(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2019년04월17일
(11) 등록번호 10-1944678
(24) 등록일자 2019년01월25일

(51) 국제특허분류(Int. Cl.)
H04B 7/08 (2017.01) *G06N 99/00* (2019.01)
H04B 7/0413 (2017.01)
(52) CPC특허분류
H04B 7/0837 (2013.01)
G06N 20/00 (2019.01)
(21) 출원번호 10-2018-0143345
(22) 출원일자 2018년11월20일
심사청구일자 2018년11월20일
(56) 선행기술조사문헌
논문, Hengtao He 외, Deep Learnging_based Channel Estimation for Beamspace mmWave Masisive MIMO Systems, arXiv.org(출처), (2018.02.05. 공개)*
(뒷면에 계속)

(73) 특허권자
인하대학교 산학협력단
인천광역시 미추홀구 인하로 100(용현동, 인하대학교)
(72) 발명자
박대영
인천광역시 연수구 신송로118번길 6, 113동 603호(송도동, 송도풍림아이원1단지아파트)
김민식
경기도 수원시 영통구 동수원로 448, 105동 402호(매탄동, 현대아파트)
(74) 대리인
양성보

전체 청구항 수 : 총 5 항 심사관 : 이철수

(54) 발명의 명칭 **LSTM을 이용한 MIMO 검출 방법 및 시스템**

(57) 요 약

LSTM을 이용한 MIMO 검출 방법 및 시스템이 개시된다. 일 실시예에 따른 MIMO 시스템에서 수행되는 MIMO 검출 방법은, 수신 안테나를 통하여 MIMO(Multiple-Input Multiple-Output) 검파를 위한 수신 신호와 채널 정보를 획득하는 단계; 및 랜덤 채널과 송신 신호를 사용하여 구성된 기계학습 기반의 네트워크 학습을 위한 학습 모델을 이용하여 상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계를 포함할 수 있다.

대 표 도

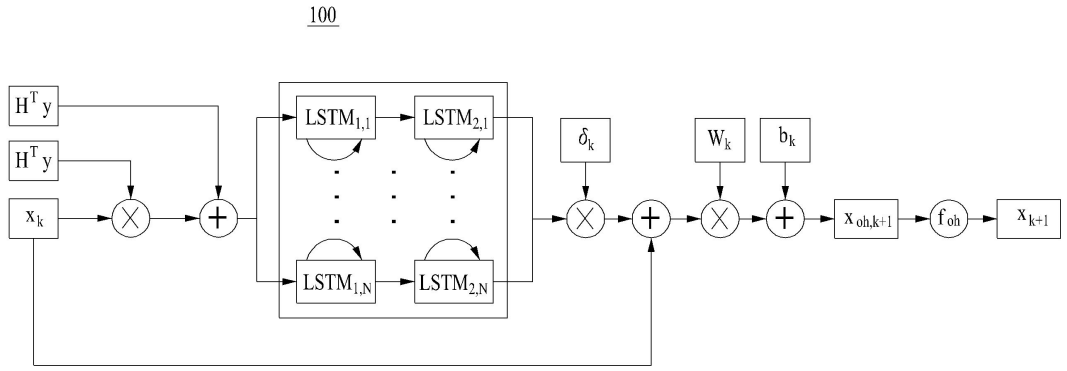

(52) CPC특허분류
H04B 7/0413 (2013.01)

(56) 선행기술조사문헌
논문, Jihoon Seo 외, A Study on the Deep Learning-based Point_to_Point MIMO Channel Wireless Transmission Technology, 한국통신학회 학술논문 (2017. 6. 공개)*
KR1020150128729 A
KR1020130006850 A
KR1020120067528 A
*는 심사관에 의하여 인용된 문헌

이 발명을 지원한 국가연구개발사업
과제고유번호 1711070432
부처명 과학기술정보통신부
연구관리전문기관 정보통신기술진흥센터
연구사업명 대학 IT연구센터 육성·지원
연구과제명 [IITP-ezbaro][정부] 스마트한 주파수 이용을 위한 스펙트럼 및 전파기술(5차년도)
기 여 율 1/1
주관기관 인하대학교 산학협력단
연구기간 2018.01.01 ~ 2018.12.31

명 세 서

청구범위

청구항 1

MIMO 시스템에서 수행되는 MIMO 검출 방법에 있어서,

수신 안테나를 통하여 MIMO(Multiple-Input Multiple-Output) 검파를 위한 수신 신호와 채널 정보를 획득하는 단계; 및

랜덤 채널과 송신 신호를 사용하여 구성된 기계학습 기반의 네트워크 학습을 위한 학습 모델을 이용하여 상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계

를 포함하고,

상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계는,

Gradient descent 방법에 메타 러닝을 적용한 Meta-Learning Detection Network(MLDNet) 학습 모델을 구성하는 단계

를 포함하고,

상기 Meta-Learning Detection Network(MLDNet) 학습 모델은, 레이어의 반복으로 구성되고 수학식으로 나타내는 것

수학식:

$$\nabla f(\mathbf{x}_k) = \mathbf{H}^T\mathbf{H}\mathbf{x}_k - \mathbf{H}^T\mathbf{y}$$
$$\mathbf{q}_k = \mathrm{LSTM}_{2-\mathrm{layer}}(\nabla f(\mathbf{x}_k); \boldsymbol{\varphi})$$
$$\hat{\mathbf{x}}_{oh,k} = \mathbf{W}_k(\mathbf{x}_k + \boldsymbol{\delta}_k\mathbf{q}_k) + \mathbf{b}_k$$
$$\mathbf{x}_{k+1} = f_{oh}(\mathbf{x}_{oh,k})$$

를 포함하는 MIMO 검출 방법.

