



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2024년08월05일
(11) 등록번호 10-2691001
(24) 등록일자 2024년07월29일

- (51) 국제특허분류(Int. Cl.)
G06N 3/0985 (2023.01) G06N 3/0464 (2023.01)
G06N 3/063 (2023.01) G06N 3/092 (2023.01)
G06N 3/098 (2023.01)
- (52) CPC특허분류
G06N 3/0985 (2023.01)
G06N 3/0464 (2023.01)
- (21) 출원번호 10-2023-0046529
(22) 출원일자 2023년04월10일
심사청구일자 2023년04월10일
(30) 우선권주장
1020230027955 2023년03월02일 대한민국(KR)
- (56) 선행기술조사문헌
KR1020210045845 A*
KR1020220170583 A*
KR1020210092529 A
*는 심사관에 의하여 인용된 문헌
- (73) 특허권자
고려대학교산학협력단
서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)
- (72) 발명자
김영근
서울특별시 양천구 중앙로29길 61 신정뉴타운롯데캐슬 109동 505호
조찬우
경기도 고양시 일산서구 대화1로 21 대화마을1단지아파트 101동 704호
- (74) 대리인
특허법인위솔

전체 청구항 수 : 총 8 항


심사관 : 노지명

(54) 발명의 명칭 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법 및 이를 위한 장치

(57) 요약

본 발명의 일 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법은 (a) 연합 학습의 매 라운드에 참여하는 각 디바이스의 특성 요소 및 상기 각 디바이스의 외부 환경 요소 중 어느 하나 이상을 포함하는 상태(State)를 파악하여, 상태 별로 하나 이상의 액션(Action)이 점수(Score)로 부여된 공유 점수 테이블(Table)을 통해 상기 파악한 상태에 대한 글로벌 파라미터를 선택하는 제1 단계 및 (b) 상기 선택한 글로벌 파라미터를 이용하여 상기 각 디바이스에서 연합 학습을 수행한 연합 학습 결과를 반영해 상기 연합 학습 테이블을 업데이트하고, 상기 글로벌 파라미터를 최적화하는 제2 단계를 포함하며, 상기 글로벌 파라미터는, 상기 연합 학습 수행에 이용하는 미니배치(MiniBatch) 사이즈인 B, 로컬 에포크(Local Epoch)인 E 및 연합 학습의 매 라운드에 참여하는 상기 각 디바이스의 수인 K 중 어느 하나 이상이다.

대표도



(52) CPC특허분류

G06N 3/063 (2013.01)

G06N 3/092 (2023.01)

G06N 3/098 (2023.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711193663
과제번호	2020-0-01819-004
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송혁신인재양성(R&D)
연구과제명	ICT명품인재양성(고려대학교)
기 여 율	1/3
과제수행기관명	고려대학교산학협력단
연구기간	2023.01.01 ~ 2023.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호	1711186154
과제번호	2021R1C1C1008617
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	개인기초연구(과기정통부)
연구과제명	스마트 엣지 기기들을 위한 시스템 수준의 딥러닝 최적화
기 여 율	1/3
과제수행기관명	고려대학교
연구기간	2023.03.01 ~ 2024.02.29

이 발명을 지원한 국가연구개발사업

과제고유번호	1345360941
과제번호	4199990214667
부처명	교육부
과제관리(전문)기관명	한국연구재단
연구사업명	4단계두뇌한국21사업(R&D)
연구과제명	데이터주도과학 미래인재 교육연구단
기 여 율	1/3
과제수행기관명	고려대학교
연구기간	2022.03.01 ~ 2023.02.28

공지예외적용 : 있음

명세서

청구범위

청구항 1

프로세서 및 메모리를 포함하는 장치가 연합 학습(Federated Learning, FL) 에너지 소비 효율 향상을 위한 공유 점수 테이블을 최적화하는 방법에 있어서,

(a) 연합 학습의 매 라운드에 참여하는 각 디바이스의 특성 요소 및 상기 각 디바이스의 외부 환경 요소 중 어느 하나 이상을 포함하는 상태(State)를 파악하여, 상태 별로 하나 이상의 액션(Action)이 점수(Score)로 부여된 공유 점수 테이블(Table)을 통해 상기 파악한 상태에 대하여 선택된 점수에 대응하는 액션에 매칭된 글로벌 파라미터를 선택하는 제1 단계; 및

(b) 상기 선택한 글로벌 파라미터를 이용하여 상기 각 디바이스에서 연합 학습을 수행한 연합 학습 결과를 반영해 상기 공유 점수 테이블을 업데이트하고, 상기 공유 점수 테이블을 상기 각 디바이스의 연합 학습 에너지 소비 효율 향상을 위해 최적화하는 제2 단계;

를 포함하며,

상기 글로벌 파라미터는,

상기 연합 학습 수행에 이용하는 미니배치(MiniBatch) 사이즈인 B, 로컬 에포크(Local Epoch)인 E 및 연합 학습의 매 라운드에 참여하는 상기 각 디바이스의 수인 K 중 어느 하나 이상인,

연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법에 있어서,

상기 제1 단계에서 상태가 포함하는 상기 각 디바이스의 외부 환경 요소는,

상기 각 디바이스의 네트워크 신호 세기 특성 및 상기 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성 중 어느 하나 이상을 포함하며,

상기 각 디바이스의 네트워크 신호 세기 특성은,

유선 네트워크의 신호 세기 및 무선 네트워크의 신호 세기 중 어느 하나 이상을 포함하고,

상기 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성은,

로컬 데이터의 클래스 및 상기 데이터의 클래스 내의 데이터 수 중 어느 하나 이상을 포함하는,

연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법.

청구항 2

제1항에 있어서,

상기 제1 단계에서 상태가 포함하는 각 디바이스의 특성 요소는,

상기 각 디바이스가 연합 학습을 수행할 인공 신경망(Neural Network) 모델의 특성, 상기 각 디바이스의 성능 특성 및 상기 각 디바이스가 연합 학습 수행과 동시에 수행 중인 응용 프로그램의 자원 사용률의 특성 중 어느 하나 이상을 포함하는,

연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법.

청구항 3

제2항에 있어서,

상기 인공 신경망 모델의 특성은,

컨볼루션 레이어(Convolution Layer)의 수, 풀리 커넥티드 레이어(Fully Connected Layer)의 수 및 리커런트(Recurrent Layer) 레이어의 수 중 어느 하나 이상을 포함하는,

연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법.

청구항 4

제2항에 있어서,

상기 각 디바이스의 성능 특성은,

상기 각 디바이스가 포함하는 프로세싱 유닛 - 상기 프로세싱 유닛은 CPU, GPU 및 NPU 중 어느 하나 이상을 포함함 - 의 최대 주파수 및 메모리의 크기 중 어느 하나 이상을 포함하는,

연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법.

청구항 5

제2항에 있어서,

상기 각 디바이스가 연합 학습 수행과 동시에 수행 중인 응용 프로그램에 따른 자원 사용률의 특성은,

상기 각 디바이스가 포함하는 프로세싱 유닛 - 상기 프로세싱 유닛은 CPU, GPU 및 NPU 중 어느 하나 이상을 포함함 - 의 사용률 및 메모리 사용률 중 어느 하나 이상을 포함하는,

연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법.

