



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0119792
(43) 공개일자 2024년08월06일

- | | |
|--|---|
| <p>(51) 국제특허분류(Int. Cl.)
G06N 20/20 (2019.01)</p> <p>(52) CPC특허분류
G06N 20/20 (2021.08)</p> <p>(21) 출원번호 10-2023-0037350</p> <p>(22) 출원일자 2023년03월22일
심사청구일자 2023년03월22일</p> <p>(30) 우선권주장
1020230011684 2023년01월30일 대한민국(KR)</p> | <p>(71) 출원인
울산과학기술원
울산광역시 울주군 언양읍 유니스트길 50</p> <p>(72) 발명자
윤성환
울산광역시 울주군 언양읍 유니스트길 50 (반연리, 울산과학기술원)</p> <p>임진혁
울산광역시 울주군 언양읍 유니스트길 50 (반연리, 울산과학기술원)</p> <p>하승범
울산광역시 울주군 언양읍 유니스트길 50 (반연리, 울산과학기술원)</p> <p>(74) 대리인
특허법인 수</p> |
|--|---|

전체 청구항 수 : 총 30 항


(54) 발명의 명칭 개인화된 연합 학습을 위한 메타 학습 장치 및 방법

(57) 요약

본 발명은 메타 러닝을 토대로 일반화가 잘되는 글로벌 임베더 모델의 학습을 수행하고, 큰 폭의 표현학습을 통해 임베더 성능을 향상할 수 있는 개인화된 연합 학습을 위한 메타 학습 장치 및 방법에 관한 것이다.

본 발명의 개인화된 연합 학습을 위한 메타 학습 장치는 글로벌 모델을 생성하고 업데이트하여 연합학습을 수행하는 서버, 및 서버로부터 글로벌 모델을 수신받아 로컬 네트워크의 로컬 업데이트 결과를 서버로 송출하는 클라이언트로 이루어진다.

대표도 - 도1



이 발명을 지원한 국가연구개발사업

과제고유번호 1711169479
 과제번호 2021R1C1C1012797
 부처명 과학기술정보통신부
 과제관리(전문)기관명 한국연구재단
 연구사업명 개인기초연구(과기정통부)
 연구과제명 소수의 학습 데이터로 상황에 적합한 연속적인 학습이 가능한 인공지능 알고리즘 개발 연구

기 여 율 45.00/100
 과제수행기관명 울산과학기술원
 연구기간 2022.03.01 ~ 2023.02.28

이 발명을 지원한 국가연구개발사업

과제고유번호 1711173189
 과제번호 2021-0-02201-002
 부처명 과학기술정보통신부
 과제관리(전문)기관명 정보통신기획평가원
 연구사업명 정보통신방송기술국제공동연구
 연구과제명 사용자 프라이버시를 보존하는 비디오 캐싱을 위한 연합 학습 시스템
 기 여 율 40.00/100
 과제수행기관명 경희대학교 산학협력단
 연구기간 2022.06.01 ~ 2023.01.31

이 발명을 지원한 국가연구개발사업

과제고유번호 1711152473
 과제번호 2020-0-01336-003
 부처명 과학기술정보통신부
 과제관리(전문)기관명 정보통신기획평가원
 연구사업명 정보통신방송혁신인재양성(R&D)
 연구과제명 인공지능대학원지원(울산과학기술원)
 기 여 율 10.00/100
 과제수행기관명 울산과학기술원
 연구기간 2023.01.01 ~ 2023.12.31

이 발명을 지원한 국가연구개발사업

과제고유번호 1711179301
 과제번호 00156361
 부처명 과학기술정보통신부
 과제관리(전문)기관명 정보통신기획평가원
 연구사업명 정보통신방송혁신인재양성
 연구과제명 지역지능화혁신인재양성(울산과학기술원)
 기 여 율 5.00/100
 과제수행기관명 울산과학기술원
 연구기간 2023.01.01 ~ 2023.12.31

명세서

청구범위

청구항 1

글로벌 모델(global model)을 생성하고 업데이트하여 연합학습을 수행하는 서버; 및

상기 서버로부터 상기 글로벌 모델을 수신받아 로컬 네트워크의 로컬 업데이트 결과를 상기 서버로 송출하는 클라이언트;를 포함하는 개인화된 연합 학습을 위한 메타 학습 장치.

청구항 2

제 1항에 있어서,

상기 글로벌 모델은 글로벌파라미터를 포함한 글로벌 임베딩 네트워크를 포함하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

청구항 3

제 2항에 있어서,

상기 글로벌 모델은 글로벌마진을 포함하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

청구항 4

제 3항에 있어서,

상기 클라이언트는,

상기 글로벌 모델을 토대로 임베딩 네트워크를 학습하는 임베딩 네트워크;

학습에 필요한 로컬마진을 계산하는 다이나믹마진 계산부;

로컬마진을 토대로 손실함수를 계산하는 손실함수 계산부; 및

임베딩 네트워크를 업데이트하는 네트워크 업데이트부;를 포함하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

청구항 5

제 4항에 있어서,

상기 임베딩 네트워크는 로컬 데이터셋으로부터 에피소드(episode)를 구비하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

청구항 6

제 5항에 있어서,

상기 에피소드는 N개의 로컬 클래스(local class), 학습을 위해 상기 로컬 클래스 당 K개 샘플(서포트샘플)로 구성되는 서포트셋(S), 및 시험을 위해 상기 로컬 클래스 당 Q개 샘플(쿼리샘플)로 구성되는 쿼리셋(Q)로 이루어지는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

청구항 7

제 6항에 있어서,

상기 임베딩 네트워크는 서포트샘플의 특징벡터 평균으로 정의되는 클래스 프로토타입(proto-type)을 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

$$\mathbf{c}_k = \frac{1}{|\mathcal{S}_k|} \sum_{x \in \mathcal{S}_k} f(x; \theta^{(\tau)})$$

여기서,

$\mathbf{c}_k$: 로컬 클래스 k 에 대한 프로토타입,

$\mathcal{S}_k$: 서포트셋(S)의 서브셋,

$f(\cdot; \theta^{(\tau)})$: 글로벌 임베딩 네트워크,

$\theta^{(\tau)}$: 파라미터

청구항 8

제 7항에 있어서,

상기 임베딩 네트워크는 상기 쿼리샘플의 특징벡터와 상기 클래스 프로토타입의 유클리디안(euclidean) 거리 기반 소프트맥스 손실(softmax loss)을 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

$$\mathcal{L}_S = \frac{1}{|Q|} \sum_{k=1}^N \sum_{x \in Q_k} \left[d(f(x; \theta^{(\tau)}), \mathbf{c}_k) + \log \sum_{l=1}^N \exp(-d(f(x; \theta^{(\tau)}), \mathbf{c}_l)) \right]$$