청구항 2

삭제

청구항 3

MIMO 시스템에서 수행되는 MIMO 검출 방법에 있어서,

수신 안테나를 통하여 MIMO(Multiple-Input Multiple-Output) 검파를 위한 수신 신호와 채널 정보를 획득하는 단계; 및

랜덤 채널과 송신 신호를 사용하여 구성된 기계학습 기반의 네트워크 학습을 위한 학습 모델을 이용하여 상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계

를 포함하고,

상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계는,

미리 정해져 있는 조건 내에서 gradient descent 연산을 하는 방식인 proximal gradient method를 사용하여 제한조건이 있는 최적화 문제를 해결하는 단계

를 포함하는 MIMO 검출 방법.

청구항 4

제1항에 있어서,

상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계는,

상기 학습 모델에서 각각의 그레디언트(Gradient)에 복수 개의 LSTM을 적용하여 옵티마이저(optimizer) 변수를 학습하는 단계

를 포함하는 MIMO 검출 방법.

청구항 5

MIMO 시스템에서 수행되는 MIMO 검출 방법에 있어서,

수신 안테나를 통하여 MIMO(Multiple-Input Multiple-Output) 검파를 위한 수신 신호와 채널 정보를 획득하는 단계; 및

랜덤 채널과 송신 신호를 사용하여 구성된 기계학습 기반의 네트워크 학습을 위한 학습 모델을 이용하여 상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계

를 포함하고,

상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계는,

학습 가능한 파라미터를 사용하여 $W(x)+b$ 형태로 비선형 함수의 역할을 수행하여 기 설정된 차원으로 변환시키고, 상기 학습 모델을 통하여 예측된 값과 정답 사이의 값으로 정의되는 손실 함수(Loss Function)을 사용하여 학습 모델에 존재하는 모든 레이어를 고려하여 N(N은 자연수)번째 레이어를 기준으로 N-1 번째 레이어의 출력을 N번째 레이어의 출력과 연관시키는 단계

를 포함하는 MIMO 검출 방법.

청구항 6

MIMO 시스템에 있어서,

수신 안테나를 통하여 MIMO(Multiple-Input Multiple-Output) 검파를 위한 수신 신호와 채널 정보를 획득하는 획득부;

랜덤 채널과 송신 신호를 사용하여 기계학습 기반의 네트워크 학습을 위한 학습 모델을 구성하는 학습부; 및

상기 구성된 학습 모델을 이용하여 상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 검출부

를 포함하고,

상기 검출부는,

Gradient descent 방법에 메타 러닝을 적용한 Meta-Learning Detection Network(MLDNet) 학습 모델을 구성하고,

상기 Meta-Learning Detection Network(MLDNet) 학습 모델은, 레이어의 반복으로 구성되고 수학식으로 나타내는 것

수학식:

$$\nabla f(\mathbf{x}_k) = \mathbf{H}^T\mathbf{H}\mathbf{x}_k - \mathbf{H}^T\mathbf{y}$$
$$\mathbf{q}_k = \mathrm{LSTM}_{2-\mathrm{layer}}(\nabla f(\mathbf{x}_k); \boldsymbol{\varphi})$$
$$\hat{\mathbf{x}}_{oh,k} = \mathbf{W}_k(\mathbf{x}_k + \boldsymbol{\delta}_k\mathbf{q}_k) + \mathbf{b}_k$$
$$\mathbf{x}_{k+1} = f_{oh}(\mathbf{x}_{oh,k})$$

을 포함하는 MIMO 시스템.

발명의 설명

기 술 분 야

[0001] 아래의 설명은 기계학습 기반의 MIMO 검출 방법 및 장치에 관한 것이다.

배 경 기 술

[0003] 최근 무선 통신 시스템에서 높은 전송률에 대한 수요가 계속해서 증가하고 있다. 다중 입력 다중 출력 시스템(Multiple-Input Multiple-Output; MIMO)은 무선 통신의 용량을 높이기 위한 스마트 기술이다. 추가적인 주파수 대역이나 전송 전력 없이 채널 용량을 증가시킬 수 있기 때문에 MIMO에 대한 관심이 높아지고 있다. MIMO 시스템은 IEEE 802.11n, LTE, WiMAX와 같은 이동 통신 시스템에 적용되고 있다. 최근에는 MIMO 시스템의 진보적인 것으로 수십 또는 수백 개의 안테나를 사용하는 대용량 MIMO 시스템이 제안되었다. MIMO 시스템은 송신 측에서 여러 개의 심볼을 동시에 전송하기 때문에 수신 측에서는 랜덤 잡음이나 간섭의 영향을 받은 심볼을 수신하게 된다. 따라서 MIMO 시스템을 설계할 때 수신 측에서는 왜곡된 심볼을 검출하는 기술을 필요로 하며 다양한 검파 기술이 연구되었다.

[0004] 최근 빅데이터, 하드웨어의 발달, 성숙된 신경망 모델 등으로 인하여 기계학습에 대한 관심이 높아지게 되었고 공학 분야의 대부분의 문제를 해결하는데 사용되고 있다. 통신 분야에서도 성능을 개선하기 위해서 다양한 방면으로 기계학습을 적용하고 있으며 채널 추정, 블라인드 검출에서 좋은 성과를 보여주었다. 최근에는 MIMO 검출 문제에 RNN을 사용하여 높은 검출 정확도를 달성할 수 있는 합리적이고 효율적인 방법이 제시되었다.

