 생각할 수 있다.

[0096] 본 발명의 실시예에 따른 심층신경망(DNN)은 각 노드에 존재할 수 있고 제한된 피드백 체인을 구성하는 고유 계층의 수학적 구조화를 강조할 수 있다.

[0097] 각 노드 레이어 집합의 완전히 연결된 심층신경망(DNN)을 구성하는 은닉 층(hidden layer)의 크기는 각각 K_{T_α}, K_{R_β}, K_{D_Γ}로 표시될 수 있다. 여기에서, $\alpha \in \mathcal{R}^{K_{T_\alpha} \times 1}$, $\beta \in \mathcal{R}^{K_{R_\beta} \times 1}$, $\Gamma \in \mathcal{R}^{K_{D_\Gamma} \times 1}$이다. 각 노드의 출력

은 바이어스 벡터 $\mathbf{b} \in \mathbb{R}^{K_m \times 1}$에 더해진 후 $a(\cdot)$로 정의되는 활성화 계층을 통과한다. 각 노드의 가능한 활성화 전 가중치 행렬은 $\mathbf{W_m} \in \mathbb{R}^{K_m \times K_{m-1}}$로 표현될 수 있다. 여기에서, $K_{T_\alpha} = K_{R_\beta} = K_{D_\Gamma} = K_m$은 어느 노드에서 학습이 진행되는지에 따라 달라진다. 따라서, 모든 심층신경망(DNN) 주입 노드(각각 M 레이어로 모델링됨) 이후 모든 레이어에 걸쳐 수행되는 학습에 대한 일반적인 표현은 하기 수학식 17로 정의될 수 있다.

[0098] [수학식 17]

[0099] $$\mathbf{x}_m = a_m\left(\mathbf{W}_m \mathbf{x}_{m-1} + \mathbf{b}_m\right)$$

[0100] 상기 수학식 17은 상기 수학식 11에서 파악한 바와 같이 DNN의 전체 성능을 극대화하는 최종 $\theta \triangleq \{\theta_D; \theta_R; \theta_T\}$ 세트를 산출하는 것을 목표로 초기 파라미터 세트 $\theta = \{\mathbf{W}_m, \mathbf{b}_m, \forall m\}$를 공급하는 M+1의 연속적인 계산을 나타낸다.

[0101] DNN 모델의 실제 구현은 Python 프로그래밍 언어를 통해 텐서플로우 프레임워크(Tensorflow framework)를 사용하여 이루어집니다. DNN 모델은 순방향 및 역방향 전파 알고리즘의 결과를 모두 활용하여 전체 비용 함수를 최소화하는 매개변수 집합의 최적값을 재귀적으로 구하는 특수 함수를 활용할 수 있다.

[0102] 도 5는 본 발명의 다른 실시예인 심화학습 기반 다중입출력 중계 전송 시스템(10)의 구성도를 나타낸다. 도 5를 참조하면, 심화학습 기반 다중입출력 중계 전송 시스템(10)은 파일럿 신호 모델링 및 전처리부(100), 심층신경망 학습부(300), 및 피드백부(500)를 포함할 수 있다. 심화학습 기반 다중입출력 중계 전송 시스템(10)은 이진화부(미도시)를 더 포함할 수 있다.

[0103] 파일럿 신호 모델링 및 전처리부(100)는 수신된 신호를 수집하여 데이터 세트를 형성할 수 있다. 파일럿 신호 모델링 및 전처리부(100)는 전술한 파일럿 신호 모델링 및 전처리 단계(S100)를 수행할 수 있다.

[0104] 심층신경망 학습부(300)는 전처리된 상기 데이터 세트를 심층신경망(DNN)에 입력하여 학습시킬 수 있다. 심층신경망 학습부(300)는 전술한 신층신경망 훈련 및 학습 단계(S300)를 수행할 수 있다.