청구항 6

삭제

청구항 7

삭제

청구항 8

삭제

청구항 9

제1항에 있어서,

상기 제2 단계에서 연합 학습 결과는,

상기 선택한 글로벌 파라미터를 이용하여 수행한 연합 학습에 따른 학습 에너지 효율, 학습 정확도 및 학습 시간 중 어느 하나 이상을 이용하여 산정한 보상(Reward)인,

연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법.

청구항 10

하나 이상의 프로세서;

네트워크 인터페이스;

상기 프로세서에 의해 수행되는 컴퓨터 프로그램을 로드(Load)하는 메모리; 및

대용량 네트워크 데이터 및 상기 컴퓨터 프로그램을 저장하는 스토리지를 포함하되,

상기 컴퓨터 프로그램은 상기 하나 이상의 프로세서에 의해,

(A) 연합 학습의 매 라운드에 참여하는 각 디바이스의 특성 요소 및 상기 각 디바이스의 외부 환경 요소 중 어느 하나 이상을 포함하는 상태(State)를 파악하여, 상태 별로 하나 이상의 액션(Action)이 점수(Score)로 부여된 공유 점수 테이블(Table)을 통해 상기 파악한 상태에 대하여 선택된 점수에 대응하는 액션에 매칭된 글로벌 파라미터를 선택하는 제1 오퍼레이션; 및

(B) 상기 선택한 글로벌 파라미터를 이용하여 상기 각 디바이스에서 연합 학습을 수행한 연합 학습 결과를 반영

해 상기 공유 점수 테이블을 업데이트하고, 상기 공유 점수 테이블을 상기 각 디바이스의 연합 학습 에너지 소비 효율 향상을 위해 최적화하는 제2 오퍼레이션;

을 실행하며,

상기 글로벌 파라미터는,

상기 연합 학습 수행에 이용하는 미니배치(MiniBatch) 사이즈인 B, 로컬 에포크(Local Epoch)인 E 및 연합 학습의 매 라운드에 참여하는 상기 각 디바이스의 수인 K 중 어느 하나 이상인,

연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화하는 장치에 있어서,

상기 제1 오퍼레이션에서 상태가 포함하는 상기 각 디바이스의 외부 환경 요소는,

상기 각 디바이스의 네트워크 신호 세기 특성 및 상기 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성 중 어느 하나 이상을 포함하며,

상기 각 디바이스의 네트워크 신호 세기 특성은,

유선 네트워크의 신호 세기 및 무선 네트워크의 신호 세기 중 어느 하나 이상을 포함하고,

상기 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성은,

로컬 데이터의 클래스 및 상기 데이터의 클래스 내의 데이터 수 중 어느 하나 이상을 포함하는,

연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화하는 장치.

청구항 11

컴퓨팅 장치와 결합하여,

(AA) 연합 학습의 매 라운드에 참여하는 각 디바이스의 특성 요소 및 상기 각 디바이스의 외부 환경 요소 중 어느 하나 이상을 포함하는 상태(State)를 파악하여, 상태 별로 하나 이상의 액션(Action)이 점수(Score)로 부여된 공유 점수 테이블(Table)을 통해 상기 파악한 상태에 대하여 선택된 점수에 대응하는 액션에 매칭된 글로벌 파라미터를 선택하는 제1 단계; 및

(BB) 상기 선택한 글로벌 파라미터를 이용하여 상기 각 디바이스에서 연합 학습을 수행한 연합 학습 결과를 반영해 상기 공유 점수 테이블을 업데이트하고, 상기 공유 점수 테이블을 상기 각 디바이스의 연합 학습 에너지 소비 효율 향상을 위해 최적화하는 제2 단계;

를 포함하며,

상기 글로벌 파라미터는,

상기 연합 학습 수행에 이용하는 미니배치(MiniBatch) 사이즈인 B, 로컬 에포크(Local Epoch)인 E 및 연합 학습의 매 라운드에 참여하는 상기 각 디바이스의 수인 K 중 어느 하나 이상인,

컴퓨터로 판독 가능한 매체에 저장된 컴퓨터 프로그램에 있어서,

상기 제1 단계에서 상태가 포함하는 상기 각 디바이스의 외부 환경 요소는,

상기 각 디바이스의 네트워크 신호 세기 특성 및 상기 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성 중 어느 하나 이상을 포함하며,

상기 각 디바이스의 네트워크 신호 세기 특성은,

유선 네트워크의 신호 세기 및 무선 네트워크의 신호 세기 중 어느 하나 이상을 포함하고,

상기 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성은,

로컬 데이터의 클래스 및 상기 데이터의 클래스 내의 데이터 수 중 어느 하나 이상을 포함하는,

컴퓨터로 판독 가능한 매체에 저장된 컴퓨터 프로그램.

발명의 설명

기술분야

[0001] 본 발명은 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법 및 이를 위한 장치에 관한 것이다. 보다 자세하게는 연합 학습에 참여하는 각 디바이스에 대한 내/외부적 요소를 파악하여 연합 학습을 진행하고, 그 결과를 반영해 공유 점수 테이블을 최적화하는 방법 및 이를 위한 장치에 관한 것이다.

배경기술

[0002] 연합 학습(Federated Learning)은 사용자 데이터의 유출을 방지하면서 기계 학습(Machine Learning) 및 심층 인공 신경망(Deep Neural Network) 모델을 중앙의 서버가 아닌, 각 모바일 기기(Mobile Device)에서 학습하는 학습 방법인바, 연합 학습의 각 라운드에 참여하는 모바일 기기들은 로컬 데이터(Local Data)를 서버에 일일이 업로드하지 않은 상태에서 로컬 모델(Local Model)의 학습을 직접 수행하며, 학습된 로컬 모델만 서버에 업로드하고 서버는 업로드된 로컬 모델만을 취합하여 글로벌 모델(Global Model)을 학습한다.

[0003] 이와 같은 연합 학습에서 널리 사용되는 알고리즘으로 FedAvg(Federated Averaging)이 존재하며, FedAvg 알고리즘에 따르면 연합 학습에 참여하는 N 개의 전체 모바일 기기 중, 각 라운드 학습을 수행할 K개의 모바일 기기를 선택하고, 선택된 K개의 모바일 기기들은 로컬 데이터를 Minibatch B로 Local Epoch E만큼 학습을 수행하게 된다. 여기서 B, E, K는 연합 학습을 위한 글로벌 파라미터(Global Parameter)로서 학습에 참여하는 각 모바일 기기에서 수행해야 하는 연산의 양 뿐만 아니라 학습 모델의 정확도에도 큰 영향을 미치기에 효율적인 연합 학습의 수행을 위해 매 라운드 글로벌 파라미터인 B, E, K를 잘 설정하는 것이 매우 중요하다.

[0004] 그러나 연합 학습의 매 라운드에 참여하는 모바일 기기들의 연산 성능 및 메모리 크기가 모두 상이하기에 각 모바일 기기 별로 최적의 B 및 E의 설정이 현저하게 달라질 수 있으며, 연합 학습과 함께 수행하는 응용 프로그램들로부터의 리소스 간섭 및 네트워크 환경의 가변성으로 인해 같은 B 및 E에 대해서도 학습 수행 시간이 현저하게 달라질 수도 있고, 각 모바일 기기에서 보유하고 있는 로컬 데이터의 종류와 양 역시 상이할 수 있는바, 그로 인해 학습 모델의 품질 역시 현저하게 달라질 수 있다는 문제점이 있다.