[0005] 최대 가능도(Maximum Likelihood; ML) 검파 방법은 성상도 집합으로 구성할 수 있는 모든 벡터를 탐색하는 것으로 주어진 채널에 대한 수신 신호 벡터의 가능성을 최대화한다. 모든 경우의 수를 확인하기 때문에 ML 검파 문제는 NP-hard (Non-deterministic Polynomial-time hard)이다. ML 검파 방법은 송신 안테나의 개수와 변조 성상도의 크기에 따른 지수(exponential) 복잡도를 가지기 때문에 계산 복잡도가 송신 안테나의 개수에 따라 지수적으로 증가하는 문제점이 있다. 수십 개의 안테나를 사용하는 MIMO 시스템의 경우에는 적합하지 않기 때문에 복잡도를 상당히 낮춘 검파 방법들이 제안되었다.

발명의 내용

해결하려는 과제

[0007] MIMO 감지를 위한 hand-designed 알고리즘에 meta learning 방식을 적용한 네트워크를 제안하는 MIMO 시스템 및 방법을 제공할 수 있다.

과제의 해결 수단

[0009] MIMO 시스템에서 수행되는 MIMO 검출 방법은, 수신 안테나를 통하여 MIMO(Multiple-Input Multiple-Output) 검파를 위한 수신 신호와 채널 정보를 획득하는 단계; 및 랜덤 채널과 송신 신호를 사용하여 구성된 기계학습 기반의 네트워크 학습을 위한 학습 모델을 이용하여 상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계를 포함할 수 있다.

[0010] 상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계는, Gradient descent 방법에 메타 러닝을 적용한 Meta-Learning Detection Network(MLDNet) 학습 모델을 구성하는 단계를 포함하고, 상기 Meta-Learning Detection Network(MLDNet) 학습 모델은, 레이어의 반복으로 구성되고 수학식

$$\nabla f(\mathbf{x}_k) = \mathbf{H}^T\mathbf{H}\mathbf{x}_k - \mathbf{H}^T\mathbf{y}$$
$$\mathbf{q}_k = \mathrm{LSTM}_{2-\mathrm{layer}}(\nabla f(\mathbf{x}_k); \boldsymbol{\varphi})$$
$$\hat{\mathbf{x}}_{oh,k} = \mathbf{W}_k(\mathbf{x}_k + \boldsymbol{\delta}_k\mathbf{q}_k) + \mathbf{b}_k$$
$$\mathbf{x}_{k+1} = f_{oh}(\mathbf{x}_{oh,k})$$

( )으로 나타낼 수 있다.

[0011] 상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계는, 미리 정해져 있는 조건 내에서 gradient descent 연산을 하는 방식인 proximal gradient method를 사용하여 제한조건이 있는 최적화 문제를 해결하는 단계를 포함할 수 있다.

[0012] 상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계는, 상기 학습 모델에서 각각의 그레디언트(Gradient)에 복수 개의 LSTM을 적용하여 옵티마이저(optimizer) 변수를 학습하는 단계를 포함할 수 있다.

[0013] 상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 단계는, 학습 가능한 파라미터를 사용하여 $W(x) + b$ 형태로 비선형 함수의 역할을 수행하여 기 설정된 차원으로 변환시키고, 상기 학습 모델을 통하여 예측된 값과 정답 사이의 값으로 정의되는 손실 함수(Loss Function)을 사용하여 학습 모델에 존재하는 모든 레이어를 고려하여 N(N은 자연수)번째 레이어를 기준으로 N-1 번째 레이어의 출력을 N번째 레이어의 출력과 연관시키는 단계를 포함할 수 있다.

[0014] MIMO 시스템은, 수신 안테나를 통하여 MIMO(Multiple-Input Multiple-Output) 검파를 위한 수신 신호와 채널 정보를 획득하는 획득부; 랜덤 채널과 송신 신호를 사용하여 기계학습 기반의 네트워크 학습을 위한 학습 모델을 구성하는 학습부; 및 상기 구성된 학습 모델을 이용하여 상기 수신 신호에 포함된 왜곡된 심볼을 검출하는 검출부를 포함할 수 있다.

발명의 효과

[0016] 실시예에 따른 MIMO 시스템은 기계학습을 적용한 검파방식으로 기존의 방식에 비하여 빠른 속도로 신호를 검출할 수 있으며 최적의 값을 도출할 수 있다.

[0017] 실시예에 따른 MIMO 시스템은 네트워크에서 복수 개의 채널 모델과 constellation을 포함한 다양한 시나리오에서 낮은 복잡성으로 최적의 감지 성능을 달성할 수 있다.

도면의 간단한 설명

[0019] 도 1은 일 실시예에 따른 MIMO 시스템에서 네트워크 학습을 위한 학습 모델을 설명하기 위한 도면이다.

도 2 및 도 3은 일 실시예에 따른 MIMO 시스템에서 SNR에 따른 BER 성능을 나타낸 그래프이다.

도 4는 일 실시예에 따른 MIMO 시스템의 구성을 설명하기 위한 블록도이다.

도 5는 일 실시예에 따른 MIMO 시스템의 MIMO 검출 방법을 설명하기 위한 흐름도이다.

발명을 실시하기 위한 구체적인 내용

[0020] 이하, 실시예를 첨부한 도면을 참조하여 상세히 설명한다.

[0022] 실시예에서는 MIMO 감지를 위한 hand-designed 알고리즘에 meta learning 방식을 적용한 네트워크를 도입하여 복수의 채널 모델과 constellation을 포함한 다양한 시나리오에서 낮은 복잡성으로 최적의 감지 성능과 최고의 성능을 달성하기 위한 MIMO 방법 및 시스템을 설명하기로 한다.