여기서,

$\mathcal{L}_S$: cross entropy loss

청구항 9

제 8항에 있어서,

상기 다이나믹마진 계산부는 상기 에피소드 내 클래스 센트로이드(centroid)의 거리 평균인 로컬 마진(local margin)을 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

$$\mathbf{m}_i^{(\tau)} = \frac{1}{(N-1)^2} \sum_k \sum_{l \neq k} d(\mathbf{a}_k, \mathbf{a}_l)$$

$\mathbf{m}_i^{(\tau)}$: 로컬 거리 마진,

$\mathbf{a}_k$: class centroid

청구항 10

제 9항에 있어서,

상기 다이내믹마진 계산부는 최대 마진을 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

$$\mathbf{m}^* = \max\{\mathbf{m}_{\text{global}}^{(\tau)}, \mathbf{m}_i^{(\tau)}\}$$

여기서,

$\mathbf{m}_{\text{global}}^{(\tau)}$: 글로벌 거리마진,

$\mathbf{m}_i^{(\tau)}$: 로컬 거리 마진

청구항 11

제 10항에 있어서,

상기 손실함수 계산부는 상기 에피소드 내 클래스 센트로이드와 유사한 샘플은 가깝게, 상이한 샘플은 멀게 배치하기 위해 상기 클래스 센트로이드, 상기 서포트샘플, 및 상기 쿼리샘플을 토대로 트리플렛 손실(triplet loss)을 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

$$\mathcal{L}_T = \sum_k \sum_{(x_p, x_n)} \mathcal{L}_T(\mathbf{a}_k, x_p, x_n)$$

여기서,

$$\mathcal{L}_T(\mathbf{a}_k, x_p, x_n) = \max \left\{ d(\mathbf{a}_k, f(x_p; \theta^{(\tau)})) - d(f(x_p; \theta^{(\tau)}), f(x_n; \theta^{(\tau)})) + \mathbf{m}^*, 0 \right\},$$

$$x_p \in \mathcal{S}_k \cup \mathcal{Q}_k, x_n \in \mathcal{S}_l \cup \mathcal{Q}_l \text{ where } l \neq k$$

청구항 12

제 11항에 있어서,

상기 네트워크 업데이트부는 상기 로컬 네트워크의 로컬파라미터의 업데이트를 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

$$\theta_i^{(\tau)} \leftarrow \theta^{(\tau)} - \eta \nabla (\gamma \mathcal{L}_S + (1 - \gamma) \mathcal{L}_T)$$

여기서,

γ : 하이퍼파라미터(hyperparameter)

청구항 13

제 12항에 있어서,

상기 네트워크 업데이트부는 상기 로컬 업데이트 결과로서, 로컬파라미터와 로컬마진을 상기 서버로 송출하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

청구항 14

제 13항에 있어서,

상기 서버는 상기 클라이언트로부터 수신한 상기 로컬 업데이트 결과를 토대로 글로벌파라미터를 다음 식으로 업데이트하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

$$\theta^{(\tau+1)} \leftarrow \frac{1}{|C_\tau|} \sum_{i \in C_\tau} \theta_i^{(\tau)}$$

여기서,

C_τ : set of active clients during round τ

청구항 15

제 14항에 있어서,

상기 서버는 상기 클라이언트로부터 수신한 상기 로컬 업데이트 결과를 토대로 글로벌마진을 다음 식으로 업데이트하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 장치.

$$m_{\text{global}}^{(\tau+1)} \leftarrow \frac{1}{W} \left\{ \sum_{t=\tau-W+1}^{\tau-1} m_{\text{global}}^{(t)} + \frac{1}{|C_\tau|} \sum_{i \in C_\tau} m_i \right\}$$

여기서,

W : round

청구항 16

서버에서 글로벌 모델(global model)을 생성하고 업데이트하여 연합학습을 수행하는 글로벌모델 업데이트단계; 및

상기 서버로부터 상기 글로벌 모델을 수신받아 로컬 네트워크의 로컬 업데이트 결과를 상기 서버로 송출하는 로컬모델 업데이트단계;를 포함하는 개인화된 연합 학습을 위한 메타 학습 방법.

청구항 17

제 16항에 있어서,

상기 글로벌 모델은 글로벌파라미터를 포함한 글로벌 임베딩 네트워크를 포함하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

청구항 18

제 17항에 있어서,

상기 글로벌 모델은 글로벌마진을 포함하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

청구항 19

제 18항에 있어서,

상기 로컬모델 업데이트단계는,

임베딩 네트워크에서 상기 글로벌 모델을 토대로 임베딩 네트워크를 학습하는 임베딩 네트워크 계산단계;

다이나믹마진 계산부에서 학습에 필요한 로컬마진을 계산하는 로컬마진 계산단계;

손실함수 계산부에서 로컬마진을 토대로 손실함수를 계산하는 손실함수 계산단계; 및

네트워크 업데이트부에서 임베딩 네트워크를 업데이트하는 네트워크 업데이트단계;를 포함하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

청구항 20

제 19항에 있어서,

상기 임베딩 네트워크는 로컬 데이터셋으로부터 에피소드(episode)를 구비하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

청구항 21

제 20항에 있어서,

상기 에피소드는 N개의 로컬 클래스(local class), 학습을 위해 상기 로컬 클래스 당 K개 샘플(서포트샘플)로 구성되는 서포트셋(S), 및 시험을 위해 상기 로컬 클래스 당 Q개 샘플(쿼리샘플)로 이루어지는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

청구항 22

제 21항에 있어서,

상기 임베딩 네트워크 계산단계에서는 서포트샘플의 특징벡터 평균으로 정의되는 클래스 프로토타입(prototype)을 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

$$c_k = \frac{1}{|S_k|} \sum_{x \in S_k} f(x; \theta^{(\tau)})$$

여기서,

c_k : 로컬 클래스 k 에 대한 프로토타입,

S_k : 서포트셋(S)의 서브셋,

$f(\cdot; \theta^{(\tau)})$: 글로벌 임베딩 네트워크,

$\theta^{(\tau)}$: 파라미터

청구항 23

제 22항에 있어서,

상기 임베딩 네트워크 계산단계에서는 상기 쿼리샘플의 특징벡터와 상기 클래스 프로토타입의 유클리디안(euclidean) 거리 기반 소프트맥스 손실(softmax loss)을 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

$$\mathcal{L}_S = \frac{1}{|Q|} \sum_{k=1}^N \sum_{x \in Q_k} \left[d(f(x; \theta^{(\tau)}), \mathbf{c}_k) + \log \sum_{l=1}^N \exp(-d(f(x; \theta^{(\tau)}), \mathbf{c}_l)) \right]$$