[0005] 그럼에도 불구하고 다양한 방면에서 널리 활용되고 있는 연합 학습 알고리즘으로 인해 효율적인 연합 학습 수행의 필요성은 여전히 높은바, 본 발명은 이러한 필요성을 반영해 최적의 공유 점수 테이블을 설정할 수 있는 새로운 접근 기술에 관한 것이다.

선행기술문헌

특허문헌

[0006] (특허문헌 0001) 대한민국 등록특허공보 제 10-2390553호(2022.04.21)

발명의 내용

해결하려는 과제

[0007] 본 발명이 해결하고자 하는 기술적 과제는 연합 학습을 수행하는 각 모바일 기기에 대하여 연합 학습 수행에 영향을 줄 수 있는 다양한 내/외부적 요소를 파악하여 이를 반영한 최적의 글로벌 파라미터를 설정하게 함으로써 연합 학습의 효율성을 향상시킬 수 있는 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법 및 이를 위한 장치를 제공하는 것이다.

[0008] 본 발명의 기술적 과제들은 이상에서 언급한 기술적 과제들로 제한되지 않으며, 언급되지 않은 또 다른 기술적 과제들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

과제의 해결 수단

[0009] 상기 기술적 과제를 달성하기 위한 본 발명의 일 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법은 (a) 연합 학습의 매 라운드에 참여하는 각 디바이스의 특성 요소 및 상기 각 디바이스의 외부 환경 요소 중 어느 하나 이상을 포함하는 상태(State)를 파악하여, 상태 별로 하나 이상의 액션(Action)이 점수(Score)로 부여된 공유 점수 테이블(Table)을 통해 상기 파악한 상태에 대한 글로벌 파라미터를

선택하는 제1 단계 및 (b) 상기 선택한 글로벌 파라미터를 이용하여 상기 각 디바이스에서 연합 학습을 수행한 연합 학습 결과를 반영해 상기 연합 학습 테이블을 업데이트하고, 상기 글로벌 파라미터를 최적화하는 제2 단계를 포함하며, 상기 글로벌 파라미터는, 상기 연합 학습 수행에 이용하는 미니배치(MiniBatch) 사이즈인 B, 로컬 에포크(Local Epoch)인 E 및 연합 학습의 매 라운드에 참여하는 상기 각 디바이스의 수인 K 중 어느 하나 이상이다.

[0010] 일 실시 예에 따르면, 상기 제1 단계에서 상태가 포함하는 각 디바이스의 특성 요소는, 상기 각 디바이스가 연합 학습을 수행할 인공 신경망(Neural Network) 모델의 특성, 상기 각 디바이스의 성능 특성 및 상기 각 디바이스가 연합 학습과 함께 수행 중인 응용 프로그램에 따른 자원 사용률의 특성 중 어느 하나 이상을 포함할 수 있다.

[0011] 일 실시 예에 따르면, 상기 인공 신경망 모델의 특성은, 컨볼루션 레이어(Convolution Layer)의 수, 풀리 커넥티드 레이어(Fully Connected Layer)의 수 및 리커런트(Recurrent Layer) 레이어의 수 중 어느 하나 이상을 포함할 수 있다.

[0012] 일 실시 예에 따르면, 상기 각 디바이스의 성능 특성은, 상기 각 디바이스가 포함하는 프로세싱 유닛 - 상기 프로세싱 유닛은 CPU, GPU 및 NPU 중 어느 하나 이상을 포함함 - 의 최대 주파수 및 메모리의 크기 중 어느 하나 이상을 포함할 수 있다.

[0013] 일 실시 예에 따르면, 상기 각 디바이스가 연합 학습과 함께 수행 중인 응용 프로그램에 따른 자원 사용률의 특성은, 상기 각 디바이스가 포함하는 프로세싱 유닛 - 상기 프로세싱 유닛은 CPU, GPU 및 NPU 중 어느 하나 이상을 포함함 - 의 사용률 및 메모리 사용률 중 어느 하나 이상을 포함할 수 있다.

[0014] 일 실시 예에 따르면, 상기 제1 단계에서 상태가 포함하는 상기 각 디바이스의 외부 환경 요소는, 상기 각 디바이스의 네트워크 신호 세기 특성 및 상기 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성 중 어느 하나 이상을 포함할 수 있다.

[0015] 일 실시 예에 따르면, 상기 각 디바이스의 네트워크 신호 세기 특성은, 유선 네트워크의 신호 세기 및 무선 네트워크의 신호 세기 중 어느 하나 이상을 포함할 수 있다.

[0016] 일 실시 예에 따르면, 상기 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성은, 로컬 데이터의 클래스 및 상기 데이터의 클래스 내의 데이터 수 중 어느 하나 이상을 포함할 수 있다.

[0017] 일 실시 예에 따르면, 상기 제2 단계에서 연합 학습 결과는, 상기 선택한 글로벌 파라미터를 이용하여 수행한 연합 학습에 따른 학습 에너지 효율, 학습 정확도 및 학습 시간 중 어느 하나 이상을 이용하여 산정한 보상(Reward)일 수 있다.

[0018] 상기 기술적 과제를 달성하기 위한 본 발명의 또 다른 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치는 하나 이상의 프로세서, 네트워크 인터페이스, 상기 프로세서에 의해 수행되는 컴퓨터 프로그램을 로드(Load)하는 메모리 및 대용량 네트워크 데이터 및 상기 컴퓨터 프로그램을 저장하는 스토리지를 포함하되, 상기 컴퓨터 프로그램은 상기 하나 이상의 프로세서에 의해, (A) 연합 학습의 매 라운드에 참여하는 각 디바이스의 특성 요소 및 상기 각 디바이스의 외부 환경 요소 중 어느 하나 이상을 포함하는 상태(State)를 파악하여, 상태 별로 하나 이상의 액션(Action)이 점수(Score)로 부여된 공유 점수 테이블(Table)을 통해 상기 파악한 상태에 대한 글로벌 파라미터를 선택하는 제1 오퍼레이션 및 (B) 상기 선택한 글로벌 파라미터를 이용하여 상기 각 디바이스에서 연합 학습을 수행한 연합 학습 결과를 반영해 상기 연합 학습 테이블을 업데이트하고, 상기 글로벌 파라미터를 최적화하는 제2 오퍼레이션을 실행하며, 상기 글로벌 파라미터는, 상기 연합 학습 수행에 이용하는 미니배치(MiniBatch) 사이즈인 B, 로컬 에포크(Local Epoch)인 E 및 연합 학습의 매 라운드에 참여하는 상기 각 디바이스의 수인 K 중 어느 하나 이상이다.

[0019] 상기 기술적 과제를 달성하기 위한 본 발명의 또 다른 실시 예에 따른 매체에 저장된 컴퓨터 프로그램은 컴퓨팅 장치와 결합하여, (AA) 연합 학습의 매 라운드에 참여하는 각 디바이스의 특성 요소 및 상기 각 디바이스의 외부 환경 요소 중 어느 하나 이상을 포함하는 상태(State)를 파악하여, 상태 별로 하나 이상의 액션(Action)이 점수(Score)로 부여된 공유 점수 테이블(Table)을 통해 상기 파악한 상태에 대한 글로벌 파라미터를 선택하는 제1 단계 및 (BB) 상기 선택한 글로벌 파라미터를 이용하여 상기 각 디바이스에서 연합 학습을 수행한 연합 학습 결과를 반영해 상기 연합 학습 테이블을 업데이트하고, 상기 글로벌 파라미터를 최적화하는 제2 단계를 포함하며, 상기 글로벌 파라미터는, 상기 연합 학습 수행에 이용하는 미니배치(MiniBatch) 사이즈인 B, 로컬 에포크

(Local Epoch)인 E 및 연합 학습의 매 라운드에 참여하는 상기 각 디바이스의 수인 K 중 어느 하나 이상이다.