[0023] 도 4는 일 실시예에 따른 MIMO 시스템의 구성을 설명하기 위한 블록도이고, 도 5는 일 실시예에 따른 MIMO 시스

템의 MIMO 검출 방법을 설명하기 위한 흐름도이다.

[0024] MIMO 시스템(400)은 획득부(410), 검출부(420) 및 학습부(430)를 포함할 수 있다. 이러한 MIMO 시스템(400)의 구성요소들은 MIMO 시스템에 저장된 프로그램 코드가 제공하는 제어 명령에 따라 프로세서에 의해 수행되는 서로 다른 기능들(different functions)의 표현들일 수 있다. MIMO 시스템(400)의 구성요소들은 도 5의 MIMO 검출 방법이 포함하는 단계들(510 내지 520)을 수행하도록 MIMO 시스템을 제어할 수 있다. 이때, 프로세서 및 프로세서의 구성요소들은 메모리가 포함하는 운영체제의 코드와 적어도 하나의 프로그램의 코드에 따른 명령(instruction)을 실행하도록 구현될 수 있다.

[0025] MIMO 시스템은 MIMO 검출 방법을 위한 프로그램의 파일에 저장된 프로그램 코드를 메모리에 로딩할 수 있다. 예를 들면, MIMO 시스템에서 프로그램이 실행되면, 프로세서는 운영체제의 제어에 따라 프로그램의 파일로부터 프로그램 코드를 메모리에 로딩하도록 MIMO 시스템을 제어할 수 있다. 이때, 획득부(410), 검출부(420) 및 학습부(430) 각각은 메모리에 로딩된 프로그램 코드 중 대응하는 부분의 명령을 실행하여 이후 단계들(510 내지 520)을 실행하기 위한 프로세서의 서로 다른 기능적 표현들일 수 있다.

[0026] 단계(510)에서 획득부(410)는 수신 안테나를 통하여 MIMO(Multiple-Input Multiple-Output) 검파를 위한 수신 신호와 채널 정보를 획득할 수 있다.

[0027] 단계(520)에서 검출부(420)는 랜덤 채널과 송신 신호를 사용하여 구성된 기계학습 기반의 네트워크 학습을 위한 학습 모델을 이용하여 수신 신호에 포함된 왜곡된 심볼을 검출할 수 있다. 이때, 학습부(430)는 Gradient descent 방법에 메타 러닝을 적용한 Meta-Learning Detection Network(MLDNet) 학습 모델을 구성할 수 있다. 이러한 학습 모델 및 학습 모델에 기반한 검파 방법에 대한 설명은 도 1에서 상세하게 설명하기로 한다.

[0028] 도 1은 일 실시예에 따른 MIMO 시스템에서 네트워크 학습을 위한 학습 모델을 설명하기 위한 도면이다.

[0029] MIMO 시스템의 학습 모델(100)은 수학식 1과 같이 나타낼 수 있다.

[0030] 수학식 1:

[0031] $$\bar{\mathbf{y}} = \bar{\mathbf{H}}\bar{\mathbf{x}} + \bar{\mathbf{w}}$$

[0032] 송신 안테나 N개, 수신안테나 M개 사용한다면, $\bar{\mathbf{y}} \in \mathbf{C}^M$는 수신 신호 벡터, $\bar{\mathbf{H}} \in \mathbf{C}^{N\times M}$는 채널 행렬, $\bar{\mathbf{x}} \in \mathbf{S}^N$는 송신 신호 벡터, $\bar{\mathbf{w}} \in \mathbf{C}^M$는 추가적인 가우시안 랜덤 잡음이다. $\mathbf{C}$는 복소수 집합을 의미하며. 채널 행렬 $\bar{\mathbf{H}}$는 수신 측에서 알고 있다고 가정하며, 원소들은 가우시안 분포를 가지고 있다. $\mathbf{S} = \{\mathbf{s_1}, \cdots, \boldsymbol{s}_{|\boldsymbol{S}|}\}$는 성상도에서 표현되는 집합이며 각각의 s_i에 해당하는 단위 벡터 $\mathbf{u}_i \in \mathbf{R}^{|S|}$를 가지는 one-hot mapping을 사용한다. 예를 들어 4-ASK에서 4-D one-hot mapping을 하면 수학식 2이다.

[0033] 수학식 2:

[0034] $$\begin{aligned} s_1 &= -3 \leftrightarrow \mathbf{u}_1 = [1,0,0,0] \\ s_2 &= -1 \leftrightarrow \mathbf{u}_2 = [0,1,0,0] \\ s_3 &= \ \ 1 \leftrightarrow \mathbf{u}_3 = [0,0,1,0] \\ s_4 &= \ \ 3 \leftrightarrow \mathbf{u}_4 = [0,0,0,1] \end{aligned}$$

[0035] $\mathbf{u}_i$를 다시 s_i로 매핑(mapping)하기 위하여 $s_i = f_{oh}(\mathbf{u}_i)$ 함수를 사용한다.

[0036] 수학식 3:

$$f_{oh}(\mathbf{u}) = \sum_{i=1}^{|\mathbf{S}|} s_i [\mathrm{x}_{oh}]_i$$

[0037]

[0038] f_{oh}는 $\mathrm{x}_{oh} \in \{0,1\}^{|\mathbf{S}|*N}$를 $\bar{\mathbf{x}} \in \mathbf{S^N}$로 매핑하는 함수이다. 또한, 복소수 변수 사용을 피하기 위하여 다음과 같은 규칙을 사용한다.