[0105] 피드백부(500)는 심층신경망(DNN)에서 출력된 유효 채널 이득을 최대화하는 프리코딩 행렬 인덱스(PMI)를 이전 노드로 피드백할 수 있다. 피드백부(500)는 전술한 피드백하는 단계(S500)를 수행할 수 있다.

[0106] 이진화부(미도시)는 [-1,1]의 통일성 범위 사이에서 상기 심층신경망(SNN)의 출력을 제한할 수 있다. 이진화부(미도시)는 전술한 이진화 단계(S700)를 수행할 수 있다.

[0107] 이하에서는 본 발명의 시뮬레이션 결과를 설명한다.

[0108] 본 시뮬레이션에서는 첫 번째로 DFT 코드북을 벤치마크로 활용한다. 표 1은 DFT 코드북의 구조와 해당 매개변수를 간략하게 나타낸다.

[0109] [표1]

[0110]

Simulation Parameters for Different models					
Conventional Relay Scheme		*DNN*		*DFT Codebook*	
Parameter	Value	Parameter	Value	Parameter	Value
N_T	$\{2,3,4\}$	# hidden layers (T)	3	codeword (CW) length	4
N_R	$\{2,3,4\}$	# hidden layers (R)	3	codebook size	64
N_D	$\{2,3,4\}$	# hidden layers (D)	3	number of data streams	1
$\#iterations$	10^4	training set matrix	Y^{train}	# antennas/column indices selected	$2/\{1\}, 3/\{1\}, 4/\{1,2\}$
Pilot bit length	–	mappings	$f_D(\cdot) \to g_D(\cdot), f_R(\cdot) \to g_R(\cdot), f_T(\cdot) \to g_T(\cdot)$	# antennas/rotation vector used	$2/\{1,0\}, 3/\{1,26,28\}, 4/\{1,8,61,45\}$
	64	Coding scheme	BPSK		

[0111] $N_T \times N_T$ 행렬 중 M 개의 열을 선택하여 얻은 초기 코드워드 $\mathbf{W}_{DFT}$는 디자인 C= $\{\mathbf{w}, \mathbf{w}\boldsymbol{\theta}, \cdots, \mathbf{w}\boldsymbol{\theta}^{L-1}\}$를 생성한다. 여기에서, $\boldsymbol{\theta} = \mathrm{diag}\left(e^{\frac{j2\pi u_1}{N_T}}, e^{\frac{j2\pi u_2}{N_T}}, \cdots, e^{\frac{j2\pi u_{N_T}}{N_T}}\right)$이다. $\boldsymbol{\theta}$의 $\{u_i\}_{i=1}^{N_T}$ 급수는 하기 수학식 18의 최대화 문제(maximization problem)인 최소 코드 거리(minimum chordal distance)를 해결한 결과이다.

[0112] [수학식 18]

[0113] $$\mathbf{u} = \underset{u_1, u_1, u_1}{\operatorname{argmax}} \underset{l=1,2,\cdots,N-1}{\min} d\left(\mathbf{W}, \mathbf{W}\boldsymbol{\theta}^l\right)$$

[0114] 본 시뮬레이션은 DFT 코드북이 모든 노드에서 활용된다고 가정하고, 목적지 노드에서의 양자화 프로세스는 목적지 노드로의 후속 전송을 위해 DFT 프리코더를 선택하는 데 필요한 필수 PMI(PMI_D)를 산출한다. 릴레이 노드에

서도 유사한 프로세스가 차례로 발생하여 송신기에서 릴레이 노드로 연속 전송하는 데 필요한 또 다른 PMI(PMI_R)를 산출한다. 두 경우 모두 프리코딩은 $\mathbf{H}_{eff} = \mathbf{F}_T\mathbf{H}$ 변환으로 이루어지며, 여기에서 $\mathbf{H} \in \{\mathbf{H}_{RT}, \mathbf{H}_{DR}\}$이다.