발명의 효과

[0020] 상기와 같은 본 발명에 따르면 연합 학습을 수행하는 각 모바일 기기에 대하여 연합 학습 수행에 영향을 줄 수 있는 다양한 내/외부적 요소를 파악하여 이를 반영한 최적의 글로벌 파라미터를 설정하게 함으로써 연합 학습의 효율성을 현저하게 향상시킬 수 있다는 효과가 있다.

[0021] 본 발명의 효과들은 이상에서 언급한 효과들로 제한되지 않으며, 언급되지 않은 또 다른 효과들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해 될 수 있을 것이다.

도면의 간단한 설명

[0022] 도 1은 본 발명의 제1 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치가 포함하는 전체 구성을 예시적으로 도시한 도면이다.

도 2는 본 발명의 제2 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법의 대표적인 단계를 나타낸 순서도이다.

도 3은 공유 점수 테이블을 예시적으로 도시한 도면이다.

도 4 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법에 있어서, 인공 신경망 모델로 CNN을 사용할 때의 최적의 글로벌 파라미터를 나타낸 시뮬레이션 결과이다.

도 5는 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법에 있어서, 인공 신경망 모델로 LSTM을 사용할 때의 최적의 글로벌 파라미터를 나타낸 시뮬레이션 결과이다.

도 6은 도 5와 같이 인공 신경망 모델로 LSTM을 사용할 때, 도 5에서 사용한 낮은 성능의 디바이스가 아니라 고성능 디바이스를 사용한 경우의 최적의 글로벌 파라미터를 나타낸 시뮬레이션 결과이다.

도 7은 도 6과 같이 고성능 디바이스에서 인공 신경망 모델로 LSTM을 사용할 때, 도 6과 같이 학습만 수행하는 것이 아니라 동영상 시청을 위한 프로그램을 함께 실행한 경우의 최적의 글로벌 파라미터를 나타낸 시뮬레이션 결과이다.

도 8은 도 6과 같이 고성능 디바이스에서 인공 신경망 모델로 LSTM을 사용할 때, 도 6과 같이 무선 네트워크 신호 세기가 우수한 경우가 아니라 무선 네트워크 신호가 매우 안좋은 상태인 경우의 최적의 글로벌 파라미터를 나타낸 시뮬레이션 결과이다.

도 9는 도 4과 같이 낮은 성능의 디바이스에서 인공 신경망 모델로 CNN을 사용할 때, 도 4과 같이 로컬 데이터셋의 분포가 고른 경우가 아니라 특정 방향으로 편중되어 분포되어 있는 경우의 최적의 글로벌 파라미터를 나타낸 시뮬레이션 결과이다.

도 10은 효율적인 연합 학습에 영향을 미칠 수 있는 각 디바이스의 특성 요소 및 외부 환경 요소 중 어느 하나 이상을 포함하는 상태를 나타낸 상태 테이블이다.

도 11은 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법에 있어서, 강화 학습 알고리즘을 도시한 도면이다.

도 12는 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법에 있어서, 보상을 산정하는 수식을 도시한 도면이다.

도 13 및 도 14는 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법의 성능 평가 자료이다.

발명을 실시하기 위한 구체적인 내용

[0023] 본 발명의 목적과 기술적 구성 및 그에 따른 작용 효과에 관한 자세한 사항은 본 발명의 명세서에 첨부된 도면에 의거한 이하의 상세한 설명에 의해 보다 명확하게 이해될 것이다. 첨부된 도면을 참조하여 본 발명에 따른 실시 예를 상세하게 설명한다.

[0024] 본 명세서에서 개시되는 실시 예들은 본 발명의 범위를 한정하는 것으로 해석되거나 이용되지 않아야 할

것이다. 이 분야의 통상의 기술자에게 본 명세서의 실시 예를 포함한 설명은 다양한 응용을 갖는다는 것이 당연하다. 따라서, 본 발명의 상세한 설명에 기재된 임의의 실시 예들은 본 발명을 보다 잘 설명하기 위한 예시적인 것이며 본 발명의 범위가 실시 예들로 한정되는 것을 의도하지 않는다.

- [0025] 도면에 표시되고 아래에 설명되는 기능 블록들은 가능한 구현의 예들일 뿐이다. 다른 구현들에서는 상세한 설명의 사상 및 범위를 벗어나지 않는 범위에서 다른 기능 블록들이 사용될 수 있다. 또한, 본 발명의 하나 이상의 기능 블록이 개별 블록들로 표시되지만, 본 발명의 기능 블록들 중 하나 이상은 동일 기능을 실행하는 다양한 하드웨어 및 소프트웨어 구성들의 조합일 수 있다.
- [0026] 또한, 어떤 구성요소들을 포함한다는 표현은 "개방형"의 표현으로서 해당 구성요소들이 존재하는 것을 단순히 지칭할 뿐이며, 추가적인 구성요소들을 배제하는 것으로 이해되어서는 안 된다.
- [0027] 나아가 어떤 구성요소가 다른 구성요소에 "연결되어" 있다거나 "접속되어" 있다고 언급될 때에는, 그 다른 구성요소에 직접적으로 연결 또는 접속되어 있을 수도 있지만, 중간에 다른 구성요소가 존재할 수도 있다고 이해되어야 한다.
- [0028] 이하에서는 도면들을 참조하여 본 발명의 세부적인 실시 예들에 대해 살펴보도록 한다.
- [0029] 도 1은 본 발명의 제1 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치(100)가 포함하는 전체 구성을 예시적으로 도시한 도면이다.
- [0030] 그러나 이는 본 발명의 목적을 달성하기 위한 바람직한 실시 예일 뿐이며, 필요에 따라 일부 구성이 추가되거나 삭제될 수 있고, 어느 한 구성이 수행하는 역할을 다른 구성이 함께 수행할 수도 있음은 물론이다.
- [0031] 본 발명의 제1 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치(100)는 프로세서(10), 네트워크 인터페이스(20), 메모리(30), 스토리지(40) 및 이들을 연결하는 데이터 버스(50)를 포함할 수 있으며, 기타 본 발명의 목적을 달성함에 있어 요구되는 부가적인 구성들을 더 포함할 수 있음은 물론이라 할 것이다.
- [0032] 프로세서(10)는 각 구성의 전반적인 동작을 제어한다. 프로세서(10)는 CPU(Central Processing Unit), MPU(Micro Processor Unit), MCU(Micro Controller Unit) 또는 본 발명이 속하는 기술 분야에서 널리 알려져 있는 형태의 인공지능 프로세서 중 어느 하나일 수 있다. 아울러, 프로세서(10)는 본 발명의 제2 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법을 수행하기 위한 적어도 하나의 애플리케이션 또는 프로그램에 대한 연산을 수행할 수 있다.
- [0033] 네트워크 인터페이스(20)는 본 발명의 제1 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치(100)의 유무선 인터넷 통신을 지원하며, 그 밖의 공지의 통신 방식을 지원할 수도 있다. 따라서 네트워크 인터페이스(20)는 그에 따른 통신 모듈을 포함하여 구성될 수 있다.
- [0034] 메모리(30)는 각종 정보, 명령 및/또는 정보를 저장하며, 본 발명의 제2 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법을 수행하기 위해 스토리지(40)로부터 하나 이상의 컴퓨터 프로그램(41)을 로드할 수 있다. 도 1에서는 메모리(30)의 하나로 RAM을 도시하였으나 이와 더불어 다양한 저장 매체를 메모리(30)로 이용할 수 있음은 물론이다.
- [0035] 스토리지(40)는 하나 이상의 컴퓨터 프로그램(41) 및 대용량 네트워크 정보(42)를 비임시적으로 저장할 수 있다. 이러한 스토리지(40)는 ROM(Read Only Memory), EPROM(Erasable Programmable ROM), EEPROM(Electrically Erasable Programmable ROM), 플래시 메모리 등과 같은 비휘발성 메모리, 하드 디스크(HDD), 보조 저장 매체(SSD), 착탈형 디스크, 또는 본 발명이 속하는 기술 분야에서 널리 알려져 있는 임의의 형태의 컴퓨터로 읽을 수 있는 기록 매체 중 어느 하나일 수 있다.
- [0036] 컴퓨터 프로그램(41)은 메모리(30)에 로드되어, 하나 이상의 프로세서(10)에 의해, (A) 연합 학습의 매 라운드에 참여하는 각 디바이스의 특성 요소 및 상기 각 디바이스의 외부 환경 요소 중 어느 하나 이상을 포함하는 상태(State)를 파악하여, 상태 별로 하나 이상의 액션(Action)이 점수(Score)로 부여된 공유 점수 테이블(Table)을 통해 상기 파악한 상태에 대한 글로벌 파라미터를 선택하는 제1 오퍼레이션, (B) 상기 선택한 글로벌 파라미터를 이용하여 상기 각 디바이스에서 연합 학습을 수행한 연합 학습 결과를 반영해 상기 연합 학습 테이블을 업데이트하고, 상기 글로벌 파라미터를 최적화하는 제2 오퍼레이션을 실행할 수 있다.
- [0037] 이상 간단하게 언급한 컴퓨터 프로그램(41)이 수행하는 오퍼레이션은 컴퓨터 프로그램(41)의 일 기능으로 볼 수