[0039] 수학식 4:

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

[0040]

[0041] 수학식 5:

$$\mathbf{y} = \begin{bmatrix} \Re(\bar{\mathbf{y}}) \\ \Im(\bar{\mathbf{y}}) \end{bmatrix}, \ \mathbf{x} = \begin{bmatrix} \Re(\bar{\mathbf{x}}) \\ \Im(\bar{\mathbf{x}}) \end{bmatrix}, \mathbf{H} = \begin{bmatrix} \Re(\bar{\mathbf{H}}) & -\Im(\bar{\mathbf{H}}) \\ \Im(\bar{\mathbf{H}}) & \Re(\bar{\mathbf{H}}) \end{bmatrix}, \ \mathbf{w} = \begin{bmatrix} \Re(\bar{\mathbf{w}}) \\ \Im(\bar{\mathbf{w}}) \end{bmatrix}$$

[0042]

[0043] 복소수를 실수와 허수부로 나눠서 표현하였으며, 수학식 1에서 N, M은 2N, 2M이 된다. 다시 말해서, $\mathbf{y} \in \mathbf{C}^{2M}$, $\mathbf{H} \in \mathbf{C}^{2N \times 2M}$, $\mathbf{x} \in \mathbf{S}^{2N}$ 그리고 $\mathbf{w} \in \mathbf{C}^{2M}$이 된다. 수학식 4에서 시스템 모델의 MIMO 검파 문제는 수학식 6으로 표현될 수 있다.

[0044] 수학식 6:

$$\min \| \mathbf{y} - \mathbf{H}\mathbf{x} \|_2^2$$
$$\mathrm{s.t.} \mathrm{x} \in \mathrm{S}^N$$

[0045]

[0046] 제한조건이 있는 최적화 문제를 해결하는 경우에 미리 정해져 있는 조건 안에서 gradient descent 연산을 하는 방식인 proximal gradient method를 사용하여 해결할 수 있다.

[0047] 수학식 7:

$$\min_{\mathbf{x}} \| \mathbf{y} - \mathbf{H}\mathbf{x} \|_2^2 + I_{A_0^N}(\mathbf{x})$$

[0048]

[0049] $I_{A_0^N}(\mathrm{x})$는 지시(indicator) 함수로써 $\mathbf{x} \in \boldsymbol{A_0^N}$을 만족한다면 0이고, $\mathbf{x} \in \boldsymbol{A_0^N}$을 만족하지 않으면 ∞이다. Proximal gradient method로 수학식 7을 풀면 수학식 8과 같이 나타낼 수 있다.

[0050] 수학식 8:

$$\begin{aligned} \mathbf{x}_{k+1} &= \Pi_{\mathbf{S}^N}\left(\mathbf{x}_k - \delta_k \frac{\partial \| \mathbf{y} - \mathbf{H}\mathbf{x} \|_2^2}{\partial \mathrm{x}}\right) \\ &= \Pi_{\mathbf{S}^N}(\mathbf{x}_k - \delta_k(\mathbf{H}^T\mathbf{H}\mathbf{x}_k - \mathbf{H}^T\mathbf{y})) \end{aligned}$$

[0051]

[0052] 수학식 8은 수학식 6의 목적함수를 gradient descent로 제한조건을 $\Pi_{\mathbf{S}^N}(\mathbf{x})$으로 대체하며 적은 복잡도로 꽤 정확한 성능을 가진다. 여기에서 $\Pi_{\mathbf{S}^N}(\mathbf{x})$는 $\mathbf{x}$를 $\mathbf{S}^N$에서 가장 가까운 성상도의 점으로의 투영(projection) 하는 것을 의미한다.

[0053] ML을 기 설정된 기준 이하(낮은)의 복잡도로 해결하기 위하여 proximal gradient method이 제시되었으며 최근에

는 DetNet과 같이 proximal gradient method의 구조에 기계학습을 더하여 높은 성능을 제안하는 알고리즘이 제시되었다. 하지만 Gradient descent의 경우 1st order만 사용하고 2nd order에 대한 정보는 무시한다는 점 때문에 성능이 저하된다. 이러한 문제를 해결하기 위하여 Rprop, RMSprop, ADAM과 같은 다양한 방법이 등장하였다. 실시예에서 기존의 Gradient descent 방법에 메타 러닝 관점을 적용함으로써 특정한 알고리즘을 선택하지 않아도 해결할 수 있다.

[0054] Gradient descent 방법, 수학식 9의 방법을 최적화하는 optimizer g를 가지는 방법으로 다시 작성하면 수학식 10과 같이 나타낼 수 있다.

[0055] 수학식 9:

[0056] $$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \nabla f(\mathbf{x}_k)$$

[0057] 수학식 10:

[0058] $$\mathbf{x}_{k+1} = \mathbf{x}_k - g_k(\nabla f(\mathbf{x}_k); \boldsymbol{\varphi})$$

[0059] optimizer g 를 학습하기 위해 RNN을 적용하는 경우 최소 수십 만 개의 매개변수를 최적화할 수 있어야 하기 때문에 가능하지 않다. 이에 따라 이러한 문제를 해결하기 위해 실시예에서는 각각의 Gradient에 2개의 LSTM을 적용하였다. 반복을 사용하면 LSTM에서 최근의 학습 절차는 업데이트에 사용되는 모멘텀과 유사한 동적 업데이트 규칙을 학습할 수 있다.

[0060] 학습가능한 파라미터 W, b를 사용하여 $W(x)+b$ 형태로 $\text{Projection}\ (\Pi_{S^N}(x))$과 같은 비선형(nonlinear) 함수의 역할을 하며 원하는 차원으로 바꿀 수 있도록 하였다. 실시예에서 제안하는 방법인 Meta-Learning Detection Network(MLDNet)의 학습 모델은 도 1과 같은 레이어(layer)의 반복으로 구성될 수 있다.

[0061] 도 1에 도시된 학습 모델을 수학식 11과 같이 수식으로 나타낼 수 있다.

