



(19) 대한민국특허청(KR)  
(12) 등록특허공보(B1)

(45) 공고일자 2019년05월16일  
(11) 등록번호 10-1979394  
(24) 등록일자 2019년05월10일

(51) 국제특허분류(Int. Cl.)  
HO4L 1/00 (2006.01) GO6N 99/00 (2019.01)  
HO4L 25/02 (2006.01)  
(52) CPC특허분류  
HO4L 1/0003 (2013.01)  
GO6N 20/00 (2019.01)  
(21) 출원번호 10-2018-0152252  
(22) 출원일자 2018년11월30일  
심사청구일자 2018년11월30일  
(56) 선행기술조사문헌  
KR1020010076756 A\*  
Zhijie Dong, "Link Adaptive Transmission Scheme in MIMO Systems through Machine Learning", 게재일 2018년3월16일.  
[http://zjdong.net/archives/Link-Adaptive-Transmission-Scheme-in-MIMO-Systems-through-Machine\\*](http://zjdong.net/archives/Link-Adaptive-Transmission-Scheme-in-MIMO-Systems-through-Machine)  
\*는 심사관에 의하여 인용된 문헌

(73) 특허권자  
세종대학교 산학협력단  
서울특별시 광진구 능동로 209 (군자동, 세종대학교)  
(72) 발명자  
송형규  
경기도 성남시 분당구 중앙공원로 17, 한양아파트 320동 303호  
하창빈  
서울특별시 성북구 장위로26길 11-12, 2층 (장위동)  
(74) 대리인  
특허법인태백

전체 청구항 수 : 총 12 항

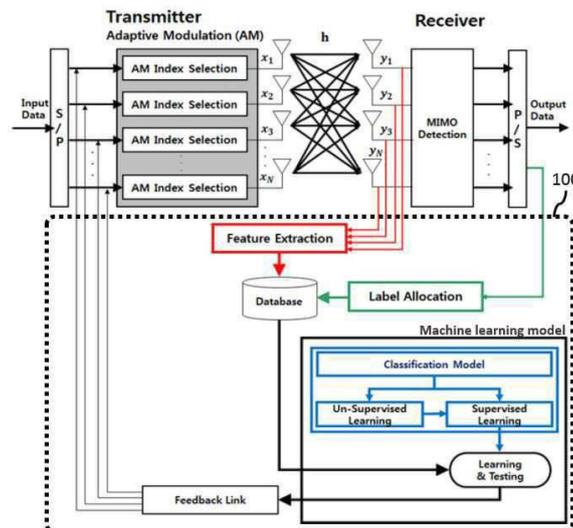
심사관 : 석상문

(54) 발명의 명칭 MIMO-OFDM 시스템 기반의 머신 러닝 모델을 이용한 적응적 전송 기법 결정 장치 및 그것을 이용한 적응적 전송 방법

(57) 요약

본 발명은 MIMO-OFDM 시스템 기반의 머신 러닝 모델을 이용한 적응적 전송 기법 결정 장치 및 그것을 이용한 적응적 전송 방법에 관한 것이다. 본 발명에 따르면, MIMO-OFDM 시스템 기반의 머신 러닝 모델을 이용한 적응적 전송 방법에 있어서, N개의 안테나를 가진 수신단에 수신된 신호의 채널 상태로부터 추출한 특징 정보를 입력으로

(뒷면에 계속)  
대표도 - 도1



하고 상기 채널 상태에 대응하여 N개의 안테나를 가진 송신단의 각 안테나 별 적용되는 최적 전송 기법 정보를 정의한 레이블을 출력으로 하는 복수의 학습 데이터들을 사용하여 상기 머신 러닝 모델을 학습시키는 단계와, 상기 송신단의 송신 신호에 대응하여 수신되는 상기 수신단의 수신 신호로부터 채널 상태를 추정하고 채널 상태로부터 특징 정보를 추출하여 상기 학습된 머신 러닝 모델에 입력시키는 단계, 및 상기 입력된 특징 정보에 대응하여 상기 머신 러닝 모델에서 출력되는 레이블을 기초로 상기 송신단의 각 안테나 별 적용되는 최적 전송 기법 정보를 결정하여 상기 송신단으로 피드백하는 단계를 포함하는 MIMO-OFDM 시스템에서 머신 러닝 모델 기반의 적응적 전송 방법을 제공한다.

본 발명에 따르면, 동일 SNR 에서도 채널 상태에 따라 서로 다른 전송 방식들을 최적 전송 방식으로 선택할 수 있고 시스템의 전송률을 향상시킬 수 있다.

(52) CPC특허분류

*H04L 1/0017* (2013.01)

*H04L 1/0039* (2013.01)

*H04L 25/024* (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711075702
부처명	과학기술정보통신부
연구관리전문기관	정보통신기술진흥센터
연구사업명	정보통신기술인력양성(정보화)
연구과제명	지능형 비행로봇 융합기술 연구
기 여 율	1/1
주관기관	세종대학교 산학협력단
연구기간	2018.06.01 ~ 2019.02.28

---

**명세서**

**청구범위**

**청구항 1**

MIMO-OFDM 시스템 기반의 머신 러닝 모델을 이용한 적응적 전송 방법에 있어서,

N개의 안테나를 가진 수신단에 수신된 신호의 채널 상태로부터 추출한 특징 정보를 입력으로 하고 상기 채널 상태에 대응하여 N개의 안테나를 가진 송신단의 각 안테나 별 적용되는 최적 전송 기법 정보를 정의한 레이블을 출력으로 하는 복수의 학습 데이터들을 사용하여 상기 머신 러닝 모델을 학습시키는 단계;

상기 송신단의 송신 신호에 대응하여 수신되는 상기 수신단의 수신 신호로부터 채널 상태를 추정하고 채널 상태로부터 특징 정보를 추출하여 상기 학습된 머신 러닝 모델에 입력시키는 단계; 및

상기 입력된 특징 정보에 대응하여 상기 머신 러닝 모델에서 출력되는 레이블을 기초로 상기 송신단의 각 안테나 별 적용되는 최적 전송 기법 정보를 결정하여 상기 송신단으로 피드백하는 단계를 포함하며,

상기 머신 러닝 모델을 학습시키는 단계는,

상기 머신 러닝 모델에서 출력 가능한 T개의 레이블 중 상기 입력된 특징 정보에 대응된 k번째 레이블이 최적일 확률값을 연산 후, 상기 확률값을 이용하여 크로스 엔트로피에 의한 로스 값을 연산하며,

상기 로스값이 설정값 이하가 되도록 상기 머신 러닝 모델 내의 가중치 및 바이어스를 조정하여 상기 머신 러닝 모델을 학습시키는 머신 러닝 모델을 이용한 적응적 전송 방법.

**청구항 2**

청구항 1에 있어서,

상기 머신 러닝 모델에 입력되는 상기 특징 정보는,

상기 수신된 신호의 SNR, 송수신단 사이의  $N \times N$ 개 채널 정보, 그리고 상기 채널 정보를 보상하는  $N \times N$ 개 채널 보상 정보를 포함하는  $1+2N^2$  차원의 특징인 머신 러닝 모델을 이용한 적응적 전송 방법.

**청구항 3**

청구항 1 또는 청구항 2에 있어서,

상기 특징 정보를 상기 머신 러닝 모델에 입력하기 이전에 상기 추출된 특징 정보를 주성분 분석 기법을 통해 전처리하여 상기 특징 정보의 차원 수를 줄이는 단계를 더 포함하는 머신 러닝 모델을 이용한 적응적 전송 방법.

**청구항 4**

청구항 1에 있어서,

상기 학습 데이터의 레이블에 정의된 최적 전송 기법 정보는,

상기 송신단의 N개 안테나에 각각 적용되는 N개의 최적 전송 기법의 조합을 의미하되,

BPSK, QPSK, 16QAM, 64QAM을 포함한 M가지 전송 기법에 따라 구분되는 T가지( $T = N^M$ ) 전송 기법 조합 중에서 상기 수신단에 수신된 신호의 검출 성능을 분석한 결과 기 설정된 목표 에러 성능을 만족하는 동시에 가장 높은 데이터율을 도출한 전송 기법 조합에 해당하는 머신 러닝 모델을 이용한 적응적 전송 방법.

**청구항 5**

청구항 4에 있어서,

상기 학습 데이터에 라벨링되는 상기 레이블(k)은,

상기 수신된 신호의 검출 성능을 기초로 아래 수학적식에 의해 선택되되, 상기 T가지 전송 기법 조합 모두 상기 목표 에러 성능을 만족하지 못하면 T가지 중 1번째 전송 방식이 선택되는 머신 러닝 모델을 이용한 적응적 전송 방법:

$$k = \begin{cases} \arg \max_t (\mathbf{R}^t) \text{ for } \forall t \text{ that} \\ \text{satisfy condition } (P_E)^t \leq T_E \\ 1, \text{ if } (P_E)^t > T_E \text{ for } \forall t \end{cases}$$

여기서,  $T_E$ 는 상기 목표 에러 성능,  $(P_E)^t$ 은 상기 시스템에 정의된 T가지 전송 기법 조합 중 t번째 조합에 대응된 에러 성능,  $\mathbf{R}^t$ 은 상기 t번째 조합에서 사용되는 전송 비트 수,  $\forall t$ 는 모든 가능한 변수 t에 대한 수식,  $\arg \max_t (\cdot)$ 은 변수 m에 의해 변화되는 수식 결과 중 가장 큰 값을 도출하는 변수 k를 출력하는 식을 나타낸다.

**청구항 6**

삭제

**청구항 7**

청구항 1에 있어서,

상기 확률값( $s_t$ ;  $t=k$ ) 및 상기 로스값( $L_{CE}$ )은 아래 수학적식으로 표현되는 머신 러닝 모델을 이용한 적응적 전송 방법:

$$s_t = \frac{\exp(o_t)}{\sum_{i=1}^T \exp(o_i)}, t = \{1, 2, \dots, T\}$$

$$L_{CE} = - \sum_k \mathbf{T}_k \log s_k$$

여기서, T는 상기 머신 러닝 모델의 출력 노드의 수,  $o_t(t=k)$ 는 상기 머신 러닝 모델에서 출력 가능한 T개의 레이블 중 상기 입력된 특징 정보에 대응된 k번째 레이블의 값,  $\mathbf{T}_k$ 는 상기 k번째 레이블에 대응된 행렬로

$\mathbf{T}_k = \begin{bmatrix} 0 & 0 & \dots & 1 & \dots & 0 & 0 \end{bmatrix}'$  로 표현되며,  $\mathbf{T}_k$  내의 T개 성분 중 k번째 성분만 1이고 나머지는 0을 가진다.