여기서,

$\mathcal{L}_S$: cross entropy loss

청구항 24

제 23항에 있어서,

상기 로컬마진 계산단계에서는 상기 에피소드 내 클래스 센트로이드(centroid)의 거리 평균인 로컬 마진(local margin)을 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법. .

$$m_i^{(\tau)} = \frac{1}{(N-1)^2} \sum_k \sum_{l \neq k} d(\mathbf{a}_k, \mathbf{a}_l)$$

$m_i^{(\tau)}$: 로컬 거리 마진,

$\mathbf{a}_k$: class centroid

청구항 25

제 24항에 있어서,

상기 로컬마진 계산단계에서는 최대 마진을 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

$$m^* = \max\{m_{\text{global}}^{(\tau)}, m_i^{(\tau)}\}$$

여기서,

$m_{\text{global}}^{(\tau)}$: 글로벌 거리마진,

$m_i^{(\tau)}$: 로컬 거리 마진

청구항 26

제 25항에 있어서,

상기 손실함수 계산단계에서는 상기 에피소드 내 클래스 센트로이드와 유사한 샘플은 가깝게, 상이한 샘플은 멀게 배치하기 위해 상기 클래스 센트로이드, 상기 서포트샘플, 및 상기 쿼리샘플을 토대로 트리플렛 손실(triplet loss)을 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

$$\mathcal{L}_T = \sum_k \sum_{(x_p, x_n)} \mathcal{L}_T(\mathbf{a}_k, x_p, x_n)$$

여기서,

$$\mathcal{L}_T(\mathbf{a}_k, x_p, x_n) = \max \left\{ d(\mathbf{a}_k, f(x_p; \theta^{(\tau)})) - d(f(x_p; \theta^{(\tau)}), f(x_n; \theta^{(\tau)})) + m^*, 0 \right\},$$

$$x_p \in \mathcal{S}_k \cup \mathcal{Q}_k, x_n \in \mathcal{S}_l \cup \mathcal{Q}_l \text{ where } l \neq k$$

청구항 27

제 26항에 있어서,

상기 네트워크 업데이트단계에서는 상기 로컬 네트워크의 로컬파라미터의 업데이트를 다음 식으로 계산하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

$$\theta_i^{(\tau)} \leftarrow \theta^{(\tau)} - \eta \nabla (\gamma \mathcal{L}_S + (1 - \gamma) \mathcal{L}_T)$$

여기서,

γ : 하이퍼파라미터(hyperparameter)

청구항 28

제 27항에 있어서,

상기 네트워크 업데이트단계에서는 상기 로컬 업데이트 결과로서, 로컬파라미터와 로컬마진을 상기 서버로 송출하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

청구항 29

제 28항에 있어서,

상기 글로벌모델 업데이트단계에서 상기 서버는 상기 클라이언트로부터 수신한 상기 로컬 업데이트 결과를 토대로 상기 글로벌파라미터를 다음 식으로 업데이트하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

$$\theta^{(\tau+1)} \leftarrow \frac{1}{|C_\tau|} \sum_{i \in C_\tau} \theta_i^{(\tau)}$$

여기서,

C_τ : set of active clients during round τ

청구항 30

제 29항에 있어서,

상기 글로벌모델 업데이트단계에서 상기 서버는 상기 클라이언트로부터 수신한 상기 로컬 업데이트 결과를 토대로 상기 글로벌모델을 다음 식으로 업데이트하는 것을 특징으로 하는 개인화된 연합 학습을 위한 메타 학습 방법.

$$m_{\text{global}}^{(\tau+1)} \leftarrow \frac{1}{W} \left\{ \sum_{t=\tau-W+1}^{\tau-1} m_{\text{global}}^{(t)} + \frac{1}{|C_\tau|} \sum_{i \in C_\tau} m_i \right\}$$

여기서,

W : round

발명의 설명

기술 분야

[0001] 본 발명은 개인화된 연합 학습을 위한 메타 학습 장치 및 방법에 관한 것으로, 상세하게는, 서버와 클라이언트 간 연합학습을 수행하는 것이다.

[0002] 또한, 본 발명은 추가적인 학습 없이 클래스 간 구분을 더욱 명확히 할 수 있는 개인화된 연합 학습을 위한 메타 학습 장치 및 방법에 관한 것이다.

배경 기술

[0003] 연합 학습은 개인 정보의 보호를 위해 분산된 환경에서 데이터의 공유 없이 다수 기관의 정보를 학습하는 기계 학습(Machine learning) 모델을 만들기 위한 기술이다.

[0004] 해당 기술은 사용자의 스마트폰과 같은 모바일 장치에서 병원, 금융 회사와 같은 기관 단위까지 넓은 범위의 사용 환경에서 연구되고 있다.

[0005] 연합학습은 로컬 데이터셋을 사용한 모델 최적화, 모델 집계 즉, 모델 평균화의 두 가지 작업을 통해 분산 모델 학습을 반복적으로 수행한다. 예를 들면, 모든 라운드에서 서버는 사용 가능한 모바일 장치에 글로벌 모델을 전송하며, 각 모바일 장치는 로컬에서 사용 가능한 데이터로 글로벌 모델을 최적화한 다음 업데이트된 모델 매개 변수(또는 업데이트된 로컬 기울기)를 통신 링크를 통해 서버로 보낸다. 이에, 서버는 모바일 장치에서 수신한 로컬 모델 또는 기울기를 평균화하여 글로벌 모델을 업데이트하고 반복하여 공유한다.

[0006] 이와 같이, 수많은 모바일 장치에 배치된 로컬 데이터 셋을 사용하여 글로벌 모델을 최적화하는 것은 어려운 작업이므로 이를 개선하려는 연구가 지속되어 왔다.

[0007] 그 일례로, 대한민국 공개특허공보 제10-2021-0010619호에서는 모바일 장치가 각각 통신 라운드마다 서버로 MSE(Mean-Squared Error; 평균 제곱 오차)를 최소화하기 위해 정량화된 로컬 기울기 정보를 보내는 연합학습 시

시스템을 제안하였다.

[0008] 그러나 이 경우에도 모바일 장치 간의 데이터 디스트리뷰션(data distribution) 차이가 클수록 로컬 업데이트 이후 발산 모델(diverse models)이 되어 하나의 모델로 수렴하기 어려우며, 수렴된 모델은 각각의 모바일 장치에 특화되어 대응되기 어려운 문제점이 있다.

선행기술문헌

특허문헌

[0009] (특허문헌 0001) 대한민국 공개특허공보 제10-2021-0010619호(2021.01.26)

발명의 내용

해결하려는 과제

[0010] 본 발명의 목적은, 메타 러닝(meta-learning)을 토대로 일반화가 잘되는 글로벌 임베더(embedder) 모델의 학습을 수행하는 개인화된 연합 학습을 위한 메타 학습 장치 및 방법을 제공하는 것이다.

