(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0052295
(43) 공개일자 2024년04월23일

(51) 국제특허분류(Int. Cl.)
G06N 3/08 (2023.01) *G06V 10/764* (2022.01)
(52) CPC특허분류
G06N 3/08 (2023.01)
G06V 10/764 (2023.08)
(21) 출원번호 10-2022-0132146
(22) 출원일자 2022년10월14일
심사청구일자 2022년10월14일

(71) 출원인
인하대학교 산학협력단
인천광역시 미추홀구 인하로 100(용현동, 인하대학교)
(72) 발명자
최동완
인천광역시 미추홀구 용정공원로 33, 108동 1303호(용현동, 인천 SK Sky VIEW)
김성웅
서울특별시 강남구 삼성로 212, 22동 1209호(대치동, 은마아파트)
(74) 대리인
양성보

전체 청구항 수 : 총 8 항

(54) 발명의 명칭 **기존 데이터 없이 신규 데이터만 사용하여 균형잡힌 학습이 가능한 일반화된 퓨샷학습 기법**

(57) 요 약

기존 데이터 없이 신규 데이터만 사용하여 균형잡힌 학습이 가능한 일반화된 퓨샷학습 방법 및 시스템이 제시된다. 본 발명에서 제안하는 기존 데이터 없이 신규 데이터만 사용하여 균형잡힌 학습이 가능한 일반화된 퓨샷학습 방법은 사전학습부를 통해 학습 모델의 특징 추출기 및 분류기를 베이스 데이터로 학습하는 사전학습 단계 및 미세조정부를 통해 상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래스를 추론 가능한 합동 선형 분류기(joint linear classifier)를 학습하며, 0-평균(zero-mean)과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행하는 미세조정 단계를 포함한다.

대 표 도 - 도1

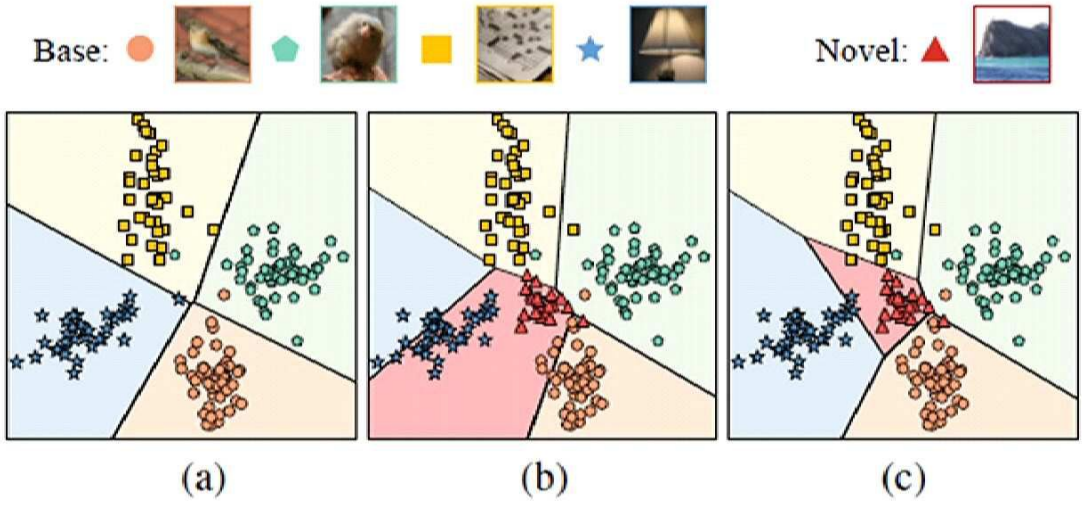

이 발명을 지원한 국가연구개발사업
과제고유번호 1711160586
과제번호 2022-0-00448-001
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 방송통신산업기술개발사업
연구과제명 [Ezbaro] 인간처럼 회상이 가능한 인공 신경망 지속학습 플랫폼 개발(1차년도)
기 여 율 50/100
과제수행기관명 인하대학교 산학협력단
연구기간 2022.04.01 ~ 2022.12.31
이 발명을 지원한 국가연구개발사업
과제고유번호 1711163299
과제번호 2021R1F1A1060160
부처명 과학기술정보통신부
과제관리(전문)기관명 한국연구재단
연구사업명 기본연구
연구과제명 [Ezbaro] 질의 가능한 인공지능: 상호작용형 XAI 서비스를 실현하기 위한 질의 기반 딥러닝 모델 해석 기술
기 여 율 30/100
과제수행기관명 인하대학교
연구기간 2022.03.01 ~ 2023.02.28
이 발명을 지원한 국가연구개발사업
과제고유번호 1711174118
과제번호 RS-2022-00155915
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 정보통신인재양성(교육운영수익)
연구과제명 [Ezbaro][정부+민간] 인공지능융합혁신인재양성(1차년도)
기 여 율 10/100
과제수행기관명 인하대학교 산학협력단
연구기간 2022.07.01 ~ 2022.12.31
이 발명을 지원한 국가연구개발사업
과제고유번호 1711152759
과제번호 2020-0-01389-003
부처명 과학기술정보통신부
과제관리(전문)기관명 정보통신기획평가원
연구사업명 인공지능융합연구센터지원사업(국고)
연구과제명 [Ezbaro][정부] 인공지능융합연구센터지원(3차년도)
기 여 율 10/100
과제수행기관명 인하대학교 산학협력단
연구기간 2022.01.01 ~ 2022.12.31