**청구항 8**

MIMO-OFDM 시스템 기반의 머신 러닝 모델을 이용한 적응적 전송 기법 결정 장치에 있어서,

N개의 안테나를 가진 수신단에 수신된 신호의 채널 상태로부터 추출한 특징 정보를 입력으로 하고 상기 채널 상태에 대응하여 N개의 안테나를 가진 송신단의 각 안테나 별 적용되는 최적 전송 기법 정보를 정의한 레이블을 출력으로 하는 복수의 학습 데이터들을 사용하여 상기 머신 러닝 모델을 학습시키는 학습부;

상기 송신단의 송신 신호에 대응하여 수신되는 상기 수신단의 수신 신호로부터 채널 상태를 추정하고 채널 상태로부터 특징 정보를 추출하여 상기 학습된 머신 러닝 모델에 입력시키는 추출부; 및

상기 입력된 특징 정보에 대응하여 상기 머신 러닝 모델에서 출력되는 레이블을 기초로 상기 송신단의 각 안테나 별 적용되는 최적 전송 기법 정보를 결정하여 상기 송신단으로 피드백하는 결정부를 포함하며,

상기 학습부는,

상기 머신 러닝 모델에서 출력 가능한 T개의 레이블 중 상기 입력된 특징 정보에 대응된 k번째 레이블이 최적이

될 확률값을 연산 후, 상기 확률값을 이용하여 크로스 엔트로피에 의한 로스 값을 연산하며,

상기 로스값이 설정값 이하가 되도록 상기 머신 러닝 모델 내의 가중치 및 바이어스를 조정하여 상기 머신 러닝 모델을 학습시키는 적응적 전송 기법 결정 장치.

**청구항 9**

청구항 8에 있어서,

상기 머신 러닝 모델에 입력되는 상기 특징 정보는,

상기 수신된 신호의 SNR, 송수신단 사이의  $N \times N$ 개 채널 정보, 그리고 상기 채널 정보를 보상하는  $N \times N$ 개 채널 보상 정보를 포함하는  $1+2N^2$  차원의 특징인 적응적 전송 기법 결정 장치.

**청구항 10**

청구항 8 또는 청구항 9에 있어서,

상기 특징 정보를 상기 머신 러닝 모델에 입력하기 이전에 상기 추출된 특징 정보를 주성분 분석 기법을 통해 전처리하여 상기 특징 정보의 차원 수를 줄이는 전처리부를 더 포함하는 적응적 전송 기법 결정 장치.

**청구항 11**

청구항 8에 있어서,

상기 학습 데이터의 레이블에 정의된 최적 전송 기법 정보는,

상기 송신단의 N개 안테나에 각각 적용되는 N개의 최적 전송 기법의 조합을 의미하되,

BPSK, QPSK, 16QAM, 64QAM을 포함한 M가지 전송 기법에 따라 구분되는 T가지( $T = N^M$ ) 전송 기법 조합 중에서 상기 수신단에 수신된 신호의 검출 성능을 분석한 결과 기 설정된 목표 에러 성능을 만족하는 동시에 가장 높은 데이터율을 도출한 전송 기법 조합에 해당하는 적응적 전송 기법 결정 장치.

**청구항 12**

청구항 11에 있어서,

상기 학습 데이터에 라벨링되는 상기 레이블(k)은,

상기 수신된 신호의 검출 성능을 기초로 아래 수학적식에 의해 선택되되, 상기 T가지 전송 기법 조합 모두 상기 목표 에러 성능을 만족하지 못하면 T가지 중 1번째 전송 방식이 선택되는 머신 러닝 모델을 이용한 적응적 전송 기법 결정 장치:

$$k = \begin{cases} \arg \max_t (\mathbf{R}^t) \text{ for } \forall t \text{ that} \\ \text{satisfy condition } (P_E)^t \leq T_E \\ 1, \text{ if } (P_E)^t > T_E \text{ for } \forall t \end{cases}$$

여기서,  $T_E$ 는 상기 목표 에러 성능,  $(P_E)^t$ 은 상기 시스템에 정의된 T가지 전송 기법 조합 중 t번째 조합에 대응된 에러 성능,  $\mathbf{R}^t$ 은 상기 t번째 조합에서 사용되는 전송 비트 수,  $\forall t$ 는 모든 가능한 변수 t에 대한 수식,  $\arg \max_t (\cdot)$ 은 변수 m에 의해 변화되는 수식 결과 중 가장 큰 값을 도출하는 변수 k를 출력하는 식을 나타낸다.

**청구항 13**

삭제

**청구항 14**

청구항 8에 있어서,

상기 확률값( $s_t$ ;  $t=k$ ) 및 상기 로스값( $L_{CE}$ )은 아래 수학식으로 표현되는 적응적 전송 기법 결정 장치:

$$s_t = \frac{\exp(o_t)}{\sum_{i=1}^T \exp(o_i)}, t = \{1, 2, \dots, T\}$$

$$L_{CE} = - \sum_k \mathbf{T}_k \log s_k$$

여기서, T는 상기 머신 러닝 모델의 출력 노드의 수,  $o_t(t=k)$ 는 상기 머신 러닝 모델에서 출력 가능한 T개의 레이블 중 상기 입력된 특징 정보에 대응된 k번째 레이블의 값,  $\mathbf{T}_k$ 는 상기 k번째 레이블에 대응된 행렬로

$\mathbf{T}_k = \begin{bmatrix} 0 & 0 & \dots & 1 & \dots & 0 & 0 \end{bmatrix}'$  로 표현되며,  $\mathbf{T}_k$  내의 T개 성분 중 k번째 성분만 1이고 나머지는 0을 가진다.

**발명의 설명**

**기술 분야**

[0001] 본 발명은 MIMO-OFDM 시스템 기반의 머신 러닝 모델을 이용한 적응적 전송 기법 결정 장치 및 그것을 이용한 적응적 전송 방법에 관한 것으로서, 보다 상세하게는 통신 환경에 따라 학습된 머신 러닝 모델을 이용하여 각 채널 상태에 대응되는 최적 전송 방식을 결정할 수 있는 적응적 전송 기법 결정 장치 및 그것을 이용한 적응적 전송 방법에 관한 것이다.

**배경 기술**

[0002] 차세대 통신 시스템은 IoT(internet of things) 분야의 자율 주행, 가상 현실, 원격 의료와 같은 서비스를 지원하기 위해 매우 높은 데이터율과 신뢰성을 요구한다. 5G NR(new radio) 시스템은 OFDM(orthogonal frequency division multiplexing) 기반의 전송 방식을 기반으로 표준화가 진행되고 있고, MIMO(multiple input multiple output) 기법은 데이터율을 개선하기 위한 핵심 기술로 사용되고 있기 때문에, 차세대 통신 시스템의 물리 계층은 MIMO-OFDM 시스템을 기반으로 구축될 것이다.

[0003] 차세대 통신 시스템의 표준화를 진행하고 있는 3GPP(3rd generation partnership project)는 km<sup>2</sup> 당 100만개의 장치를 지원 및 1%의 PER(packet error rate)의 신뢰도를 목표로 하고 있다. 따라서, 신뢰도를 보장하는 동시에 전송률을 지원하기 위해, 채널 상태에 따라 변조 기법들을 적응적으로 조정하는 적응적 변조는 차세대 통신 시스템에서 효과적으로 사용될 것이다.

[0004] MIMO 기법을 채택하고 있는 무선 통신 시스템의 최신 표준들은 채널 상태에 따라 전송률과 신뢰성을 조정하기 위해, 여러 변조 기법들을 정의하고 있다. 예를 들어, IEEE(institute of electrical and electronics engineers) 802.11n 표준은 BPSK(biphase shift keying), QPSK(quaternary phase shift keying), 16-QAM(quadrature amplitude modulation), 64-QAM을 정의하고 있다. 또한, IEEE 802.11n 표준은 채널 상태에 따라 모든 공간 스트림들에서 동일한 변조 기법을 사용하는 EQM(equal modulation)과, 서로 다른 변조 기법들을 사용할 수 있는 UEQM(unequal modulation)에 대한 룩업 테이블(lookup table)들을 제공한다.

[0005] 기존의 규칙 기반 적응적 전송 기법의 일반적인 메커니즘은 다음과 같다. 수신단은 CQI(channel quality information)를 기반으로 각 SNR(signal to noise ratio)에 따른 최적 전송 방식을 정의하고 그 정보를 피드백 링크를 통하여 송신단에게 전송한다. 최적 전송 방식은 미리 정의된 타겟 에러 성능을 만족하는 동시에 가장 높은 데이터율을 가지는 전송 방식으로 결정된다.

[0006] 그러나 차세대 통신 시스템에서는 다양한 서비스에 따라 서로 다른 전송률과 신뢰성을 목표로 하기 때문에, 여러 변조 기법들의 적응적인 사용에 따라 전송 가능한 방식의 수가 크게 증가된다. 특히, MIMO 시스템을 사용하는 경우, 적응적 변조에 대한 전송 방식의 수는 공간 스트림들의 수와 사용 가능한 변조 기법들의 수에 따라 기

하급수적으로 증가될 수 있다.

- [0007] 또한 MIMO 시스템을 사용하는 경우, 송신단의 각 공간 스트림으로부터 전송되는 신호는 수신단의 각 안테나로부터 수신되기 때문에, 각 채널간의 상관 관계가 통신 성능에 영향을 미친다. 따라서, SNR이 동일하더라도 서로 다른 전송 방식이 최적일 수 있지만, SNR을 이용하여 최적 전송 방식을 결정하는 기존의 적응적 변조 방법의 경우 채널 상태를 전혀 고려하지 않기 때문에 최적의 전송 방식이 선택되지 않을 수 있는 문제점이 존재한다.
- [0008] 본 발명의 배경이 되는 기술은 한국공개특허 제2007-0093557호(2007.09.19 공개)에 개시되어 있다.

**발명의 내용**

**해결하려는 과제**

- [0009] 본 발명은, 통신 환경에 따라 학습된 머신 러닝 모델을 기초로 각 채널 상태에 대응되는 최적 전송 방식을 결정함으로써 전송률을 개선할 수 있는 MIMO-OFDM 시스템 기반의 머신 러닝 모델을 이용한 적응적 전송 기법 결정 장치 및 그것을 이용한 적응적 전송 방법을 제공하는데 목적이 있다.