[0115] 본 시뮬레이션에서는 두 번째로 SVD을 벤치마크로 활용한다. 두 번째 SVD 벤치마킹 방식은 완벽한 CSI를 가정한다. 채널 행렬은 SVD 분해를 통해 $\mathbf{H} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^H$로 분해된다. 행렬 V는 프리코더로 사용되는 반면, 행렬 U는 기존 필터로 사용된다.

[0116] DL 모델링에 사용되는 다양한 파라미터는 상기 표 1에 나와 있고, DNN 설정은 앞서 언급한 바와 같다. SGD 학습을 위해 배치 스냅샷 크기(batch snap-shot size) B=2000에 대해 104회 반복을 수행한다. DFT 코드북의 정의에는 코드북 크기(codebook size) 64, 코드워드 길이(codeword length) 4를 사용하며, 전송에는 하나의 데이터스트림(datastream)도 사용한다.

[0117] 본 시뮬레이션을 통해 제안된 DNN 기반 시스템의 성능을 기호 호류율(symbol-error-rate, SER) 메트릭 측면에서 분석하였다. 본 발명을 통한 새로운 방식은 기존의 SVD 방식 뿐만 아니라 차선책인 DFT 방식보다 성능이 뛰어나다는 것이 확인된다.

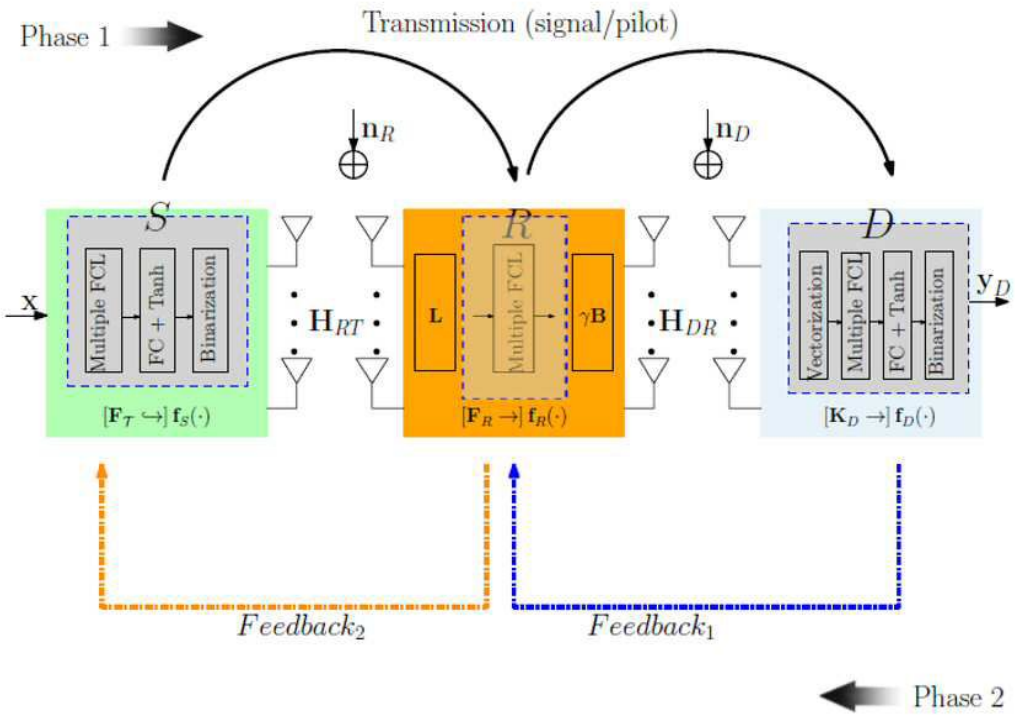
[0118] 도 2는 안테나의 수에 따른 SNR에 대한 SER의 관계를 나타내는 그래프이다. 도 2를 참조하면, 기존 방식과 SVD 방식 간에는 5~7dB의 성능 격차가 있으며, DFT 방식에서는 약 20dB의 더 큰 격차를 보임을 알 수 있다. DL은 안테나의 상관 관계가 증가함에 따라 더 나은 성능을 발휘하는 것으로 이해된다.