[0011] 본 발명은 큰 폭의 표현학습(Large Margin Representation Learning)을 통해 임베더 성능을 향상할 수 있는 개인화된 연합 학습을 위한 메타 학습 장치 및 방법을 제공하는데 또 다른 목적이 있다.

과제의 해결 수단

[0012] 본 발명에 따른 개인화된 연합 학습을 위한 메타 학습 장치는 글로벌 모델(global model)을 생성하고 업데이트 하여 연합학습을 수행하는 서버 및 서버로부터 글로벌 모델을 수신받아 로컬 네트워크의 로컬 업데이트 결과를 서버로 송출하는 클라이언트를 포함할 수 있다.

[0013] 여기서, 글로벌 모델은 글로벌파라미터를 포함한 글로벌 임베딩 네트워크를 포함할 수 있다.

[0014] 또한, 글로벌 모델은 글로벌마진을 포함할 수 있다.

[0015] 여기서, 클라이언트는 글로벌 모델을 토대로 임베딩 네트워크를 학습하는 임베딩 네트워크, 학습에 필요한 로컬 마진을 계산하는 다이내믹마진 계산부, 로컬마진을 토대로 손실함수를 계산하는 손실함수 계산부, 및 임베딩 네트워크를 업데이트하는 네트워크 업데이트부를 포함할 수 있다.

[0016] 또한, 임베딩 네트워크는 로컬 데이터셋으로부터 에피소드(episode)를 구비할 수 있다.

[0017] 여기서, 에피소드는 N개의 로컬 클래스(local class), 학습을 위해 로컬 클래스 당 K개 샘플(서포트샘플)로 구성되는 서포트셋(S), 및 시험을 위해 로컬 클래스 당 Q개 샘플(쿼리샘플)로 구성되는 쿼리셋(Q)로 이루어질 수 있다.

[0018] 또한, 임베딩 네트워크는 서포트샘플의 특징벡터 평균으로 정의되는 클래스 프로토타입(proto-type)을 다음 식으로 계산할 수 있다.

$$\mathbf{c}_k = \frac{1}{|\mathcal{S}_k|} \sum_{x \in \mathcal{S}_k} f(x; \theta^{(\tau)})$$

[0019]

[0020] 여기서,

[0021] $\mathbf{c}_k$: 로컬 클래스 k 에 대한 프로토타입,

[0022] $\mathcal{S}_k$: 서포트셋(S)의 서브셋,

[0023] $f(\cdot; \theta^{(\tau)})$: 글로벌 임베딩 네트워크,

[0024] $\theta^{(\tau)}$: 파라미터.

[0026] 여기서, 임베딩 네트워크는 쿼리샘플의 특징벡터와 클래스 프로토타입의 유클리디안(euclidean) 거리 기반 소프트맥스 손실(softmax loss)을 다음 식으로 계산할 수 있다.

$$\mathcal{L}_S = \frac{1}{|Q|} \sum_{k=1}^N \sum_{x \in Q_k} \left[d(f(x; \theta^{(\tau)}), \mathbf{c}_k) + \log \sum_{l=1}^N \exp(-d(f(x; \theta^{(\tau)}), \mathbf{c}_l)) \right]$$

[0027] 여기서,

[0029] $\mathcal{L}_S$: cross entropy loss.

[0031] 또한, 다이내믹마진 계산부는 에피소드 내 클래스 센트로이드(centroid)의 거리 평균인 로컬 마진(local margin)을 다음 식으로 계산할 수 있다.

$$\mathbf{m}_i^{(\tau)} = \frac{1}{(N-1)^2} \sum_k \sum_{l \neq k} d(\mathbf{a}_k, \mathbf{a}_l)$$

[0033] $\mathbf{m}_i^{(\tau)}$: 로컬 거리 마진,

[0034] $\mathbf{a}_k$: class centroid.

[0036] 여기서, 다이내믹마진 계산부는 최대 마진을 다음 식으로 계산할 수 있다.

$$\mathbf{m}^* = \max\{\mathbf{m}_{\text{global}}^{(\tau)}, \mathbf{m}_i^{(\tau)}\}$$

[0038] 여기서,

[0039] $\mathbf{m}_{\text{global}}^{(\tau)}$: 글로벌 거리마진,

[0040] $\mathbf{m}_i^{(\tau)}$: 로컬 거리 마진.

[0042] 또한, 손실함수 계산부는 에피소드 내 클래스 센트로이드와 유사한 샘플은 가깝게, 상이한 샘플은 멀게 배치하기 위해 클래스 센트로이드, 서포트샘플, 및 쿼리샘플을 토대로 트리플렛 손실(triplet loss)을 다음 식으로 계

산할 수 있다.

$$\mathcal{L}_T = \sum_k \sum_{(x_p, x_n)} \mathcal{L}_T(\mathbf{a}_k, x_p, x_n)$$

여기서,

$$\mathcal{L}_T(\mathbf{a}_k, x_p, x_n) = \max \left\{ d(\mathbf{a}_k, f(x_p; \theta^{(\tau)})) - d(f(x_p; \theta^{(\tau)}), f(x_n; \theta^{(\tau)})) + m^*, 0 \right\},$$

$$x_p \in \mathcal{S}_k \cup \mathcal{Q}_k, x_n \in \mathcal{S}_l \cup \mathcal{Q}_l \text{ where } l \neq k$$

여기서, 네트워크 업데이트부는 로컬 네트워크의 로컬파라미터의 업데이트를 다음 식으로 계산할 수 있다.

$$\theta_i^{(\tau)} \leftarrow \theta^{(\tau)} - \eta \nabla (\gamma \mathcal{L}_S + (1 - \gamma) \mathcal{L}_T)$$

여기서,

γ : 하이퍼파라미터(hyperparameter).

또한, 네트워크 업데이트부는 로컬 업데이트 결과로서, 로컬파라미터와 로컬마진을 서버로 송출할 수 있다.

여기서, 서버는 클라이언트로부터 수신한 로컬 업데이트 결과를 토대로 글로벌파라미터를 다음 식으로 업데이트할 수 있다.

$$\theta^{(\tau+1)} \leftarrow \frac{1}{|C_\tau|} \sum_{i \in C_\tau} \theta_i^{(\tau)}$$

여기서,

C_τ : set of active clients during round τ .

또한, 서버는 클라이언트로부터 수신한 로컬 업데이트 결과를 토대로 글로벌마진을 다음 식으로 업데이트할 수 있다.

$$m_{\text{global}}^{(\tau+1)} \leftarrow \frac{1}{W} \left\{ \sum_{t=\tau-W+1}^{\tau-1} m_{\text{global}}^{(t)} + \frac{1}{|C_\tau|} \sum_{i \in C_\tau} m_i \right\}$$

여기서,

W : round.