**과제의 해결 수단**

- [0010] 본 발명은, MIMO-OFDM 시스템 기반의 머신 러닝 모델을 이용한 적응적 전송 방법에 있어서, N개의 안테나를 가진 수신단에 수신된 신호의 채널 상태로부터 추출한 특징 정보를 입력으로 하고 상기 채널 상태에 대응하여 N개의 안테나를 가진 송신단의 각 안테나 별 적용되는 최적 전송 기법 정보를 정의한 레이블을 출력으로 하는 복수의 학습 데이터들을 사용하여 상기 머신 러닝 모델을 학습시키는 단계와, 상기 송신단의 송신 신호에 대응하여 수신되는 상기 수신단의 수신 신호로부터 채널 상태를 추정하고 채널 상태로부터 특징 정보를 추출하여 상기 학습된 머신 러닝 모델에 입력시키는 단계, 및 상기 입력된 특징 정보에 대응하여 상기 머신 러닝 모델에서 출력되는 레이블을 기초로 상기 송신단의 각 안테나 별 적용되는 최적 전송 기법 정보를 결정하여 상기 송신단으로 피드백하는 단계를 포함하는 MIMO-OFDM 시스템에서 머신 러닝 모델 기반의 적응적 전송 방법을 제공한다.
- [0011] 또한, 상기 머신 러닝 모델에 입력되는 상기 특징 정보는, 상기 수신된 신호의 SNR, 송수신단 사이의 N×N개 채널 정보, 그리고 상기 채널 정보를 보상하는 N×N개 채널 보상 정보를 포함하는 1+2N<sup>2</sup> 차원의 특징일 수 있다.
- [0012] 또한, 상기 적응적 전송 방법은, 상기 특징 정보를 상기 머신 러닝 모델에 입력하기 이전에 상기 추출된 특징 정보를 주성분 분석 기법을 통해 전처리하여 상기 특징 정보의 차원 수를 줄이는 단계를 더 포함할 수 있다.
- [0013] 또한, 상기 학습 데이터의 레이블에 정의된 최적 전송 기법 정보는, 상기 송신단의 N개 안테나에 각각 적용되는 N개의 최적 전송 기법의 조합을 의미하되, BPSK, QPSK, 16QAM, 64QAM을 포함한 M가지 전송 기법에 따라 구분되는 T가지(T = N<sup>M</sup>) 전송 기법 조합 중에서 상기 수신단에 수신된 신호의 검출 성능을 분석한 결과 기 설정된 목표 에러 성능을 만족하는 동시에 가장 높은 데이터율을 도출한 전송 기법 조합에 해당할 수 있다.
- [0014] 또한, 상기 학습 데이터에 라벨링되는 상기 레이블(k)은, 상기 수신된 신호의 검출 성능을 기초로 아래 수학적식에 의해 선택되되, 상기 T가지 전송 기법 조합 모두 상기 목표 에러 성능을 만족하지 못하면 T가지 중 1번째 전송 방식이 선택될 수 있다.

$$k = \begin{cases} \arg \max_t (\mathbf{R}^t) \text{ for } \forall t \text{ that} \\ \text{satisfy condition } (P_E)^t \leq T_E \\ 1, \text{ if } (P_E)^t > T_E \text{ for } \forall t \end{cases}$$

[0015] 여기서, T<sub>E</sub>는 상기 목표 에러 성능, (P<sub>E</sub>)<sup>t</sup>은 상기 시스템에 정의된 T가지 전송 기법 조합 중 t번째 조합에 대응된 에러 성능, R<sup>t</sup>은 상기 t번째 조합에서 사용되는 전송 비트 수, ∀t는 모든 가능한 변수 t에 대한 수식, arg max<sub>t</sub>(·)은 변수 m에 의해 변화되는 수식 결과 중 가장 큰 값을 도출하는 변수 k를 출력하는 식을 나타낸다.

- [0017] 또한, 상기 머신 러닝 모델을 학습시키는 단계는, 상기 머신 러닝 모델에서 출력 가능한 T개의 레이블 중 상기 입력된 특징 정보에 대응된 k번째 레이블이 최적일 확률값을 연산 후, 상기 확률값을 이용하여 크로스 엔트

로피에 의한 로스 값을 연산하며, 상기 로스값이 설정값 이하가 되도록 상기 머신 러닝 모델 내의 가중치 및 바이어스를 조정하여 상기 머신 러닝 모델을 학습시킬 수 있다.

[0018] 또한, 상기 확률값( $s_t$ ;  $t=k$ ) 및 상기 로스값( $L_{CE}$ )은 아래 수학적식으로 표현될 수 있다.

[0019] 
$$s_t = \frac{\exp(o_t)}{\sum_{i=1}^T \exp(o_i)}, t = \{1, 2, \dots, T\}$$

[0020] 
$$L_{CE} = - \sum_k \mathbf{T}_k \log s_k$$

[0021] 여기서, T는 상기 머신 러닝 모델의 출력 노드의 수,  $o_t(t=k)$ 는 상기 머신 러닝 모델에서 출력 가능한 T개의 레이블 중 상기 입력된 특징 정보에 대응된 k번째 레이블의 값,  $\mathbf{T}_k$ 는 상기 k번째 레이블에 대응된 행렬로

[0021] 
$$\mathbf{T}_k = \begin{bmatrix} 0 & 0 & \dots & 1 & \dots & 0 & 0 \end{bmatrix}'$$
 로 표현되며,  $\mathbf{T}_k$  내의 T개 성분 중 k번째 성분만 1이고 나머지는 0을 가진다.

[0022] 그리고, 본 발명은, MIMO-OFDM 시스템 기반의 머신 러닝 모델을 이용한 적응적 전송 기법 결정 장치에 있어서, N개의 안테나를 가진 수신단에 수신된 신호의 채널 상태로부터 추출한 특징 정보를 입력으로 하고 상기 채널 상태에 대응하여 N개의 안테나를 가진 송신단의 각 안테나 별 적용되는 최적 전송 기법 정보를 정의한 레이블을 출력으로 하는 복수의 학습 데이터들을 사용하여 상기 머신 러닝 모델을 학습시키는 학습부와, 상기 송신단의 송신 신호에 대응하여 수신되는 상기 수신단의 수신 신호로부터 채널 상태를 추정하고 채널 상태로부터 특징 정보를 추출하여 상기 학습된 머신 러닝 모델에 입력시키는 추출부, 및 상기 입력된 특징 정보에 대응하여 상기 머신 러닝 모델에서 출력되는 레이블을 기초로 상기 송신단의 각 안테나 별 적용되는 최적 전송 기법 정보를 결정하여 상기 송신단으로 피드백하는 결정부를 포함하는 적응적 전송 기법 결정 장치를 제공한다.

[0023] 또한, 상기 적응적 전송 기법 결정 장치는, 상기 특징 정보를 상기 머신 러닝 모델에 입력하기 이전에 상기 추출된 특징 정보를 주성분 분석 기법을 통해 전처리하여 상기 특징 정보의 차원 수를 줄이는 전처리부를 더 포함할 수 있다.

**발명의 효과**

[0024] 본 발명에 따르면, 채널 상태로부터 추출한 특징 정보 및 그에 대응된 최적 전송 기법을 머신 러닝 모델의 학습 데이터로 사용하여 송신단과 수신단 사이의 복잡한 채널 모델을 이해시킴에 따라, 동일 SNR 에서도 채널 상태에 따라 송신단의 각 안테나 별 서로 다른 전송 방식들을 최적 전송 방식으로 선택할 수 있으며 이를 통해 전송률을 높일 수 있다.

[0025] 또한, 본 발명에 따르면, 특징의 정보량을 분석하고 변형된 피쳐 공간에서 변형된 특징을 생성하는 모델을 추가로 결합하여 특징의 차원 수를 간소화하고 특징 간 분산을 증가시킴에 따라, 머신 러닝 모델에서 최적 전송 방식을 선택할 가능성을 더욱 높이고 이를 통해 전송률을 더욱 개선할 수 있는 효과가 있다.

**도면의 간단한 설명**

[0026] 도 1은 본 발명의 실시예에 따른 머신 러닝 모델을 이용한 적응적 전송 기법 결정 장치가 적용된 MIMO-OFDM 시스템 모델을 도시한 도면이다.

도 2는 도 1의 송신단에서 사용하는 각각의 변조 기법에 대한 정상도를 도시한 도면이다.

도 3은 본 발명의 실시예에 따른 적응적 전송 기법 결정 장치의 구성을 나타낸 도면이다.

도 4는 본 발명의 실시예에 따른 학습 데이터의 구조를 나타낸 도면이다.

도 5는 본 발명의 실시예에 따른 학습 데이터의 구조를 나타낸 도면이다.

도 6은 본 발명의 실시예에서 송신 안테나 별 적용되는 전송 방식에 따른 각 공간 스트림에 대한 변조 기법 및

데이터 비트수를 나타낸 테이블이다.

도 7은 본 발명의 실시예에 따른 딥 뉴럴 네트워크 모델의 구조를 도시한 도면이다.

도 8은 SNR에 따른 최적 전송 방식의 시뮬레이션 결과를 나타낸 그래프이다.

도 9는 SNR에 따른 기존 및 제안된 적응적 전송 방법에 의해 분류된 최적 전송 방식의 시뮬레이션 결과를 나타낸 그래프이다.

도 10은 통신 파라미터에 따른 제안된 모델의 최적 전송 방식의 분류 정확도에 대한 시뮬레이션 결과를 나타낸 테이블이다.

도 11은 도 9는 딥 뉴럴 네트워크 모델과 주성분 분석 모델로 구성되는 하이브리드 모델의 구조를 나타낸 도면이다.

도 12는 SNR에 따른 기존 및 제안된 모델의 평균 전송률에 대한 시뮬레이션 결과를 나타낸 그래프이다.