있으며, 보다 자세한 설명은 본 발명의 제2 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법 에 대한 설명에서 후술하도록 한다.

- [0038] 데이터 버스(50)는 이상 설명한 프로세서(10), 네트워크 인터페이스(20), 메모리(30) 및 스토리지(40) 사이의 명령 및/또는 정보의 이동 경로가 된다.
- [0039] 이상 간단하게 설명한 본 발명의 제1 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치(100)는 독립된 디바이스의 형태, 예를 들어 전자 기기나 서버(클라우드 포함)의 형태일 수 있으며, 여기서 전자 기기는 한 장소에 고정 설치되어 사용하는 데스크톱 PC, 서버 디바이스 등과 같은 기기 뿐만 아니라, 스마트폰, 태블릿 PC, 노트북 PC, PDA, PMP 등과 같이 휴대가 용이한 포터블 기기 등이라도 무방한바, 프로세서(10)에 해당하는 CPU 등이 설치되고 네트워크 기능만 보유하고 있는 전자 기기라면 어떠한 것이라도 무방하다 할 것이다.
- [0040] 이하, 본 발명의 제1 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치(100)가 독립된 디바이스인 전자 기기 형태 중, "서버"의 형태임을 전제로 연합 학습을 위한 글로벌 파라미터를 최적화하고자 하는 사용자의 사용자 단말(미도시)에 설치된 전용 어플리케이션을 통해 본 발명의 제2 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법을 제공하는 과정에 대하여 도 2 내지 도 14를 참조하여 설명하도록 한다.
- [0041] 도 2는 본 발명의 제2 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법의 대표적인 단계를 나타낸 순서도이다.
- [0042] 그러나 이는 본 발명의 목적을 달성함에 있어서 바람직한 실시 예일 뿐이며, 필요에 따라 일부 단계가 추가 또는 삭제될 수 있음은 물론이고, 어느 한 단계가 다른 단계에 포함되어 수행될 수도 있다.
- [0043] 한편, 각 단계는 본 발명의 제1 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치(100)를 통해 이루어지는 것을 전제로 하며, 본 발명의 제1 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치(100)가 "서버"의 형태임을 전제로 하였기 때문에 사용자 단말(미도시)에 설치된 전용 어플리케이션을 본 발명의 제1 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치(100)와 동일한 의미로 볼 것이고, 설명의 편의를 위해 이들 모두를 "장치(100)"로 명명하도록 한다.
- [0044] 우선, 장치(100)가 연합 학습의 매 라운드에 참여하는 각 디바이스의 특성 요소 및 각 디바이스의 외부 환경 요소 중 어느 하나 이상을 포함하는 상태(State)를 파악하여, 상태 별로 하나 이상의 액션(Action)이 점수(Score)로 부여된 공유 점수 테이블(Table)을 통해 상기 파악한 상태에 대한 글로벌 파라미터를 선택하며(S210), 이를 제1 단계라 한다.
- [0045] 도 3에 공유 점수 테이블을 예시적으로 도시한바, 세로 방향으로 복수 개의 상태(State, S_i , i 는 자연수)가, 각각의 상태에 대하여 가로 방향으로 복수 개의 액션(Action, A_i , i 는 자연수)이, 각각의 상태에 대한 각각의 액션에 대하여 가치 함수(Value Function)인 점수(Score) $Q(S_i, A_i)$ 가 기재되어 있음을 확인할 수 있는바, 여기서 상태(State, S_i)가 각 디바이스에서 학습 모델의 현재 상태를, 행동(Action, A_i)이 현재 상태(State, S_i)와 가치 함수 $Q(S_i, A_i)$ 를 기반으로 주어진 시간 내에 학습 모델이 내릴 수 있는 결정을, 가치 함수인 점수(Score) $Q(S_i, A_i)$ 가 각 디바이스 또는 학습 모델이 주어진 상태에서 특정 작업을 수행하여 달성할 수 있는 예상 보상의 척도를 나타내며, 가치 함수인 점수(Score) $Q(S_i, A_i)$ 는 각 디바이스가 연합 학습을 수행한 결과를 반영해 추후 업데이트될 수 있다.
- [0046] 이상과 같은 공유 점수 테이블을 이용하는 연합 학습의 매 라운드의 시작은 각 디바이스의 상태를 파악하는 것 인바, 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법은 연합 학습에 영향을 미칠 수 있는 각 디바이스에 대한 다양한 내/외부적 요소들을 공유 점수 테이블 상의 상태에 반영해 글로벌 파라미터를 선택하게 함으로써 효율적인 연합 학습이 수행될 수 있도록 이바지할 수 있는바, 여기서 글로벌 파라미터는 앞서 연합 학습에 영향을 미칠 수 있다고 언급했던 파라미터, 보다 구체적으로 연합 학습 수행에 이용하는 미니배치(MiniBatch) 사이즈인 B, 로컬 에포크(Local Epoch)인 E 및 연합 학습의 매 라운드에 참여하는 각 디바이스의 수인 K 중 어느 하나 이상일 수 있다.
- [0047] 한편, 각 디바이스에 대한 다양한 내/외부적 요소들을 반영한 상태는 각 디바이스의 특성 요소와 각 디바이스의

외부 환경 요소 중 어느 하나 이상을 포함할 수 있는바, 여기서 각 디바이스의 특성 요소는 디바이스 자체의 특성(내부적 요소)에 관한 것이며, 각 디바이스의 외부 환경 요소는 디바이스 자체가 아닌 다른 외부의 요소(외부적 요소)에 관한 것인바, 이하 설명하도록 한다.

