(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2023-0052117
(43) 공개일자 2023년04월19일

(51) 국제특허분류(Int. Cl.)
G06N 3/08 (2023.01) *G06N 3/04* (2023.01)
H04W 24/02 (2009.01) *H04W 72/04* (2009.01)
(52) CPC특허분류
G06N 3/08 (2023.01)
G06N 3/045 (2023.01)
(21) 출원번호 10-2021-0135296
(22) 출원일자 2021년10월12일
심사청구일자 2021년10월12일

(71) 출원인
부경대학교 산학협력단
부산광역시 남구 용소로 45, 부경대학교내 (대연동)
고려대학교 산학협력단
서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)
(72) 발명자
이훈
부산광역시 남구 유엔로 246 대연자이아파트 108동 2203호
이상현
서울특별시 동대문구 답십리로56길 105 104동 1302호
(74) 대리인
이철희

전체 청구항 수 : 총 18 항

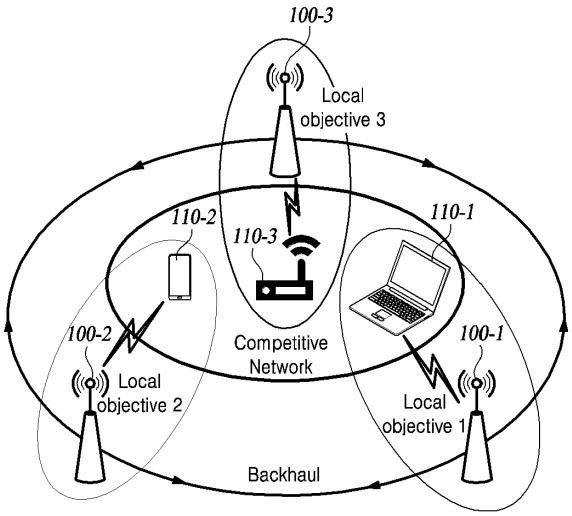
(54) 발명의 명칭 **딥러닝 기반 분산형 다목적 최적화 방법, 이를 위한 컴퓨터 프로그램 및 장치**

(57) 요 약

딥러닝 기반 분산형 다목적 최적화 방법, 이를 위한 컴퓨터 프로그램 및 장치를 개시한다.

본 개시의 일 측면에 의하면, 다목적 최적화 문제에서, 연산장치에 대한 지역 해를 산출하는 방법으로서, 상기 연산장치의 지역 데이터 및 선호도 가중치에 기초하여, 하나 이상의 상대 연산장치와의 협력을 위한 제1 협력통신신호를 생성하는 과정; 상기 제1 협력통신신호를 상기 상대 연산장치에게 전송하는 과정; 상기 상대 연산장치로부터 제2 협력통신신호를 수신하는 과정; 상기 지역 데이터, 상기 선호도 가중치 및 상기 제2 협력통신신호에 기초하여, 상기 연산장치에 대한 지역 해(local solution)를 산출하는 과정을 포함하는 것을 특징으로 하는 방법을 제공한다.

대 표 도 - 도1



(52) CPC특허분류
H04W 24/02 (2013.01)
H04W 72/04 (2023.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711134433
과제번호	2021-0-00467
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	6G핵심 기술개발
연구과제명	지능형 6G 무선 액세스 시스템 (Intelligent 6G Wireless Access System)
기 여 율	1/1
과제수행기관명	부경대학교 산학협력단
연구기간	2021.04.01 ~ 2025.12.31

명 세 서

청구범위

청구항 1

다목적 최적화 문제에서, 연산장치에 대한 지역 해를 산출하는 방법으로서,

상기 연산장치의 지역 데이터 및 선호도 가중치에 기초하여, 하나 이상의 상대 연산장치와의 협력을 위한 제1 협력통신신호를 생성하는 과정;

상기 제1 협력통신신호를 상기 상대 연산장치에게 전송하는 과정;

상기 상대 연산장치로부터 제2 협력통신신호를 수신하는 과정;

상기 지역 데이터, 상기 선호도 가중치 및 상기 제2 협력통신신호에 기초하여, 상기 연산장치에 대한 지역 해(local solution)를 산출하는 과정

을 포함하는 것을 특징으로 하는 방법.

청구항 2

제1항에 있어서,

상기 제1 협력통신신호를 생성하는 과정은,

기학습된 메신저 신경망에 상기 지역 데이터 및 상기 선호도 가중치를 입력하여, 상기 제1 협력통신신호를 획득하는 과정

을 포함하는 것을 특징으로 하는 방법.

청구항 3

제2항에 있어서,

상기 메신저 신경망은,

상기 지역 데이터 및 상기 선호도 가중치를 양자화하여 상기 제1 협력통신신호로 변환하도록 학습된 것을 특징으로 하는 방법.

청구항 4

제1항에 있어서,

상기 지역 해를 산출하는 과정은,

기학습된 옵티마이저 신경망에 상기 지역 데이터, 상기 선호도 가중치 및 상기 제2 협력통신신호를 입력하여, 상기 지역 해를 획득하는 과정

을 포함하는 것을 특징으로 하는 방법.

청구항 5

제4항에 있어서,

상기 옵티마이저 신경망은,

상기 연산장치 및 상기 상대 연산장치의 전역 목적(global objective)을 최대화하되, 상기 연산장치의 지역 목적(local objective)이 상기 선호도 가중치 및 상기 전역 목적에 기초하여 설정되는 제약조건(constraint)을 충족하는 지역 해를 산출하도록 학습된 것을 특징으로 하는 방법.

청구항 6

제1항에 있어서,

하나 이상의 단말로부터 상기 지역 데이터 및 상기 선호도 가중치 중 적어도 하나를 수집하는 과정

을 더 포함하는 것을 특징으로 하는 방법.

청구항 7

목적 신경망 및 듀얼 신경망을 이용하여 하나 이상의 신경망 모듈을 훈련하는 방법으로서,

하나 이상의 지역 데이터 및 하나 이상의 선호도 가중치를 포함하는 훈련 데이터 셋을 획득하는 과정;

상기 하나 이상의 선호도 가중치 및 상기 목적 신경망의 출력 값을 기반으로, 상기 듀얼 신경망이 프라이멀-듀얼 최적화(primal-dual optimization)를 위한 듀얼 변수(dual variable)를 출력하도록 훈련시키는 과정;

상기 하나 이상의 선호도 가중치 및 상기 듀얼 신경망의 출력 값을 기반으로, 상기 목적 신경망이 상기 하나 이상의 신경망 모듈의 전역 목적(global objective)을 출력하도록 훈련시키는 과정; 및

상기 훈련 데이터 셋 및 상기 듀얼 신경망의 출력 값을 기반으로, 상기 하나 이상의 신경망 모듈이 지역 해 및 다른 신경망 모듈과의 협력을 위한 협력통신신호를 출력하도록 훈련시키는 과정

을 포함하는 것을 특징으로 하는 훈련 방법.

청구항 8

제7항에 있어서,

상기 신경망 모듈을 훈련시키는 과정은,

상기 하나 이상의 신경망 모듈의 파라미터에 대한 제1 손실 함수의 기울기를 계산하고, 상기 제1 손실 함수의 기울기를 기초로 상기 하나 이상의 신경망 모듈의 파라미터를 업데이트하는 과정을 포함하되,

상기 신경망 모듈은,

상기 전역 목적을 최대화하되, 각 신경망 모듈의 지역 목적이 상기 각 신경망 모듈에 대한 선호도 가중치 및 상기 전역 목적에 기초하여 설정되는 제약조건을 충족하는 지역 해를 산출하도록 훈련되는 훈련 방법.

청구항 9

제8항에 있어서,

상기 제1 손실 함수는,

하기의 수학식에 기초하여 산출되는 것을 특징으로 하는 훈련 방법.

$$\mathcal{G}(\theta,\psi) \triangleq \sum_{\mathbf{w}\in\mathcal{W}} \mathcal{N}_{\psi}(\mathbf{w})^{T}\tilde{\mathbf{f}}(\theta,\mathbf{w})$$

여기서, $\mathcal{G}(\theta,\psi)$는 상기 제1 손실 함수, θ는 상기 하나 이상의 신경망 모듈의 파라미터, ψ는 상기 듀얼 신경망의 파라미터, $\mathbf{w}$는 각 신경망 모듈에 대한 선호도 가중치로 구성되는 선호도 벡터, $\mathcal{N}_{\psi}(\mathbf{w})$는 상기 듀얼 신경망의 출력 값, $\tilde{\mathbf{f}}(\theta,\mathbf{w})$는 각 신경망 모듈의 평균 지역 목적의 집합임.

청구항 10

제7항에 있어서,

상기 신경망 모듈은,

상기 지역 데이터 및 상기 선호도 가중치를 양자화하여 상기 협력통신신호를 생성하도록 훈련되는 것을 특징으로 하는 훈련 방법.

청구항 11

제7항에 있어서,

상기 목적 신경망을 훈련시키는 과정은,

상기 목적 신경망의 파라미터에 대한 제2 손실 함수의 기울기를 계산하고, 상기 제2 손실 함수의 기울기를 기초로, 상기 목적 신경망의 파라미터를 업데이트하는 과정을 포함하되,

상기 제2 손실 함수는 상기 하나 이상의 신경망 모듈의 전역 목적에 대한 가중 평균인 것을 특징으로 하는 훈련 방법.

청구항 12

제11항에 있어서,

상기 제2 손실 함수는,

하기의 수학식에 기초하여 산출되는 것을 특징으로 하는 훈련 방법.

$$\mathcal{H}(\varphi,\psi) \triangleq \sum_{\mathbf{w}\in\mathcal{W}} \left(\frac{1}{|\mathcal{W}|} - \mathcal{N}_{\psi}(\mathbf{w})^{T}\mathbf{w} \right) \cdot \mathcal{F}_{\varphi}(\mathbf{w})$$

여기서, $\mathcal{H}(\varphi,\psi)$는 상기 제2 손실 함수, w는 각 신경망 모듈에 대한 선호도 가중치로 구성되는 선호도 벡터, $\mathcal{N}_{\psi}(\mathbf{w})$는 상기 듀얼 신경망의 출력 값, $\mathcal{F}_{\varphi}(\mathbf{w})$는 상기 목적 신경망의 출력 값, $|\mathcal{W}|$는 모든 선호도 가중치 후보들(priority weight candidates)의 수임.

청구항 13

제7항에 있어서,

상기 듀얼 신경망을 훈련시키는 과정은,

상기 목적 신경망의 파라미터에 대한 제3 손실 함수의 기울기를 계산하고, 상기 제3 손실 함수의 기울기를 기초로, 상기 하나 이상의 듀얼 신경망의 파라미터를 업데이트하는 과정을 포함하되,

상기 듀얼 신경망의 출력 값은 비음성(nonnegativity)을 가지는 것을 특징으로 하는 훈련 방법.

청구항 14

제13항에 있어서,

상기 제3 손실 함수는,

하기의 수학식에 기초하여 산출되는 것을 특징으로 하는 훈련 방법.

$$\mathcal{J}(\theta,\varphi,\psi) \triangleq \sum_{\mathbf{w}\in\mathcal{W}} \mathcal{N}_{\psi}(\mathbf{w})^{T}(\tilde{\mathbf{f}}(\theta,\mathbf{w}) - \mathbf{w}\cdot\mathcal{F}_{\varphi}(\mathbf{w}))$$

여기서, $\mathcal{J}(\theta,\varphi,\psi)$는 상기 제3 손실 함수, $\mathcal{N}_{\psi}(\mathbf{w})$는 상기 듀얼 신경망의 출력 값, $\tilde{\mathbf{f}}(\theta,\mathbf{w})$는 각 신경망 모듈의 평균 지역 목적의 집합, w는 각 신경망 모듈에 대한 선호도 가중치로 구성되는 선호도 벡터, $\mathcal{F}_{\varphi}(\mathbf{w})$는 상기 목적 신경망의 출력 값임.

청구항 15

프로세서(processor); 및

상기 프로세서를 통해 실행가능한 적어도 하나의 명령어를 저장하는 메모리(memory)를 포함하되,

상기 프로세서는,

연산장치의 지역 데이터 및 선호도 가중치에 기초하여, 상대 연산장치와의 협력을 위한 제1 협력통신신호를 생성하고,

상기 제1 협력통신신호를 상기 상대 연산장치에게 전송하고,

상기 상대 연산장치부터 제2 협력통신신호를 수신하고,

상기 지역 데이터, 상기 선호도 가중치 및 상기 제2 협력통신신호에 기초하여, 상기 연산장치에 대한 지역 해(local solution)를 산출하도록 구성된 연산장치.

청구항 16

목적 신경망 및 듀얼 신경망을 이용하여 하나 이상의 신경망 모듈을 훈련하기위한 장치로서,

프로세서(processor); 및

상기 프로세서를 통해 실행가능한 적어도 하나의 명령어를 저장하는 메모리(memory)를 포함하되,

상기 프로세서는,

하나 이상의 지역 데이터 및 하나 이상의 선호도 가중치를 포함하는 훈련 데이터 셋을 획득하고,

상기 하나 이상의 선호도 가중치 및 상기 목적 신경망의 출력 값을 기반으로, 상기 듀얼 신경망이 프라이멀-듀얼 최적화(primal-dual optimization)를 위한 듀얼 변수(dual variable)를 출력하도록 훈련시키고,

상기 하나 이상의 선호도 가중치 및 상기 듀얼 신경망의 출력 값을 기반으로, 상기 목적 신경망이 상기 하나 이상의 신경망 모듈의 전역 목적(global objective)을 출력하도록 훈련시키고,

상기 훈련 데이터 셋 및 상기 듀얼 신경망의 출력 값을 기반으로, 상기 하나 이상의 신경망 모듈이 지역 해 및 다른 신경망 모듈과의 협력을 위한 협력통신신호를 출력하도록 훈련시키도록 구성된 것을 특징으로 하는 훈련장치.

청구항 17

제1항 내지 제6항 중 어느 한 항에 따른 방법이 포함하는 각 과정을 실행시키기 위하여 컴퓨터로 읽을 수 있는 기록매체에 저장된 컴퓨터프로그램.

청구항 18

제7항 내지 제14항 중 어느 한 항에 따른 훈련 방법이 포함하는 각 과정을 실행시키기 위하여 컴퓨터로 읽을 수 있는 기록매체에 저장된 컴퓨터프로그램.

발명의 설명

기 술 분 야

[0001] 본 개시는 딥러닝 기반 분산형 다목적 최적화 방법, 이를 위한 컴퓨터 프로그램 및 장치에 관한 것이다.

배 경 기 술

[0002] 이 부분에 기술된 내용은 단순히 본 발명에 대한 배경 정보를 제공할 뿐 종래기술을 구성하는 것은 아니다.

[0003] 차세대 통신 네트워크는 사물인터넷 시스템을 포괄하는 machine-type communication(MTC) 표준화에 중점을 둔다. MTC 시스템은 다양한 종류의 사물인터넷 단말로 구성되어 있으며, 각 기기가 요구하는 통신 서비스의 종류, 선호도, 품질이 상이하다. MTC의 특성상 모든 사물인터넷 기기를 관장하는 네트워크 장비 없이 Ad-hoc 형태로 구현되므로 동일한 무선 채널 자원을 공유한다.