**발명을 실시하기 위한 구체적인 내용**

- [0027] 그러면 첨부한 도면을 참고로 하여 본 발명의 실시예에 대하여 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 상세히 설명한다.
- [0028] 도 1은 본 발명의 실시예에 따른 머신 러닝 모델을 이용한 적응적 전송 기법 결정 장치가 적용된 MIMO-OFDM 시스템 모델을 도시한 도면이다.
- [0029] 도 1에 나타난 바와 같이, MIMO-OFDM 통신 시스템은 송신단(Transmitter) 및 수신단(Receiver)를 포함하며, 송신단과 수신단의 각 안테나의 수는 N개로 동일한 것을 가정한다. 송신단은 피드백 링크를 통해 전송받은 정보를 참조하여 자신의 각 안테나에서 전송되는 공간 스트림에 실리는 데이터를 각기 다른 전송 기법을 사용하여 변조할 수 있다. 이하에서 송신단은 BPSK, QPSK, 16QAM, 64QAM을 포함한 4가지 전송 기법(L=4)을 사용하는 것을 가정한다.
- [0030] 도 2는 도 1의 송신단에서 사용하는 각각의 변조 기법에 대한 성상도를 도시한 도면이다. 도 2를 참조하면, 고차 변조일수록 하나의 심볼이 전송하는 데이터의 양이 증가되어 전송률이 증가되지만, 각 성상도 포인트 사이의 거리가 작아지기 때문에 잡음에 취약한 단점을 갖는다. 송신단의 전송 전력은 동일하기 때문에, 도 2의 각 변조 기법에 대한 성상도는 도 2에 기재된  $d_m$ 에 따라 정규화되며, R은 데이터율을 나타낸다.
- [0031] 도 1에 나타난 것과 같이, 본 발명의 실시예에 따른 적응적 전송 기법 결정 장치(100)는 MIMO-OFDM 시스템의 수신단(Receiver)에 포함되어 동작할 수 있다. 적응적 전송 기법 결정 장치(100)는 수신단(Receiver)에 수신된 수신 신호의 채널 상태를 분석하여 특징 정보를 추출하고 이를 미리 학습된 머신 러닝 모델에 입력시켜, 송신단(Transmitter)의 각 안테나 채널에 적용될 최적 전송(변조) 기법을 도출하고 이를 송신단(Transmitter)으로 피드백하여 제공한다.
- [0032] 이에 따라, 송신단(Transmitter)은 각 안테나 채널 별로 그에 대응된 최적 변조 기법을 적용하여 신호를 변조하여 전송할 수 있다. 또한, 이를 통해, 동일 SNR(Signal to Noise Rate)에서도 송수신단 사이의 채널 상태에 따라 송신단(Transmitter)의 각 안테나 별로 서로 다른 최적 전송 방식을 사용하여 신호를 전송할 수 있어 데이터 전송률을 개선할 수 있다.
- [0033] 도 3은 본 발명의 실시예에 따른 적응적 전송 기법 결정 장치의 구성을 나타낸 도면이다. 도 3 및 도 4를 참조하면, 본 발명의 실시예에 따른 적응적 전송 기법 결정 장치(100)는 학습부(110), 추출부(120), 결정부(130), 전처리부(140)를 포함한다.
- [0034] 학습부(110)는 수신단(Receiver)에 수신된 신호의 채널 상태로부터 추출한 특징 정보를 입력으로 하고 채널 상태에 대응하여 송신단(Transmitter)의 각 안테나 별 적용되는 최적 전송 기법 정보를 정의한 레이블을 출력으로 하는 복수의 학습 데이터들을 사용하여, 머신 러닝 모델을 학습시킨다(S410).
- [0035] 수신 신호로부터 추출한 특징 정보와 해당 수신 신호의 성능 분석 결과에 기초하여 얻은 레이블(label)은 도 1의 database에 저장되고 머신 러닝 모델의 학습 데이터로 사용된다. 수신 신호에 대한 특징 추출 및 그에 대응된 레이블 할당은 도 1의 Feature Extraction 및 Label Allocation 블록에서 각각 수행된다.
- [0036] 이와 같이 학습부(110)는 수집된 학습 데이터들을 기초로 머신 러닝 모델을 학습시킨다. 학습 과정에서 가중치

및 바이어스 조정을 통한 모델 최적화가 이루어진다. 학습이 완료된 이후부터는 수신단(Receiver)에 신호가 수신되면 수신 신호로부터 채널 상태를 분석하여 채널 상태에 대응된 특징 정보를 머신 러닝 모델에 입력하고 머신 러닝 모델에서 출력되는 레이블을 기초로 최적 전송 기법 정보를 결정할 수 있다.

- [0037] 이를 위해, 추출부(120)는 송신단의 송신 신호에 대응하여 수신되는 수신단(Receiver)의 수신 신호로부터 채널 상태를 추정하고 채널 상태로부터 특징 정보를 추출하여, 머신 러닝 모델에 입력시킨다(S420).
- [0038] 결정부(130)는 입력된 특징 정보에 대응하여 머신 러닝 모델에서 출력되는 레이블을 기초로 송신단(Transmitter)의 각 안테나 별 적용되는 최적 전송 기법 정보를 파악하고 이를 송신단(Transmitter)으로 피드백하여 제공한다(S430).
- [0039] 즉, 본 발명의 실시예는 현재 수신 신호에 대한 특징 정보를 머신 러닝 모델에 입력하는 것만으로 송신단의 각 안테나에 적용될 최적 전송 기법을 결정하여 이를 송신단(Transmitter)으로 제공할 수 있다.
- [0040] 전처리부(140)는 특징 정보를 머신 러닝 모델에 입력하기 이전에, 해당 특징 정보를 주성분 분석 기법(PCA; Principal Component Analysis)을 통해 전처리하여 특징 정보의 차원 수를 줄이고 특징을 변형한다. 이러한 전처리부(140)는 데이터 학습 과정 또는 학습 이후 수신 신호에 대한 결과 도출 과정에 적용될 수 있다.
- [0041] 이와 같이, 주성분 분석 모델을 이용할 경우 특징의 차원 수를 줄이고 특징 간 분산을 높일 수 있어, 머신 러닝 모델에서 최적 전송 기법을 선택할 가능성을 높여주고 모델의 신뢰성을 높일 수 있다. 이에 대해서는 추후 상세히 설명할 것이다.
- [0042] 이하에서는 머신 러닝 모델의 학습 과정에 대하여 상세히 설명한다. 학습 데이터는 채널 상태에 따른 특징 정보 및 그에 대응된 최적 전송 기법에 대한 레이블의 세트르 구성된다. 학습 데이터가 다양할수록 머신 러닝 모델의 성능 및 정확도가 높아진다.
- [0043] 본 발명의 실시예에서 머신 러닝 모델은 입력된 특징 정보에 대응하여 해당 레이블을 출력하도록 학습되며, 도 5에 도시된 학습 데이터에 의해 모델링된다.
- [0044] 도 5는 본 발명의 실시예에 따른 학습 데이터의 구조를 나타낸 도면이다. 학습 데이터는 특징(feature) 및 레이블(label)의 세트르 구성되며, 이들은 각각 머신 러닝 모델의 입력 및 출력 노드에 대입되어 학습된다.
- [0045] 도 5에서와 같이, 특징 정보는 수신 신호의 SNR, 송수신단 간의  $N \times N$ 개 채널 정보, 그리고 채널 정보를 보상하는  $N \times N$ 개 채널 보상 정보를 포함한 다차원의 특징으로, 실질적으로 [1개의 SNR +  $N^2$ 개의 채널 정보 +  $N^2$ 개의 채널 보상 정보]에 의한  $1+2N^2$  차원의 특징 구조를 가진다.
- [0046] 특징 정보를 더욱 구체적으로 설명하면 다음과 같다. 머신 러닝 모델에서 사용되는 피쳐(이하, 특징)는 수신 신호의 데이터에서 추출 가능한 파라미터로 구성되어야 한다.
- [0047] 특징 정보는 수신 신호의 잡음의 민감도를 결정하는 요소인 SNR의 추정치와 추정된 채널 계수 및 채널을 보상하는 보상 행렬의 계수로 구성된다.
- [0048] 수신단(Receiver)에서 잡음이 부가되어 수신된 MIMO-OFDM 심볼은 다음의 수학적 식 1과 같이 나타낼 수 있다.

**수학적 식 1**

$$y = h * x + n = \sum_{i=1}^N \sum_{j=1}^N h_{i,j} * x_j + n_i$$

- [0049]
- [0050] 여기서, y는 수신된 MIMO-OFDM 심볼을 나타내며, h는 송신단(Transmitter)의 N개 송신 안테나 및 수신단(Receiver)의 N개 수신 안테나에 의해 구성되는 MIMO 채널이며,  $h_{i,j}$ 는 j번째 송신 안테나와 i번째 수신 안테나 사이의 채널을 의미한다.
- [0051] x는 각 송신 안테나로부터의 송신 신호이며,  $x_j$ 는 j번째 송신 안테나로부터의 전송 신호를 의미한다. 또한 n은 백색 가우시안 잡음(Additive White Gaussian Noise; AWGN)을 의미하며,  $n_i$ 는 i번째 수신 안테나의 백색 가우시

안 잡음을 의미한다. 수신된 MIMO-OFDM 심볼은 채널 보상을 위하여, FFT(fast Fourier transform)를 통해 주파수 영역으로 다음의 수학적 식 2와 같이 변환된다.

수학적 식 2

$$\mathbf{Y} = \mathbf{H}\mathbf{X} + \mathbf{N}$$

신호 검출에 대한 채널 보상 과정은 다음의 수학적 식 3과 같다.

수학적 식 3

$$\hat{\mathbf{X}} = \mathbf{G}\mathbf{Y} = \mathbf{X} + \mathbf{N}'$$

수학적 식 3에서  $\mathbf{G}$ 는 아래 수학적 식 4와 같이 추정된 채널  $\hat{\mathbf{H}}$ 의 Moore-Penrose 준 역행렬을 의미하며 채널 보상을 위해 수신 신호에 곱하여진다.

수학적 식 4

$$\mathbf{G} = (\hat{\mathbf{H}}^H \hat{\mathbf{H}})^{-1} \hat{\mathbf{H}}^H$$

학습 데이터의 특징 중 SNR은 주파수 영역에서의 수신 신호  $\mathbf{Y}$ 와 백색 가우시안 잡음  $\mathbf{N}$ 의 전력비를 나타내며, 채널 성분은 수신 신호의 전력에 영향을 미친다. 수학적 식 4의 채널 보상 행렬  $\mathbf{G}$ 는 채널 보상 후의 잔여 잡음 ( $\mathbf{N}'$ )에 영향을 미친다. 따라서 학습 데이터의 특징으로 구성되는 SNR, 추정된 채널 행렬 및 채널 보상 행렬은 수신 신호에 대한 잡음의 민감성 정도를 나타내는 지표가 된다. 또한, 모든 특징들은 기존의 통신 시스템에서 추정 및 생성 가능하다. 추정된 채널 행렬 및 채널 보상 행렬은 도 5에서와 같이 각 계수에 대한 절댓값(abs)으로 저장된다.

머신 러닝 모델의 입력 노드의 개수는 특징의 차원 수에 따라 결정될 수 있고 출력 노드의 개수는 레이블 수에 따라 결정될 수 있다. 레이블의 수는  $N^M$  개이며 송신 안테나의 개수  $N$ 과 지원하는 전송 기법의 개수  $M$ 에 의해 결정된다.