[0062] 수학식 11:

[0063] $$\begin{aligned}\nabla f(\mathbf{x}_k) &= \mathbf{H}^T\mathbf{H}\mathbf{x}_k - \mathbf{H}^T\mathbf{y} \\ \mathbf{q}_k &= \text{LSTM}_{2-\text{layer}}(\nabla f(\mathbf{x}_k); \boldsymbol{\varphi}) \\ \hat{\mathbf{x}}_{oh,k} &= \mathbf{W}_k(\mathbf{x}_k + \boldsymbol{\delta}_k \mathbf{q}_k) + \mathbf{b}_k \\ \mathbf{x}_{k+1} &= f_{oh}(\mathbf{x}_{oh,k})\end{aligned}$$

[0064] 실시예에서 학습 가능한 파라미터는 수학식 12로 나타낼 수 있다.

[0065] 수학식 12:

[0066] $$\boldsymbol{\theta} = \{\boldsymbol{\varphi}_k, \mathbf{W}_k, \mathbf{b}_k, \boldsymbol{\delta}_k\}_{k=1}^{L}$$

[0067] 실시예에서 손실 함수는 one-hot을 사용하여 구하였으며 모델을 통해 예측된 값과 정답 사이의 $l_2 - norm$으로 정의하였다. 깊은 네트워크를 학습시키는 경우 vanishing gradients, saturation of the activation functions, sensitivity to initialization 등의 이유로 학습이 잘 되지 않는다. 이에 따라 실시예에서는 성능을 향상시키기 위하여 GoogLeNet과 같이 모든 계층을 고려하는 loss function을 사용하였으며, ResNet과 같이 현재 계층의 출력에서 이전 계층의 출력을 고려해주었다.

[0068] 수학식 13:

[0069] $$l\left(\mathbf{x}_{oh};\hat{\mathbf{x}}_{oh}(\mathbf{H},\mathbf{y};\boldsymbol{\theta})\right)=\sum_{l=1}^{L}\log(l)\parallel\mathbf{x}_{oh}-\hat{\mathbf{x}}_{oh,l}\parallel^{2}$$

[0070] 도 2 및 도 3은 일 실시예에 따른 MIMO 시스템에서 SNR에 따른 BER 성능을 나타낸 그래프이다.

[0071] 도 2 및 도 3은 비교 알고리즘들과 실시예에서 제안하는 알고리즘에 대한 성능을 나타낸다. 실시예에서 컴퓨터는 Intel 제온 프로세서와 TitanXP GPU를 사용하고 파이썬의 텐서플로우 라이브러리로 구현하고 실험하였다. 실시예에서 제안하는 네트워크는 랜덤 채널과 송신 신호를 사용하여 Adam Optimizer 방법을 통하여 최적화한 성능을 예시로 나타낼 수 있다. 다음과 같은 알고리즘의 성능을 비교할 수 있다.

[0072] Zero Forcing(ZF)은 MIMO 채널 행렬의 역행렬을 이용해 수신 신호로부터 다중 스트림을 분리한다. ZF 검파 방법은 간단하면서도 간섭을 상쇄시킬 수 있다. 하지만 잡음을 증가시키기 때문에 ML 검파 방법에 비해 성능이 매우 좋지 않다.

[0073] Sphere Decoding(SD)은 수신 신호로부터 어떠한 반지름을 갖는 hypersphere 내에 있는 격자 점들을 탐색한다. SD 검파 방법은 성능이 가장 좋은 최적의 검파방식이다. 하지만 다항식(polynomial) 복잡도를 가지며 최악의 경우 지수 복잡도를 갖게 되어 처리시간이 오래 걸린다.

[0074] Semidefinite Relaxation(SDR)은 semidefinite 프로그램을 기반으로 한 ML 접근법을 이용한 것이다. 대부분의 SDR 검파 방법은 내부 점 법(Interior Point Method; IPM)을 이용하며 최악의 경우 다항식 복잡도를 갖는다. 대부분의 SDR 검파 방법은 특정 변조 성상도에만 제한적으로 동작하기 때문에 SD 검파 방법에 비하여 빠르지만 다항식 복잡도 이므로 SD 검파 방법과 같이 처리시간이 오래 걸리는 문제점이 있다.

[0075] Detection Network(DetNet)은 MIMO 검파를 위해 제안된 최신 기술로서 기존의 방식(Projected Gradient Descent)에 기계학습을 적용한 검파 방식이다. 성능을 향상시키기 위하여 latent 변수를 추가하였으며 학습 가능한 파라미터로 구성된 함수를 사용하여 projection과 같은 nonlinear 함수의 역할을 수행한다. 최신 기술로서 한번 학습하면 기존의 방식에 비하여 처리시간이 빠르다.

[0076] Meta-Learning Detection Network(MLDNet)은 실시예에서 제안하는 검파 기술로 기존의 방식에 메타 러닝 관점을 적용하여 만든 신경회로망이다. Gradient descent 알고리즘의 한계를 극복하기 위하여 학습 방법을 학습하기 위한 optimizer를 도입하였다. 파라미터의 수를 줄이기 위하여 각각의 원소마다 2개의 LSTM을 갖도록 구현하였다. DetNet과 같이 기계학습을 적용한 검파 방식으로 기존의 방식에 비하여 빠른 속도로 신호를 검출할 수 있으며 최적의 값을 가지는 SD 검파 방식에 가까운 성능을 가진다.