[0004] 이러한 MTC 시스템의 초연결성을 지원하기 위해서는 단말의 개별 선호도를 기반으로 모든 단말의 상이한 지역 목적을 동시에 극대화하는 다목적 자원 할당 기법이 필요하다. 자원 할당 해를 계산하는 주체는 단말을 서비스하는 기지국이 되는데, 마찬가지로 모든 기지국을 제어하는 중앙 네트워크 장비가 존재하지 않으므로 분산형 다목적 자원 할당 기법이 요구된다. 기존 다목적 자원 할당 기법은 중앙집중형 및 반복적 계산을 요구하므로 실시

간 해 도출이 불가능하다.

선행기술문헌

비특허문헌

[0005] (비특허문헌 0001) D. Liu, C. Sun, C. Yang, and L. Hanzo, “Optimizing wireless systems using unsupervised and reinforced-unsupervised deep learning,” IEEE Netw., vol. 34, no. 4, pp. 270-277, Jul. 2020.

(비특허문헌 0002) Q. Zhang and H. Li, “MOEA/D: A multiobjective evolutionary algorithm based on decomposition,” IEEE Trans. Evol. Comput., vol. 11, no. 6, pp. 712-731, Aug. 2007.

(비특허문헌 0003) A. Trivedi, D. Srinivasan, K. Sanyal, and A. Ghosh, “A survey of multiobjective evolutionary algorithms based on decomposition,” IEEE Trans. Evol. Comput., vol. 21, no. 3, pp. 440-462, Jun. 2017.

발명의 내용

해결하려는 과제

[0006] 본 개시는, 모든 기지국이 동일한 무선 채널을 공유하는 네트워크 환경에서 각 기지국의 개별 성능 목적을 동시에 최적화하는 다목적 자원 할당 문제를 분산적/실시간으로 해결하는 방법과 이를 위한 컴퓨터 프로그램 및 장치를 제공하는 데 주된 목적이 있다.

과제의 해결 수단

[0007] 본 개시의 일 측면에 의하면, 다목적 최적화 문제에서, 연산장치에 대한 지역 해를 산출하는 방법으로서, 상기 연산장치의 지역 데이터 및 선호도 가중치에 기초하여, 하나 이상의 상대 연산장치와의 협력을 위한 제1 협력통신신호를 생성하는 과정; 상기 제1 협력통신신호를 상기 상대 연산장치에게 전송하는 과정; 상기 상대 연산장치로부터 제2 협력통신신호를 수신하는 과정; 상기 지역 데이터, 상기 선호도 가중치 및 상기 제2 협력통신신호에 기초하여, 상기 연산장치에 대한 지역 해(local solution)를 산출하는 과정을 포함하는 것을 특징으로 하는 방법을 제공한다.

[0008] 본 개시의 다른 측면에 의하면, 목적 신경망 및 듀얼 신경망을 이용하여 하나 이상의 신경망 모듈을 훈련하는 방법으로서, 하나 이상의 지역 데이터 및 하나 이상의 선호도 가중치를 포함하는 훈련 데이터 셋을 획득하는 과정; 상기 하나 이상의 선호도 가중치 및 상기 목적 신경망의 출력 값을 기반으로, 상기 듀얼 신경망이 프라이멀-듀얼 최적화(primal-dual optimization)를 위한 듀얼 변수(dual variable)를 출력하도록 훈련시키는 과정; 상기 하나 이상의 선호도 가중치 및 상기 듀얼 신경망의 출력 값을 기반으로, 상기 목적 신경망이 상기 하나 이상의 신경망 모듈의 전역 목적(global objective)을 출력하도록 훈련시키는 과정; 및 상기 훈련 데이터 셋 및 상기 듀얼 신경망의 출력 값을 기반으로, 상기 하나 이상의 신경망 모듈이 지역 해 및 다른 신경망 모듈과의 협력을 위한 협력통신신호를 출력하도록 훈련시키는 과정을 포함하는 것을 특징으로 하는 훈련 방법을 제공한다.

[0009] 본 개시의 다른 측면에 의하면, 프로세서(processor); 및 상기 프로세서를 통해 실행가능한 적어도 하나의 명령어를 저장하는 메모리(memory)를 포함하되, 상기 프로세서는, 연산장치의 지역 데이터 및 선호도 가중치에 기초하여, 상대 연산장치와의 협력을 위한 제1 협력통신신호를 생성하고, 상기 제1 협력통신신호를 상기 상대 연산장치에게 전송하고, 상기 상대 연산장치부터 제2 협력통신신호를 수신하고, 상기 지역 데이터, 상기 선호도 가중치 및 상기 제2 협력통신신호에 기초하여, 상기 연산장치에 대한 지역 해(local solution)를 산출하도록 구성된 연산장치를 제공한다.

[0010] 본 개시의 다른 측면에 의하면, 목적 신경망 및 듀얼 신경망을 이용하여 하나 이상의 신경망 모듈을 훈련하기위한 장치로서, 프로세서(processor); 및 상기 프로세서를 통해 실행가능한 적어도 하나의 명령어를 저장하는 메모리(memory)를 포함하되, 상기 프로세서는, 하나 이상의 지역 데이터 및 하나 이상의 선호도 가중치를 포함하는 훈련 데이터 셋을 획득하고, 상기 하나 이상의 선호도 가중치 및 상기 목적 신경망의 출력 값을 기반으로, 상기 듀얼 신경망이 프라이멀-듀얼 최적화(primal-dual optimization)를 위한 듀얼 변수(dual variable)를 출

력하도록 훈련시키고, 상기 하나 이상의 선호도 가중치 및 상기 듀얼 신경망의 출력 값을 기반으로, 상기 목적 신경망이 상기 하나 이상의 신경망 모듈의 전역 목적(global objective)을 출력하도록 훈련시키고, 상기 훈련 데이터 셋 및 상기 듀얼 신경망의 출력 값을 기반으로, 상기 하나 이상의 신경망 모듈이 지역 해 및 다른 신경망 모듈과의 협력을 위한 협력통신신호를 출력하도록 훈련시키도록 구성된 것을 특징으로 하는 훈련장치를 제공한다.

[0011] 본 개시의 다른 측면에 의하면, 본 실시예에 따른 지역해 산출 방법 또는 훈련 방법이 포함하는 각 과정을 실행시키기 위하여 컴퓨터로 읽을 수 있는 기록매체에 저장된 컴퓨터 프로그램을 제공한다.

발명의 효과

[0012] 본 개시의 실시예에 의하면, 실측 또는 수학적 모델에 기반하여 생성된 각 기지국의 지역 데이터로부터 다목적 자원 할당 해 및 기지국 간 협력통신신호의 관계를 딥러닝을 통해 학습할 수 있다.

[0013] 또한, 본 개시의 실시예에 의하면, 학습이 종료된 딥러닝 모듈을 각 기지국에 배치하여 실시간으로 무선 네트워크의 성능을 극대화하는 자원 할당 해 및 기지국 간 협력통신신호를 실시간으로 계산할 수 있다.

도면의 간단한 설명

[0014] 도 1은 본 개시의 일 실시예에 따른 다목적 최적화 방법이 적용되는 네트워크를 예시적으로 나타낸 도면이다.

도 2는 본 개시의 일 실시예에 따른 scalarization 기법과 비교 실시예에 따른 기법들을 설명하기 위한 도면이다.

도 3은 본 개시의 일 실시예에 따른 3-노드 네트워크에서 COO 접근법에 의해 구해지는 파레토 최적 경계에 대한 기하학적 해석을 보여주는 예시도이다.

도 4a는 본 개시의 일 실시예에 따른 기지국의 신경망 모듈을 나타낸 예시도이다.

도 4b는 본 개시의 일 실시예에 따른 신경망 모듈을 중앙집중적 학습 과정의 일 예를 도시한 예시도이다.

도 4c는 본 개시의 일 실시예에 따른 신경망 모듈이 기지국에 분산적으로 배치되는 일 예를 도시한 예시도이다.

도 5는 본 개시의 일 실시예에 따른 메신저 신경망의 훈련 과정의 일 예를 도시한 예시도이다.

도 6은 본 개시의 일 실시예에 따른 신경망을 훈련 과정을 나타내는 순서도이다.

도 7은 본 개시의 일 실시예에 따른 신경망의 실시간 협력 및 계산 과정을 나타내는 순서도이다.

도 8은 본 개시의 일 실시예에 따른 신경망의 훈련을 위한 장치를 개략적으로 나타낸 블럭 구성도이다.

도 9는 본 개시의 일 실시예에 따른 기지국을 개략적으로 나타낸 블럭 구성도이다.

발명을 실시하기 위한 구체적인 내용

[0015] 이하, 본 개시의 일부 실시예들을 예시적인 도면을 통해 상세하게 설명한다. 각 도면의 구성요소들에 참조부호를 부가함에 있어서, 동일한 구성요소들에 대해서는 비록 다른 도면상에 표시되더라도 가능한 한 동일한 부호를 가지도록 하고 있음에 유의해야 한다. 또한, 본 개시를 설명함에 있어, 관련된 공지 구성 또는 기능에 대한 구체적인 설명이 본 개시의 요지를 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명은 생략한다.

[0016] 또한, 본 개시의 구성 요소를 설명하는 데 있어서, 제 1, 제 2, A, B, (a), (b) 등의 용어를 사용할 수 있다. 이러한 용어는 그 구성 요소를 다른 구성 요소와 구별하기 위한 것일 뿐, 그 용어에 의해 해당 구성 요소의 본질이나 차례 또는 순서 등이 한정되지 않는다. 명세서 전체에서, 어떤 부분이 어떤 구성요소를 '포함', '구비'한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있는 것을 의미한다. 또한, 명세서에 기재된 '…부', '모듈' 등의 용어는 적어도 하나의 기능이나 동작을 처리하는 단위를 의미하며, 이는 하드웨어나 소프트웨어 또는 하드웨어 및 소프트웨어의 결합으로 구현될 수 있다.

[0017] 이하, 본 개시의 일 실시예에 따른 분산형 다목적 최적화 방법으로서, 기지국들이 동일한 무선 채널을 공유하는 네트워크 환경 하에서 각 기지국이 자원 할당 해를 분산적으로 산출하는 방법을 예로 들어 설명하나, 본 개시가 이에 한정되는 것은 아니다. 본 개시는 다른 분산 제어 및 분산 계산 상황에서 다목적 최적화 문제의 지역해를

분산적으로 산출하는데에 적용될 수 있다.

[0018] 도 1은 본 개시의 일 실시예에 따른 다목적 최적화 방법이 적용되는 네트워크를 예시적으로 나타낸 도면이다.

[0019] 도 1을 참조하면, 본 개시의 일 실시예에 따른 네트워크(10)는 하나 이상의 기지국(base station)및 하나 이상의 단말(terminal)을 포함할 수 있다. 한편, 도 1에서는 하나 이상의 기지국으로 제1 내지 제3 기지국(100-1, 100-2 및 100-3)을 도시하고 있고, 하나 이상의 단말로 제1 내지 제3 단말(110-1, 110-2 및 110-3)을 도시하고 있으나 이는 설명의 편의를 위한 것으로, 본 개시는 다른 개수의 기지국 및 단말을 포함하는 네트워크에도 적용될 수 있다.

[0020] 제1 내지 제3 기지국(100-1, 100-2 및 100-3)은 기지국 이외에도, 노드(node), 무선 노드(wireless node), 액세스 포인트(access point, AP), 모바일 엣지 컴퓨팅 장치(mobile edge-computing device) 또는 이와 동등한 기술적 의미를 가지는 다른 용어로 지칭될 수 있다.

[0021] 실시예들에 따라, 제1 내지 제3 기지국(100-1, 100-2 및 100-3)은 백홀 링크(backhaul link)를 이용하여 다른 기지국과 통신할 수 있다.

[0022] 제1 내지 제3 단말(110-1, 110-2 및 110-3)은 사용자 장비(user equipment, UE), 이동국(mobile station), 무선 단말(wireless terminal), 사용자 장치(user device) 또는 이와 동등한 기술적 의미를 가지는 다른 용어로 지칭될 수 있다. 본 개시의 다양한 실시 예들에 따른 제1 내지 제3 단말은, 예를 들면, 스마트폰, 태블릿 PC, 이동 전화기, 영상 전화기, 전자책 리더기, 데스크탑 PC, 랩탑 PC, 넷북 컴퓨터, 워크스테이션, 서버, PDA, PMP(portable multimedia player), MP3 플레이어, 의료기기, 카메라, 또는 웨어러블 장치 중 적어도 하나를 포함할 수 있다.

[0023] 실시예들에 따라, 제1 내지 제3 단말(110-1, 110-2 및 110-3)은 동일한 무선 채널(wireless channel)을 공유할 수 있다. 이에 따라, 제1 내지 제3 단말(110-1, 110-2 및 110-3)의 통신 품질이 상호 경쟁적으로 결정될 수 있다.

[0024] 무선 네트워크 관리는 일반적으로 QoS(Quality of Service) 및 데이터 처리량 메트릭(data throughput metrics)과 같이 개별 노드들이 이끌어내고자 하는 이기종 성능 메트릭(heterogeneous performance metrics)의 동시 최대화로 이어지는 다목적 최적화(multi-objective optimization, MOO)로 설명될 수 있다.

[0025] 제i 기지국(i는 자연수)은 지역 목적(local objective) $f_i(\cdot)$를 최대화하기 위한 네트워킹 전략으로부터 자체 지역 해 $\mathbf{x}_i$를 결정할 수 있다. 지역 해는 예컨대, 각 기지국의 자원 할당 해일 수 있다. 지역 해들의 집합은 전역 해(global solution)를 구성할 수 있다. 기지국들의 집합을 $\mathcal{V}$라 할 때, 전역 해는 $\mathbf{x} \triangleq \{\mathbf{x}_i : i \in \mathcal{V}\}$와 같이 표현될 수 있다. 제i 기지국은 주변 환경으로부터 채널 상태 정보(channel state information, CSI)와 같은 지역 관측치(local observation) $\mathbf{a}_i$를 수집할 수 있다. 본 개시에서 지역 관측치는 지역 데이터로 지칭될 수 있다. 지역 관측치들의 집합, 즉 전역 관측치(global observation) $\mathbf{a} \triangleq \{\mathbf{a}_i : i \in \mathcal{V}\}$는 성능에 영향을 미치는 확률적 특성(stochastic properties)을 파악하는데 이용될 수 있다. 지역 목적은 전역 데이터 $\mathbf{a}$ 및 연관된 전역 해 $\mathbf{x}$에 따라 달라질 수 있으므로 $f_i(\mathbf{a}, \mathbf{x})$와 같이 표현될 수 있다. 다목적 자원 관리(multi-objective resource management)는 MOO에서 모든 지역 목적 함수(local objective function)의 분산 솔루션을 구하는 것이다. 분산 무선 네트워크에서 개별 기지국들은 최적 해를 식별하기에는 불충분한 부분적인 정보 $\mathbf{a}_i$에만 액세스할 수 있기 때문에, 다목적 자원 관리에 대한 근본적인 최적화 과제가 제기된다.

[0026] 분산 네트워크의 복잡한 MOO 솔루션을 위해서는, 최적화를 위한 조정 메커니즘(coordinated mechanism)이 필요하다. 기지국들을 상호 연결하는 백홀 인프라(backhaul infrastructure)를 통해, 기지국들 간 지역 데이터 및 관련된 통계(statistics)의 교환이 수행될 수 있다.