본 발명의 실시예에서 학습 데이터의 레이블에 정의된 최적 전송 기법 정보란, 송신단의  $N$ 개 안테나에 각각 적용되기 위한  $N$ 개의 최적 전송 기법의 조합을 의미하는 정보이다. 본 실시예의 경우, 송신단(Transmitter)에서 4가지 전송 기법(BPSK, QPSK, 16QAM, 64QAM;  $M=4$ )을 지원하고 송신 안테나의 개수는 4개( $N=4$ )이므로, 가능한 전송 기법 조합은 총 256가지( $N^M = 256$ )가 존재할 수 있다. 즉, 레이블의 개수는 가능한 모든 전송 기법 조합의 개수와 동일한 것을 알 수 있다.

도 6은 본 발명의 실시예에서 송신 안테나 별 적용되는 전송 방식에 따른 각 공간 스트림에 대한 변조 기법 및 데이터 비트수를 나타낸 테이블이다. 표에서 아래로 갈수록 사용 비트수가 많기 때문에, 데이터율이 높아진다.

도 6에서 index는 1부터 256까지 존재하는데, 이는 레이블 각각의 인덱스를 나타낸다. 또한, 도 6의 상단에 stream 1~4는 송신 안테나 1~4에 해당하고 R은 전송 비트 수를 나타낸다. 레이블은 총 256가지 존재하며 이는 곧 256가지의 전송 기법 조합 정보에 해당한다.

여기서, index=1에 해당하는 첫 번째 레이블은 송신 안테나 1,2,3,4를 통해 모두 BPSK 방식으로 변조된 신호를 전송한 경우이므로 총 사용 비트 수는 4(=1+1+1+1)이며, index=256에 해당하는 마지막 레이블은 송신 안테나 1,2,3,4 모두 64QAM 방식으로 변조된 신호를 전송한 경우이므로 총 사용 비트수는 24(=6+6+6+6)이다.

[0063] 본 발명의 실시예에서 학습 데이터의 레이블에 정의된 최적 전송 기법 정보란, 256가지 전송 기법 조합 중에 수신단(Receiver)에 수신된 신호의 검출 성능을 분석한 결과 기 설정된 목표 에러 성능을 만족하는 동시에 가장 높은 데이터율을 도출한 전송 기법 조합에 해당할 수 있다.

[0064] 학습 데이터의 레이블은 특징들로 표현되는 각 채널 상태에서의 최적 전송 방식으로서 특징 정보와 함께 데이터 베이스(database)에 저장되며, 최적 전송 기법은 미리 정의된 목표 신뢰도를 만족하는 동시에 지원되는 전송 방식 중 가장 높은 데이터율을 가지는 전송 방식으로 정의된다. 시뮬레이션을 위해, 목표 신뢰도는 0.1의 PER로 정의하였다.

[0065] 본 발명의 실시예에서 학습 데이터에 라벨링되는 레이블(k)은 수신된 신호의 검출 성능을 기초로 아래 수학적 식 5에 의해 선택된다.

**수학적 식 5**

$$k = \begin{cases} \arg \max_t (\mathbf{R}^t) \text{ for } \forall t \text{ that} \\ \text{satisfy condition } (P_E)^t \leq T_E \\ 1, \text{ if } (P_E)^t > T_E \text{ for } \forall t \end{cases}$$

[0067] 여기서,  $T_E$ 는 목표 에러 성능(=신뢰도),  $(P_E)^t$ 은 본 시스템에 정의된 T가지 전송 기법 조합 중 t번째 조합에 대응된 에러 성능,  $\mathbf{R}^t$ 은 t번째 조합에서 사용되는 전송 비트 수,  $\forall t$ 는 모든 가능한 변수 t에 대한 수식,  $\arg \max_t (\cdot)$ 은 변수 m에 의해 변화되는 수식 결과 중 가장 큰 값을 도출하는 변수 k를 출력하는 식을 나타낸다.

[0068] 전송 안테나 및 수신 안테나의 수가 각각 4일 때, 시스템에서 정의된 전송 방식 조합의 예는 도 6에 나타낸 바 있다. 수학적 식 6의  $\arg \max_t$ 에 의한 첫 줄의 수식은 목표 에러 성능을 만족시키는 모든 256개의 전송 방식 조합 중 가장 높은 데이터율을 가지는 방식을 최적 전송 방식 조합으로 선택하기 위한 수식이다. 수학적 식 6의 두 번째 줄의 수식은 T가지 전송 기법 조합 모두 목표 에러 성능을 만족시키지 못하면 그 중에서 가장 높은 신뢰도를 가지는 1번째 전송 기법 조합(index=1에 해당하는 조합)을 최적 전송 기법으로 선택한다. 선택된 전송 방식의 인덱스 k는 레이블로서 저장된다.

[0069] 본 발명의 실시예에서 학습 모델은 지도 학습 및 비지도 학습 모델로 구성된다. 지도 학습 모델로는 딥 뉴럴 네트워크가 사용된다.

[0070] 도 7은 본 발명의 실시예에 따른 딥 뉴럴 네트워크 모델의 구조를 도시한 도면이다. 도 7에서 Input layer의 뉴런의 수는 수신된 신호로부터 추출된 특징의 수(차원)에 따라 조정된다. Input layer, 다수의 hidden layer 및 output layer의 뉴런들은 각각  $\mathbf{I}$ ,  $\mathbf{H}$  및  $\mathbf{O}$ 로 표기된다. 또한 각 layer 사이의 가중치 및 바이어스는 각각  $\mathbf{W}$ 와  $\mathbf{b}$ 로 표기된다. Hidden layer와 output layer의 뉴런들의 값들은 다음의 수학적 식 6으로 표현할 수 있다.

**수학적 식 6**

$$\begin{aligned} \mathbf{H}_1 &= \text{ReLU}(\mathbf{W}_1 \mathbf{I} + \mathbf{b}_1), \\ \mathbf{H}_i &= \text{ReLU}(\mathbf{W}_i \mathbf{H}_{i-1} + \mathbf{b}_i), \quad i = \{ 2, 3, \dots, L - 1 \} \\ \mathbf{O} &= \text{ReLU}(\mathbf{W}_L \mathbf{H}_{L-1} + \mathbf{b}_L) \end{aligned}$$

[0072] 여기서, ReLU(rectified linear unit)는 최근의 뉴럴 네트워크에서 주로 사용되는 활성화 함수를 의미한다. Output layer의 각 뉴런(노드)은 송신단(Transmitter)에서 사용 가능한 전송 기법 정보에 대한 각 레이블의 개수(T)에 대응한다.

[0073] Output layer의 각 뉴런은 입력된 특징들에 대하여 대응되는 레이블(=최적 전송 기법 정보)이 최적일 확률에 대한 수치를 유도한다. 확률값( $s_t$ ;  $t=k$ )은 다음의 수학적 식 7과 같이 softmax function을 통해 확률의 형태로 변형된다.

수학적 식 7

$$s_t = \frac{\exp(o_t)}{\sum_{i=1}^T \exp(o_i)}, t = \{1, 2, \dots, T\}$$

[0074] 수학적 식 7에서 T는 output layer의 뉴런들의 수를 의미하며, 시스템에서 전송 가능한 전송 방식 조합의 개수인 레이블 수와 동일하다. 입력된 특징들에 대응되는 레이블은 수신된 신호의 검출 성능 분석을 통해, 각 학습 데이터에 할당되기 때문에, 입력된 특징들에 따른 최적 전송 방식에 대한 사전 정보를 크로스 엔트로피(cross entropy layer)에서 활용할 수 있다. Cross entropy에 의한 로스값(loss;  $L_{CE}$ )은 다음의 수학적 식 8과 같이 표현된다.

수학적 식 8

$$L_{CE} = - \sum_k T_k \log s_k$$

[0075] 여기서,  $T_k$ 는 k번째 레이블에 대응된 행렬로서 수학적 식 9과 같이 표현된다.

수학적 식 9

$$T_k = [0 \quad 0 \quad \dots \quad \underset{(k\text{-th component})}{1} \quad \dots \quad 0 \quad 0]'$$

[0076] 수학적 식 9에서 알 수 있듯이, 행렬  $T_k$ 는  $T_k$  내의 T개 성분 중 k번째 성분만 1이고 나머지는 0을 가진다. 이를 수학적 식 8에 대입하면 로스값이 연산된다.

[0077] 도 7의 Cross entropy layer로부터 유도된 loss에 기반한 역전파(back propagation)를 통하여, 각 레이어 사이의 가중치들은 softmax layer의 결과가 행렬  $T_k$ 로 유도되도록 조정된다. 이와 같은 학습 과정을 통하여, 딥 뉴럴 네트워크 모델은 입력된 수신 신호에 대한 잡음의 민감도에 대한 특징들과 최적 전송 방식 사이의 관계를 파라미터화한다.

[0078] 이와 같이, 본 발명의 실시예에서 학습부(110)는 머신 러닝 모델에서 출력 가능한 T개의 레이블 중에서, 입력된 특징 정보에 대응된 k번째 레이블이 최적일 확률값을 연산한 후 연산된 확률값을 이용하여 크로스 엔트로피에 의한 로스 값을 연산한다. 그리고, 로스값이 설정값 이하가 되도록 머신 러닝 모델 내의 가중치 및 바이어스를 조정하여 머신 러닝 모델을 학습시키고 최적화한다.

[0079] 도 8은 SNR에 따른 최적 전송 방식의 시뮬레이션 결과를 나타낸 그래프이다. 도 8의 각 도면에서 가로축은 SNR, 세로축은 레이블의 개수(T)를 나타낸다.

[0080] 시뮬레이션 파라미터로서, 전송 안테나 및 수신 안테나의 수 N은 1 ~ 4개로 정하였고, 각 송/수신 안테나에서 사용가능한 변조 기법의 수 M은 2 ~ 4로 정하였다. 변조 기법의 수가 2일 경우에는 BPSK와 QPSK를 사용하는 경우를 의미하며, 3일 경우에는 BPSK, QPSK 및 16-QAM, 그리고 4일 경우에는 BPSK, QPSK, 16-QAM 및 64-QAM을 사용하는 경우를 의미한다. 따라서, 앞서 설명한 바와 같이, 각 파라미터에 대하여 사용 가능한 전송 기법 조합의

수(T)는  $M^N$  개가 되며 이는 곧 레이블 종류를 의미하므로, 도 8의 각 도면에서 세로축의 스케일은 달라진다.