본 발명의 다른 실시예에 따른 개인화된 연합 학습을 위한 메타 학습 방법은 서버에서 글로벌 모델(global

model)을 생성하고 업데이트하여 연합학습을 수행하는 글로벌모델 업데이트단계 및 서버로부터 글로벌 모델을 수신받아 로컬 네트워크의 로컬 업데이트 결과를 서버로 송출하는 로컬모델 업데이트단계를 포함할 수 있다.

[0065] 여기서, 글로벌 모델은 글로벌파라미터를 포함한 글로벌 임베딩 네트워크를 포함할 수 있다.

[0066] 또한, 글로벌 모델은 글로벌마진을 포함할 수 있다.

[0067] 여기서, 로컬모델 업데이트단계는 임베딩 네트워크에서 글로벌 모델을 토대로 임베딩 네트워크를 학습하는 임베딩 네트워크 계산단계, 다이나믹마진 계산부에서 학습에 필요한 로컬마진을 계산하는 로컬마진 계산단계, 손실 함수 계산부에서 로컬마진을 토대로 손실함수를 계산하는 손실함수 계산단계, 및 네트워크 업데이트부에서 임베딩 네트워크를 업데이트하는 네트워크 업데이트단계를 포함할 수 있다.

[0068] 또한, 임베딩 네트워크는 로컬 데이터셋으로부터 에피소드(episode)를 구비할 수 있다.

[0069] 여기서, 에피소드는 N개의 로컬 클래스(local class), 학습을 위해 로컬 클래스 당 K개 샘플(서포트샘플)로 구성되는 서포트셋트(S), 및 시험을 위해 로컬 클래스 당 Q개 샘플(쿼리샘플)로 구성되는 쿼리셋트(Q)로 이루어질 수 있다.

[0070] 또한, 임베딩 네트워크 계산단계에서는 서포트샘플의 특징벡터 평균으로 정의되는 클래스 프로토타입(prototype)을 다음 식으로 계산할 수 있다.

$$\mathbf{c}_k = \frac{1}{|\mathcal{S}_k|} \sum_{x \in \mathcal{S}_k} f(x; \theta^{(\tau)})$$

[0071] 여기서,

[0073] $\mathbf{c}_k$: 로컬 클래스 k 에 대한 프로토타입,

[0074] $\mathcal{S}_k$: 서포트셋트(S)의 서브셋트,

[0075] $f(\cdot; \theta^{(\tau)})$: 글로벌 임베딩 네트워크,

[0076] $\theta^{(\tau)}$: 파라미터.

[0078] 여기서, 임베딩 네트워크 계산단계에서는 쿼리샘플의 특징벡터와 클래스 프로토타입의 유클리디안(euclidean) 거리 기반 소프트맥스 손실(softmax loss)을 다음 식으로 계산할 수 있다.

$$\mathcal{L}_S = \frac{1}{|Q|} \sum_{k=1}^N \sum_{x \in Q_k} \left[d(f(x; \theta^{(\tau)}), \mathbf{c}_k) + \log \sum_{l=1}^N \exp(-d(f(x; \theta^{(\tau)}), \mathbf{c}_l)) \right]$$

[0080] 여기서,

[0081] $\mathcal{L}_S$: cross entropy loss.

[0083] 또한, 로컬마진 계산단계에서는 에피소드 내 클래스 센트로이드(centroid)의 거리 평균인 로컬 마진(local margin)을 다음 식으로 계산할 수 있다.

$$m_i^{(\tau)} = \frac{1}{(N-1)^2} \sum_k \sum_{l \neq k} d(\mathbf{a}_k, \mathbf{a}_l)$$

[0084]

[0085] $m_i^{(\tau)}$: 로컬 거리 마진,

[0086] $\mathbf{a}_k$: class centroid.

[0088] 여기서, 로컬마진 계산단계에서는 최대 마진을 다음 식으로 계산할 수 있다.

$$m^* = \max\{m_{\text{global}}^{(\tau)}, m_i^{(\tau)}\}$$

[0089]

[0090] 여기서,

[0091] $m_{\text{global}}^{(\tau)}$: 글로벌 거리마진,

[0092] $m_i^{(\tau)}$: 로컬 거리 마진.

[0094] 또한, 손실함수 계산단계에서는 에피소드 내 클래스 센트로이드와 유사한 샘플은 가깝게, 상이한 샘플은 멀게 배치하기 위해 클래스 센트로이드, 서포트샘플, 및 쿼리샘플을 토대로 트리플렛 손실(triplet loss)을 다음 식으로 계산할 수 있다.

$$\mathcal{L}_T = \sum_k \sum_{(x_p, x_n)} \mathcal{L}_T(\mathbf{a}_k, x_p, x_n)$$

[0095]

[0096] 여기서,

$$\mathcal{L}_T(\mathbf{a}_k, x_p, x_n) = \max \left\{ d(\mathbf{a}_k, f(x_p; \theta^{(\tau)})) - d(f(x_p; \theta^{(\tau)}), f(x_n; \theta^{(\tau)})) + m^*, 0 \right\},$$

[0097]

$$x_p \in \mathcal{S}_k \cup \mathcal{Q}_k, x_n \in \mathcal{S}_l \cup \mathcal{Q}_l \text{ where } l \neq k.$$

[0098]

[0100] 여기서, 네트워크 업데이트단계에서는 로컬 네트워크의 로컬파라미터의 업데이트를 다음 식으로 계산할 수 있다.

$$\theta_i^{(\tau)} \leftarrow \theta^{(\tau)} - \eta \nabla (\gamma \mathcal{L}_S + (1 - \gamma) \mathcal{L}_T)$$

[0101]

[0102] 여기서,

[0103] γ : 하이퍼파라미터(hyperparameter).

[0105] 또한, 네트워크 업데이트단계에서는 로컬 업데이트 결과로서, 로컬파라미터와 로컬마진을 서버로 송출할 수 있다.

[0106] 여기서, 글로벌모델 업데이트단계에서 서버는 클라이언트로부터 수신한 로컬 업데이트 결과를 토대로 글로벌파라미터를 다음 식으로 업데이트할 수 있다.

$$\theta^{(\tau+1)} \leftarrow \frac{1}{|C_\tau|} \sum_{i \in C_\tau} \theta_i^{(\tau)}$$

[0107]

[0108] 여기서,

[0109] C_τ : set of active clients during round τ .

[0111] 또한, 글로벌모델 업데이트단계에서 서버는 클라이언트로부터 수신한 로컬 업데이트 결과를 토대로 글로벌마진을 다음 식으로 업데이트할 수 있다.

$$m_{\text{global}}^{(\tau+1)} \leftarrow \frac{1}{W} \left\{ \sum_{t=\tau-W+1}^{\tau-1} m_{\text{global}}^{(t)} + \frac{1}{|C_\tau|} \sum_{i \in C_\tau} m_i \right\}$$

[0112]

[0113] 여기서,

[0114] W : round.