[0077] 도 2는 채널 크기 30X60, BPSK 변조 방식에서 SNR에 따른 비트 오류율을 나타낸 그래프이다. 수신 안테나의 개수가 송신 안테나의 개수보다 많은 경우로 사용한 파라미터는 송신 안테나 개수(N) = 30, 수신 안테나의 개수(M) = 60, 전송 신호는 BPSK이다. BER 성능이 가장 좋은 것은 SD, SDR-RBR 검파 방법이다. 그 다음으로는 MLDNet, DetNet, ZF 순으로 BER이 낮으며 MLDNet 검파 방법은 최적의 성능을 가지는 SD 검파 방법과 비슷한 성능을 확인할 수 있다.

[0078] 도 3은 채널 크기 40X40, BPSK 변조 방식에서 SNR에 따른 비트 오류율을 나타낸 그래프이다. 수신 안테나의 개수와 송신 안테나의 개수가 같은 경우로 사용한 파라미터는 송신 안테나 개수(N) = 40, 수신 안테나의 개수(M) = 40, 전송 신호는 BPSK이다. 도 2와 마찬가지로 SD, SDR-RBR, MLDNet, DetNet, ZF 순으로 BER이 낮다. 수신 안테나의 개수가 적어서 송수신 안테나의 비율이 작은 경우 DetNet과 MLDNet은 성능열화가 발생하지만 최신 기술인 DetNet 보다 본 발명에서 제안하는 MLDNet의 BER이 낮은 것을 확인할 수 있다.

[0079] 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 설

명된 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.

[0080] 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.

[0081] 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.

[0082] 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.

[0083] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.

도면

도면1

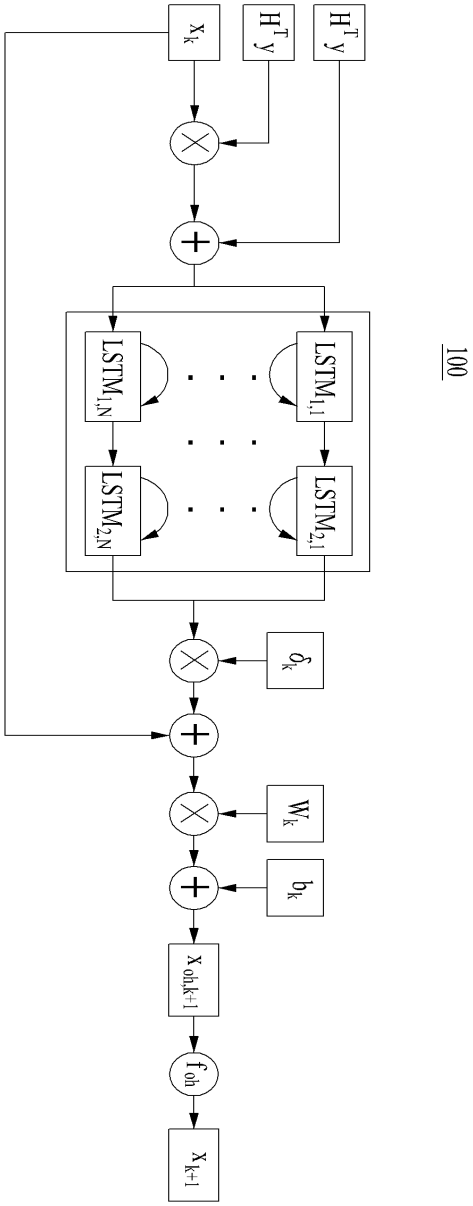
x_k
$H^T y$
$H^T y$
$LSTM_{1,N}$
$LSTM_{1,1}$
$LSTM_{2,N}$
$LSTM_{2,1}$
100
δ_k
W_k
b_k
$x_{obj,k+1}$
f_{obj}
x_{k+1}

도면2

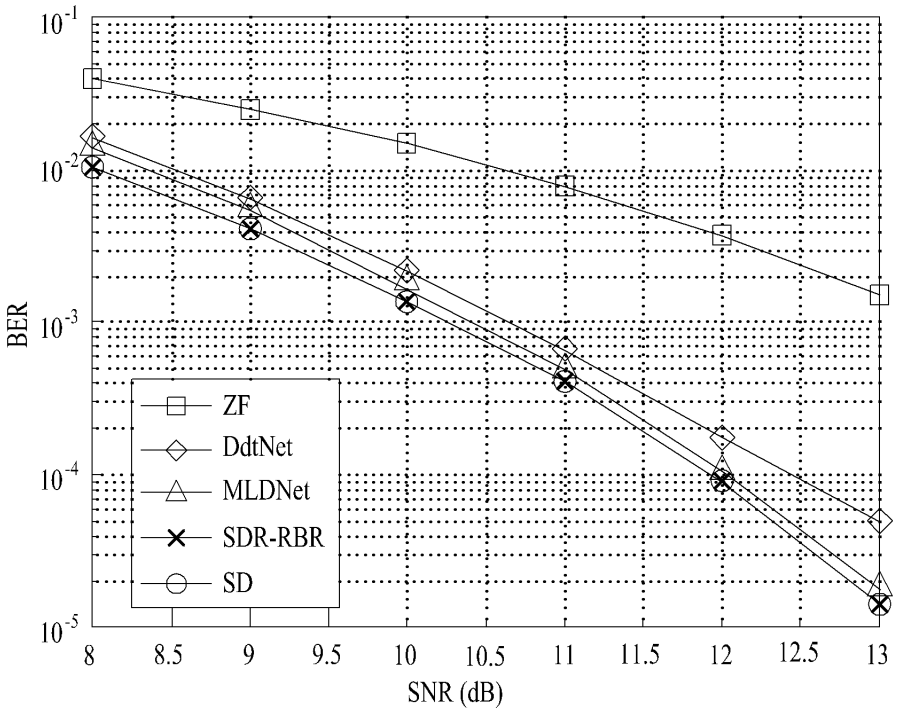
BER
SNR (dB)
ZF
DdtNet
MLDNet
SDR-RBR
SD