- [0048] 각 디바이스의 특성 요소는 각 디바이스가 연합 학습을 수행할 인공 신경망(Neural Network) 모델의 특성, 각 디바이스의 성능 특성 및 각 디바이스가 연합 학습과 함께 수행 중인 응용 프로그램에 따른 자원 사용률의 특성 중 어느 하나 이상을 포함할 수 있다.
- [0049] 여기서 각 디바이스가 연합 학습을 수행할 인공 신경망 모델의 특성은 컨볼루션 레이어(Convolution Layer)의 수, 풀리 커넥티드 레이어(Fully Connected Layer)의 수 및 리커런트(Recurrent Layer) 레이어의 수 중 어느 하나 이상을 포함할 수 있는바, 이들의 수에 따라 인공 신경망 모델을 결정할 수 있기 때문이다.
- [0050] 도 4 및 도 5는 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법에 있어서, 인공 신경망 모델로 CNN을 사용할 때(도 4)와 LSTM을 사용할 때(도 5)의 최적의 글로벌 파라미터를 나타낸 시뮬레이션 결과인바, PPW는 전송비로서 PPW가 높을수록 디바이스가 학습에 에너지를 적게 소모한 것, 즉 효율적인 학습을 진행한 것으로 볼 수 있다.
- [0051] 도 4 및 도 5를 참조하면, 동일한 성능의 디바이스에 대하여 연합 학습을 수행할 인공 신경망 모델이 CNN인 경우 가장 높은 PPW를 나타내는 최적의 B, E, K는 8, 10, 20임에 반해, 인공 신경망 모델이 LSTM인 경우 가장 높은 PPW를 나타내는 최적의 B, E, K는 4, 20, 20으로 차이가 있음을 확인할 수 있는바, 연합 학습을 수행할 인공 신경망 모델의 특성이 연합 학습의 효율성에 영향을 미침을 알 수 있다.
- [0052] 이번에는 각 디바이스의 성능 특성에 대하여 설명하도록 한다.
- [0053] 각 디바이스의 성능 특성은 각 디바이스가 포함하는 프로세싱 유닛 - 상기 프로세싱 유닛은 CPU, GPU 및 NPU 중 어느 하나 이상을 포함함 - 의 최대 주파수 및 메모리의 크기 중 어느 하나 이상을 포함할 수 있다.
- [0054] 이와 같은 각 디바이스의 성능 특성은 디바이스의 하드웨어적 특성으로 볼 수 있는바, 도 6은 도 5와 같이 인공 신경망 모델로 LSTM을 사용할 때, 도 5에서 사용한 낮은 성능의 디바이스가 아니라 고성능 디바이스를 사용한 경우의 최적의 글로벌 파라미터를 나타낸 시뮬레이션 결과이며, 고성능 디바이스는 낮은 성능의 디바이스 대비 프로세싱 유닛의 최대 주파수가 높고 메모리의 크기 역시 크다고 할 것이다.
- [0055] 도 6을 참조하면, 인공 신경망 모델로 LSTM을 사용한 고성능 디바이스의 경우 가장 높은 PPW를 나타내는 최적의 B, E, K가 4, 10, 20임에 반해, 도 5에서 인공 신경망 모델로 LSTM을 사용한 낮은 성능의 디바이스에서의 최적의 B, E, K인 4, 20, 20과 차이가 있음을 확인할 수 있는바, 연합 학습을 수행할 디바이스의 성능 특성이 연합 학습의 효율성에 영향을 미침을 알 수 있다.
- [0056] 이번에는 각 디바이스가 연합 학습과 함께 수행 중인 응용 프로그램에 따른 자원 사용률의 특성에 대하여 설명하도록 한다.
- [0057] 각 디바이스가 연합 학습과 함께 수행 중인 응용 프로그램에 따른 자원 사용률의 특성은 각 디바이스가 포함하는 프로세싱 유닛 - 상기 프로세싱 유닛은 CPU, GPU 및 NPU 중 어느 하나 이상을 포함함 - 의 사용률 및 메모리 사용률 중 어느 하나 이상을 포함할 수 있다.
- [0058] 여기서 응용 프로그램의 종류는 제한이 없다. 예를 들어 인터넷 서핑을 위한 프로그램, 동영상 시청을 위한 프로그램 또는 도면 작성을 위한 프로그램 등 어떠한 것이라도 무방하며, 각각의 응용 프로그램의 실행에 따라 프로세싱 유닛의 사용률 및 메모리 사용률은 상이해질 것이고, 이는 학습 수행에 있어서 프로세싱 유닛 입장에서 일종의 부하로 작용하여 프로세싱 유닛의 사용률 및 메모리 사용률에 영향을 미칠 수 있다.
- [0059] 도 7은 도 6과 같이 고성능 디바이스에서 인공 신경망 모델로 LSTM을 사용할 때, 도 6과 같이 학습만 수행하는 것이 아니라 동영상 시청을 위한 프로그램을 함께 실행한 경우의 최적의 글로벌 파라미터를 나타낸 시뮬레이션 결과이다.
- [0060] 도 7을 참조하면, 인공 신경망 모델로 LSTM을 사용한 고성능 디바이스가 학습과 동시에 동영상 시청 프로그램을 함께 실행하고 있을 경우 가장 높은 PPW를 나타내는 최적의 B, E, K가 8, 10, 20임에 반해, 도 6에서 인공 신경망 모델로 LSTM을 사용한 고성능 디바이스가 학습만 실행하고 있을 경우에서의 최적의 B, E, K인 4, 10, 20과 차이가 있음을 확인할 수 있는바, 연합 학습을 수행할 디바이스가 연합 학습과 함께 수행 중인 응용 프로그램에 따른 자원 사용률의 특성이 연합 학습의 효율성에 영향을 미침을 알 수 있다.