명 세 서

청구범위

청구항 1

사전학습부를 통해 학습 모델의 특징 추출기 및 분류기를 베이스 데이터로 학습하는 사전학습 단계; 및

미세조정부를 통해 상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래스를 추론 가능한 합동 선형 분류기(joint linear classifier)를 학습하며, 0-평균(zero-mean)과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행하는 미세조정 단계

를 포함하는 퓨샷학습 방법.

청구항 2

제1항에 있어서,

상기 미세조정부를 통해 상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래스를 추론 가능한 합동 선형 분류기를 학습하며, 0-평균과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행하는 미세조정 단계는,

노블 분류기의 가중치 평균을 0으로 유지하기 위해 학습 과정 중 정규화를 수행하는 단계;

미세조정을 완료한 후, 표준 편차(standard deviations)의 비율을 맞추기 위해 베이스 분류기의 가중치를 조정하는 단계; 및

클래스 별 학습 가능한 매개변수를 이용하여 노블 클래스의 결정 경계를 최적화하는 단계

를 포함하는 퓨샷학습 방법.

청구항 3

제1항에 있어서,

상기 미세조정부를 통해 상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래스를 추론 가능한 합동 선형 분류기를 학습하며, 0-평균과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행하는 미세조정 단계는,

상기 노블 클래스의 가중치의 평균과 분산을 제어하여 상기 노블 클래스의 학습 데이터에 대한 지식을 상기 베이스 클래스의 데이터 없이 사전 학습된 모델에 새롭게 통합하는

퓨샷학습 방법.

청구항 4

제1항에 있어서,

상기 미세조정을 완료한 후, 표준 편차의 비율을 맞추기 위해 베이스 분류기의 가중치를 조정하는 단계는,

상기 노블 분류기와 상기 베이스 분류기의 표준편차 비율을 상기 베이스 분류기에 곱해줌으로써, 베이스 분류기 가중치의 크기를 재조정하는

퓨샷학습 방법.

청구항 5

학습 모델의 특징 추출기 및 분류기를 베이스 데이터로 학습하는 사전학습부; 및

상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래스를 추론 가능한 합동 선형 분류기(joint linear classifier)를 학습하며, 0-평균(zero-mean)과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행하는 미세조정부

를 포함하는 퓨샷학습 시스템.

청구항 6

제5항에 있어서,

상기 미세조정부는,

노블 분류기 및 베이스 분류기를 포함하는 합동 선형 분류기를 포함하고,

노블 분류기의 가중치 평균을 0으로 유지하기 위해 학습 과정 중 정규화를 수행하고,

미세조정을 완료한 후, 표준 편차(standard deviations)의 비율을 맞추기 위해 베이스 분류기의 가중치를 조정하며,

클래스 별 학습 가능한 매개변수를 이용하여 노블 클래스의 결정 경계를 최적화하는

퓨샷학습 시스템.

청구항 7

제5항에 있어서,

상기 미세조정부는,

상기 노블 클래스의 가중치의 평균과 분산을 제어하여 상기 노블 클래스의 학습 데이터에 대한 지식을 상기 베이스 클래스의 데이터 없이 사전 학습된 모델에 새롭게 통합하는

퓨샷학습 시스템.

청구항 8

제5항에 있어서,

상기 미세조정부는,

상기 노블 분류기와 상기 베이스 분류기의 표준편차 비율을 상기 베이스 분류기에 곱해줌으로써, 베이스 분류기 가중치의 크기를 재조정하는

퓨샷학습 시스템.

발명의 설명

기 술 분 야

[0001] 본 발명은 기존 데이터 없이 신규 데이터만 사용하여 균형잡힌 학습이 가능한 일반화된 퓨샷학습 방법 및 시스템에 관한 것이다.

배 경 기 술

[0002] 퓨샷 학습은 활발히 연구가 이루어지고 있는 분야 중 하나이다. 퓨샷 학습은 기존의 많은 데이터로 학습한 지식을 활용해 소량의 데이터를 가진 노블 클래스에 빠르게 적응 가능한 학습을 목표로 한다. 최근 퓨샷 학습은 크게 메타학습(meta learning)과 전이학습(transfer learning)으로 나뉜다. 메타학습은 베이스 데이터를 N개의 클래스와 K개의 이미지를 가지는 테스크로 쪼개는 에피소드 방식을 사용한다. 전이학습은 복잡한 방식이 필요한 메타학습과 달리, 단순히 베이스 데이터로 학습한 특징 추출기(feature extractor)를 재사용한다. 전이학습 방법은 분류기(classifier)를 새로운 클래스의 데이터로 미세조정(fine-tuning)하는 것만으로도, 좋은 성능을 달성하였다. 전이 학습이 퓨샷 학습에서 효과적인 방법으로 사용되는 것과 달리, 일반화된 퓨샷 학습에선 추가적인 학습 방식 없이는 충분한 성능을 달성하지 못한다.