- [0084] 각 파라미터에 대하여 100,000개의 MIMO-OFDM 패킷에 대하여 시스템에서 결정한 최적 전송 방식(전송 기법 조합)은 도 6에서 정의한 인덱스의 형태로 표기되어 있다. 도 8에서 각각의 점이 위치한 세로축 값은 해당 SNR에서 선택되는 최적 전송 기법에 대한 레이블 인덱스에 해당한다.
- [0085] 파라미터에 따라서 최적 전송 방식으로 할당되지 않는 전송 방식도 발생될 수 있다. 예를 들어, SISO(single input single output) 시스템 ( $M=1$ )의 경우, 대부분의 데이터들은 SNR에 따라 분류될 수 있지만, MIMO 채널 환경에서 안테나의 수가 증가할수록 채널 성분들의 수( $M^2$ )가 증가되고 검출 성능이 각 성분들 사이의 상관 관계에 크게 영향받기 때문에, SNR에 따른 분류는 어려워진다. 또한 안테나의 수와 사용 가능한 변조 기법의 수가 증가함에 따라 사용될 수 있는 전송 기법 조합의 수가 증가되기 때문에, 데이터의 분류는 더 어려워진다.
- [0086] 도 8의 시뮬레이션 결과를 보면, 본 발명의 실시예를 사용할 경우, 동일 SNR에서도 서로 다른 전송 방식이 최적 전송 방식으로 할당됨을 확인할 수 있다. 100,000개의 데이터 중 2,000개 (2%)의 데이터가 모델을 학습시키기 위해 사용되었으며, 테스트는 학습 데이터를 포함한 모든 데이터가 사용되었다. 실제로 기존 및 제안된 모델에 의해 분류된 SNR에 따른 최적 전송 방식은 도 9과 같다.
- [0087] 도 9는 SNR에 따른 기존 및 제안된 적응적 전송 방법에 의해 분류된 최적 전송 방식의 시뮬레이션 결과를 나타낸 그래프이다.
- [0088] 도 9에서 초록색 역삼각형 포인트의 데이터는 제안 모델을 사용한 결과이고, 검정색 삼각형 포인트의 데이터는 기존 모델 즉, 채널 상태를 고려하지 않고 SNR만을 고려하여 전송 기법을 결정하는 기존 방식을 사용한 경우이다.
- [0089] 도 9의 결과로부터, 기존의 적응적 전송 기법과 달리, 제안된 모델에 의한 적응적 전송 기법은 동일 SNR에서도 입력된 특징들에 따라 서로 다른 전송 방식을 최적 전송 방식으로 분류함을 확인할 수 있다. 따라서 제안된 모델은 기존의 방법보다 MIMO 채널 환경에 따라 합리적인 적응성을 가짐을 시뮬레이션 결과로부터 확인할 수 있다.
- [0090] 도 10은 통신 파라미터에 따른 제안된 모델의 최적 전송 방식의 분류 정확도에 대한 시뮬레이션 결과를 나타낸 테이블이다.
- [0091] 비록 분류 정확도가 채널 성분 및 사용 가능한 변조 기법들의 수가 증가함에 따라 감소하는 경향을 가지지만, 분류 정확도는 수학적 5에 의해 할당된 최적 전송 방식의 분류 확률을 의미하며, 신호 검출에 대한 에러를 의미하는 것은 아니다. 그러나, 평균 전송률은 타겟 에러 성능을 만족시키는 동시에 최대의 데이터율을 가지는 최적 전송 방식을 정확하게 결정할수록 증가하기 때문에, 분류 정확도는 성능의 중요한 척도로 고려되어야 한다.
- [0092] 비록 검출 과정에서 통신 시스템의 성능에 영향을 미치는 요소들을 딥 뉴럴 네트워크의 input layer에 입력 특징들로서 할당하였지만, 통신 환경에 따라 할당된 특징들은 최적이지 아닐 수 있다. 모델의 성능은 특징의 적합성에 크게 의존하기 때문에, 특징들의 정보 손실을 최소한으로 유지하면서, 새로운 특징 공간에서 특징들을 변형하는 주성분 분석(PCA 기법)을 활용하여 딥 뉴럴 네트워크 모델의 성능을 개선할 수 있다.
- [0093] 도 11은 도 9는 딥 뉴럴 네트워크 모델과 주성분 분석 모델로 구성되는 하이브리드 모델의 구조를 나타낸 도면이다. SNR과  $M^2$ 개의 채널 성분 및  $M^2$ 개의 채널 보상 성분으로 구성되는  $2M^2+1$  차원의 특징들은 PCA를 통하여,  $2M^2+1$  내지 1 차원으로 변형되고, 딥 뉴럴 네트워크 모델의 입력으로 할당될 수 있다.
- [0094] 또한, 기존의 특징들은 주성분 분석 모델 없이 딥 뉴럴 네트워크 모델의 입력으로 할당될 수 있다. 기존의 특징들을 어떻게 변형할지에 대한 여부는 도 10의 각 특징 차원에서 변형된 특징들을 입력으로 할당한 경우의 학습 데이터에 대한 분류 정확도 성능을 비교하여 결정된다. 도 10에서 F는 PCA 적용 전의 기존 특징들의 차원을 의미한다. 도 10에서 파란색으로 표시된 수치는 해당 통신 파라미터에 대한 최적 모델에 대한 값이며, 비교를 위해 가장 좋지 못한 성능을 가진 모델의 수치를 빨간색으로 표기하였다. 특징의 차원이 감소할수록 특징의 정보 손실이 크기 때문에, 이와 같은 성능 분석을 하기 전에, 특정 파라미터에 대한 최적 모델은 확인할 수 없다. 성능 분석은 학습 데이터를 통해 이루어지며, 학습 데이터를 통해, 딥 뉴럴 네트워크 모델의 가중치에 대한 학습 및 주성분 분석 모델의 특징 전처리 방법이 결정되면 모든 모델링 과정이 완료된다.
- [0095] 도 12는 SNR에 따른 기존 및 제안된 모델의 평균 전송률에 대한 시뮬레이션 결과를 나타낸 그래프이다. 도 12에

서 검정색 점선은 기존 기법에 대한 결과이고, 파란색 점선은 본 발명의 기법에서 비지도 기법인 PCA를 사용하지 않은 경우의 결과이며, 빨간색은 PCA를 사용한 경우의 결과를 나타낸다. 전송률은 아래의 수학적 식 10을 통해 연산될 수 있다.

**수학적 식 10**

$$\text{Throughput} = (1 - \text{PER}) \times R^k$$

[0096]

[0097]

수학적 식 10에서  $R^k$ 는 도 6과 같은 통신 시스템에서 전송 가능한 전송 방식 중, 제안된 모델에 의해 선택된 k번째 전송 방식의 데이터율을 의미한다. 시뮬레이션 결과들로부터 제안된 모델의 성능은 대부분의 SNR 범위에서 기존의 방법보다 상당히 개선된 전송률 성능을 확인할 수 있다.

[0098]

기존 적응적 전송 기법의 경우, 성능이 크게 변화하는 SNR의 경계에서 데이터율이 계단식으로 급격히 변동하지만, 제안된 모델에 의한 전송 방식들은 동일 SNR에 대해 다른 전송 기법을 선택하여 사용할 수 있기 때문에, 부드러운 커브 형태를 가지는 것을 알 수 있다. 또한, 모델의 분류 정확도가 높을수록 앞서 SNR의 경계에서 발생하는 성능 하락의 정도가 감소하기 때문에, 모델의 성능을 개선하게 되면 평균 전송률 성능을 개선할 수 있다.

[0099]

이상과 같은 본 발명에 따르면, 채널 상태로부터 추출한 특징 정보 및 그에 대응된 최적 전송 기법을 머신 러닝 모델의 학습 데이터로 사용하여 송신단과 수신단 사이의 복잡한 채널 모델을 이해시킴에 따라, 동일 SNR 에서도 채널 상태에 따라 송신단의 각 안테나 별 서로 다른 전송 방식들을 최적 전송 방식으로 선택할 수 있으며 전송률을 개선할 수 있다.

[0100]

또한, 본 발명은 머신 러닝 모델의 성능이 학습 데이터의 특징 정보에 의해 크게 의존하는 점을 고려하여, 각 특징의 정보량을 분석하고 변형된 피쳐 공간에서 변형된 특징을 생성하는 모델을 추가로 결합하여 특징의 차원수를 간소화하고 특징 간 분산을 증가시킴에 따라, 머신 러닝 모델에서 최적 전송 방식을 선택할 가능성을 더욱 높이고 이를 통해 전송률을 더욱 개선할 수 있는 효과가 있다.

[0101]

본 발명은 도면에 도시된 실시 예를 참고로 설명되었으나 이는 예시적인 것에 불과하며, 본 기술 분야의 통상의 지식을 가진 자라면 이로부터 다양한 변형 및 균등한 다른 실시 예가 가능하다는 점을 이해할 것이다. 따라서, 본 발명의 진정한 기술적 보호 범위는 첨부된 특허청구범위의 기술적 사상에 의하여 정해져야 할 것이다.

**부호의 설명**

[0102]

100: 적응적 전송 기법 결정 장치 110: 학습부

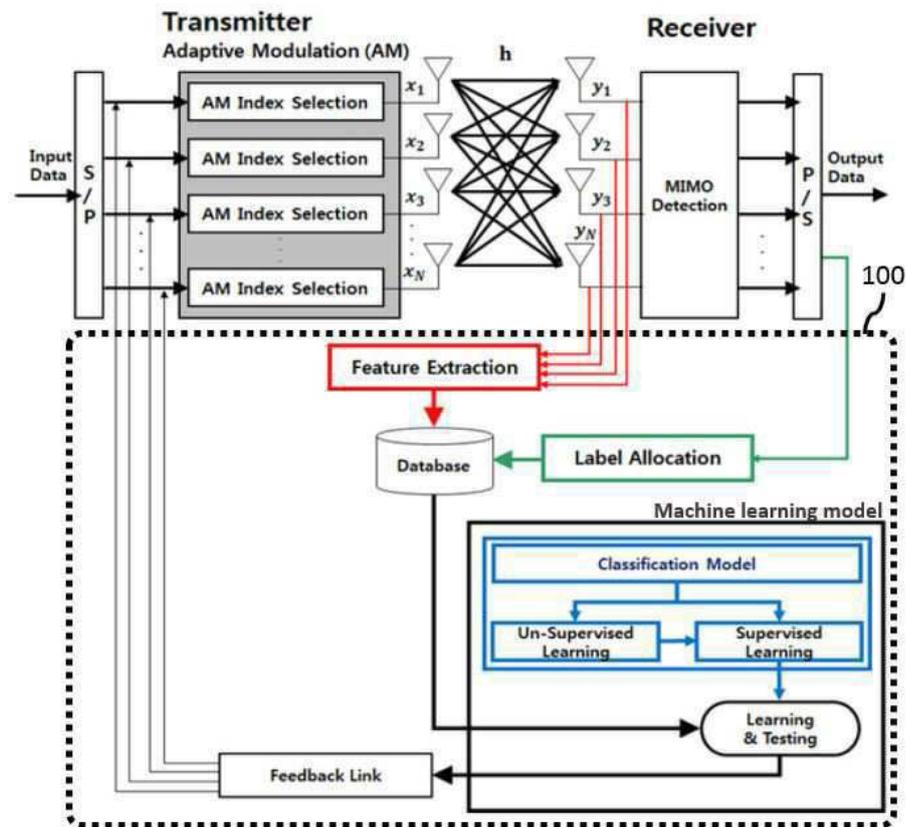
120: 추출부

130: 결정부

140: 전처리부

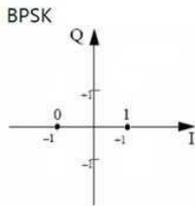
도면

도면1

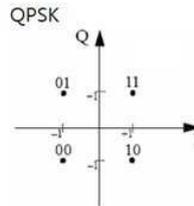


도면2

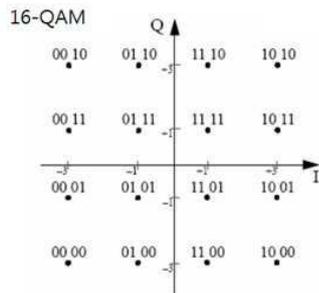
Modulation Scheme	$d_{rm}$	$R$
BPSK	1	1
QPSK	$1/\sqrt{2}$	2
16QAM	$1/\sqrt{10}$	4
64QAM	$1/\sqrt{42}$	6