[0027] 제i 기지국은 백홀 링크 $\mathcal{E}$를 통해 제j 기지국(j는 i와 다른 자연수)으로 전달할 메시지 μ_{ij}를 생성할 수 있

다. 제i 기지국으로부터 전송되는 메시지들의 집합 $\hat{\boldsymbol{\mu}}_i \triangleq \{\mu_{ij} : (i,j) \in \mathcal{E}\}$ 은 지역 데이터 $\mathbf{a}_i$에 대해, 감소된 시그널링 지연 및 오버헤드를 위한 백홀 링크 용량(capacity) 내에 적합하도록 양자화된 정보(quantized information)를 실어 나를 수 있다. 제i 기지국으로부터 제j 기지국으로의 백홀 링크의 용량은 Q_{ij} 와 같이 표현될 수 있다. 양자화된 메시지는 $\mu_{ij} \in \mathbb{Z}_{Q_{ij}} \triangleq \{0, 1, \cdots, Q_{ij}-1\}$ 와 같이 음이 아닌(nonnegative) 정수 Q_{ij} 에 의해 특징지어질 수 있다. 이웃 기지국으로부터 메시지를 수신하면, 제i 기지국은 지역 데이터 $\mathbf{a}_i$ 및 수신한 메시지 $\check{\boldsymbol{\mu}}_i \triangleq \{\mu_{ji} : (i,j) \in \mathcal{E}\}$ 를 사용하여, 지역 해 $\mathbf{x}_i$를 독립적으로 식별할 수 있다.

[0028] 본 개시에서 양자화된 메시지는 협력통신신호로 지칭될 수 있다. 다른 기지국과 송수신하는 협력통신신호들을 구별하기 위해, 상대 기지국으로 전송되는 협력통신신호 $\hat{\boldsymbol{\mu}}_i$ 를 제1 협력통신신호라 지칭하고, 상대 기지국으로부터 수신하는 협력통신신호 $\check{\boldsymbol{\mu}}_i$ 를 제2 협력통신신호라 지칭한다. 여기서, 상대 기지국은, 기지국과 백홀 링크를 통해 상호 연결된 다른 기지국을 의미할 수 있다.

[0029] **<u>다목적 최적화를 위한 학습</u>**

[0030] functional 최적화는 각 변수들 $\hat{\boldsymbol{\mu}}_i$ 및 $\mathbf{x}_i$ 를 직접 결정하기보다는, 지역 관측치로부터 각 변수 $\hat{\boldsymbol{\mu}}_i$ 및 $\mathbf{x}_i$로의 매핑 규칙(mapping rules)을 설계한다(비특허문헌 1). 이러한 매핑 규칙은 수학식 1과 같이 표현될 수 있다.

수학식 1

[0031]
$$\hat{\boldsymbol{\mu}}_i = \mathcal{M}_i(\mathbf{a}_i), \qquad (1a)$$
$$\mathbf{x}_i = \mathcal{X}_i(\mathbf{a}_i, \check{\boldsymbol{\mu}}_i), \qquad (1b)$$

[0032] 연산자 $\mathcal{M}_i(\cdot)$ 는 제i 기지국에서 메시지 생성의 입출력 관계를 도출한다. 나아가, 지역 해 $\mathbf{x}_i$는 연산자 $\mathcal{X}_i(\cdot)$를 이용한 제2 협력통신신호 $\check{\boldsymbol{\mu}}_i$ 와 지역 데이터 $\mathbf{a}_i$ 과의 매핑을 통해 결정될 수 있다. 이러한 함수들은 특정한 고정된 구현 대신, 임의로 주어진 $\mathbf{a}_i$에 대한 일반적인 계산 절차를 제시할 수 있다. 이를 위해, functional 최적화는 매핑되는 입력들, 즉 확률적 공간 $\mathcal{A}$ 상의 랜덤 네트워크 통계들 $\mathbf{a} \in \mathcal{A}$에 대한 평균 성능 메트릭(average performance metrics)들을 포함할 수 있다.

[0033] 분산 MOO 태스크의 functional formalism은 수학식 2와 같이 유도될 수 있다.

수학식 2

[0034]
$$\max_{\{\mathcal{M}_i(\cdot), \mathcal{X}_i(\cdot): \forall i\}} \left(\mathbb{E}_{\mathbf{a}}[f_1(\mathbf{a}, \mathbf{x})], \cdots, \mathbb{E}_{\mathbf{a}}[f_N(\mathbf{a}, \mathbf{x})]\right) \qquad (2a)$$
$$\text{subject to } \mu_{ij} = [\mathcal{M}_i(\mathbf{a}_i)]_j \in \mathbb{Z}_{Q_{ij}}, \ (i,j) \in \mathcal{E}, \mathbf{a} \in \mathcal{A}, \ (2b)$$

[0035] 여기서, $[\mathbf{u}]_j$ 는 벡터 $\mathbf{u}$의 j번째 요소(element)를 나타낸다. 수학식 2의 functional MOO는 지역 목적들의 평균 $\mathbb{E}_{\mathbf{a}}[f_i(\mathbf{a}, \mathbf{x})]$을 최대화하기 위해, 두 가지 함수 $\mathcal{M}_i(\cdot)$ 및 $\mathcal{X}_i(\cdot)$를 얻는 것을 목표로 한다. 이러한 목적 함수의 정의는, 지역 데이터들의 랜덤 인스턴스에 적응하는 것을 용이하게 한다.

[0036] 수학식 1의 계산 함수들 $\mathcal{M}_i(\cdot)$ 및 $\mathcal{X}_i(\cdot)$는 수학식 2와 같이 개별 심층 신경망(Deep Neural Network, DNN)으로 각각 대체될 수 있다.

수학식 3

$$\hat{\boldsymbol{\mu}}_i \simeq \mathcal{M}_{\theta_i}(\mathbf{a}_i), \qquad (3a)$$

[0037] $$\mathbf{x}_i \simeq \mathcal{X}_{\vartheta_i}(\mathbf{a}_i, \check{\boldsymbol{\mu}}_i), \qquad (3b)$$

[0038] 여기서, θ_i 및 ϑ_i는 각각 $\mathcal{M}_{\theta_i}(\cdot)$ 및 $\mathcal{X}_{\vartheta_i}(\cdot)$의 훈련 가능한 파라미터 셋(trainable parameter sets)이다.

[0039] **협력적 다목적 학습 기법**

[0040] 본 개시에서는, 기지국들의 지역 목적(local objective)들을 달성할 수 있는 특정한 하나의 파레토 최적 지점(Pareto-optimum point)을 찾는 것이 아닌, 복수의 파레토 최적 지점들의 집합, 즉, 파레토 경계(Pareto boundary)를 동시에 찾을 수 있도록 하는 기법을 제안한다.

[0041] 일반적인 무선 네트워크는 제한된 무선 자원의 환경에서 동작한다. 신뢰할 수 있는 액세스 링크(access link)를 위해, 네트워크는 다양한 이기종 QoS 요구사항들을 따라야 한다. QoS 요구사항들은 일반적으로 서로 경쟁하는 지역 목적들에 의해 특징지어질 수 있다. 이들을 중재하기 위해, 지역 목적들 사이의 선호도(priority)가 반영될 수 있다.

[0042] 선호도 벡터(priority vector)는 $\mathbf{w} \triangleq \{w_i : i \in \mathcal{V}\}$와 같이 표현될 수 있다. 여기서, 선호도 가중치(priority weight) w_i는 비음(non-negative)인 계수일 수 있다. 선호도 가중치의 값이 클수록 연관된 노드(즉, 제i 기지국)에 의해 높은 연결 신뢰도를 요구받음을 의미할 수 있고, 추가적인 무선 자원이 필요하다는 것으로 해석될 수 있다. 각 기지국은 지역 목적에 따라 기정의된 규칙으로부터 가중치를 결정할 수 있다. 따라서 선호도 가중치는 시간에 따라 달라질 수 있으며, 연관된 노드(즉, 제i 기지국)에서만 구해질 수 있다.

[0043] 진화된 다목적 최적화(multi-objective optimization, MOO) 기술들은 목적 공간 경계 지점들(objective space boundary points)의 다양성을 제공할 수 있다. 획득된 해들의 집합에는 선호도 벡터가 의도된 방향으로 경계에 닿는 지점이 포함되지 않을 수 있다. 원하는 선호도 가중치를 가진 해를 구할 수 있는 다양한 종래 기술들이 존재한다. 그러나 이러한 종래 기술들은, 무선 네트워크 관리에 일반적으로 적합하지 않은, 중앙 집중식 계산을 기반으로 한다.

[0044] MOO는 여러 노드가 협력적으로 최적화될 수 있는 협력적 다목적 최적화(cooperative-objective optimization, COO)로 재구성될 수 있다. 이러한 COO는 MOO가 볼록하지 않은(nonconvex) 지역 목적에 대해서도 보장된 최적성을 갖는 단일 목적(single-objective) 공식으로 동등하게 변환될 수 있음을 보여준다. COO 결과는 협력적 최대화(cooperative maximization)를 위해 개별 노드들이 처리하는 지역 목적들과 관련된 일련의 하위 태스크의 집합으로 분리될 수 있다.

[0045] 수학식 2를 COO로 재구성하면 수학식 4와 같이 표현될 수 있다.

수학식 4

$$\max_{\{\mathcal{M}_i(\cdot),\mathcal{X}_i(\cdot):\forall i\},F} \; F \qquad (4a)$$

[0046] $$\text{subject to (2b) and } \mathbb{E}_{\mathbf{a}}[f_i(\mathbf{a},\mathbf{x})] \geq w_i F, \; i \in \mathcal{V}. \qquad (4b)$$

[0047] 이러한 COO는 전역 목적 값(global objective value) F와 함께 수학식 1의 해 계산 규칙을 얻을 수 있다. 즉, 단일 전역 목적 F가 최대화되는 동시에, 제i 기지국은 지역 목적 값(local objective value)이 전역 목적의

w_i 배보다는 커야하는 제약조건 $\mathbb{E}_{\mathbf{a}}[f_i(\mathbf{a},\mathbf{x})] \geq w_i F$ 을 충족하여야 한다. 일반적으로 지역 목적들은 분명한 물리적 양들(예컨대, 데이터 전송 속도 및 전송 전력)과 연관되기 때문에, 이러한 지역 목적 제약조건은 개별 목적들 간의 비교를 통해 전역 목적의 최대화를 가져오게 된다. 따라서, 이러한 COO는 여러 지역 목적 제약조건들에 따라 제약된 최적화 공식이다.

[0048] 제약된 최적화에 대한 다루기 쉬운 접근법은 라그랑주 듀얼 최적화(Lagrange dual optimization) 기법이다. 라그랑주 듀얼 최적화는 제약된 최적화 문제를 페널티를 주는 파라미터(penalizing parameters)들, 즉 듀얼 변수들(dual variables)을 가진 가중 제약조건에 의해 페널티를 받는 동등한 무제약 최적화(unconstrained optimization)로 해결한다. 프라이멀-듀얼(primal dual) 접근법은 단일 선호도 가중치에 대해 수학식 4에 간단하게 적용될 수 있지만, 많은 선호도 벡터 **w** 에 대한 COO 해들을 동시에 구하는 것은 쉽지 않다.

[0049] 도 2는 본 개시의 일 실시예에 따른 scalarization 기법과 비교 실시예에 따른 기법들을 설명하기 위한 도면이다.

[0050] 다양한 scalarization 기법들 중 가장 인기있는 방법은 분리기반 진화 알고리즘(decomposition-based evolutionary algorithm)에 사용되는 weighted Chebychev 방법이다. 도 2의 (a)에 나타나듯이, 이는 유토피아 지점(utopia point)과 $(\frac{1}{w_1}, \frac{1}{w_2})$ 방향을 향하는 경계 지점 간 거리의 가중 척도를 최소화한다.

[0051] 이와는 대조적으로, 도 2의 (b)를 참조하면, 제안된 COO 공식은 원점으로부터의 파레토 경계 지점의 거리를 다루며, 이는 유토피아 지점에 대한 사전 지식을 배제한다. 전역 목적은 선호도 벡터 (w_1, w_2)의 길이에 해당한다. 따라서, 이는 선호도 벡터의 방향에서의 파레토 최적에 대응한다.

[0052] 도 2의 (c)와 같이 다목적 함수 출력 공간에서 개별 지역 목적 값의 방향에 따라 하한을 설정하는 ε-제약조건 방법(ε-constraint method)과 비교할 때, 제안된 방법은 개별 지역 목적들의 하한들을 동시에 최대화하여 선호도 벡터 **w** 방향의 목적 공간 경계 지점을 찾는다. 이에 따라, 단말 선호도에 따른 경계 지점의 조정이 단순화된다.

[0053] 도 3은 본 개시의 일 실시예에 따른 3-노드 네트워크에서 COO 접근법에 의해 구해지는 파레토 최적 경계에 대한 기하학적 해석을 보여주는 예시도이다.

[0054] 3차원 선호도 벡터 (w_1, w_2, w_3)는 네트워크에서 제공되는 서비스와 관련된 전반적인 목적을 반영한다. 3개의 노드들에 의한 전역 목적의 협력적 최대화는 개별 노드들이 최대 인센티브, 즉 최대 지역 목적들을 보장하도록 하는 것에서 착안되었다. 여기서 중요한 관측은, 선호도 벡터와 파레토 최적 경계의 교차점에 해당하는 전역 목적 값 F가 선호도 벡터의 방향에 따라 달라진다는 것이다.

[0055] 본 개시에서는 비특허문헌 2 및 비특허문헌 3의 분리기반 진화 원리(decomposition-based evolutionary principles)에서 착안하여, 수학식 4의 COO 공식에서 선호도 벡터의 구성들과 관련되는 여러 인스턴스들을 동시에 처리하도록 한다.

[0056] 제i 기지국(i는 자연수)의 지역 해(예컨대, 자원 할당 해) x_i뿐만 아니라, 다른 기지국으로 전송하는 협력통신 신호 $\hat{\boldsymbol{\mu}}_i = \{\mu_{ij} : (i,j) \in \mathcal{E}\}$ 는 지역 관측 데이터들과 선호도 벡터에 의존한다.

[0057] 보편적인 MOO 학습 전략을 개발하기 위해서는 개별 변수들을 처리하는 함수에 추가 입력 특징으로 선호도 벡터 **w**를 포함하는 것이 중요하다. 이를 위해, 본 개시에서는 추가적인 매핑(mapping) $F = \mathcal{F}(\mathbf{w})$ 을 도입하여, 전역 목적 값 F와 선호도 벡터 입력 **w**을 연관시킨다. 이에 따라, 수학식 1의 연산에 지역 선호도 가중치 w_i를 포함시켜 $\hat{\boldsymbol{\mu}}_i = \mathcal{M}_i(\mathbf{a}_i, w_i)$ 및 $\mathbf{x}_i = \mathcal{X}_i(\mathbf{a}_i, \check{\boldsymbol{\mu}}_i, w_i)$와 같이 표현할 수 있다.

[0058] 최적화를 위한 학습(learning to optimize) 원리들에 기반하여, 전술한 계산 기능 단위들은 수학식 5와 같이 심층 신경망(Deep Neural Network, DNN)으로 모델링될 수 있다.