[0003] 일반화된 퓨샷 학습은 노블 클래스에 빠르게 적응할 뿐만 아니라, 베이스 클래스의 지식을 잊지 않는 것을 목표로 한다. 일반화된 퓨샷 학습의 주요 접근 방식은 베이스 데이터로 사전 학습된 모델을 변경하지 않고, 일부 아키텍처를 추가해 학습한다. 추가 아키텍처는 노블 분류기의 파라미터를 사전 생성하거나 사전 훈련된 모델의 출력 값을 적절히 변경해, 베이스 클래스와 노블 클래스 사이의 균형잡힌 추론을 가능하게 해준다.

[0004] 종래기술에서는 추가 아키텍처와 더불어 의미론적 정보를 더해 노블 클래스와 베이스 클래스의 관계를

학습한다. 또 다른 접근 방식은 균형잡힌 미세 조정으로, 추가 아키텍처를 사용하지 않고 노블 클래스와 베이스 클래스로 구성된 균형잡힌 데이터셋을 사용해 사전 학습된 모델을 미세조정한다. 균형잡힌 미세조정에서 추가적인 성능 향상을 위해, 또 다른 종래기술은 노블 데이터의 평균 특징 벡터를 노블 분류기의 가중치로 초기화하는 가중치 각인(weight imprinting)을 사용한다. 또 다른 종래기술은 단계마다 데이터의 구성을 다르게 하는 세 가지 단계 프레임워크(three step framework)를 도입한다. 또 다른 종래기술은 베이스 데이터를 기반으로 인공적인 노블 데이터를 만드는 환각(hallucination)방법을 통해, 더 나은 균형잡힌 데이터셋을 만든다.

선행기술문헌

특허문헌

[0005] (특허문헌 0001) [1] Fei-Fei, L.; Fergus, R.; and Perona, P. 2006. One-Shot Learning of Object Categories. IEEE Trans. Pattern Anal. Mach. Intell., 28(4): 594-611.

(특허문헌 0002) [2] Finn, C.; Abbeel, P.; and Levine, S. 2017. Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks. In Precup, D.; and Teh, Y. W., eds., Proceedings of the 34th International Conference on Machine Learning, ICML 2017, volume 70 of Proceedings of Machine Learning Research, 1126-1135.

(특허문헌 0003) [3] Chen, W.; Liu, Y.; Kira, Z.; Wang, Y. F.; and Huang, J. 2019. A Closer Look at Few-shot Classification. In 7th Interna- tional Conference on Learning Representations, ICLR 2019.

(특허문헌 0004) [4] Gidaris, S.; and Komodakis, N. 2018. Dynamic Few-Shot Vi- sual Learning Without Forgetting. In 2018 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2018, 4367-4375.

(특허문헌 0005) [5] Yoon, S. W.; Kim, D.; Seo, J.; and Moon, J. 2020. XtarNet: Learning to Extract Task-Adaptive Representation for Incremental Few-Shot Learning. In Proceedings of the 37th International Conference on Machine Learning, ICML 2020, 13-18 July 2020, Virtual Event, volume 119 of Proceedings of Machine Learning Research, 10852-10860.

(특허문헌 0006) [6] Shi, X.; Salewski, L.; Schiegg, M.; and Welling, M. 2020. Relational Generalized Few-Shot Learning. In 31st British Machine Vision Conference 2020, BMVC 2020.

(특허문헌 0007) [7] Qi, H.; Brown, M.; and Lowe, D. G. 2018. Low-Shot Learning With Imprinted Weights. In 2018 IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2018, 5822- 5830.

(특허문헌 0008) [8] Kukleva, A.; Kuehne, H.; and Schiele, B. 2021. Generalized and Incremental Few-Shot Learning by Explicit Learning and Calibration without Forgetting. In 2021 IEEE/CVF International Conference on Computer Vision, ICCV 2021, 9000-9009.

(특허문헌 0009) [9] Hariharan, B.; and Girshick, R. B. 2017. Low-Shot Visual Recognition by Shrinking and Hallucinating Features. In IEEE International Conference on Computer Vision, ICCV 2017, 3037-3046.