[0119] 도 3는 t-value에 따른 SNR에 대한 SER의 관계를 나타내는 그래프이다. 도 3을 참조하면, 0.3, 0.7, 0.9의 t-value값($|t|$)으로 표시된 상관관계 값의 증가는 다른 접근 방식에 비해 성능 수준이 향상되었음을 반영한다. 이러한 관찰 결과는 두 벤치마킹 방식이 각각 양자화 및 제한된 피드백 프로세스를 개별적으로 처리하기 때문인 것으로 보인다. 따라서 고려 중인 문제를 공동으로 최적화할 때 얻을 수 있는 동일한 이득을 실현하지 못합니다. 또한, 안테나 수를 $N_t = N_r = N_d = 2$로 설정한 경우 본 발명은 약 8dB의 차이로 SVD 방식보다 성능이 뛰어나다. 또한 안테나 수가 증가함에 따라 SER이 감소하는 것을 관찰할 수 있으며, 본 발명의 설정은 SVD와 DFT 모두에서 성능이 뛰어나다.

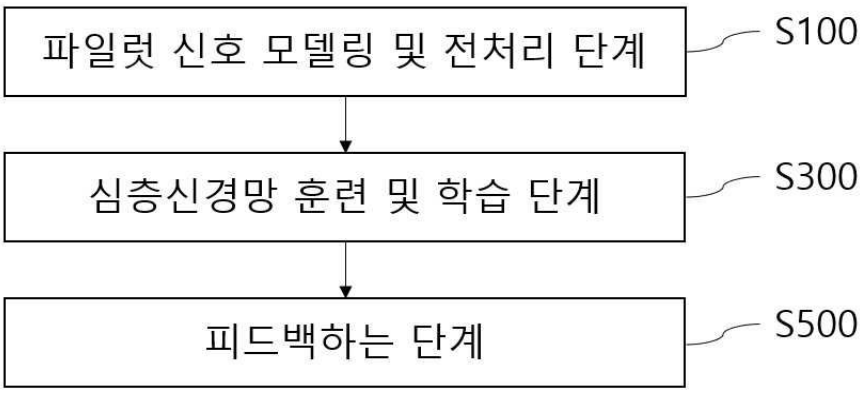
[0120] 이상에서 대표적인 실시예를 통하여 본 발명을 상세하게 설명하였으나, 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자는 상술한 실시예에 대하여 본 발명의 범주에서 벗어나지 않는 한도 내에서 다양한 변형이 가능함을 이해할 것이다. 그러므로 본 발명의 권리 범위는 설명한 실시예에 국한되어 정해져서는 안 되며, 후술하는 특허청구범위뿐만 아니라 특허청구범위와 균등 개념으로부터 도출되는 모든 변경 또는 변형된 형태에 의하여 정해져야 한다.