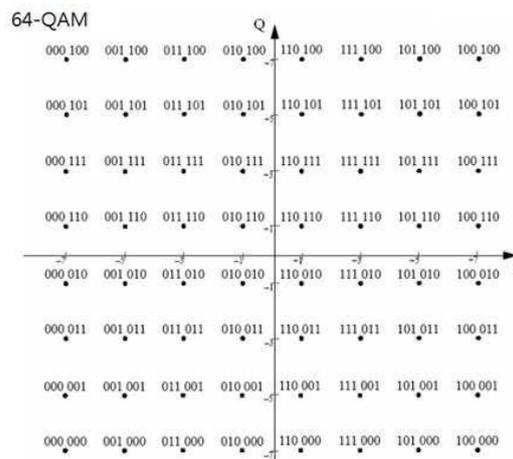
(a)



(b)



(c)

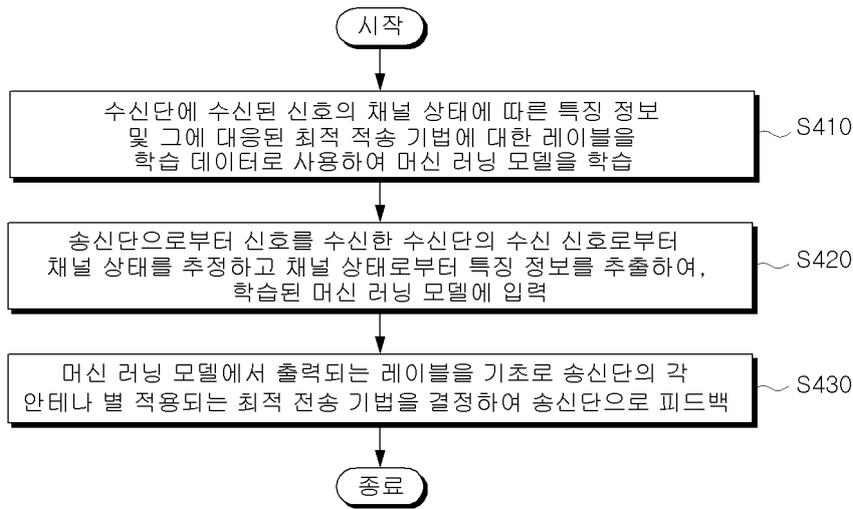


(d)

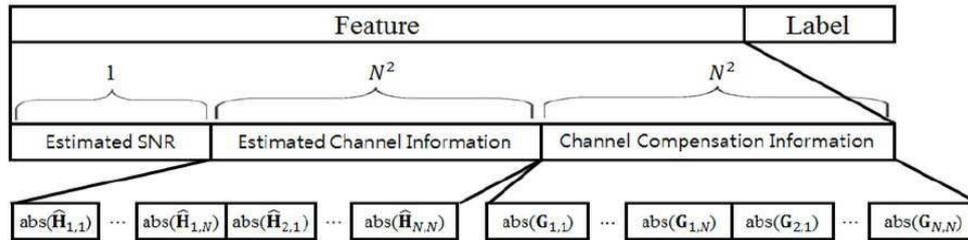
도면3



도면4



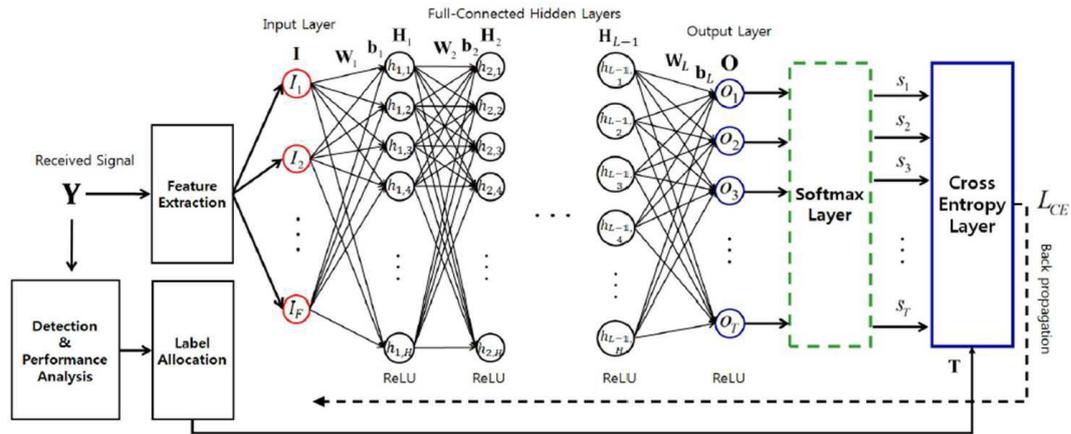
도면5



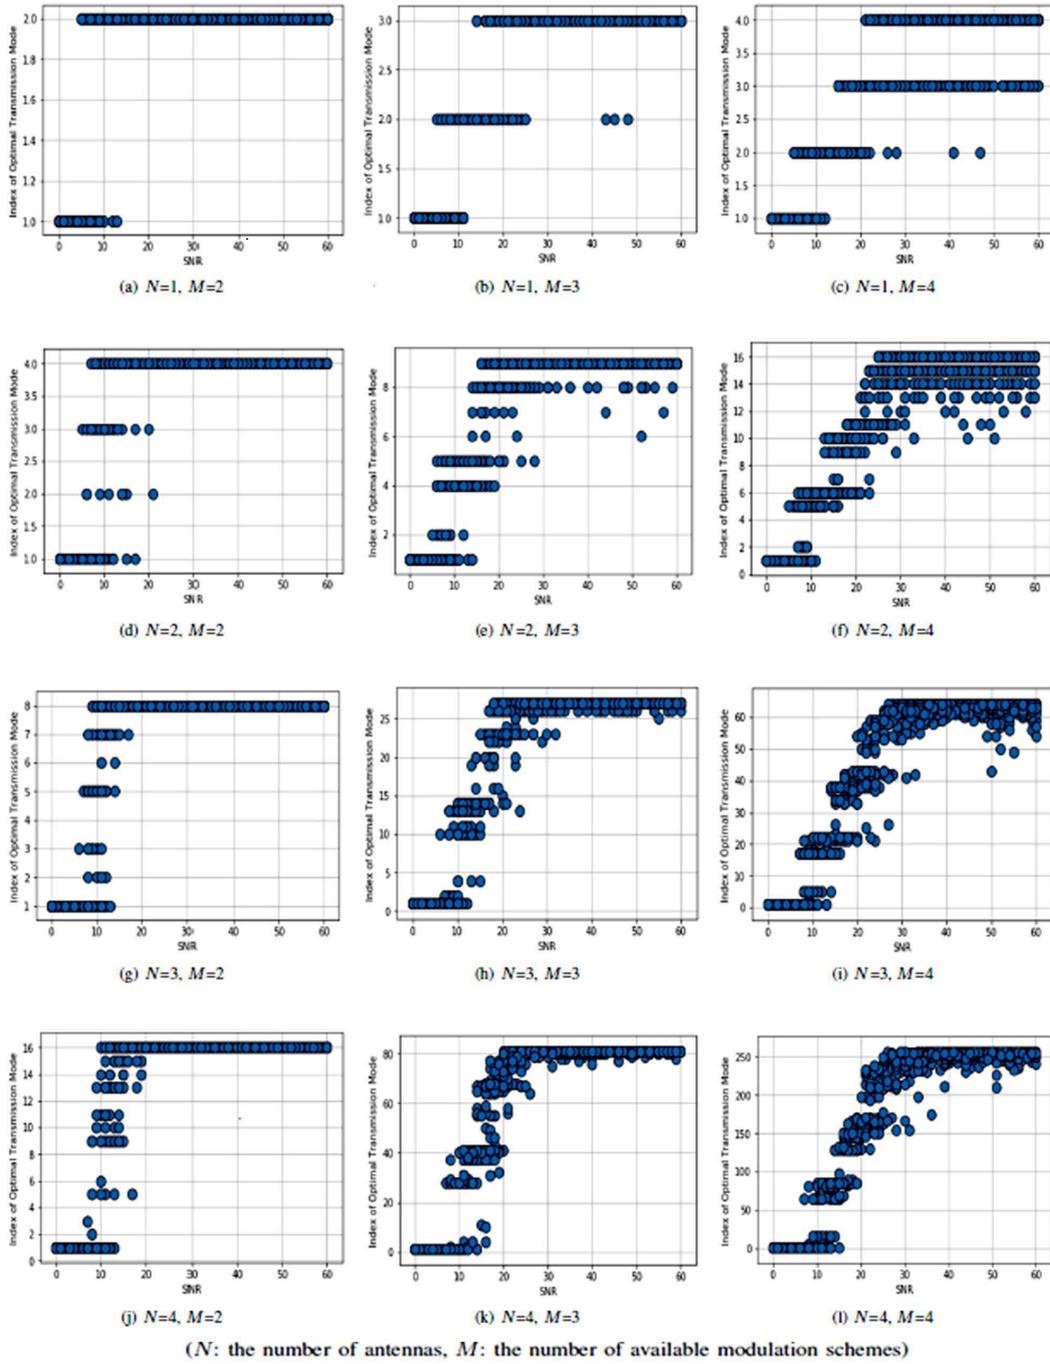
도면6

index	Modulation Scheme				R
	Stream 1	Stream 2	Stream 3	Stream 4	
1	BPSK	BPSK	BPSK	BPSK	4
2	QPSK	BPSK	BPSK	BPSK	5
3	16 QAM	BPSK	BPSK	BPSK	7
4	64 QAM	BPSK	BPSK	BPSK	9
5	BPSK	QPSK	BPSK	BPSK	5
6	QPSK	QPSK	BPSK	BPSK	6
7	16 QAM	QPSK	BPSK	BPSK	8
8	64 QAM	QPSK	BPSK	BPSK	10
9	BPSK	16 QAM	BPSK	BPSK	7
10	QPSK	16 QAM	BPSK	BPSK	8
⋮	⋮	⋮	⋮	⋮	⋮
250	QPSK	16 QAM	64 QAM	64 QAM	18
251	16 QAM	16 QAM	64 QAM	64 QAM	20
252	64 QAM	16 QAM	64 QAM	64 QAM	22
253	BPSK	64 QAM	64 QAM	64 QAM	19
254	QPSK	64 QAM	64 QAM	64 QAM	20
255	16 QAM	64 QAM	64 QAM	64 QAM	22
256	64 QAM	64 QAM	64 QAM	64 QAM	24