발명의 내용

해결하려는 과제

[0006] 본 발명이 이루고자 하는 기술적 과제는 노블 클래스의 소량의 데이터에 대한 지식을 베이스 클래스의 데이터 없이 사전 학습된 모델에 새롭게 통합하는 방법 및 시스템을 제공하는데 있다. 제안하는 퓨샷학습 기법을 통해 프라이버시나 윤리적 문제로 인해 베이스 데이터 사용이 제약되는 상황에도 사용 가능하도록 하고, 노블 클래스의 가중치 분포의 평균과 분산을 제어하여 노블 클래스와 베이스 클래스 모두에서의 성능 개선을 제공하고자 한다.

과제의 해결 수단

[0007] 일 측면에 있어서, 본 발명에서 제안하는 기존 데이터 없이 신규 데이터만 사용하여 균형잡힌 학습이 가능한 일반화된 퓨샷학습 방법은 사전학습부를 통해 학습 모델의 특징 추출기 및 분류기를 베이스 데이터로 학습하는 사

전학습 단계 및 미세조정부를 통해 상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래스를 추론 가능한 합동 선형 분류기(joint linear classifier)를 학습하며, 0-평균(zero-mean)과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행하는 미세조정 단계를 포함한다.

[0008] 상기 미세조정부를 통해 상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래스를 추론 가능한 합동 선형 분류기를 학습하며, 0-평균과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행하는 미세조정 단계는 노블 분류기의 가중치 평균을 0으로 유지하기 위해 학습 과정 중 정규화를 수행하는 단계, 미세조정을 완료한 후, 표준 편차(standard deviations)의 비율을 맞추기 위해 베이스 분류기의 가중치를 조정하는 단계 및 클래스 별 학습 가능한 매개변수를 이용하여 노블 클래스의 결정 경계를 최적화하는 단계를 포함한다.

[0009] 상기 미세조정부를 통해 상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래스를 추론 가능한 합동 선형 분류기를 학습하며, 0-평균과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행하는 미세조정 단계는 상기 노블 클래스의 가중치의 평균과 분산을 제어하여 상기 노블 클래스의 학습 데이터에 대한 지식을 상기 베이스 클래스의 데이터 없이 사전 학습된 모델에 새롭게 통합한다.

[0010] 상기 미세조정을 완료한 후, 표준 편차의 비율을 맞추기 위해 베이스 분류기의 가중치를 조정하는 단계는 상기 노블 분류기와 상기 베이스 분류기의 표준편차 비율을 상기 베이스 분류기에 곱해줌으로써, 베이스 분류기 가중치의 크기를 재조정한다.

[0011] 또 다른 일 측면에 있어서, 본 발명에서 제안하는 기존 데이터 없이 신규 데이터만 사용하여 균형잡힌 학습이 가능한 일반화된 퓨샷학습 시스템은 학습 모델의 특징 추출기 및 분류기를 베이스 데이터로 학습하는 사전학습부 및 상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래스를 추론 가능한 합동 선형 분류기(joint linear classifier)를 학습하며, 0-평균(zero-mean)과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행하는 미세조정부를 포함한다.

발명의 효과

[0012] 본 발명의 실시예들에 따르면 노블 클래스의 소량의 데이터에 대한 지식을 베이스 클래스의 데이터 없이 사전 학습된 모델에 새롭게 통합할 수 있다. 또한, 제안하는 퓨샷학습 기법을 통해 프라이버시나 윤리적 문제로 인해 베이스 데이터 사용이 제약되는 상황에도 사용 가능하고, 노블 클래스의 가중치 분포의 평균과 분산을 제어하여 노블 클래스와 베이스 클래스 모두에서의 성능을 개선할 수 있다.

도면의 간단한 설명

[0013] 도 1은 본 발명의 일 실시예에 따른 퓨샷학습 기법을 설명하기 위한 개략도이다.

도 2는 본 발명의 일 실시예에 따른 일반화된 퓨샷학습 방법을 설명하기 위한 흐름도이다.

도 3은 본 발명의 일 실시예에 따른 일반화된 퓨샷학습 시스템의 구성을 나타내는 도면이다.

도 4는 본 발명의 일 실시예에 따른 혼동 행렬을 종래기술과 비교하기 위한 도면이다.

도 5는 본 발명의 일 실시예에 따른 베이스 클래스와 노블 클래스의 가중치 분포를 나타내는 도면이다.

발명을 실시하기 위한 구체적인 내용

[0014] 본 발명은 노블 클래스의 소량의 데이터에 대한 지식을 베이스 클래스의 데이터 없이 사전 학습된 모델에 새롭게 통합하는 방법을 제안한다. 베이스 데이터를 필요로 하는 기존의 일반화된 퓨샷 학습(generalized few-shot learning)과 달리, 본 발명에서 제안한 방법은 프라이버시나 윤리적 문제로 인해 베이스 데이터 사용이 제약되는 상황에도 사용 가능하다.