- [0061] 이번에는 각 디바이스의 외부 환경 요소에 대하여 설명하도록 한다.
- [0062] 각 디바이스의 외부 환경 요소는 각 디바이스의 네트워크 신호 세기 특성 및 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성 중 어느 하나 이상을 포함할 수 있다.
- [0063] 여기서 각 디바이스의 네트워크 신호 세기 특성은 유선 네트워크의 신호 세기 및 무선 네트워크의 신호 세기 중 어느 하나 이상을 포함할 수 있다.
- [0064] 도 8은 도 6과 같이 고성능 디바이스에서 인공 신경망 모델로 LSTM을 사용할 때, 도 6과 같이 무선 네트워크 신호 세기가 우수한 경우가 아니라 무선 네트워크 신호가 매우 안좋은 상태인 경우의 최적의 글로벌 파라미터를 나타낸 시뮬레이션 결과이다.
- [0065] 도 8을 참조하면, 인공 신경망 모델로 LSTM을 사용한 고성능 디바이스가 무선 네트워크 신호가 매우 안좋은 상태인 경우 가장 높은 PPW를 나타내는 최적의 B, E, K가 4, 10, 10임에 반해, 도 6에서 인공 신경망 모델로 LSTM을 사용한 고성능 디바이스가 학습만 실행하고 있을 경우에서의 최적의 B, E, K인 4, 10, 20과 차이가 있음을 확인할 수 있는바, 각 디바이스의 네트워크 신호 세기 특성이 연합 학습의 효율성에 영향을 미침을 알 수 있다.
- [0066] 한편, 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성은 로컬 데이터의 클래스 및 해당 데이터의 클래스 내의 데이터 수 중 어느 하나 이상을 포함할 수 있는바, 이는 얼마나 다양한 종류의 데이터가 많이 존재하는지 그리고 데이터가 특정 방향으로 편중되어 분포되어 있는지 등에 관한 것이다.
- [0067] 도 9는 도 4과 같이 낮은 성능의 디바이스에서 인공 신경망 모델로 CNN을 사용할 때, 도 4과 같이 로컬 데이터셋의 분포가 고른 경우가 아니라 특정 방향으로 편중되어 분포되어 있는 경우의 최적의 글로벌 파라미터를 나타낸 시뮬레이션 결과이다.
- [0068] 도 9를 참조하면, 인공 신경망 모델로 CNN을 사용한 낮은 성능의 디바이스가 로컬 데이터셋이 특정 방향으로 편중되어 있는 경우 가장 높은 PPW를 나타내는 최적의 B, E, K가 8, 10, 10임에 반해, 도 4에서 인공 신경망 모델로 CNN을 사용한 낮은 성능의 디바이스가 로컬 데이터셋의 분포가 고른 경우에서의 최적의 B, E, K인 8, 10, 20과 차이가 있음을 확인할 수 있는바, 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성이 연합 학습의 효율성에 영향을 미침을 알 수 있다.
- [0069] 지금까지 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법에 있어서 본 발명의 핵심적인 사항에 해당하며, 효율적인 연합 학습에 영향을 미칠 수 있는 각 디바이스의 특성 요소 및 외부 환경 요소 중 어느 하나 이상을 포함하는 상태에 대하여 예를 들어 설명하였다. 도 10은 이와 같은 상태를 보다 구체적으로 나타낸 상태 테이블인바, S_{CONV} , S_{FC} , S_{RC} 가 연합 학습을 수행할 인공 신경망 모델의 특성을, S_{Co_CPU} , S_{Co_MEM} 이 각 디바이스의 성능 특성과 각 디바이스가 연합 학습과 함께 수행 중인 응용 프로그램에 따른 자원 사용률 특성을, $S_{Network}$ 가 각 디바이스의 네트워크 신호 세기 특성을, S_{Data} 가 각 디바이스가 연합 학습 수행에 이용할 로컬 데이터셋의 분포 특성을 나타내며, 이와 같은 상태를 도 3에 도시된 공유 점수 테이블 상에 반영한다면 각각의 상태 별로 가능한 값(value)의 수를 전부 곱하여 $4*2*3*4*4*2*3 = 2,304$ 개의 상태가 세로 방향의 상태에 기재될 수 있을 것이다.
- [0070] 다시 도 2에 대한 설명으로 돌아가도록 한다.
- [0071] 각 디바이스의 특성 요소 및 각 디바이스의 외부 환경 요소 중 어느 하나 이상을 포함하는 상태의 파악은 장치(100)가 매 연합 학습 라운드마다 각 디바이스로부터 앞서 설명한 특성 요소에 대한 정보를 수신함으로써 이루어질 수 있으며, 각 디바이스의 특성 요소 중 인공 신경망 모델의 특성이나 각 디바이스의 성능 특성과 같이 쉽게 변경이 이루어지지 않는 특성에 대해서는 매번 수신함이 없이 한번 수신하여 저장해 두었다가 필요한 경우에 로딩하여 사용할 수 있음은 물론이라 할 것이다.
- [0072] 한편, 장치(100)는 파악한 상태를 통해 공유 점수 테이블 상에서 해당 상태에 대하여 가로 방향으로 매칭된 복수 개의 액션 중 하나를 선택하여 해당 액션에 대응되는 글로벌 파라미터를 선택하게 되는바, 이는 도 11을 참조하여 설명하도록 한다.
- [0073] 도 11은 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법에 있어서, 보편적인 강화 학습 알고리즘을 예시적으로 도시한 도면이다.
- [0074] 도 11을 참조하면, S가 상태, A가 액션이며, 각 디바이스로부터 정보를 수신하여 상태를 파악하고(Observe

state and store S), 난수를 생성하여(rand()) 해당 난수를 ϵ 와 비교한다(rand() < ϵ). 비교 결과 난수가 ϵ 보다 낮으면(if rand() < ϵ then), 액션을 랜덤하게 선택하며(Choose action A randomly), 그렇지 않은 경우(else), 해당 상태에 대한 모든 액션의 Q(S, A)값을 비교하여 그 중에서 가장 높은 값을 갖는 액션을 선택한다(Choose action A which maximizes Q(S, A)). 이러한 과정을 통해 강화 학습의 글로벌 파라미터 선택 정책이 Local Optima에 빠지게 되는 현상을 방지할 수 있다.

[0075] 한편, 공유 점수 테이블 상의 모든 액션은 각각의 액션에 개별적인 글로벌 파라미터가 대응되어 있으며, 장치(100)는 각 디바이스에 선택한 액션에 대응되는 글로벌 파라미터에 대한 정보를 송신하여 각 디바이스로 하여금 수신한 글로벌 파라미터로 학습을 수행할 수 있게 한다.

[0076] 장치(100)는 선택한 글로벌 파라미터를 이용하여 각 디바이스에서 연합 학습을 수행한 연합 학습 결과를 반영해 연합 학습 테이블을 업데이트하고, 글로벌 파라미터를 최적화하며(S220), 이를 제2 단계라 한다.

[0077] 여기서 연합 학습 결과는 선택한 글로벌 파라미터를 이용하여 수행한 연합 학습에 따른 학습 에너지 효율(R_{energy_global} , R_{energy_local}), 학습 정확도($R_{accuracy}$) 및 학습 시간(R_{energy_global} , R_{energy_local} 과 연관) 중 어느 하나 이상을 이용하여 산정한 보상(Reward)일 수 있으며, 보상에 따라 점수(Score) $Q(S_i, A_i)$ 가 업데이트될 수 있다.

[0078] 도 12는 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법에 있어서, 보상을 산정하는 수식을 도식한 도면이다.

[0079] 도 12를 참조하면 보상의 산정은 이번 학습 라운드에서 측정한 정확도 $R_{accuracy}$ 가 지난 라운드에서 측정한 정확도 $R_{accuracy_prev}$ 보다 높지 않다면 $R_{accuracy} - 100$ 으로 낮아지도록 하며, 다음에 해당 액션이 선택될 가능성을 낮춘다. 그렇지 않은 경우 학습 에너지 효율(R_{energy_global} , R_{energy_local})과 학습 정확도($R_{accuracy}$)를 활용하여 계산하며, 여기서 α 와 β 는 정확도의 가중치에 해당하는 값으로 연합 학습을 활용한 서비스가 학습 품질을 중요하게 생각하는 경우 해당 가중치를 높게 설정하여 정확도의 중요성이 보상에 충실히 반영되게 할 수 있다.