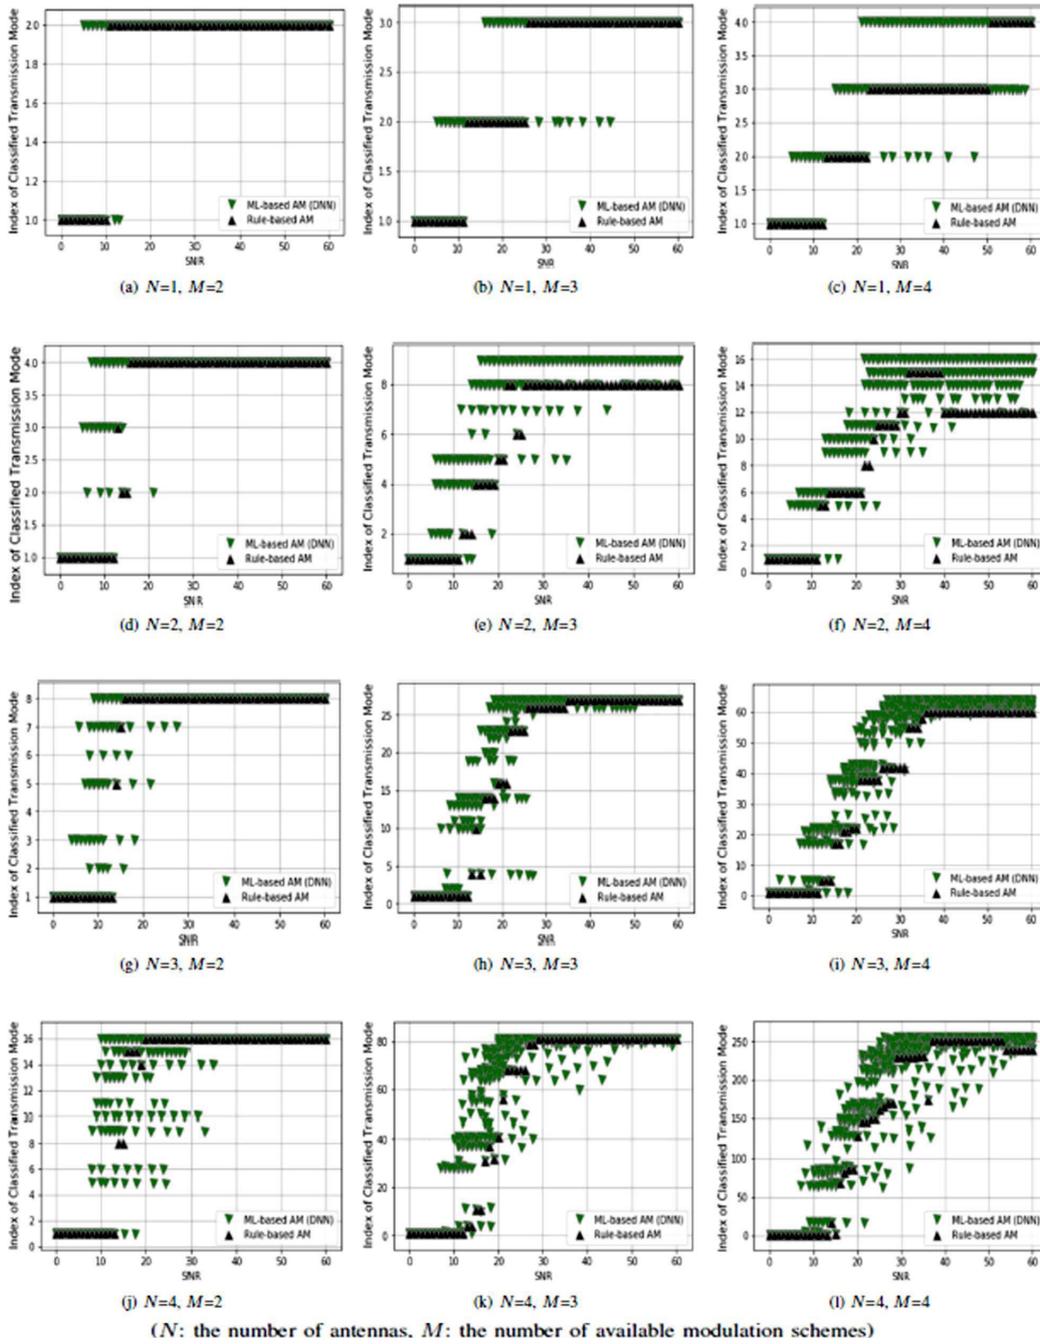
도면7



도면8



도면9

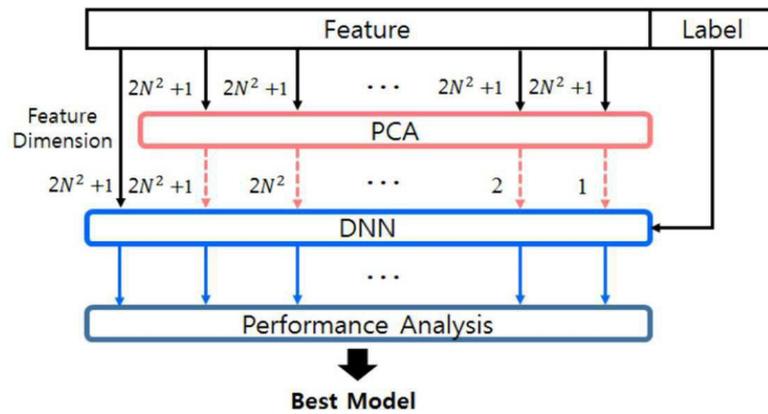


도면10

( $N$ : THE NUMBER OF ANTENNAS,  $M$ : THE NUMBER OF AVAILABLE MODULATION SCHEMES,  $F$ : THE NUMBER OF ORIGINAL FEATURES)  
 (BEST MODEL, WORST MODEL)

	$N$	1			2			3			4			
		$M$	2	3	4	2	3	4	2	3	4	2	3	4
DNN	Feature Dimension													
	$F(= 2N^2 + 1)$	0.9698	0.8894	0.6547	0.9228	0.5478	0.4533	0.9627	0.6748	0.4317	0.8473	0.6744	0.3006	
	$F(= 2N^2 + 1)$	0.9932	0.9436	0.7469	0.9108	0.7457	0.5371	0.9588	0.7695	0.5290	0.8160	0.6756	0.3804	
	$F - 1$	0.9914	0.9026	0.7136	0.9149	0.7468	0.5234	0.9461	0.7629	0.5097	0.8152	0.6765	0.3290	
	$F - 2$	0.8867	0.6831	0.4866	0.9063	0.7316	0.5193	0.9432	0.7614	0.4971	0.8060	0.6806	0.3117	
	$F - 3$				0.8965	0.7186	0.5159	0.9394	0.7603	0.4694	0.8070	0.6875	0.3001	
	$F - 4$				0.8763	0.6837	0.4723	0.9362	0.7584	0.4577	0.8027	0.6721	0.2791	
	$F - 5$				0.8531	0.6378	0.4218	0.9373	0.7593	0.4213	0.7983	0.6489	0.2593	
	$F - 6$				0.8206	0.5618	0.3478	0.9386	0.7567	0.4017	0.7994	0.6552	0.2378	
	$F - 7$				0.8115	0.5645	0.2894	0.9302	0.7503	0.3883	0.7953	0.6525	0.2145	
	$F - 8$				0.8161	0.5682	0.2578	0.9267	0.7307	0.3416	0.7972	0.6734	0.1924	
	$F - 9$							0.9171	0.7219	0.3379	0.7506	0.6751	0.1967	
	$F - 10$							0.8910	0.7095	0.3177	0.7677	0.6433	0.1965	
	$F - 11$							0.8873	0.6748	0.3225	0.7378	0.6255	0.1994	
	$F - 12$							0.8651	0.6578	0.3184	0.7119	0.6348	0.1823	
	$F - 13$							0.8631	0.6372	0.2844	0.6952	0.6363	0.1726	
	$F - 14$							0.8448	0.6078	0.2279	0.6822	0.6369	0.1726	
	$F - 15$							0.8483	0.6097	0.2182	0.6874	0.6348	0.1695	
	$F - 16$							0.8408	0.6051	0.2893	0.6944	0.6342	0.1647	
	$F - 17$							0.8484	0.6049	0.2570	0.6922	0.6351	0.1683	
	$F - 18$							0.8401	0.6035	0.2418	0.6996	0.6158	0.1664	
	$F - 19$										0.6991	0.5865	0.1627	
	$F - 20$										0.6787	0.5218	0.1688	
	$F - 21$										0.6786	0.5427	0.1581	
	$F - 22$										0.6720	0.5319	0.1697	
	$F - 23$										0.6714	0.4884	0.1530	
	$F - 24$										0.6840	0.4579	0.1563	
	$F - 25$										0.6891	0.4144	0.1565	
	$F - 26$										0.6729	0.4537	0.1468	
	$F - 27$										0.6800	0.4617	0.1349	
	$F - 28$										0.7069	0.4487	0.1352	
	$F - 29$										0.6730	0.4845	0.1210	
$F - 30$										0.6867	0.5259	0.1228		
$F - 31$										0.6830	0.4702	0.1348		
$F - 32$										0.7003	0.4620	0.1277		

도면11



도면12