[0015] 본 발명은 노블 클래스의 가중치 분포의 평균과 분산이 베이스 클래스 가중치 분포의 평균과 분산과 비교하여 제대로 설정되지 않았다는 사실을 발견한다. 아울러 기존 방법은 가중치 놈(norm)의 균형을 맞추려고 시도하지만, 이는 분산에만 도움이 되고 평균의 중요성을 무시하여 제한된 성능으로 이어진다. 이러한 한계를 극복하기 위해 본 발명에서는 노블 클래스의 가중치 분포의 평균과 분산을 제어하여 노블 클래스와 베이스 클래스 모두에서 좋은 성능을 달성한다. 또한, 베이스 데이터를 전혀 사용하지 않는 본 발명에서 제안한 방법이 베이스 데이터를 최대한 활용하는 이전 방법보다 우수한 성능을 보임을 확인하였다. 본 발명에서 제안한 정규화(normalization) 방법을 통해, 전이학습이 베이스 데이터를 사용하지 않고도 일반화된 퓨샷 학습에서 효과적임

을 확인하였다. 이하, 본 발명의 실시 예를 첨부된 도면을 참조하여 상세하게 설명한다.

[0017] 본 발명의 일 실시예에 따른 용어 모델(model)은 심층신경망(deep neural network)을 의미한다.

[0018] 본 발명의 일 실시예에 따른 용어 베이스 클래스(base classes)는 모델이 기존에 학습한 클래스를 의미하고, 모델이 학습하기에 충분한 학습 데이터를 가지고 있다.

[0019] 본 발명의 일 실시예에 따른 용어 베이스 데이터(base data)는 베이스 클래스의 데이터를 의미한다.

[0020] 본 발명의 일 실시예에 따른 용어 노블 클래스(novel classes)는 모델이 기존에 보지 못한 새로운 클래스를 의미하고, 학습 데이터로 소량의 데이터만을 가지고 있으며, 베이스 클래스에 비해 클래스의 수가 적다.

[0021] 본 발명의 일 실시예에 따른 용어 노블 데이터는 노블 클래스의 데이터를 의미한다.

[0022] 본 발명의 일 실시예에 따른 용어 분류기(classifier)는 데이터가 어떤 클래스에 속하는지 결정하는 선형 모델을 의미하고, 분류기의 가중치와 특징벡터(feature vectors)와의 선형결합(linear combination)에 기반해 결정한다.

[0023] 본 발명의 일 실시예에 따른 용어 베이스 분류기(base classifier)는 베이스 클래스의 분류기를 의미한다.

[0024] 본 발명의 일 실시예에 따른 용어 노블 분류기(novel classifier)는 노블 클래스의 분류기를 의미한다.

[0025] 본 발명의 일 실시예에 따른 용어 특징 추출기(feature extractor)는 합성곱 신경망(convolutional neural network)으로 이루어져 있으며, 고차원 데이터를 저차원으로 임베딩(embedding)하는 모델을 의미한다.

[0026] 본 발명의 일 실시예에 따른 용어 퓨샷 학습(few-shot learning)는 모델이 새로운 클래스를 적은 수의 데이터만으로 학습해 추론하는 것을 목표로 하고, 일반적으로 10개 이하의 데이터를 사용한다.

[0027] 본 발명의 일 실시예에 따른 용어 일반화된 퓨샷 학습(generalized few-shot learning)은 모델이 적은 수의 데이터를 가진 새로운 클래스를 학습할 뿐만 아니라, 기존에 많은 양의 데이터로 학습한 클래스 또한 같이 추론하는 것을 목표로 한다.

[0029] 도 1은 본 발명의 일 실시예에 따른 퓨샷학습 기법을 설명하기 위한 개략도이다.

[0030] 종래기술에서의 일반화된 퓨샷 학습은 추가 아키텍처를 학습하거나 균형잡힌 미세조정을 수행하는 등, 기존 지식을 보존하는 과정에서 베이스 데이터를 항상 필요로 한다. 본 발명은 새로운 가중치 정규화를 이용하여 베이스 데이터 없이 일반화된 퓨샷 학습을 하고자 한다. 베이스 데이터 없이 사전 학습된 모델(도 1(a))을 미세조정하면, 모델의 특징 추출기(feature extractor)를 동결(freeze)하더라도 모델이 노블 클래스에 강하게 편향(bias)된다. 도 1(b)와 같이, 노블 클래스의 결정 경계(decision boundary)가 불필요하게 크게 형성되어, 베이스 데이터가 노블 클래스로 잘못 분류될 수 있다. 종래기술에서의 분류기의 가중치를 정규화하는 균형잡힌 결정 경계를 형성하기 위해, 기본적인 가중치 정규화인 코사인 분류기(cosine classifier)를 사용한다. 하지만, 이러한 정규화는 베이스 데이터 없이 사용할 경우, 베이스 클래스에 대한 추론 성능이 오히려 크게 하락한다.