발명의 효과

[0116] 본 발명에 의한 개인화된 연합 학습을 위한 메타 학습 장치 및 방법은 메타 러닝(meta-learning)을 토대로 일반화가 잘되는 글로벌 임베더(embedder) 모델의 학습을 수행하는 장점이 있다.

[0117] 또한, 본 발명에 의한 개인화된 연합 학습을 위한 메타 학습 장치 및 방법은 큰 폭의 표현학습(Large Margin Representation Learning)을 통해 임베더 성능을 향상할 수 있는 장점이 있다.

도면의 간단한 설명

[0118] 도 1은 본 발명의 일 실시예에 따른 개인화된 연합 학습을 위한 메타 학습 장치를 나타낸 구성도이다.

도 2는 도 1의 클라이언트를 상세히 나타낸 구성도이다.

도 3은 본 발명의 일 실시예에 따른 개인화된 연합 학습을 위한 메타 학습 방법을 나타낸 순서도이다.

도 4는 도 3의 로컬모델 업데이트단계를 상세히 나타낸 순서도이다.

발명을 실시하기 위한 구체적인 내용

[0119] 이하, 본 발명의 실시를 위한 구체적인 실시예를 첨부된 도면들을 참조하여 설명한다.

[0120] 본 발명을 설명함에 있어서 제 1, 제 2 등의 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 구성요소들은 용어들에 의해 한정되지 않을 수 있다. 용어들은 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 된다. 예를 들어, 본 발명의 권리 범위를 벗어나지 않으면서 제 1 구성요소는 제 2 구성요소로 명명될 수 있고, 유사하게 제 2 구성요소도 제 1 구성요소로 명명될 수 있다.

- [0121] 어떤 구성요소가 다른 구성요소에 연결되어 있거나 접속되어 있다고 언급되는 경우는, 그 다른 구성요소에 직접적으로 연결되어 있거나 또는 접속되어 있을 수도 있지만, 중간에 다른 구성요소가 존재할 수도 있다고 이해될 수 있다.
- [0122] 본 명세서에서 사용한 용어는 단지 특정한 실시예를 설명하기 위해 사용된 것으로, 본 발명을 한정하려는 의도가 아니다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함할 수 있다.
- [0123] 본 명세서에서, 포함하다 또는 구비하다 등의 용어는 명세서상에 기재된 특징, 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것이 존재함을 지정하려는 것으로서, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해될 수 있다.
- [0124] 또한, 도면에서의 요소들의 형상 및 크기 등은 보다 명확한 설명을 위해 과장될 수 있다.
- [0125] 이하, 첨부된 도면을 참조하여 본 발명에 따른 개인화된 연합 학습을 위한 메타 학습 장치 및 방법에 대해 상세히 설명한다.
- [0127] 도 1은 본 발명의 일 실시예에 따른 개인화된 연합 학습을 위한 메타 학습 장치를 나타낸 구성도이며, 도 2는 도 1을 상세히 설명하기 위한 세부 구성도이다.
- [0128] 이하, 도 1 내지 도 2를 참조하여 본 발명의 일 실시예에 따른 개인화된 연합 학습을 위한 메타 학습 장치를 설명한다.
- [0129] 먼저, 도 1을 참조하면, 본 발명의 일 실시예에 따른 개인화된 연합 학습을 위한 메타 학습 장치는 글로벌 모델(global model)을 생성하고 업데이트하여 연합학습을 수행하는 서버(100) 및 서버(100)로부터 글로벌 모델을 수신받아 로컬 네트워크의 로컬 업데이트 결과를 서버(100)로 송출하는 클라이언트(200)로 이루어진다.
- [0130] 여기서, 서버(100)는 적어도 어느 하나 이상의 클라이언트(200)로 글로벌 모델을 송신하고 다수의 클라이언트(200)로부터 클라이언트(200) 마다의 로컬 업데이트 결과를 받아 평균을 취함으로써, 글로벌 모델을 업데이트할 수 있다.
- [0131] 여기서, 글로벌 모델은 글로벌파라미터를 포함한 글로벌 임베딩 네트워크 및 글로벌마진을 사용하며, 상세한 내용은 이하 도 2에서 설명한다.
- [0133] 도 2는 도 1의 클라이언트(200)를 상세히 나타낸 구성도이다.
- [0134] 도 2에서 볼 수 있는 바와 같이, 클라이언트(200)는 글로벌 모델을 토대로 임베딩 네트워크를 학습하는 임베딩 네트워크(210), 학습에 필요한 로컬마진을 계산하는 다이나믹마진 계산부(220), 로컬마진을 토대로 손실함수를 계산하는 손실함수 계산부(230), 및 임베딩 네트워크를 업데이트하는 네트워크 업데이트부(240)를 포함한다.
- [0135] 이때, 클라이언트(200)는 글로벌 모델의 수신 전에 사전 작업을 수행하는데, 우선 클라이언트(200) 내에 있는 로컬 데이터셋으로부터 에피소드(episode)를 구비한다.
- [0136] 여기서, 에피소드는 N개의 로컬 클래스(local class), 학습을 위해 로컬 클래스 당 K개 샘플(서포트샘플)로 구성되는 서포트셋(S), 및 시험을 위해 로컬 클래스 당 Q개 샘플(쿼리샘플)로 구성되는 쿼리셋(Q)로 이루어진다.
- [0137] 여기서, 클라이언트(200)는 서포트샘플의 특징벡터 평균으로 정의되는 클래스 프로토타입(proto-type)을 다음 식으로 계산한다.

수학식 1

$$\mathbf{c}_k = \frac{1}{|\mathcal{S}_k|} \sum_{x \in \mathcal{S}_k} f(x; \theta^{(\tau)})$$

[0138]

[0139] 여기서,

[0140] $\mathbf{c}_k$: 로컬 클래스 k 에 대한 프로토타입,

[0141] $\mathcal{S}_k$: 서포트셋(S)의 서브셋,

[0142] $f(\cdot; \theta^{(\tau)})$: 글로벌 임베딩 네트워크,

[0143] $\theta^{(\tau)}$: 파라미터.

[0145] 또한, 클라이언트(200)는 쿼리샘플의 특징벡터와 클래스 프로토타입의 유클리디안(euclidian) 거리를 토대로 소프트맥스 손실(softmax loss)을 다음 식으로 계산한다.

수학식 2

$$\mathcal{L}_S = \frac{1}{|Q|} \sum_{k=1}^N \sum_{x \in Q_k} \left[d(f(x; \theta^{(\tau)}), \mathbf{c}_k) + \log \sum_{l=1}^N \exp(-d(f(x; \theta^{(\tau)}), \mathbf{c}_l)) \right]$$

[0146]

[0147] 여기서,

[0148] $\mathcal{L}_S$: cross entropy loss.