수학식 5

[0059]
$$F = \mathcal{F}(\mathbf{w}) \simeq \mathcal{F}_{\varphi}(\mathbf{w}), \quad (5a)$$
$$\hat{\boldsymbol{\mu}}_i = \mathcal{M}_i(\mathbf{a}_i, w_i) \simeq \mathcal{M}_{\theta_i}(\mathbf{a}_i, w_i), \quad (5b)$$
$$\mathbf{x}_i = \mathcal{X}_i(\mathbf{a}_i, \check{\boldsymbol{\mu}}_i, w_i) \simeq \mathcal{X}_{\vartheta_i}(\mathbf{a}_i, \check{\boldsymbol{\mu}}_i, w_i). \quad (5c)$$

[0060] 수학식 5의 (5a)에서 학습 가능한 파라미터 셋(learnable parameter set) φ을 갖는 목적 신경망 $\mathcal{F}_{\varphi}(\cdot)$은, 임의의 주어진 선호도 벡터 w에 대한 목적 공간 경계에서 전역 목적 F의 위치를 산출한다.

[0061] 수학식 5의 (5b)에서 학습 가능한 파라미터 셋 θ_i를 갖는 메신저(messenger) 신경망 $\mathcal{M}_{\theta_i}(\cdot)$은, 지역 통계, 즉 지역 데이터 벡터 $\mathbf{a}_i$ 및 선호도 가중치 w_i를 캡슐화(encapsulating)하여, 제i 기지국으로부터 브로드캐스팅되는 협력통신신호를 산출한다.

[0062] 수학식 5에서 학습 가능한 파라미터 셋 ϑ_i를 갖는 옵티마이저(optimizer) 신경망 $\mathcal{X}_{\vartheta_i}(\cdot)$은, 지역 통계 및 수신한 협력통신신호 $\check{\boldsymbol{\mu}}_i$에 기초하여 지역 해 $\mathbf{x}_i$를 결정한다.

[0063] 이러한 DNN 유닛들은 다양한 선호도 가중치 및 지역 상태와 관련된 COO 인스턴스들을 보편적으로 처리한다. 이를 위해, 이러한 DNN 유닛들은 제약된 최적화 문제를 해결하는 프라이멀-듀얼 알고리즘(primal-dual algorithm)을 파라미터화 하도록 조정된다. 따라서, 프라이멀-듀얼 알고리즘에 관련된 모든 계산은 DNN 유닛들에 의해 수행된다. 이러한 접근법은 다수의 단일 목적 최적화(single objective optimization, SOO) 애플리케이션들에서 검증되었지만, 다수의 파레토 최적 지점을 찾는 MOO 태스크에 적합한 새로운 훈련 전략이 필요하다.

[0064] 파라미터화된 MOO 솔루션을 위해, 진화적 MOO 프레임워크(evolutionary MOO frameworks) 하에서 기계학습 기반 대체 모델링(ML-based surrogate modeling)이 연구되고 있다. 대체 모델링은 기존의 진화 알고리즘(evolutional algorithms)에서 특징 변수들을 출력하기 위해 요구된다. 이는 특히 데이터만 있고 명시적 공식이 없는 경우의 최적화 문제를 처리하는 데 효율적이다. 본 개시에서 대체 모델링은 MOO 솔루션 추론의 종단 간 계산 및 구성 요소 단위의 공동 설계를 특성화하여 DNN 학습 구조에 추가적인 유연성을 도입하기 위해 수학식 5에 적용된다.

[0065] 수학식 5의 파라미터화된 함수들은 전역 관측치 및 선호도 벡터 w의 측면에서 네트워크 상태에 적응한다. functional 최적화 프레임워크는 사용 가능한 모든 관측치와 선호도 벡터의 모든 실현 가능한 선택에 대한 평균 성능 측정을 요구한다. 따라서 전역 목적 $\tilde{F}(\varphi) \triangleq \mathbb{E}_{\mathbf{w}}[\mathcal{F}_{\varphi}(\mathbf{w})]$는 COO 공식의 스칼라 최대화 목표가 된다. 평균 지역 목적에 대한 해당 제약조건은 $\mathbb{E}_{\mathbf{a}}[f_i(\mathbf{a}, \mathbf{x})] \geq w_i F$와 같이 부등식으로 부과된다. 평균 지역 목적은 수학식 6과 같이 표현될 수 있다.

수학식 6

[0066]
$$\tilde{f}_i(\theta, \mathbf{w}) = \mathbb{E}_{\mathbf{a}}\Big[f_i\big(\mathbf{a}, \{\mathcal{X}_{\vartheta_j}(\mathbf{a}_j, \check{\boldsymbol{\mu}}_j, w_j) : (i,j) \in \mathcal{E}\}\big)\Big], \quad (6)$$

[0067] 여기서, $\theta \triangleq \{\vartheta_i, \theta_i : i \in \mathcal{V}\}$는 메신저 신경망 및 옵티마이저 신경망의 학습 가능한 파라미터 셋을 나타낸다.

[0068] 수학식 6을 수학식 5와 결합하면, 수학식 4의 분산 COO는 수학식 7과 같은 학습 모델로 공식화된다.

수학식 7

$$\max_{\theta,\varphi} \quad \tilde{F}(\varphi) \tag{7a}$$

$$\text{subject to } \tilde{f}_i(\theta,\mathbf{w}) \geq w_i \mathcal{F}_\varphi(\mathbf{w}),\ i \in \mathcal{V}, \mathbf{w} \in \mathcal{W}, \tag{7b}$$

$$\mu_{ij} = [\mathcal{M}_{\theta_i}(\mathbf{a}_i, w_i)]_j \in \mathbb{Z}_{Q_{ij}},\ (i,j) \in \mathcal{E},$$

$$\mathbf{a} \in \mathcal{A}, \mathbf{w} \in \mathcal{W}. \tag{7c}$$

[0069]

[0070] 수학식 7의 분산 COO는 선호도 가중치 $\mathbf{w} \in \mathcal{W}$로 수학식 4의 모든 인스턴스들을 처리한다. 또한, 이는 DNN의 파라미터들 θ 및 φ의 훈련 문제로 볼 수 있다. 그러나 수학식 7의 (7b) 및 (7c)와 같은 사소하지 않은 제약조건을 직접 고려하지 못하는 기존의 무제약 훈련 알고리즘(예컨대, SGD 알고리즘)을 사용하여 수학식 4를 처리하는 것은 여전히 상당히 어려운 일이다. 제약조건의 유형은 관측 벡터 **a**를 처리하는 방식에 따라 달라진다. 예를 들어, 수학식 5의 옵티마이저 신경망의 동작을 규제하는 수학식 7의 (7b)의 제약조건은, **a**의 분포에 대해 취한 평균값에 대한 부등식을 정의하는 평균 제약조건(average constraint)이다. 반면, 수학식 7의 (7c)의 제약조건은 **a**의 특정 구현에 대해 만족되어, 수학식 5의 메신저 신경망에 대해 즉각적인 제약을 부과한다. 따라서 이기종 제약조건 유형은 옵티마이저 신경망과 메신저 신경망에 대해 별도의 훈련 전략을 요구한다.

[0071] **다목적 최적해를 위한 학습 전략**

[0072] 제약된 학습 접근방식은, 수학식 4의 분산 COO에 대한 평균 지역 목적 제약조건에 초점을 맞춘다. 제약된 최적화 문제는 일반적으로 라그랑주 듀얼 방법(Lagrange dual method)을 통해 접근된다. 라그랑지안 함수(Lagrangian function)로 불리는 제약되지 않은 듀얼 함수(dual function)의 해는 기존의 제약 있는 문제에 대한 해와 동일하다. 수학식 4의 라그랑지안 함수는 수학식 8과 같이 표현된다.

수학식 8

$$\mathcal{L}(\theta,\varphi,\boldsymbol{\lambda}) = \tilde{F}(\varphi) + \sum_{\mathbf{w}\in\mathcal{W}} \sum_{i\in\mathcal{V}} \lambda_{i,\mathbf{w}} (\tilde{f}_i(\theta,\mathbf{w}) - w_i \mathcal{F}_\varphi(\mathbf{w})). \tag{8}$$

[0073]

[0074] 여기서, $\boldsymbol{\lambda} \triangleq \{\lambda_{i,\mathbf{w}} : i \in \mathcal{V}, \mathbf{w} \in \mathcal{W}\}$는 수학식 7의 (7b)의 제약조건과 관련된 음이 아닌 듀얼 변수(dual variable)의 집합이다. 제약된 공식의 해는 $\min_{\boldsymbol{\lambda}} \max_{\theta,\varphi} \mathcal{L}(\theta,\varphi,\boldsymbol{\lambda})$로 주어진 라그랑주 듀얼 최적화 문제를 해결함으로써 대안적으로 얻어질 수 있다. 이는 $\boldsymbol{\lambda}$에 대한 계산 규칙의 식별과 관련된 라그랑지안 함수의 최소화를 위해 DNN 파라미터들과 및 듀얼 변수들이 최적화됨을 나타낸다. 본 개시에서는 비특허문헌 1의 functional 최적화 기법을 확장하여 듀얼 변수의 맵핑 함수(mapping function)을 결정한다. 듀얼 변수 $\lambda_{i,\mathbf{w}}$는 벡터 공간 $\mathcal{W}$ 상에 있는 선호도 벡터 **w**에 대한 함수로 표현될 수 있다. 이러한 계산 규칙은 수학식 9와 같이 듀얼 신경망 $\mathcal{N}_\psi(\cdot)$에 의해 구현될 수 있다.

수학식 9

$$\lambda_{i,\mathbf{w}} = [\mathcal{N}_\psi(\mathbf{w})]_i. \tag{9}$$

[0075]

[0076] 듀얼 신경망의 출력층(output layer)에 비음수 활성화 함수(예컨대, ReLU(rectified linear unit) 또는 softplus)를 사용하여 상보적 여유 (complementary slackness)를 위한 비음성 듀얼 변수를 생성한다.

[0077] 수학식 9를 수학식 8로 대체하면, 라그랑지안 함수는 메신저-옵티마이저 신경망, 목적 신경망 및 듀얼 신경망의 학습 가능한 파라미터들 θ, φ 및 ψ의 함수로 수정된다. 그 결과 라그랑지안 함수는 $\mathcal{L}(\theta,\varphi,\psi)=\mathcal{G}(\theta,\psi)+\mathcal{H}(\varphi,\psi)$와 같이 두 개의 하위 함수의 합으로 분해될 수 있다. 하위 함수는 수학식 10과 같이 표현될 수 있다.

수학식 10

$$\mathcal{G}(\theta,\psi)\triangleq\sum_{\mathbf{w}\in\mathcal{W}}\mathcal{N}_{\psi}(\mathbf{w})^{T}\tilde{\mathbf{f}}(\theta,\mathbf{w}), \tag{10a}$$

$$\mathcal{H}(\varphi,\psi)\triangleq\sum_{\mathbf{w}\in\mathcal{W}}\left(\frac{1}{|\mathcal{W}|}-\mathcal{N}_{\psi}(\mathbf{w})^{T}\mathbf{w}\right)\cdot\mathcal{F}_{\varphi}(\mathbf{w}), \tag{10b}$$

[0078]

[0079] 여기서, $|\mathcal{W}|$는 네트워크의 모든 선호도 가중치 후보들(priority weight candidates)의 수이고, $\tilde{\mathbf{f}}(\theta,\mathbf{w})\triangleq\{\tilde{f}_i(\theta,\mathbf{w}):i\in\mathcal{V}\}$이다. 이에 따른 듀얼 문제는 수학식 11과 같이 공식화된다.

수학식 11

$$\min_{\boldsymbol{\psi}}\max_{\theta,\varphi}\mathcal{L}(\theta,\varphi,\psi). \tag{11}$$

[0080]

[0081] 수학식 11의 듀얼 최적화 문제는 프라이멀-듀얼 방법으로 해결된다. 이는 프라이멀 변수와 듀얼 변수의 업데이트를 번갈아 수행한다. 프라이멀 DNN 파라미터들 θ 및 φ은 라그랑지안이 최대화되도록 업데이트되고, 이는 표준 GD 알고리즘(standard GD algorithm)을 기반으로 $\mathcal{L}(\theta,\varphi,\boldsymbol{\lambda})$을 역전파(backpropagate)한다. 이어서, φ에 대한 듀얼 업데이트는 라그랑지안이 최소화되도록 수행된다. 이러한 교차적인 업데이트 전략은 수학식 12와 같이 표현될 수 있다.

수학식 12

$$\text{Primal update: }\begin{cases}\theta\leftarrow\theta+\eta\nabla_{\theta}\mathcal{G}(\theta,\varphi,\psi),\\ \varphi\leftarrow\varphi+\eta\nabla_{\varphi}\mathcal{H}(\theta,\varphi,\psi),\end{cases} \tag{12a}$$

$$\text{Dual update: }\psi\leftarrow\psi-\eta\nabla_{\psi}\mathcal{L}(\theta,\varphi,\psi), \tag{12b}$$

[0082]

[0083] 여기서, η은 학습률(learning rate)을 조정하는 음이 아닌 파라미터이고, $\nabla_{\mathbf{u}}$는 $\mathbf{u}$에 대한 gradient 연산자를 나타낸다. 제한된 DNN 훈련 작업을 가능하게 하는 프라이멀-듀얼 학습 원리를 구현하기 위해 아담 알고리즘(Adam algorithm)과 같은 미니 배치 SGD(mini-batch SGD)가 적용될 수 있다.

[0084] **신경망 모듈 훈련**

[0085] 도 4a는 본 개시의 일 실시예에 따른 기지국의 신경망 모듈을 나타낸 예시도이다.

[0086] 도 4b는 본 개시의 일 실시예에 따른 신경망 모듈을 중앙집중적 학습 과정의 일 예를 도시한 예시도이다.

[0087] 도 4c는 본 개시의 일 실시예에 따른 신경망 모듈이 기지국에 분산적으로 배치되는 일 예를 도시한 예시도이다.

[0088] 본 개시에서는 분산 MOO 자원 관리를 위해, MOSAICS(multi-objective optimization strategy for AI-aided communication systems) 프레임워크를 제안한다.

[0089] MOSAICS 방식의 네트워크에서, 각 기지국들은 신경망 모듈(400)을 구비할 수 있다. 도 4a에 도시되듯이, 신경망 모듈(400)은 상대 기지국과의 협력을 위한 협력통신신호를 생성하도록 기학습된 메신저 신경망(402) 및 개별 기지국에서 지역 해를 분산적으로 계산하도록 기학습된 옵티마이저 신경망(404)을 전부 또는 일부 포함할 수 있다. 메신저 신경망(402) 및 옵티마이저 신경망(404)은 심층 신경망(Deep Neural Network)으로 구현될 수 있으나, 이에 한정되는 것은 아니다.

[0090] 제i 기지국의 신경망 모듈(400)의 메신저 신경망(402) 및 옵티마이저 신경망(404)은 각각 수학식 5의 $\mathcal{M}_{\theta_i}(\cdot)$ 및 $\mathcal{X}_{\vartheta_i}(\cdot)$에 대응할 수 있다.