[0031] 본 발명에서는 결정 경계를 형성하는 분류기의 가중치 분포를 분석한 결과, 평균과 분산 측면에서의 두 가지 문제를 해결하고자 한다. 하나는 노블 클래스와 베이스 클래스의 가중치 분포의 분산이 불균형한 문제이다. 기존의 가중치 정규화 방법은 가중치 분포의 분산만을 고려하는 것을 확인한다. 다른 하나는 노블 클래스의 평균이 베이스 클래스 보다 양(positive)의 방향으로 이동되는 문제이다. 이러한 평균 이동 현상(mean shifting phenomenon)이 편향된 모델의 주요한 원인임을 확인하고 이를 해결하기 위해, 본 발명에서는 균형잡힌 분산과 0-평균(zero-mean)이 되는 가중치 정규화 방법을 제안한다. 제안된 방법을 기반으로 베이스 데이터 없이 도 1(c)와 같은 결정 경계를 형성할 수 있고, 이를 통해 노블 클래스와 베이스 클래스의 균형잡힌 성능을 달성하고자 한다.

[0033] 도 2는 본 발명의 일 실시예에 따른 일반화된 퓨샷학습 방법을 설명하기 위한 흐름도이다.

[0034] 제안하는 일반화된 퓨샷학습 방법은 사전학습부를 통해 학습 모델의 특징 추출기 및 분류기를 베이스 데이터로 학습하는 사전학습 단계(210) 및 미세조정부를 통해 상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래

스를 추론 가능한 합동 선형 분류기(joint linear classifier)를 학습하며, 0-평균(zero-mean)과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행하는 미세조정 단계(220)를 포함한다.

[0035] 단계(210)에서, 사전학습부를 통해 학습 모델의 특징 추출기 및 분류기를 베이스 데이터로 학습하는 사전학습을 수행한다.

[0036] 단계(220)에서, 미세조정부를 통해 상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래스를 추론 가능한 합동 선형 분류기를 학습하며, 0-평균과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행하는 미세조정을 수행한다. 미세조정 단계에서 학습 데이터는 베이스 데이터 없이 소량의 노블 데이터만을 사용한다. 본 발명에서 제안한 가중치 정규화 방법은 미세조정 단계에 적용한다.

[0037] 미세조정 단계에서는 상기 노블 클래스의 가중치의 평균과 분산을 제어하여 상기 노블 클래스의 학습 데이터에 대한 지식을 상기 베이스 클래스의 데이터 없이 사전 학습된 모델에 새롭게 통합할 수 있다.

[0038] 미세조정 단계에서 먼저, 온라인 평균 중심화(Online mean centering)를 수행한다.

[0039] 노블 분류기 가중치 평균을 0으로 유지하기 위해 학습 과정 중에 다음과 같은 식의 정규화를 적용한다.

[0040] $$\hat{\theta}_{novel} = \theta_{novel} - \mu_{novel}$$

[0041] 여기서, θ_{novel}은 노블 분류기이고, μ_{novel}은 노블 분류기의 클래스 별 가중치의 평균 벡터다. 합동 분류기를 미세조정할 때, 온라인 평균 중심화는 노블 분류기에만 적용한다. 이는 노블 분류기의 양의 가중치를 직접적으로 줄이고, 노블 클래스의 특징을 학습하는 동안 0-평균을 유지하게 만들어준다. 미세 조정 중에 가중치의 분산에 어떠한 제약도 주지 않는 것으로, 각 분류기가 필요한 특징을 가능한 많이 학습할 수 있도록 한다.

[0042] 다음으로, 오프라인 분산 균형화(Offline variance balancing)를 수행한다.

[0043] 미세조정을 완료한 후, 표준 편차(standard deviations)의 비율을 맞추기 위해 베이스 분류기의 가중치를 다음과 같은 식으로 조정한다.

[0044] $$\hat{\theta}_{base} = \frac{\bar{\sigma}_{novel}}{\sigma_{base}} \cdot \theta_{base}$$

[0045] 여기서, $\bar{\sigma}_{novel}$은 모든 노블 분류기의 클래스 별 표준 편차의 평균이다. 본 발명은 노블 분류기와 베이스 분류기의 표준편차 비율을 베이스 분류기에 곱해줌으로써, 베이스 분류기 가중치의 크기를 재조정(re-scale)한다. 이를 통해, 베이스 분류기의 가중치의 분산은 노블과 비슷해진다.

[0046] 마지막으로, 사후 선형 최적화(Post linear optimization)를 수행한다.

[0047] 이때, 클래스 별 학습 가능한 매개변수를 이용하여 노블 클래스의 결정 경계를 최적화한다.

[0048] 본 발명은 노블 클래스의 결정 경계를 더욱 최적화하기 위해, 클래스 $i \in C_{base} \cup C_{novel}$에 대한 클래스 별 학습가능한 매개변수인 γ_i와 β_i를 도입한다. $\theta = \{\theta_{baes}, \theta_{novel}\}$를 동결하고, γ_i와 β_i를 노블 데이터로 학습한다. 추론 시에는 $\gamma \cdot \theta^{\top} f_{\phi}(x) + \beta$를 적용한다. 이러한 추가적인 매개변수를 통해, 본 발명은 특히 원샷학습과 같은 극단적인 경우에 노블 클래스의 성능을 크게 향상시킬 수 있다.