[0080] 연합 학습 결과인 보상을 산정했다면, 학습 수행 동안 또는 이후 변경된 새로운 상태(S')를 다시 파악하여 가장 높은 점수 $Q(S', A')$ 값을 갖는 액션(A')을 선택하며(난수가 ϵ 보다 큰 경우), 선택한 액션(A')과 기존에 선택한 액션에 대하여 $Q(S, A)$, Reward, Learning Rate γ , Discount Factor μ 에 기반하여 $Q(S, A)$ 값을 업데이트하는바, S210 단계 및 S220 단계를 반복하는 것으로 볼 수 있으며, 이들 모두 앞선 도 11에 도시되어 있는 사항이다.

[0081] 이상과 같은 $Q(S, A)$ 값의 업데이트는 각각의 특정 상태에 대한 모든 액션들 중, 어느 하나의 액션에 대하여 $Q(S, A)$ 값이 일정 임계값 이상으로 수렴하여 해당 특정 상태에 대해서는 하나의 액션만 수행하게 되는 경우까지 반복하는바, 그 이후에는 상태만 파악하면 일정 임계값 이상으로 수렴한 하나의 액션만 자동으로 선택함으로써 연합 학습의 효율성을 극대화시킬 수 있을 것이다.

[0082] 지금까지 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법에 대하여 설명하였다. 본 발명에 따르면 연합 학습을 수행하는 각 모바일 기기에 대하여 연합 학습 수행에 영향을 줄 수 있는 다양한 내/외부적 요소를 파악하여 이를 반영한 최적의 글로벌 파라미터를 설정하게 함으로써 연합 학습의 효율성을 현저하게 향상시킬 수 있다. 도 13 및 도 14는 본 발명의 제2 실시 예에 따른 연합 학습을 위한 글로벌 파라미터를 최적화하는 방법의 성능 평가 자료인바, 도 13을 참조하면 종래 기술인 Bayesian Optimization과 Genetic Algorithm 대비 학습 수렴 시간(Convergence time)을 현저하게 단축시키는 것을 확인할 수 있는바, 학습 속도를 향상시켜 학습 시간을 현저하게 단축시킴을 알 수 있으며, 도 14를 참조하면, 종래 기술 대비 전송비를 현저하게 증가시켜 에너지 효율성을 극대화시킨 것을 확인할 수 있다.

[0083] 마지막으로, 본 발명의 제1 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치(100)와 본 발명의 제2 실시 예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법은 본 발명의 제3 실시 예에 따른 컴퓨터로 판독 가능한 매체에 저장된 컴퓨터 프로그램으로 구현할 수도 있는바, 이 경우 컴퓨팅 장치와 결합하여 (AA) 연합 학습의 매 라운드에 참여하는 각 디바이스의 특성 요소 및 상기 각 디바이스의 외부 환경 요소 중 어느 하나 이상을 포함하는 상태(State)를 파악하여, 상태 별로 하나 이상의 액션(Action)이 점수(Score)로 부여된 공유 점수 테이블(Table)을 통해 상기 파악한 상태에 대한 글로벌 파라미터를 선택하는 제1 단계 및 (BB) 상기 선택한 글로벌 파라미터를 이용하여 상기 각 디바이스에서 연합 학습을 수행한 연합 학습 결과를 반영해 상기 연합 학습 테이블을 업데이트하고, 상기 글로벌 파라미터를 최적화하는 제2 단계를 실행할 수 있을 것이며, 중복 서술을 위해 자세히 기재하지는 않았지만 본 발명의 제1 실시 예

에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치(100) 및 본 발명의 제2 실시예에 따른 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 방법에 적용된 모든 기술적 특징은 본 발명의 제3 실시예에 따른 컴퓨터로 판독 가능한 매체에 저장된 컴퓨터 프로그램에 모두 동일하게 적용될 수 있음은 물론이라 할 것이다.


[0084] 이상 첨부된 도면을 참조하여 본 발명의 실시예들을 설명하였지만, 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자는 본 발명이 그 기술적 사상이나 필수적인 특징을 변경하지 않고서 다른 구체적인 형태로 실시될 수 있다는 것을 이해할 수 있을 것이다. 그러므로 이상에서 기술한 실시예들은 모든 면에서 예시적인 것이며 한정적이 아닌 것으로 이해해야만 한다.

부호의 설명


[0085] 10: 프로세서
20: 네트워크 인터페이스
30: 메모리
40: 스토리지
41: 컴퓨터 프로그램
50: 정보 버스
100: 연합 학습 에너지 소비 효율 향상을 위한 공유 점수 테이블 최적화 장치

도면

도면1




도면2




도면3

Action State	A_1	A_2	...	A_i
S_1	$Q(S_1, A_1)$	$Q(S_1, A_2)$	...	$Q(S_1, A_i)$
S_2	$Q(S_2, A_1)$	$Q(S_2, A_2)$	...	$Q(S_2, A_i)$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
S_i	$Q(S_i, A_1)$	$Q(S_i, A_2)$	...	$Q(S_i, A_i)$


도면4




도면5




도면6




도면7



도면8



도면9



도면10

State	Discrete Values
S_{CONV}	Small (<10), medium (<20), large (<30), larger (≥ 40)
S_{FC}	Small (<10), large (≥ 10)
S_{RC}	Small (<5), medium (<10), large (≥ 10)
S_{Co_CPU}	None (0%), small ($<25\%$), medium ($<75\%$), large ($\leq 100\%$)
S_{Co_MEM}	None (0%), small ($<25\%$), medium ($<75\%$), large ($\leq 100\%$)
$S_{Network}$	Regular ($>40\text{Mbps}$), bad ($\leq 40\text{Mbps}$)
S_{Data}	Small ($<25\%$), medium ($<100\%$), large ($=100\%$)

도면11

Variable: S, A

S is the variable for the state

A is the variable for the action

Constants: γ, μ, ϵ

γ is the learning rate

μ is the discount factor

ϵ is the exploration probability

Initialize $Q(S, A)$ as random values

Repeat (whenever an aggregation round begins):

Observe state and store in S

if $\text{rand}() < \epsilon$ **then**

Choose action A randomly

else

Choose action A which maximizes $Q(S, A)$

Run training with global parameters defined by A
(when local training and aggregation terminate)

Obtain $R_{\text{energy_global}}$, $R_{\text{energy_local}}$, and R_{accuracy}

Calculate reward R

Observe new state S'

Choose action A' which maximizes $Q(S', A')$

$Q(S, A) \leftarrow Q(S, A) + \gamma[R + \mu Q(S', A') - Q(S, A)]$

$S \leftarrow S'$

도면12

if $R_{\text{accuracy}} - R_{\text{accuracy_prev}} \leq 0$,


$R = R_{\text{accuracy}} - 100$

else

$R = -R_{\text{energy_global}} - R_{\text{energy_local}}$

$+ \alpha R_{\text{accuracy}} + \beta(R_{\text{accuracy}} - R_{\text{accuracy_prev}})$

도면13



도면14