도면3

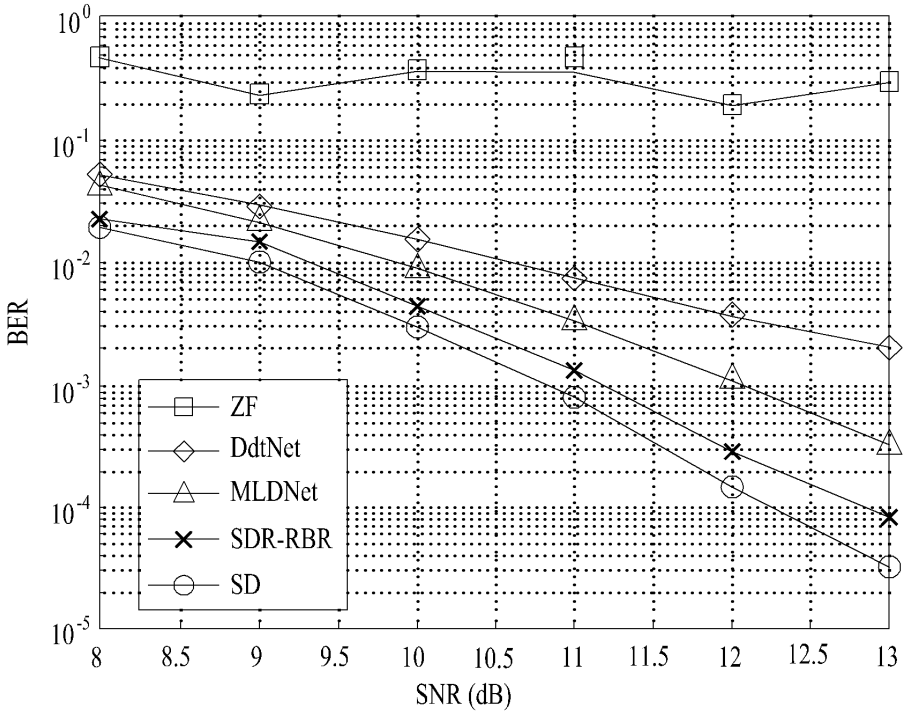
BER
SNR (dB)
ZF
DdtNet
MLDNet
SDR-RBR
SD

도면4

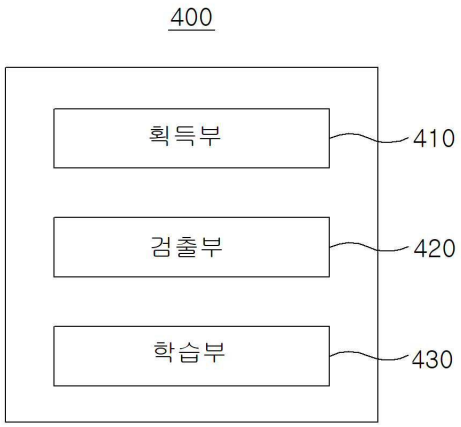

도면5

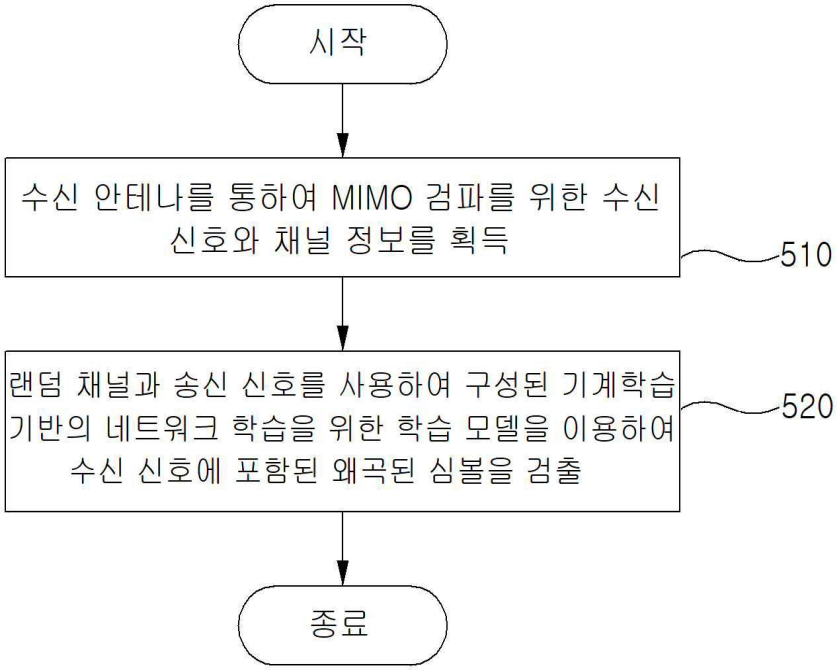

【심사관 직권보정사항】

【직권보정 1】

【보정항목】 발명(고안)의 설명

【보정세부항목】 단락 [0012]

【변경전】

각각의 그레디언트(Gredient)에 복수 개의 LSTM을 적용하여

【변경후】

각각의 그레디언트(Gradient)에 복수 개의 LSTM을 적용하여

【직권보정 2】

【보정항목】 청구범위

【보정세부항목】 청구항 4

【변경전】

학습 모델에서 각각의 그레디언트(Gredient)에 복수 개의 LSTM을 적 용하여

【변경후】

학습 모델에서 각각의 그레디언트(Gradient)에 복수 개의 LSTM을 적 용하여