[0050] 도 3은 본 발명의 일 실시예에 따른 일반화된 퓨샷학습 시스템의 구성을 나타내는 도면이다.

[0051] 본 실시예에 따른 일반화된 퓨샷학습 시스템(300)은 프로세서(310), 버스(320), 네트워크 인터페이스(330), 메모리(340) 및 데이터베이스(350)를 포함할 수 있다. 메모리(340)는 운영체제(341) 및 일반화된 퓨샷학습 루틴(342)을 포함할 수 있다. 프로세서(310)는 사전 학습부(311) 및 미세 조정부(312)를 포함할 수 있다. 다른 실시예들에서 일반화된 퓨샷학습 시스템(300)은 도 3의 구성요소들보다 더 많은 구성요소들을 포함할 수도 있다. 그러나, 대부분의 종래기술적 구성요소들을 명확하게 도시할 필요성은 없다. 예를 들어, 일반화된 퓨샷학습 시스템(300)은 디스플레이나 트랜시버(transceiver)와 같은 다른 구성요소들을 포함할 수도 있다.

[0052] 메모리(340)는 컴퓨터에서 판독 가능한 기록 매체로서, RAM(random access memory), ROM(read only memory) 및 디스크 드라이브와 같은 비소멸성 대용량 기록장치(permanent mass storage device)를 포함할 수 있다. 또한, 메모리(340)에는 운영체제(341)와 일반화된 퓨샷학습 루틴(342)을 위한 프로그램 코드가 저장될 수 있다. 이러한 소프트웨어 구성요소들은 드라이브 메커니즘(drive mechanism, 미도시)을 이용하여 메모리(340)와는 별도의 컴퓨터에서 판독 가능한 기록 매체로부터 로딩될 수 있다. 이러한 별도의 컴퓨터에서 판독 가능한 기록 매체는 플로피 드라이브, 디스크, 테이프, DVD/CD-ROM 드라이브, 메모리 카드 등의 컴퓨터에서 판독 가능한 기록 매체(미도시)를 포함할 수 있다. 다른 실시예에서 소프트웨어 구성요소들은 컴퓨터에서 판독 가능한 기록 매체가 아닌 네트워크 인터페이스(330)를 통해 메모리(340)에 로딩될 수도 있다.

[0053] 버스(320)는 일반화된 퓨샷학습 시스템(300)의 구성요소들간의 통신 및 데이터 전송을 가능하게 할 수 있다. 버스(320)는 고속 시리얼 버스(high-speed serial bus), 병렬 버스(parallel bus), SAN(Storage Area Network) 및/또는 다른 적절한 통신 기술을 이용하여 구성될 수 있다.

[0054] 네트워크 인터페이스(330)는 일반화된 퓨샷학습 시스템(300)을 컴퓨터 네트워크에 연결하기 위한 컴퓨터 하드웨어 구성요소일 수 있다. 네트워크 인터페이스(330)는 일반화된 퓨샷학습 시스템(300)을 무선 또는 유선 커넥션을 통해 컴퓨터 네트워크에 연결시킬 수 있다.

[0055] 데이터베이스(350)는 일반화된 퓨샷학습을 위해 필요한 모든 정보를 저장 및 유지하는 역할을 할 수 있다. 도 3에서는 일반화된 퓨샷학습 시스템(300)의 내부에 데이터베이스(350)를 구축하여 포함하는 것으로 도시하고 있으나, 이에 한정되는 것은 아니며 시스템 구현 방식이나 환경 등에 따라 생략될 수 있고 혹은 전체 또는 일부의 데이터베이스가 별개의 다른 시스템 상에 구축된 외부 데이터베이스로서 존재하는 것 또한 가능하다.

[0056] 프로세서(310)는 기본적인 산술, 로직 및 일반화된 퓨샷학습 시스템(300)의 입출력 연산을 수행함으로써, 컴퓨터 프로그램의 명령을 처리하도록 구성될 수 있다. 명령은 메모리(340) 또는 네트워크 인터페이스(330)에 의해, 그리고 버스(320)를 통해 프로세서(310)로 제공될 수 있다. 프로세서(310)는 사전 학습부(311) 및 미세 조정부(312)를 위한 프로그램 코드를 실행하도록 구성될 수 있다. 이러한 프로그램 코드는 메모리(340)와 같은 기록 장치에 저장될 수 있다.

[0057] 사전 학습부(311) 및 미세 조정부(312)는 도 1의 단계들(110~120)을 수행하기 위해 구성될 수 있다.

[0058] 일반화된 퓨샷학습 시스템(300)은 사전 학습부(311) 및 미세 조정부(312)를 포함할 수 있다.

[0059] 사전 학습부(311)는 학습 모델의 특징 추출기 및 분류기를 베이스 데이터로 학습한다.