[0091] 본 개시에 따른 MOSAICS 프레임워크의 학습 메커니즘은 신경망 모듈이 포함하는 한 쌍의 신경망들의 상호작용에 의존한다. 이 신경망 쌍은 분산 MOO에 관련된 지역 계산을 수행하고, 이기종 목적 MOO 태스크에서 신경망 모듈(400)들 간의 보편적인 협력을 위한 메시지의 저차원 표현을 각각 획득한다.

[0092] 본 개시에 따른 MOSAICS 프레임워크의 훈련 알고리즘은 기존의 학습 기법과 구별될 수 있다. 전역 목적 값은 서로 다른 물리적 해석과 관련된 지역 목적 값들을 비교할 수 있도록 비물리적 양(non-physical quantity)을 취할 수 있다. 각 기지국의 신경망 모듈(400)은 이기종 지역 목적을 이용하여 최종 해를 얻기 위해 보편적으로 처리되는 메타 출력(meta-output)을 생성할 수 있다. 이에 따라, 특정 MOO 문제 전용의 실제 목적 함수를 평가하는 AI 유닛이 추가될 수 있다. 따라서, 전체 훈련 전략을 통해 MOSAICS는 모든 선호도 가중치 구성에 대해서 이기종 유틸리티들 사이에서 파레토 최적의 절충(Pareto-optimal tradeoff)을 달성하는 지역 해들을 평가할 수 있게 된다. 결과적으로 MOSAICS 프레임워크는 임의의 네트워킹 설정에 대해 여러 파레토 경계 지점을 설정하는 분산 구현을 수용할 수 있다.

[0093] 도 4a에 도시되듯이, 메신저 신경망(402)은 지역 데이터 및 선호도 가중치를 다른 기지국으로 전송할 제1 협력통신신호로 변환할 수 있다. 옵티마이저 신경망(404)은 지역 데이터, 선호도 가중치 및 다른 기지국으로부터 수신한 제2 협력통신신호를 이용하여 지역 해를 결정할 수 있다. 따라서, 개별 기지국들에서의 신경망 모듈(400)의 동작들은 로컬에서 사용할 수 있는 지식만으로 독립적으로 진행될 수 있다.

[0094] 도 4b를 참조하면, 신경망 모듈들(400-1, 400-2 및 400-3)을 학습시키기 위해, 두 개의 보조적인 신경망 모듈, 즉 목적 신경망(420) 및 듀얼 신경망(430)이 사용될 수 있다. 목적 신경망(420)은 수학식 5의 (5a)의 $\mathcal{F}_{\varphi}(\cdot)$에 대응할 수 있고, 듀얼 신경망(430)은 수학식 9의 $\mathcal{N}_{\psi}(\cdot)$에 대응할 수 있다. 목적 신경망(420) 및 듀얼 신경망(430)은 수학식 7의 (7b)의 제약조건을 충족하도록 신경망 모듈들(400-1, 400-2 및 400-3)의 업데이트를 감독하여, 제i 기지국의 지역 목적이 전역 목적의 w_i 배를 차지하도록 한다. 이들은 선호도 벡터의 범용 구성 하에서 여러 파레토 경계 지점들을 식별하도록 하는 MOSAICS 프레임워크의 핵심 요소들(key enablers)이다.

[0095] 수학식 12의 프라이멀-듀얼 업데이트 알고리즘은 관련 파라미터에 전용된 별개의 신경망들의 셋으로 구현될 수 있다. 신경망 모듈들(400-1, 400-2 및 400-3), 목적 신경망(420) 및 듀얼 신경망(430) 간의 상호작용은 표 1에 예시된 MOSAICS 프레임워크의 훈련 절차를 통합할 수 있다.

표 1

Algorithm 1 MOSAICS training algorithm

Initialize θ, φ, and ψ.
repeat
Primal update:
$\theta \leftarrow \theta + \eta \nabla_{\theta} \mathcal{G}(\theta, \psi)$
$\varphi \leftarrow \varphi + \eta \nabla_{\varphi} \mathcal{H}(\varphi, \psi)$
Dual update:
$\psi \leftarrow \psi - \eta \nabla_{\psi} \mathcal{J}(\theta, \varphi, \psi)$
until convergence

[0096]

[0097] 신경망 모듈들(400-1, 400-2 및 400-3)의 파라미터 θ는 모든 지역 목적들 $\tilde{\mathbf{f}}(\theta, \mathbf{w})$이 수학식 10의 (10a)의 $\mathcal{G}(\theta, \psi)$의 최대치를 공동으로 달성하도록 학습된다. 또한, 듀얼 신경망(430), 즉 수학식 9의 $\mathcal{N}_{\psi}(\cdot)$은 개별 지역 목적들의 기여도를 조정하여 선호도 벡터 방향으로 파레토 경계 지점에 도달하도록 한다. 이를 위해, 수학식 13과 같이 정의된 가용성 척도(feasibility measure)를 최소화하여 지역 목적들과 관련된 수학식 7의 (7b)의 여러 개별 제약조건들의 가용성을 공동으로 제어할 수 있다.

수학식 13

$$\mathcal{J}(\theta, \varphi, \psi) \triangleq \sum_{\mathbf{w} \in \mathcal{W}} \mathcal{N}_{\psi}(\mathbf{w})^{T} (\tilde{\mathbf{f}}(\theta, \mathbf{w}) - \mathbf{w} \cdot \mathcal{F}_{\varphi}(\mathbf{w})). \quad (13)$$

[0098]

[0099] 여기서, $\mathcal{J}(\theta, \varphi, \psi)$는 상보적 여유정리(complementary slackness)에 따른 최적 조건에서 '0'이 된다. 듀얼 신경망(430)의 출력의 비음성성(nonnegativity)은 제약조건에 페널티를 주는 듀얼 변수 $[\mathcal{N}_{\psi}(\mathbf{w})]_i$를 증가시킴으로써 라그랑지안의 비가용적인(infeasible) 지역 제약조건 $\tilde{f}_i(\theta, \mathbf{w}) < w_i \mathcal{F}_{\varphi}(\mathbf{w})$을 통제한다. 이는 결과적으로 목적 신경망(420)의 파라미터 φ의 프라이멀 업데이트에 영향을 미쳐, 수학식 10의 (10b)의 프라이멀 목적(primal objective) $\mathcal{H}(\varphi, \psi)$, 즉 다양한 w 방향에 대한 전역 목적 $\mathcal{F}_{\varphi}(\mathbf{w})$의 가중 평균(weighted average)을 증가시킬 수 있다. 한편, 듀얼 신경망(430)은 gradient 업데이트의 부호(sign)를 제어할 수 있다. 만약 출력이 큰 값이 되거나 수학식 7의 (7b)의 지역 목적 제약 조건이 비가용적이 되면, $\mathcal{H}(\varphi, \psi)$과 관련된 신경망은 전역 목적 값을 감소시켜, 지역 제약조건에서의 부등식의 경계(bound)를 완화하게 된다. $\lambda_{i,\mathbf{w}}$를 무효화(nullify)하는 모든 제약 조건들이 충족되면, $\mathcal{H}(\varphi, \psi)$는 $\mathcal{F}_{\varphi}(\mathbf{w})$를 개선하도록 업데이트된다.

[0100] 본 개시에서 전체 신경망들의 훈련 계산은 함께 결합되어 수행될 수 있다. 네트워크 클라우드(network cloud)는 강력한 연산 자원(computation resources)을 사용하여, MOSAICS(410)를 구성하는 신경망 모듈들(400-1, 400-2 및 400-3)과 두 개의 보조 신경망(즉 목적 신경망(420) 및 듀얼 신경망(430))을 공동으로 훈련시킬 수 있다. 훈련 데이터 셋(training data set)은 지역 데이터들 및 선호도 가중치들의 집합으로 구성될 수 있다. 표 1의 프라이멀-듀얼 업데이트 규칙에 따라, 미니-배치 훈련 정책(mini-batch training policy)이 실행될 수 있다. 훈련 알고리즘은 지역 목적들과 관련된 제약 조건하에서 지역 해가 전역 목적을 협력적으로 최대화하도록 신경망들의 파라미터를 업데이트할 수 있다. 이를 구현하기 위해, 역전파(back propagation)를 이용하여 프라이멀 변수의

측면에서 라그랑지안을 최대화하는 동시에, SGD 알고리즘을 이용하여 듀얼 변수를 최소화할 수 있다. 목적 신경망(420) 및 듀얼 신경망(430)은 임의로 샘플링된 선호도 가중치들에 대한 전역 목적과 듀얼 변수를 각각 평가하여, 전역 목적 값이 목적 공간 경계에 위치하고 각 신경망 모듈(400-1, 400-2 및 400-3)이 최대화된 지역 목적을 산출하도록 할 수 있다. 추정된 전역 목적을 이용해 듀얼 신경망(430)을 업데이트하여, 듀얼 변수가 관련 제약 조건의 가용성을 결정하도록 할 수 있다. 따라서, 목적 신경망(420)은 선호도 벡터의 방향, 즉 가용한 솔루션들 사이에서 전역 목적을 개선할 수 있다. 또한, 기지국의 신경망 모듈(400-1, 400-2 및 400-3)들은 대응하는 가용한 지역 해들을 계산할 수 있다.

[0101] 본 개시에 따르면, 목적 신경망(420) 및 듀얼 신경망(430)은 선호도 벡터 $\mathbf{w}$에만 의존한다. 따라서, 목적 신경망(420) 및 듀얼 신경망(430)은 신경망 모듈들(400-1, 400-2 및 400-3)의 순방향 패스 계산(forward pass computation)에는 영향을 미치지 않으므로, MOSAICS(410), 즉 전체 신경망 모듈들(400-1, 400-2 및 400-3)을 훈련할 때에만 사용된다. 훈련된 MOSAICS(410)는 목적 신경망(420) 및 듀얼 신경망(430)에 의해 계산된 출력에 대한 지식 없이 실시간 추론을 통해 프라이멀 솔루션 셋(primal solution set)을 계산할 수 있다. 훈련이 완료되면, 도 5에 도시된 목적 신경망(420) 및 듀얼 신경망(430)이 MOSAICS(410)로부터 제거될 수 있으며, MOSAICS(410)를 구성하는 각 신경망 모듈(400-1, 400-2 및 400-3)들은 각 기지국들에 설치될 수 있다. 이와 같은 분산 구현은 도 4c에 나타나는 바와 같이 신경망 모듈(400-1, 400-2 및 400-3)들의 네트워크 구성(network arrangement)을 감소시킬 수 있다.

[0102] 도 4a 및 도 4c를 참조하면, 각 신경망 모듈(신경망 모듈(400-1, 400-2 및 400-3)에 포함되는 메신저 신경망(402)은 지역 데이터를 입력으로 받아 메시지, 즉 협력통신신호를 생성한다. 도 4c에 도시되는 바와 같이, 메신저 신경망(402)에서 출력되는 제1 협력통신신호는 목적 노드에 따라 구별될 수 있으며, 각 제1 협력통신신호는 노드 간 링크를 통해 상호 연결된 상대 신경망 모듈로 전송될 수 있다. 신경망 모듈(400-1, 400-2 및 400-3)에서 수집되는 제2 협력통신신호는, 각 신경망 모듈(400-1, 400-2 및 400-3)들의 옵티마이저 신경망(404)으로 입력되어 독립적인 지역 해 계산에 이용될 수 있다. 메신저 신경망(402) 및 옵티마이저 신경망(404)들은 훈련 계산 과정에서의 신경망 모듈(400-1, 400-2 및 400-3)들의 네트워크 구성(network arrangement)에 따라, 신경망 모듈(400-1, 400-2 및 400-3) 상에서 균등하게 훈련되거나 별개로 훈련될 수도 있다.

[0103] 훈련된 신경망 모듈(400-1, 400-2 및 400-3)들의 수학식 5의 (5b) 및 (5c)의 순방향 패스 계산으로 인해 야기되는 계산 비용(computational costs)은 레이어 수 및 잠재 차원(latent dimensions)과 같은 DNN 구조 파라미터들에 따라 달라질 수 있다. DNN 추론에는 시스템 크기에 대한 3차 계산 복잡성을 갖는 선형 행렬 곱셈(linear matrix multiplications)이 포함되므로, 본 개시의 일 실시예에 따른 목적 공간 경계 식별은 종래기술에 따른 반복적 MOO 솔버(iterative MOO solver)에 비해 비용 효율적이다.

[0104] **신경망 모듈의 협력통신신호 생성**

[0105] 도 5는 본 개시의 일 실시예에 따른 메신저 신경망의 훈련 과정의 일 예를 도시한 예시도이다.

[0106] 신경망 모듈들의 분산된 구조(decentralized coordination)에서는, 노드 간 연결의 제한된 용량에 의한 불충분한 메시지 교환에 의해 성능 저하가 발생하기 쉽다. 본 개시에 따른 MOSAICS 프레임워크에서는 수학식 7의 (7c)의 메시지 양자화 제약조건(message quantization constraint)을 포함하는 학습 정책(learning policy)을 제공한다. 이하에서는 설명의 편의를 위해 모든 첨자(subscripts)를 생략하도록 한다. 예컨대, 협력통신신호는 $\mu \in \mathbb{Z}_Q = \{0, 1, \cdots, Q-1\}$로 표현될 수 있다.

[0107] 메시지 양자화 제약조건은 $\mathbf{a}$와 $\mathbf{w}$의 즉각적인 구현에 자연스럽게 부과될 수 있다. 따라서, 신경망 모듈들의 평균 동작(average behavior)을 처리하기 위해 일반적으로 도입되는 프라이멀-듀얼 학습 알고리즘과는 다른 새로운 훈련 전략이 필요하다. 본 개시에서는 이를 위해, 메신저 신경망(402)의 연속-값 입력(continuous-valued inputs), 즉 지역 데이터 및 선호도 가중치를 이산 메시지(discrete messages)로 인코딩(encoding)하는 고도화된 활성화 기법(sophisticated activation technique)을 제안한다. 이러한 기법에서 주요 과제는 MOSAICS를 훈련하기 위해 종단 간 역전파(end-to-end back propagation)에 필요한 이산 DNN 출력의 유효한 gradients를 보장하는 데 있다. DNN 출력에서 바이너리 활성화(binary activation)와 같은 간단한 양자화는 훈련 실패로 끝나는 기울기 소실 문제(gradient vanishing issues)를 가져올 수 있다.

[0108] 이를 해결 하기 위해, 본 개시의 일 실시예에 따른 확률적 양자화 활성화(stochastic quantization activation)는 임의의 입력 값 $\tilde{\mu} \in [0, Q-1]$에 대해 정수 출력 $\mu \in \mathbb{Z}_Q$를 보장한다. 이는 Q=2인 경우에

대한 확률론적 이진화 활성화(stochastic binarization activation)를 일반화한 것이다.

[0109] 정수 $z \in \{1, \cdots, Q-1\}$에 대해, DNN 출력 $\tilde{\mu}$이 $[z-1, z)$ 영역 내에 있는 경우, 출력 활성화로서 $z-\tilde{\mu}$ 및 $1-(z-\tilde{\mu})$의 확률로 $\tilde{\mu}$을 $\mu = z-1$ 또는 $\mu = z$으로 매핑하는 랜덤 노이즈 레이어(random noise layer)가 추가될 수 있다. 도 5에 도시되듯이, 매핑 확률(mapping probabilities)은 연속 값 q에서 인접 정수 z-1 및 z까지의 거리에 따라 달라진다. μ는 $\tilde{\mu}$의 편향되지 않은 추정자(unbiased estimator)이며, 좋은 근사치로 작용하는 것으로 알려져 있으므로, 훈련을 위한 확률적 양자화 활성화의 기울기를 평가하기 위해, $\tilde{\mu}$의 순시 값 대신 양자화된 정수 μ를 사용하여 역방향 패스 계산에서 기울기를 평가할 수 있다.