도면

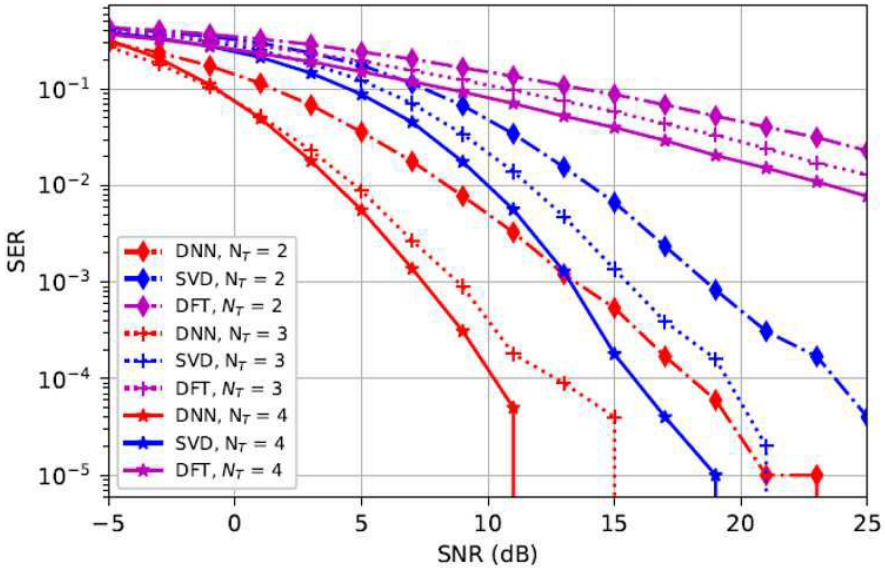
도면1


Phase 1
Transmission (signal/pilot)
$\mathbf{n}_R$
$\mathbf{n}_D$
S
Multiple FCL
FC + Tanh
Binarization
$[\mathbf{F}_T \hookrightarrow] \mathbf{f}_S(\cdot)$
x
$\mathbf{H}_{RT}$
R
L
Multiple FCL
γB
$[\mathbf{F}_R \rightarrow] \mathbf{f}_R(\cdot)$
$\mathbf{H}_{DR}$
D
Vectorization
Multiple FCL
FC + Tanh
Binarization
$[\mathbf{K}_D \rightarrow] \mathbf{f}_D(\cdot)$
$\mathbf{y}_D$
$Feedback_2$
$Feedback_1$
Phase 2

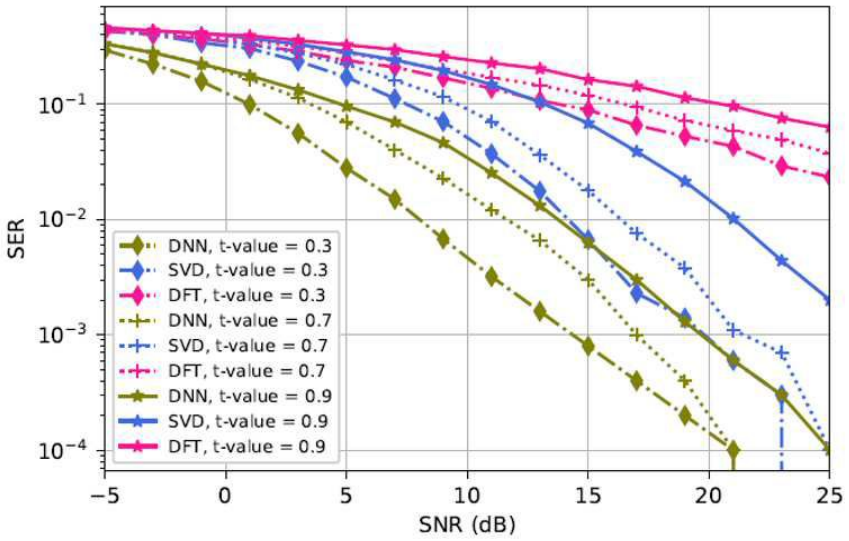
도면2


파일럿 신호 모델링 및 전처리 단계
S100
심층신경망 훈련 및 학습 단계
S300
피드백하는 단계
S500

도면3


SER
SNR (dB)
DNN, $N_T = 2$
SVD, $N_T = 2$
DFT, $N_T = 2$
DNN, $N_T = 3$
SVD, $N_T = 3$
DFT, $N_T = 3$
DNN, $N_T = 4$
SVD, $N_T = 4$
DFT, $N_T = 4$

도면4


SER
SNR (dB)
DNN, t-value = 0.3
SVD, t-value = 0.3
DFT, t-value = 0.3
DNN, t-value = 0.7
SVD, t-value = 0.7
DFT, t-value = 0.7
DNN, t-value = 0.9
SVD, t-value = 0.9
DFT, t-value = 0.9

도면5