[0150] 또한, 클라이언트(200)는 에피소드 내 클래스 센트로이드(centroid) 간 거리 평균인 로컬 마진(local margin)을 다음 식으로 계산한다.

수학식 3

$$m_i^{(\tau)} = \frac{1}{(N-1)^2} \sum_k \sum_{l \neq k} d(\mathbf{a}_k, \mathbf{a}_l)$$

$m_i^{(\tau)}$: 로컬 거리 마진,

$\mathbf{a}_k$: class centroid.

한편, 클라이언트(200)는 서버(100)에서 수신한 글로벌마진과 클라이언트(200)에서 산출한 로컬 마진 중 최대 마진을 다음 식으로 계산한다.

수학식 4

$$m^* = \max\{m_{\text{global}}^{(\tau)}, m_i^{(\tau)}\}$$

여기서,

$m_{\text{global}}^{(\tau)}$: 글로벌 거리마진,

$m_i^{(\tau)}$: 로컬 거리 마진.

여기서, 클라이언트(200)는 에피소드 내 클래스 센트로이드와 유사한 샘플은 가깝게, 상이한 샘플은 멀게 배치 하기 위해 클래스 센트로이드, 서포트샘플, 및 쿼리샘플을 토대로 트리플렛 손실(triplet loss)을 다음 식으로 계산한다.

수학식 5

$$\mathcal{L}_T = \sum_k \sum_{(x_p, x_n)} \mathcal{L}_T(\mathbf{a}_k, x_p, x_n)$$

여기서,

$$\mathcal{L}_T(\mathbf{a}_k, x_p, x_n) = \max \left\{ d(\mathbf{a}_k, f(x_p; \theta^{(\tau)})) - d(f(x_p; \theta^{(\tau)}), f(x_n; \theta^{(\tau)})) + m^*, 0 \right\},$$

$$x_p \in \mathcal{S}_k \cup \mathcal{Q}_k, x_n \in \mathcal{S}_l \cup \mathcal{Q}_l \text{ where } l \neq k$$

또한, 클라이언트(200)는 로컬 네트워크의 로컬파라미터의 업데이트를 다음 식으로 계산한다.

수학식 6

$$\theta_i^{(\tau)} \leftarrow \theta^{(\tau)} - \eta \nabla (\gamma \mathcal{L}_S + (1 - \gamma) \mathcal{L}_T)$$

여기서,

γ : 하이퍼파라미터(hyperparameter).

여기서, 클라이언트(200)는 로컬 업데이트 결과로서, 로컬파라미터와 로컬마진을 서버(100)로 송출함으로써, 서버(100)에서의 업데이트를 종료한다.

한편, 서버(100)는 클라이언트(200)로부터 수신한 로컬 업데이트 결과를 토대로 글로벌파라미터를 다음 식으로 업데이트한다.

수학식 7

$$\theta^{(\tau+1)} \leftarrow \frac{1}{|C_\tau|} \sum_{i \in C_\tau} \theta_i^{(\tau)}$$

여기서,

C_τ : set of active clients during round τ .

또한, 서버(100)는 클라이언트(200)로부터 수신한 로컬 업데이트 결과를 토대로 글로벌마진을 다음 식으로 업데이트한다.

수학식 8

$$m_{\text{global}}^{(\tau+1)} \leftarrow \frac{1}{W} \left\{ \sum_{t=\tau-W+1}^{\tau-1} m_{\text{global}}^{(t)} + \frac{1}{|C_\tau|} \sum_{i \in C_\tau} m_i \right\}$$

여기서,

W : round.

이와 같은 본 발명에 의한 개인화된 연합 학습을 위한 메타 학습 장치는 다수의 클라이언트(200)를 통해 메타학

습을 수행함으로써, 추가적인 학습 없이 분류를 수행하며, 트리플렛 손실을 사용하여 클래스 간 거리를 최대한 멀리함으로써, 클래스 간 구분을 더욱 명확히 수행할 수 있다.

- [0185] 도 3은 본 발명의 일 실시예에 따른 개인화된 연합 학습을 위한 메타 학습 방법을 나타낸 순서도이며, 도 4는 도 3을 상세히 설명하기 위한 세부 순서도이다.
- [0186] 이하, 도 3 내지 도 4를 참조하여 본 발명의 일 실시예에 따른 개인화된 연합 학습을 위한 메타 학습 방법을 설명한다.
- [0187] 먼저, 도 3을 참조하면, 본 발명에 따른 개인화된 연합 학습을 위한 메타 학습 방법은 서버(100)에서 글로벌 모델(global model)을 생성하고 업데이트하여 연합학습을 수행하는 글로벌모델 업데이트단계(S100), 및 클라이언트(200)에서 서버(100)로부터 글로벌 모델을 수신받아 로컬 네트워크의 로컬 업데이트 결과를 서버(100)로 송출하는 로컬모델 업데이트단계(S200)로 이루어진다.
- [0188] 여기서, 서버(100)는 적어도 어느 하나 이상의 클라이언트(200)로 글로벌 모델을 송신하고 다수의 클라이언트(200)로부터 클라이언트(200) 마다의 로컬 업데이트 결과를 받아 평균을 취함으로써, 글로벌 모델을 업데이트할 수 있다.
- [0189] 여기서, 글로벌 모델은 글로벌파라미터를 포함한 글로벌 임베딩 네트워크 및 글로벌마진을 사용하며, 상세한 내용은 이하 도 4에서 설명한다.
- [0191] 도 4는 도 3의 로컬모델 업데이트단계(S200)를 상세히 나타낸 순서도이다.
- [0192] 도 4에서 볼 수 있는 바와 같이, 로컬모델 업데이트단계(S200)는 임베딩 네트워크(210)에서 글로벌 모델을 토대로 임베딩 네트워크를 학습하는 임베딩 네트워크 계산단계(S210), 다이내믹마진 계산부(220)에서 학습에 필요한 로컬마진을 계산하는 로컬마진 계산단계(S220), 손실함수 계산부(230)에서 로컬마진을 토대로 손실함수를 계산하는 손실함수 계산단계(S230), 및 네트워크 업데이트부(240)에서 임베딩 네트워크를 업데이트하는 네트워크 업데이트단계(S240)로 이루어진다.
- [0193] 로컬모델 업데이트단계(S200)에서 클라이언트(200)는 글로벌 모델의 수신 전에 사전 작업을 수행하는데, 우선 클라이언트(200) 내에 있는 로컬 데이터셋으로부터 에피소드(episode)를 구비한다. 여기서, 에피소드는 N개의 로컬 클래스(local class), 학습을 위해 로컬 클래스 당 K개 샘플(서포트샘플)로 구성되는 서포트셋(S), 및 시험을 위해 로컬 클래스 당 Q개 샘플(쿼리샘플)로 구성되는 쿼리셋(Q)로 이루어진다.
- [0194] 임베딩 네트워크 계산단계(S210)에서는 서포트샘플의 특징벡터 평균으로 정의되는 클래스 프로토타입(prototype)을 상기의 수학식 1로 계산한다. 또한, 쿼리샘플의 특징벡터와 클래스 프로토타입의 유클리디안(euclidian) 거리를 토대로 소프트맥스 손실(softmax loss)을 상기의 수학식 2로 계산한다.
- [0195] 한편, 로컬마진 계산단계(S220)에서는 에피소드 내 클래스 센트로이드(centroid) 간 거리 평균인 로컬 마진(local margin)을 상기의 수학식 4로 계산한다. 또한, 서버(100)에서 수신한 글로벌마진과 클라이언트(200)에서 산출한 로컬 마진 중 최대 마진을 상기의 수학식 4로 계산한다.
- [0196] 손실함수 계산단계(S230)에서 손실함수 계산부(230)는 에피소드 내 클래스 센트로이드와 유사한 샘플은 가깝게, 상이한 샘플은 멀게 배치하기 위해 클래스 센트로이드, 서포트샘플, 및 쿼리샘플을 토대로 트리플렛 손실(triplet loss)을 상기의 수학식 5로 계산한다.
- [0197] 네트워크 업데이트단계(S240)에서 네트워크 업데이트부(240)는 로컬 네트워크의 로컬파라미터의 업데이트를 상기의 수학식 6으로 계산한다. 이때, 로컬 업데이트 결과로서, 로컬파라미터와 로컬마진을 서버(100)로 송출함으로써, 서버(100)에서의 업데이트를 종료한다.
- [0198] 한편, 글로벌모델 업데이트단계(S100)에서 서버(100)는 클라이언트(200)로부터 수신한 로컬 업데이트 결과를 토대로 글로벌파라미터를 상기의 수학식 7로 업데이트한다.
- [0199] 또한, 클라이언트(200)로부터 수신한 로컬 업데이트 결과를 토대로 글로벌마진을 상기의 수학식 8로 업데이트한다.
- [0200] 이와 같은 본 발명에 의한 개인화된 연합 학습을 위한 메타 학습 방법은 다수의 클라이언트(200)를 통해 메타학