[0110] 도 5는 메신저 신경망의 순방향 패스 및 역방향 패스를 위한 하이브리드 계산 구조(hybrid computation structure)를 도시한다. [0, Q-1] 내에서 연속-값 메시지 출력을 묶기 위해 시그모이드 함수(sigmoid function)가 먼저 적용될 수 있다. 순방향 패스는 확률적 양자화 활성화를 통해 진행되는 반면, 역방향 패스는 경계 활성화(bounding activation)의 출력에서 시작된다. 결과적으로, 메신저 신경망(402)은 연속적인 값을 갖는 지역 데이터를 입력받아 이산 메시지 출력(즉, 제1 협력통신신호)을 생성하기 위해 기울기 소실 문제를 방지하도록 훈련될 수 있다. 확률적 양자화는 신경망을 훈련할 때만 유효하므로, 확률적 양자화 활성화는 균일 양자화 활성화(uniform quantization activation)로 대체될 수 있다.

[0111] 도 6은 본 개시의 일 실시예에 따른 신경망을 훈련 과정을 나타내는 순서도이다.

[0112] 도 6에 도시된 방법은, 도 1 내지 도 5에서 전술한 신경망 모듈들의 훈련을 위한 전자장치(이하, 훈련장치), 예컨대, 기지국 제조사에 의해 운용되는 컴퓨팅 디바이스에 의해 수행될 수 있다.

[0113] 훈련장치는 하나 이상의 지역 데이터 및 하나 이상의 선호도 가중치를 포함하는 훈련 데이터 셋을 획득한다(S600). 예컨대, 훈련장치는 각 신경망 모듈(400)이 설치될 하나 이상의 기지국들로부터 훈련 데이터 셋을 획득할 수 있으나 이에 한정되는 것은 아니며, 기설정된 수학적 모델에 기반하여 훈련 데이터 셋을 생성할 수도 있다.

[0114] 훈련장치는 하나 이상의 신경망 모듈(400), 목적 신경망(420) 및 듀얼 신경망(430)의 훈련을 위한 손실 함수(loss function)를 획득한다(S610). 손실 함수는, 신경망 모듈(400), 목적 신경망(420) 및 듀얼 신경망(430)의 훈련 가능한 파라미터 셋들(trainable parameter sets) θ, φ 및 ψ에 대한 손실 함수를 의미할 수 있다. 손실 함수는 예컨대, 수학식 10의 $\mathcal{G}(\theta, \psi)$, $\mathcal{H}(\varphi, \psi)$ 및 수학식 13의 $\mathcal{J}(\theta, \varphi, \psi)$일 수 있다.

[0115] 훈련장치는 훈련 데이터 셋 및 듀얼 신경망(430)의 출력 값을 기반으로, 메신저 신경망(402) 및 옵티마이저 신경망(404)을 포함하는 하나 이상의 신경망 모듈(400)을 훈련시킬 수 있다(S620). 훈련장치는 옵티마이저 신경망(404)이 지역 해를 출력하고, 메신저 신경망(402)이 다른 신경망 모듈과의 협력을 위한 협력통신신호를 출력하도록 훈련시킬 수 있다. 신경망 모듈(400)은 전역 목적을 최대화하되, 각 신경망 모듈의 지역 목적이 상기 각 신경망 모듈에 대한 선호도 가중치 및 상기 전역 목적에 기초하여 설정되는 제약조건을 충족하는 지역 해를 산출하도록 훈련될 수 있다. 신경망 모듈(400)은 지역 데이터 및 선호도 가중치를 양자화하여 협력통신신호를 생성하도록 훈련될 수 있다.

[0116] 신경망 모듈(400)의 훈련은 신경망 모듈(400)의 파라미터를 훈련시키는 것 또는 신경망 모듈(400)들의 파라미터를 업데이트하는 것을 포함할 수 있다. 훈련장치는 신경망 모듈(400)들의 파라미터 θ에 대한 손실 함수 $\mathcal{G}(\theta, \psi)$의 기울기를 계산하고, 손실 함수의 기울기를 기초로 신경망 모듈(400)의 파라미터 θ을 업데이트할 수 있다. 신경망 모듈(400)의 파라미터 θ는 $\mathcal{G}(\theta, \psi)$가 최대화되도록 업데이트될 수 있다.

[0117] 훈련장치는 훈련 데이터 셋의 선호도 가중치 및 듀얼 신경망(430)의 출력 값을 이용하여 목적 신경망(420)이 하나 이상의 신경망 모듈의 전역 목적을 출력하도록 훈련시킬 수 있다(S620).

[0118] 목적 신경망(420)의 훈련은 목적 신경망(420)의 파라미터를 훈련시키는 것 또는 목적 신경망(420)의 파라미터를

업데이트하는 것을 포함할 수 있다. 훈련장치는 목적 신경망(420)의 파라미터 φ에 대한 손실 함수 $\mathcal{H}(\varphi,\psi)$의 기울기를 계산하고, 손실 함수의 기울기를 기초로 목적 신경망(420)의 파라미터 φ을 업데이트할 수 있다. 목적 신경망(420)의 파라미터 φ는 $\mathcal{H}(\varphi,\psi)$, 즉 하나 이상의 신경망 모듈(400)들의 전역 목적에 대한 가중 평균이 증가하도록 업데이트 될 수 있다.

[0119] 훈련장치는 훈련 데이터 셋의 선호도 가중치 및 목적 신경망(420)의 출력 값을 이용하여 듀얼 신경망(430)이 프라이멀-듀얼 최적화를 위한 듀얼 변수를 출력하도록 훈련시킬 수 있다(S630).

[0120] 듀얼 신경망(430)의 훈련은 듀얼 신경망(430)의 파라미터를 훈련시키는 것 또는 듀얼 신경망(430)의 파라미터를 업데이트하는 것을 포함할 수 있다. 훈련장치는 듀얼 신경망(430)의 파라미터 ψ에 대한 손실 함수 $\mathcal{J}(\theta,\varphi,\psi)$의 기울기를 계산하고, 손실 함수의 기울기를 기초로 듀얼 신경망(430)의 파라미터 ψ를 업데이트할 수 있다. 듀얼 신경망(430)의 파라미터 ψ는 $\mathcal{J}(\theta,\varphi,\psi)$가 최소화되도록 업데이트될 수 있다. 듀얼 신경망의 출력 값은 비음성(nonnegativity)을 가질 수 있다.

[0121] 훈련장치는 신경망 모듈(400)들이 목적 성능을 달성하였는지 판단할 수 있다(S650). 목적 성능 달성은, 예컨대, 신경망 모듈(400)들의 지역 목적이 기설정된 임계치에 도달하거나, 훈련 과정의 반복횟수가 기설정된 임계치에 도달하는 것을 포함할 수 있으나 이에 한정되는 것은 아니다.

[0122] 훈련장치는 신경망 모듈(400)들이 목적 성능을 달성할 때까지, 신경망 모듈(400), 목적 신경망(420) 및 듀얼 신경망(430)의 훈련을 번갈아 수행할 수 있다(S610 내지 S650).

[0123] 한편, 하나 이상의 신경망 모듈(400)의 학습이 완료되면, 각 기지국으로 분산적으로 배치될 수 있다.

[0124] 도 7은 본 개시의 일 실시예에 따른 신경망의 실시간 협력 및 계산 과정을 나타내는 순서도이다.

[0125] 도 7에 도시된 방법은, 도 1 내지 도 5에서 전술한 신경망 모듈 또는 이를 구비한 전자장치(이하, 연산장치)에 의해 수행될 수 있으므로, 중복되는 내용에 대해서는 자세한 설명을 생략한다.

[0126] 연산장치는 지역 데이터를 획득한다(S700). 연산장치는 단말로부터 지역 데이터를 실시간으로 획득할 수 있다. 예컨대, 연산장치는 지역 데이터로서, 단말로부터 채널 상태 정보(CSI)를 보고받을 수 있다.

[0127] 연산장치는 지역 데이터 및 선호도 가중치에 기초하여, 하나 이상의 상대 연산장치와의 협력을 위한 제1 협력통신신호를 생성하고, 제1 협력통신신호를 상대 연산장치에게 전송한다(S710). 연산장치는 기학습된 메신저 신경망(402)에 지역 데이터 및 선호도 가중치를 입력하여, 제1 협력통신신호를 획득할 수 있다. 메신저 신경망(402)은, 지역 데이터 및 선호도 가중치를 양자화하여 상기 제1 협력통신신호로 변환하도록 학습될 수 있다. 이를 위해, 연산장치는 단말로부터 선호도 가중치를 획득할 수 있다. 연산장치가 기지국으로 구현되는 경우, 상대 연산장치는 기지국과 백홀 링크를 통해 상호 연결된 다른 기지국을 의미할 수 있다.

[0128] 연산장치는 상대 연산장치로부터 제2 협력통신신호를 수신한다(S720).

[0129] 연산장치는 지역 데이터, 선호도 가중치 및 제2 협력통신신호에 기초하여, 연산장치에 대한 지역 해를 산출한다(S730). 연산장치는 기학습된 옵티마이저 신경망(404)에 지역 데이터, 선호도 가중치 및 제2 협력통신신호를 입력하여, 지역 해를 획득할 수 있다. 옵티마이저 신경망(404)은 연산장치 및 상대 연산장치의 전역 목적을 최대화하되, 연산장치의 지역 목적이 선호도 가중치 및 전역 목적에 기초하여 설정되는 제약조건을 충족하는 지역 해를 산출하도록 학습될 수 있다.

[0130] 도 8은 본 개시의 일 실시예에 따른 신경망의 훈련을 위한 장치를 개략적으로 나타낸 블럭 구성도이다.

[0131] 훈련장치(80)는 송수신기(800), 메모리(802) 및 프로세서(804)를 전부 또는 일부 포함할 수 있다. 본 개시에서 훈련장치(80)는 신경망 모듈들의 훈련을 위한 전자장치로서, 예컨대, 기지국 제조사에 의해 운용되는 컴퓨팅 디바이스일 수 있으나 이에 한정되는 것은 아니다.

[0132] 송수신기(800)는 프로세서(804)와 연결되어, 기지국들과 각종 신호를 송수신할 수 있다. 송수신기(800)는 예컨대, 송신 필터, 수신 필터, 증폭기, 믹서(mixer), 오실레이터(oscillator), DAC(Digital to Analog Convertor)

및 ADC(Analog to Digital Convertor) 등을 전부 또는 일부 포함할 수 있다.

[0133] 메모리(802)는 프로세서(804)와 연결되어, 프로세서(804)를 구동하기 위한 다양한 정보를 저장할 수 있다. 메모리(802)는 프로세서를 통해 실행가능한 적어도 하나의 명령어를 저장할 수 있다. 메모리(802)는 휘발성 메모리 및 비휘발성 메모리 중 적어도 하나를 포함할 수 있다. 휘발성 메모리는 SRAM(Static Random Access Memory) 또는 DRAM(Dynamic Random Access Memory) 등 중 어느 하나를 포함할 수 있고, 비휘발성 메모리는 플래시 메모리(flash memory) 등 중 어느 하나를 포함할 수 있다.

[0134] 프로세서(804)는 훈련장치(80)를 제어하기 위한 전반적인 기능들을 제어하는 역할을 한다. 예를 들어, 프로세서(804)는 훈련장치(80) 내의 메모리(802)에 저장된 프로그램들을 실행함으로써, 훈련장치(80)를 전반적으로 제어할 수 있다.

[0135] 프로세서(804)는 송수신기(800)가 기지국들과 각종 신호를 송수신하도록 제어할 수 있으며, 전송할 또는 수신한 신호 등을 메모리(802)에 저장하도록 제어할 수도 있다.

[0136] 프로세서(904)는 도 1 내지 도 7에서 제안된 기능, 과정 및/또는 방법을 구현하도록 구성될 수 있다. 전술한 실시예에서 신경망 모듈을 훈련시키기 위한 기능, 과정 및/또는 방법들이 프로세서(804)에 의해 구현될 수 있다.

[0137] 예를 들어, 프로세서(804)는 하나 이상의 지역 데이터 및 하나 이상의 선호도 가중치를 포함하는 훈련 데이터 셋을 획득하고, 하나 이상의 선호도 가중치 및 목적 신경망(420)의 출력 값을 기반으로 듀얼 신경망(430)이 프라이멀-듀얼 최적화(primal-dual optimization)를 위한 듀얼 변수(dual variable)를 출력하도록 훈련시키고, 하나 이상의 선호도 가중치 및 듀얼 신경망의 출력 값을 기반으로, 목적 신경망(420)이 하나 이상의 신경망 모듈의 전역 목적을 출력하도록 훈련시키고, 상기 훈련 데이터 셋 및 상기 듀얼 신경망의 출력 값을 기반으로, 상기 하나 이상의 신경망 모듈이 지역 해 및 다른 신경망 모듈과의 협력을 위한 협력통신신호를 출력하도록 훈련시키도록 구성하도록 구성될 수 있다.

[0138] 도 9는 본 개시의 일 실시예에 따른 연산장치를 개략적으로 나타낸 블럭 구성도이다.

[0139] 연산장치(90)는 송수신기(900), 메모리(902) 및 프로세서(904)를 전부 또는 일부 포함할 수 있다. 본 개시에서 연산장치(90)는 다목적 최적화 문제의 지역해를 분산적으로 산출하기 위한 전자장치로서, 예컨대, 분산 네트워크의 기지국일 수 있으나 이에 한정되는 것은 아니다.

[0140] 송수신기(900)는 프로세서(904)와 연결되어, 단말, 다른 연산장치 및/또는 훈련장치(80)와 각종 신호를 송수신할 수 있다. 송수신기(900)는 예컨대, 송신 필터, 수신 필터, 증폭기, 믹서(mixer), 오실레이터(oscillator), DAC(Digital to Analog Convertor) 및 ADC(Analog to Digital Convertor) 등을 전부 또는 일부 포함할 수 있다.

[0141] 메모리(902)는 프로세서(904)와 연결되어, 프로세서(904)를 구동하기 위한 다양한 정보를 저장할 수 있다. 메모리(902)는 프로세서를 통해 실행가능한 적어도 하나의 명령어를 저장할 수 있다. 메모리(902)는 휘발성 메모리 및 비휘발성 메모리 중 적어도 하나를 포함할 수 있다. 휘발성 메모리는 SRAM(Static Random Access Memory) 또는 DRAM(Dynamic Random Access Memory) 등 중 어느 하나를 포함할 수 있고, 비휘발성 메모리는 플래시 메모리(flash memory) 등 중 어느 하나를 포함할 수 있다. 메모리(902)는 상대 연산장치와의 협력을 위한 협력통신신호를 생성하도록 기학습된 메신저 신경망 및 개별 연상장치에서 지역 해를 분산적으로 계산하도록 기학습된 옵티마이저 신경망을 포함하는 신경망 모듈을 저장할 수 있다.