습을 수행함으로써, 추가적인 학습 없이 분류를 수행하며, 트리플렛 손실을 사용하여 클래스 간 거리를 최대한 멀리함으로써, 클래스 간 구분을 더욱 명확히 수행할 수 있다.

[0202] 이상과 같이 본 발명에 따른 개인화된 연합 학습을 위한 메타 학습 장치 및 방법은 메타 러닝(meta-learning)을 토대로 일반화가 잘되는 글로벌 임베더(embedder) 모델의 학습을 수행하는 장점이 있으며, 큰 폭의 표현학습(Large Margin Representation Learning)을 통해 임베더 성능을 향상할 수 있는 장점이 있다.

[0204] 본 발명의 기술 분야에서 통상의 지식을 가진 자는 여기에 개시된 실시예들과 관련하여 설명된 다양한 예시적인 논리 블록들, 모듈들, 프로세서들, 수단들, 회로들 및 알고리즘 단계들이 전자 하드웨어, (편의를 위해, 여기에서 소프트웨어로 지칭되는) 다양한 형태들의 프로그램 또는 설계 코드 또는 이들 모두의 결합에 의해 구현될 수 있다는 것을 이해할 것이다. 하드웨어 및 소프트웨어의 이러한 상호 호환성을 명확하게 설명하기 위해, 다양한 예시적인 컴포넌트들, 블록들, 모듈들, 회로들 및 단계들이 이들의 기능과 관련하여 위에서 일반적으로 설명되었다. 이러한 기능이 하드웨어 또는 소프트웨어로서 구현되는지 여부는 특정한 애플리케이션 및 전체 시스템에 대하여 부과되는 설계 제약들에 따라 좌우된다. 본 발명의 기술 분야에서 통상의 지식을 가진 자는 각각의 특정한 애플리케이션에 대하여 다양한 방식으로 설명된 기능을 구현할 수 있으나, 이러한 구현 결정들은 본 발명의 범위를 벗어나는 것으로 해석되어서는 안 될 것이다.


[0205] 여기서 제시된 다양한 실시예들은 방법, 장치, 또는 표준 프로그래밍 및/또는 엔지니어링 기술을 사용한 제조 물품(article)으로 구현될 수 있다. 용어 제조 물품은 임의의 컴퓨터-판독가능 저장장치로부터 액세스 가능한 컴퓨터 프로그램, 캐리어, 또는 매체(media)를 포함한다. 예를 들어, 컴퓨터-판독가능 저장매체는 자기 저장 장치(예를 들면, 하드 디스크, 플로피 디스크, 자기 스트림, 등), 광학 디스크(예를 들면, CD, DVD, 등), 스마트 카드, 및 플래쉬 메모리 장치(예를 들면, EEPROM, 카드, 스틱, 키 드라이브, 등)를 포함하지만, 이들로 제한되는 것은 아니다. 또한, 여기서 제시되는 다양한 저장 매체는 정보를 저장하기 위한 하나 이상의 장치 및/또는 다른 기계-판독가능한 매체를 포함한다.

[0206] 제시된 프로세스들에 있는 단계들의 특정한 순서 또는 계층 구조는 예시적인 접근들의 일례임을 이해하도록 한다. 설계 우선순위들에 기반하여, 본 발명의 범위 내에서 프로세스들에 있는 단계들의 특정한 순서 또는 계층 구조가 재배열될 수 있다는 것을 이해하도록 한다. 첨부된 방법 청구항들은 샘플 순서로 다양한 단계들의 엘리먼트들을 제공하지만 제시된 특정한 순서 또는 계층 구조에 한정되는 것을 의미하지는 않는다.


[0207] 제시된 실시예들에 대한 설명은 임의의 본 발명의 기술 분야에서 통상의 지식을 가진 자가 본 발명을 이용하거나 또는 실시할 수 있도록 제공된다. 이러한 실시예들에 대한 다양한 변형들은 본 발명의 기술 분야에서 통상의 지식을 가진 자에게 명백할 것이며, 여기에 정의된 일반적인 원리들은 본 발명의 범위를 벗어남이 없이 다른 실시예들에 적용될 수 있다. 그리하여, 본 발명은 여기에 제시된 실시예들로 한정되는 것이 아니라, 여기에 제시된 원리들 및 신규한 특징들과 일관되는 최광의의 범위에서 해석되어야 할 것이다.

도면


도면1



도면2



도면3



도면4