[0142] 프로세서(904)는 연산장치(90)을 제어하기 위한 전반적인 기능들을 제어하는 역할을 한다. 예를 들어, 프로세서(904)는 연산장치(90) 내의 메모리(902)에 저장된 프로그램들을 실행함으로써, 연산장치(90)를 전반적으로 제어할 수 있다.

[0143] 프로세서(904)는 송수신기(900)가 단말, 다른 연산장치 및/또는 훈련장치(80)와 각종 신호를 송수신하도록 제어할 수 있으며, 전송할 또는 수신한 신호 등을 메모리(902)에 저장하도록 제어할 수도 있다.

[0144] 프로세서(904)는 도 1 내지 도 7에서 제안된 기능, 과정 및/또는 방법을 구현하도록 구성될 수 있다. 전술한 실시예에서 기지국 또는 연산장치의 동작은 프로세서(904)에 의해 구현될 수 있다.

[0145] 예를 들어, 프로세서(904)는 연산장치(90)의 지역 데이터 및 선호도 가중치에 기초하여, 상대 연산장치와의 협력을 위한 제1 협력통신신호를 생성하고, 상기 제1 협력통신신호를 상기 상대 연산장치에게 전송하고, 상기 상대 연산장치로부터 제2 협력통신신호를 수신하고, 상기 지역 데이터, 상기 선호도 가중치 및 상기 제2 협력통신

신호에 기초하여, 상기 연산장치에 대한 지역 해를 산출하도록 구성될 수 있다.

[0146] 도 6 및 도 7에서는 각 과정들을 순차적으로 실행하는 것으로 기재하고 있으나, 이는 본 개시의 일 실시예의 기술 사상을 예시적으로 설명한 것에 불과한 것이다. 다시 말해, 본 개시의 일 실시예가 속하는 기술 분야에서 통상의 지식을 가진 자라면 본 개시의 일 실시예의 본질적인 특성에서 벗어나지 않는 범위에서 도 6 및 도 7에 기재된 순서를 변경하여 실행하거나 각 과정들 중 하나 이상의 과정을 병렬적으로 실행하는 것으로 다양하게 수정 및 변형하여 적용 가능할 것이므로, 도 6 및 도 7은 시계열적인 순서로 한정되는 것은 아니다.

[0147] 본 명세서에 설명되는 시스템들 및 기법들의 다양한 구현예들은, 디지털 전자 회로, 집적 회로, FPGA(field programmable gate array), ASIC(application specific integrated circuit), 컴퓨터 하드웨어, 펌웨어, 소프트웨어, 및/또는 이들의 조합으로 실현될 수 있다. 이러한 다양한 구현예들은 프로그래밍가능 시스템 상에서 실행가능한 하나 이상의 컴퓨터 프로그램들로 구현되는 것을 포함할 수 있다. 프로그래밍가능 시스템은, 저장 시스템, 적어도 하나의 입력 디바이스, 그리고 적어도 하나의 출력 디바이스로부터 데이터 및 명령들을 수신하고 이들에게 데이터 및 명령들을 전송하도록 결합되는 적어도 하나의 프로그래밍가능 프로세서(이것은 특수 목적 프로세서일 수 있거나 혹은 범용 프로세서일 수 있음)를 포함한다. 컴퓨터 프로그램들(이것은 또한 프로그램들, 소프트웨어, 소프트웨어 애플리케이션들 혹은 코드로서 알려져 있음)은 프로그래밍가능 프로세서에 대한 명령어들을 포함하며 "컴퓨터가 읽을 수 있는 기록매체"에 저장된다.

[0148] 컴퓨터가 읽을 수 있는 기록매체는, 컴퓨터 시스템에 의하여 읽혀질 수 있는 데이터가 저장되는 모든 종류의 기록장치를 포함한다. 이러한 컴퓨터가 읽을 수 있는 기록매체는 ROM, CD-ROM, 자기 테이프, 플로피디스크, 메모리 카드, 하드 디스크, 광자기 디스크, 스토리지 디바이스 등의 비휘발성(non-volatile) 또는 비일시적인(non-transitory) 매체일 수 있으며, 또한 데이터 전송 매체(data transmission medium)와 같은 일시적인(transitory) 매체를 더 포함할 수도 있다. 또한, 컴퓨터가 읽을 수 있는 기록매체는 네트워크로 연결된 컴퓨터 시스템에 분산되어, 분산방식으로 컴퓨터가 읽을 수 있는 코드가 저장되고 실행될 수도 있다.

[0149] 본 명세서에 설명되는 시스템들 및 기법들의 다양한 구현예들은, 프로그램가능 컴퓨터에 의하여 구현될 수 있다. 여기서, 컴퓨터는 프로그램가능 프로세서, 데이터 저장 시스템(휘발성 메모리, 비휘발성 메모리, 또는 다른 종류의 저장 시스템이거나 이들의 조합을 포함함) 및 적어도 한 개의 커뮤니케이션 인터페이스를 포함한다. 예컨대, 프로그램가능 컴퓨터는 서버, 네트워크 기기, 셋탑 박스, 내장형 장치, 컴퓨터 확장 모듈, 개인용 컴퓨터, 랩탑, PDA(Personal Data Assistant), 클라우드 컴퓨팅 시스템 또는 모바일 장치 중 하나일 수 있다.

[0150] 이상의 설명은 본 실시예의 기술 사상을 예시적으로 설명한 것에 불과한 것으로서, 본 실시예가 속하는 기술 분야에서 통상의 지식을 가진 자라면 본 실시예의 본질적인 특성에서 벗어나지 않는 범위에서 다양한 수정 및 변형이 가능할 것이다. 따라서, 본 실시예들은 본 실시예의 기술 사상을 한정하기 위한 것이 아니라 설명하기 위한 것이고, 이러한 실시예에 의하여 본 실시예의 기술 사상의 범위가 한정되는 것은 아니다. 본 실시예의 보호 범위는 아래의 청구범위에 의하여 해석되어야 하며, 그와 동등한 범위 내에 있는 모든 기술 사상은 본 실시예의 권리범위에 포함되는 것으로 해석되어야 할 것이다.

부호의 설명

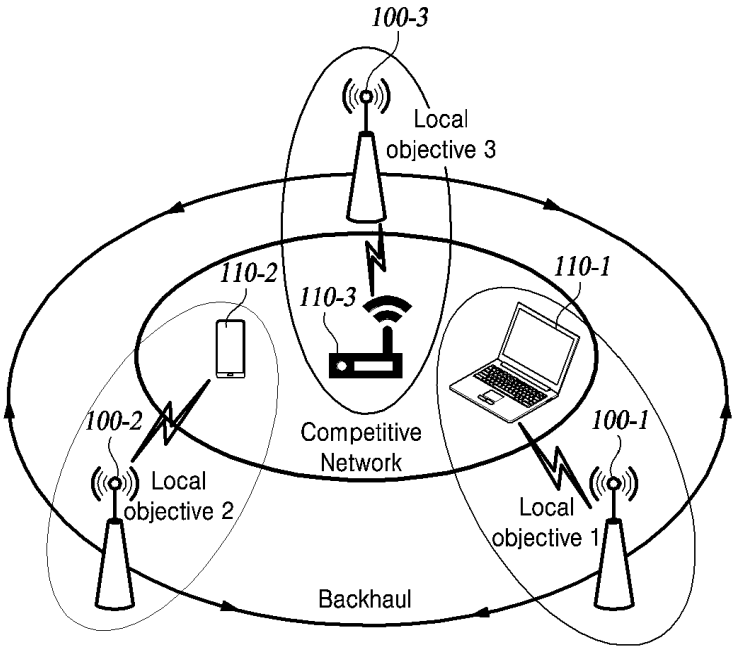
[0151] 10: 네트워크

100-1 내지 100-3: 기지국 110-1 내지 110-3: 단말

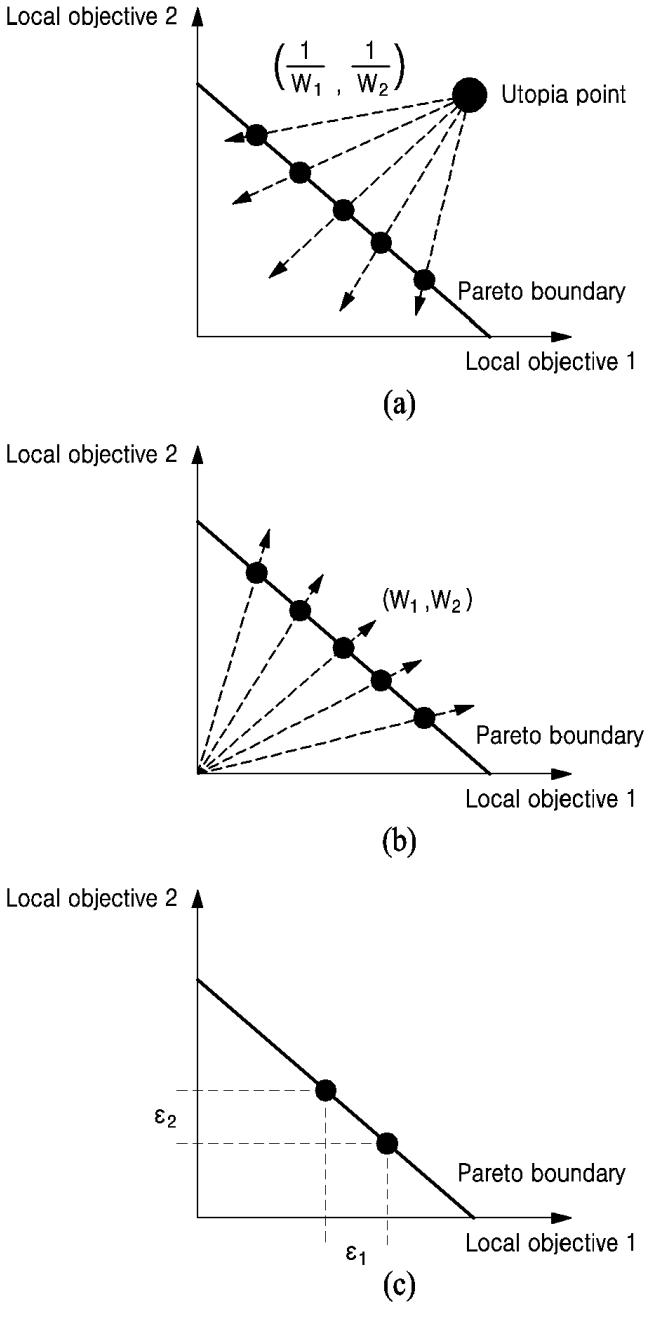
400: 신경망 모듈 400-1 내지 400-3: 신경망 모듈

도면

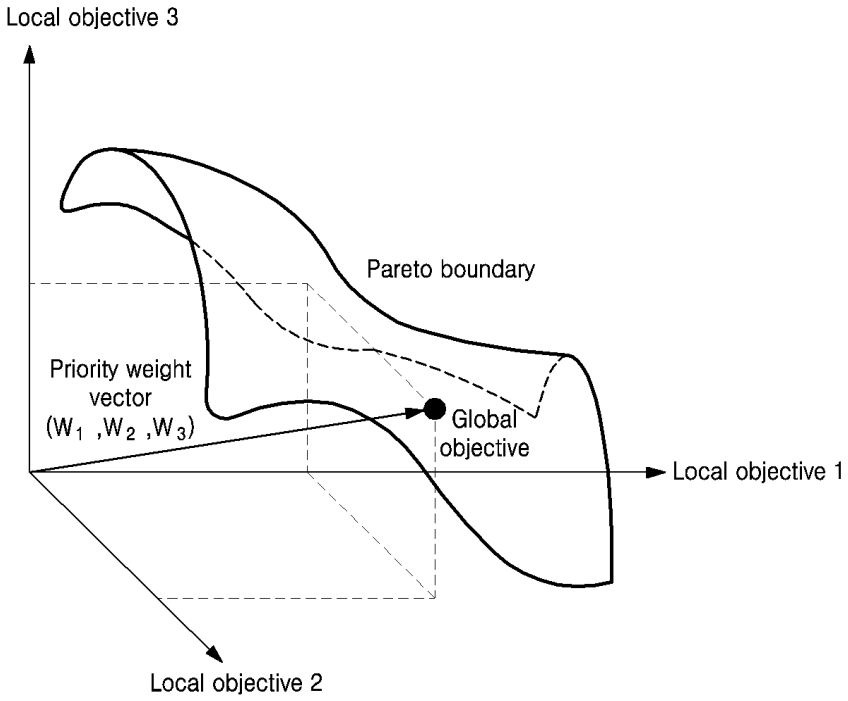
도면1


100-3
Local
objective 3
110-2
110-3
110-1
100-2
Competitive
Network
100-1
Local
objective 2
Local
objective 1
Backhaul

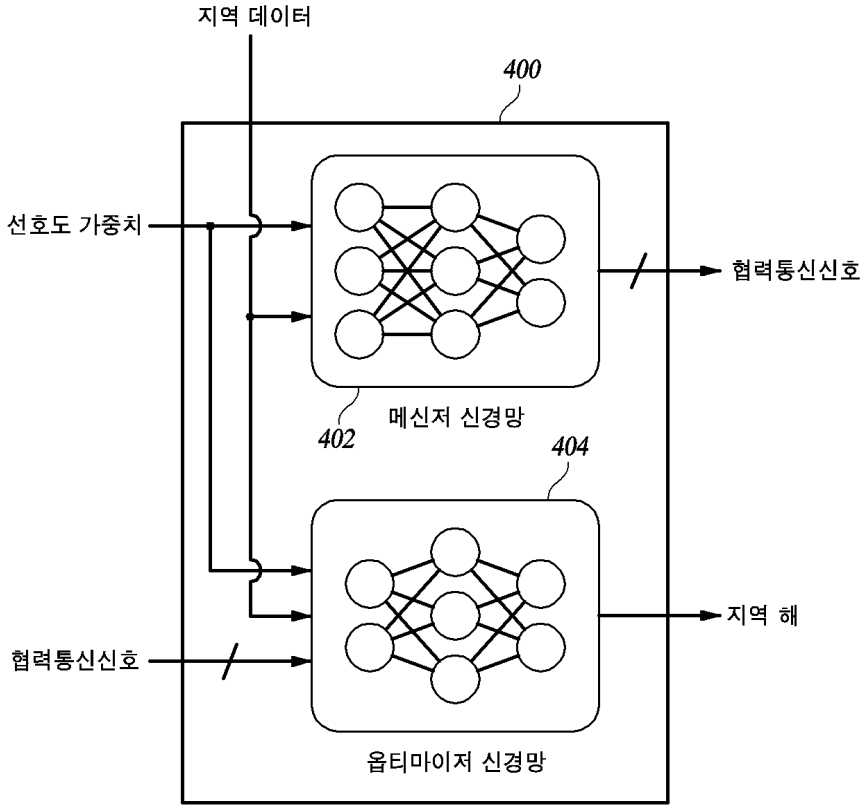
도면2


Local objective 2
$\left(\frac{1}{W_1}, \frac{1}{W_2}\right)$
Utopia point
Pareto boundary
Local objective 1
(a)
Local objective 2
(W_1, W_2)
Pareto boundary
Local objective 1
(b)
Local objective 2
ε_2
Pareto boundary
Local objective 1
ε_1
(c)

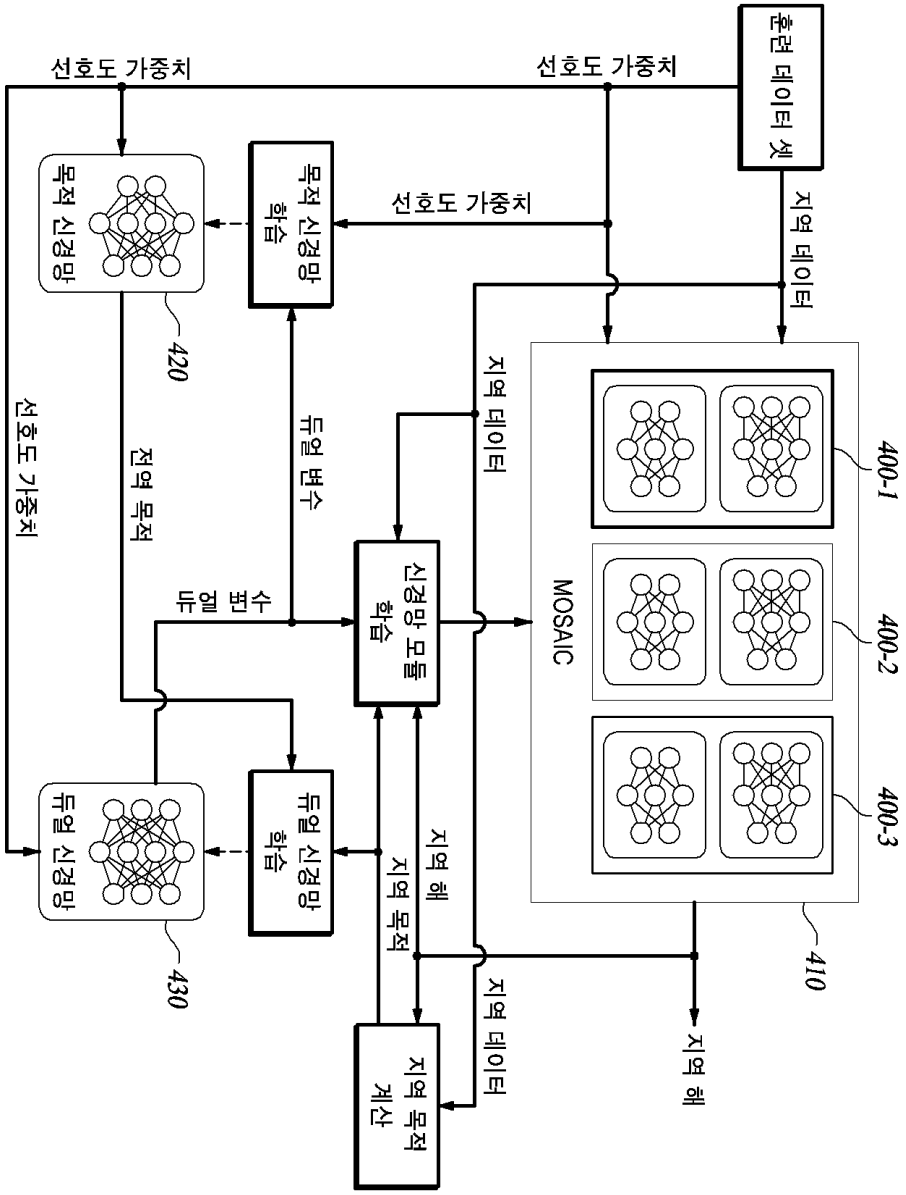
도면3


Local objective 3
Pareto boundary
Priority weight vector
(W1 ,W2 ,W3)
Global objective
Local objective 1
Local objective 2

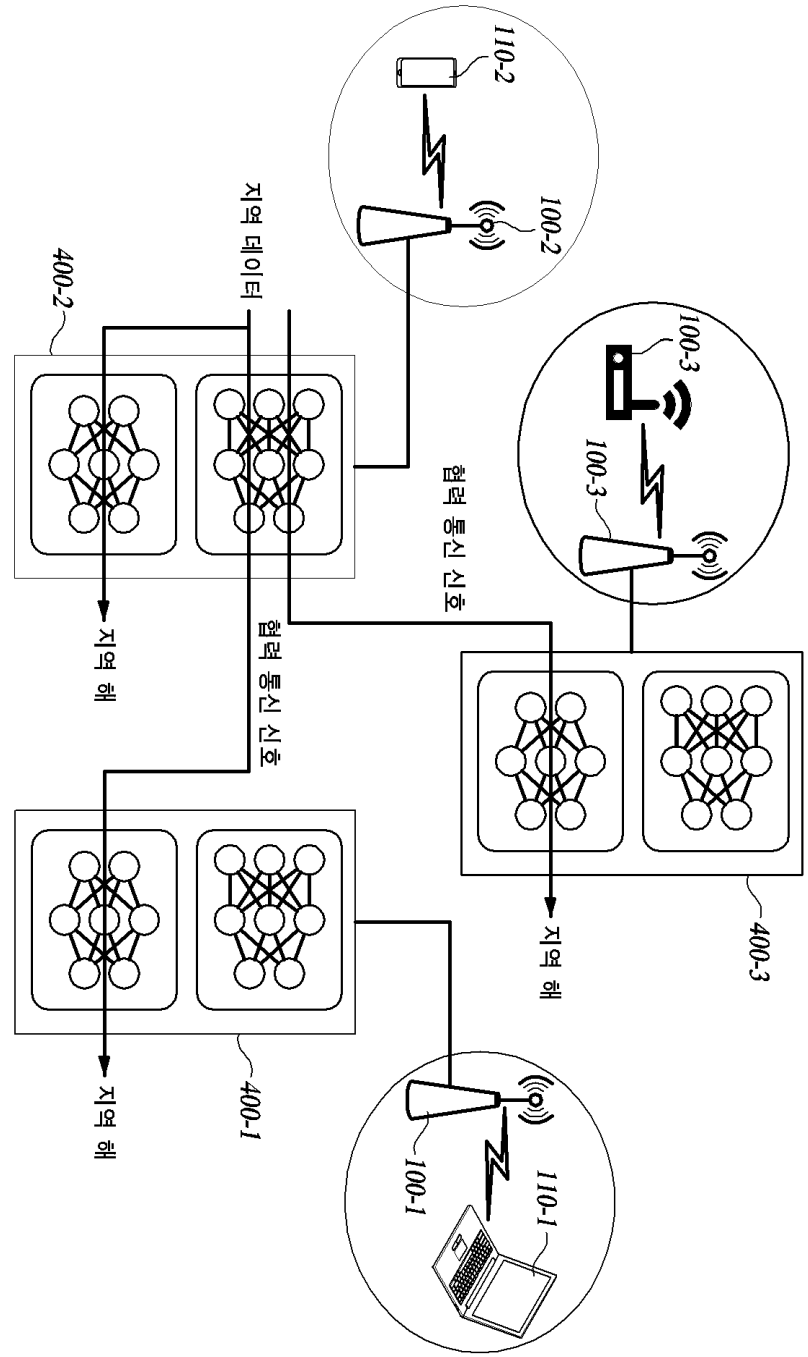
도면4a


지역 데이터
400
선호도 가중치
협력통신신호
메신저 신경망
402
404
지역 해
협력통신신호
옵티마이저 신경망

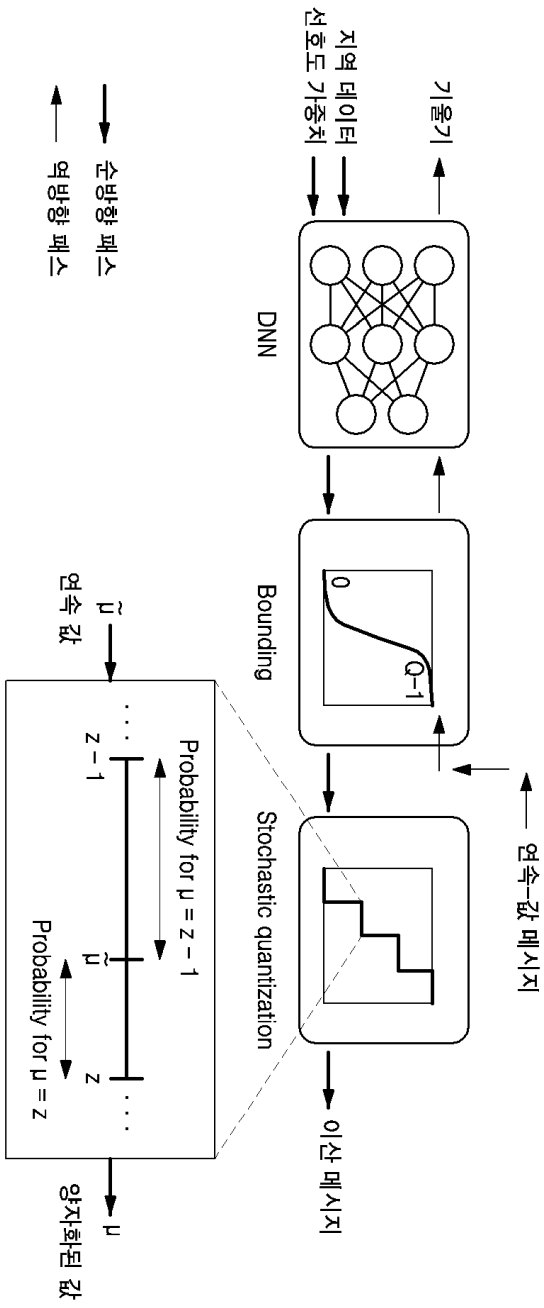
도면4b


훈련 데이터 셋
선호도 가중치
선호도 가중치
목적 신경망 학습
선호도 가중치
지역 데이터
목적 신경망
420
선호도 가중치
전역 목적
듀얼 변수
지역 데이터
400-1
400-2
400-3
MOSAIC
410
신경망 모듈 학습
수렴 된 듀얼
듀얼 신경망
430
듀얼 신경망 학습
지역 해
지역 목적
지역 데이터
지역 목적 계산
지역 해

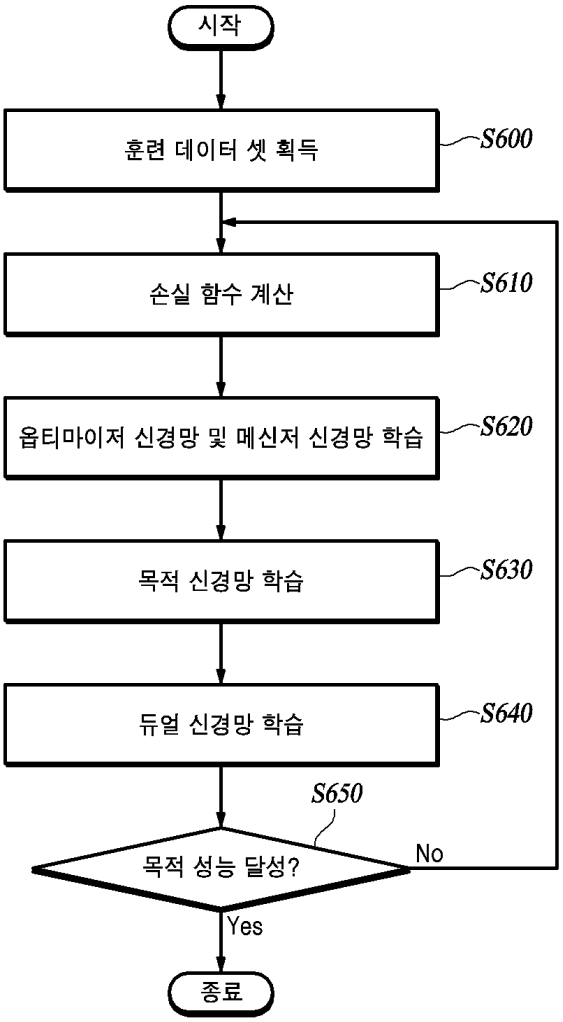
도면4c


110-2
100-2
지역 데이터
400-2
100-3
100-3
협력 통신 신호
지역 해
협력 통신 신호
지역 해
400-3
지역 해
400-1
100-1
110-1

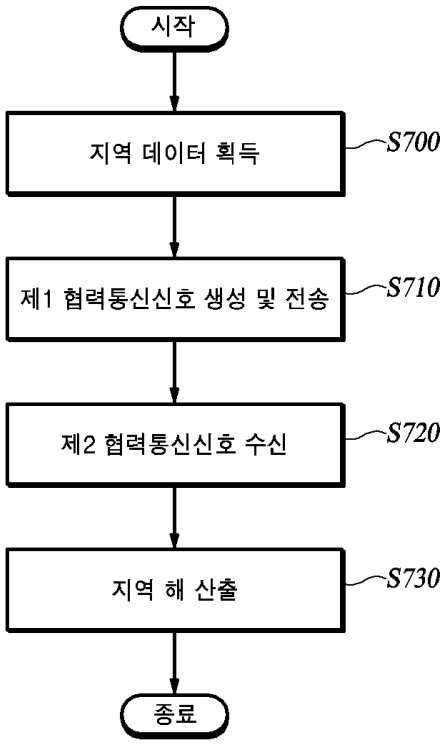
도면5


기울기
지역 데이터
선호도 가중치
DNN
Bounding
Q-1
0
연속-값 메시지
Stochastic quantization
이산 메시지
연속 값
Probability for μ = z − 1
Probability for μ = z
양자화된 값
순방향 패스
역방향 패스

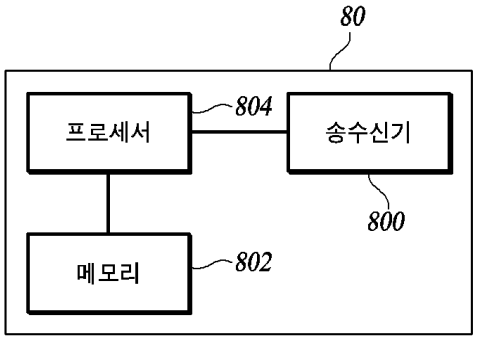
도면6


시작
훈련 데이터 셋 획득
S600
손실 함수 계산
S610
옵티마이저 신경망 및 메신저 신경망 학습
S620
목적 신경망 학습
S630
듀얼 신경망 학습
S640
S650
목적 성능 달성?
No
Yes
종료

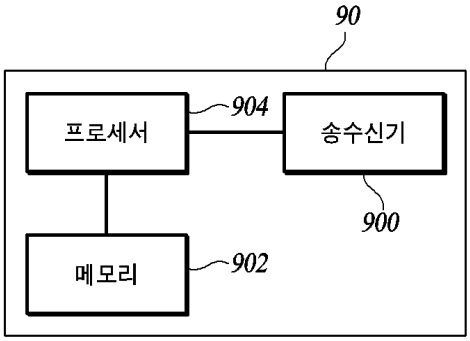
도면7


시작
지역 데이터 획득
S700
제1 협력통신신호 생성 및 전송
S710
제2 협력통신신호 수신
S720
지역 해 산출
S730
종료

도면8


80
프로세서
804
송수신기
800
메모리
802

도면9


90
프로세서
904
송수신기
900
메모리
902