[0060] 미세 조정부(312)는 상기 특징 추출기를 동결하고, 베이스 클래스와 노블 클래스를 추론 가능한 합동 선형 분류기(joint linear classifier)를 학습하며, 0-평균(zero-mean)과 균형잡힌 분산을 달성하기 위해 가중치 정규화를 수행한다.

[0061] 미세 조정부(312)는 노블 분류기 및 베이스 분류기를 포함하는 합동 선형 분류기를 포함하고, 먼저 노블 분류기의 가중치 평균을 0으로 유지하기 위해 학습 과정 중 정규화를 수행한다. 미세조정을 완료한 후, 표준 편차(standard deviations)의 비율을 맞추기 위해 베이스 분류기의 가중치를 조정한다. 마지막으로, 클래스 별 학습 가능한 매개변수를 이용하여 노블 클래스의 결정 경계를 최적화한다.

[0063] 표 1 내지 표 3은 종래기술의 일반화된 퓨샷 학습 방법과 본 발명에서 제안한 가중치 정규화를 통한 베이스 데이터 없이 일반화된 퓨샷 학습 방법에 대한 총 6개의 데이터셋에 대한 결과이다. 실험에 대한 성능은 노블 데이터의 수(shot)에 따른 노블 클래스, 베이스 클래스, 전체 클래스의 평균 정확도의 결과이다. 실험 결과에 따르면, 제안된 방법이 베이스 데이터를 사용하는 다른 비교 실험군보다 다양한 데이터와 모델에서 평균적으로 높은 성능을 보임을 확인할 수 있다.

[0064] <표 1>

Methods/ Shots	1-shot			5-shot			10-shot		
	Novel	Base	All	Novel	Base	All	Novel	Base	All
GcGPN (Shi et al. 2020)	39.86	54.65	47.25	56.32	59.30	57.81	-	-	-
IW (Qi, Brown, and Lowe 2018)	41.32	58.04	49.68	59.27	58.68	58.98	45.85	72.53	59.19 ± 0.19
DFSL (Gidaris and Komodakis 2018)	31.25	17.72	39.49	46.96	58.92	52.94	66.04	69.87	67.95 ± 0.17
AAN (Ren et al. 2019)	45.61	63.92	54.76	60.82	64.14	62.48	66.33	62.49	64.41 ± 0.16
LCwoF (Kukleva, Kuehne, and Schiele 2021)	53.78	62.89	57.84	68.58	64.53	66.55	76.71 ± 0.58	62.86 ± 0.07	69.78 ± 0.28
XtarNet (Yoon et al. 2020)	47.04 ± 0.29	64.17 ± 0.22	55.61 ± 0.17	62.46 ± 0.25	**70.57 ± 0.20**	66.52 ± 0.16	70.46 ± 0.23	**70.88 ± 0.21**	70.67 ± 0.15
MVCN (ours)	**51.72 ± 0.64**	**65.81 ± 0.08**	**58.77 ± 0.35**	**75.20 ± 0.46**	67.62 ± 0.09	**71.22 ± 0.26**	**78.7 ± 0.51**	68.06 ± 0.09	**73.38 ± 0.25**

[0065]

[0066] <표 2>

Methods/ Shots	1-shot			5-shot			10-shot		
	Novel	Base	All	Novel	Base	All	Novel	Base	All
IW (Qi, Brown, and Lowe 2018)	44.95	62.53	53.74	71.85	56.11	63.98	74.01	61.67	65.50 ± 0.16
DFSL (Gidaris and Komodakis 2018)	47.32	36.10	41.71	67.94	39.08	53.51	73.97	56.94	65.46 ± 0.17
AAN (Ren et al. 2019)	54.39	55.85	55.12	57.76	64.13	60.95	70.88	57.49	64.18 ± 0.17
LCwoF (Kukleva, Kuehne, and Schiele 2021)	57.13	60.39	58.76	69.05	63.44	66.25	79.20 ± 0.72	61.76 ± 0.10	70.57 ± 0.41
XtarNet (Yoon et al. 2020)	58.90 ± 0.29	**64.02 ± 0.22**	61.46 ± 0.18	74.49 ± 0.24	63.13 ± 0.21	68.81 ± 0.16	78.36 ± 0.23	63.08 ± 0.22	70.72 ± 0.16
MVCN (ours)	**62.11 ± 0.70**	61.23 ± 0.22	**61.67 ± 0.31**	**79.59 ± 0.55**	**66.3 ± 0.20**	**72.34 ± 0.28**	**83.06 ± 0.56**	**67.46 ± 0.16**	**75.26 ± 0.27**

[0067]

[0068] <표 3>

Datasets	CUB				AWA1				AWA2			
Methods/ Shots	1-shot	2-shot	5-shot	10-shot	1-shot	2-shot	5-shot	10-shot	1-shot	2-shot	5-shot	10-shot
ReViSE (Tsai, Huang, and Salakhutdinov 2017)	36.3	41.1	44.6	50.9	56.1	60.3	64.1	67.8	-	-	-	-
CA-VAE (Schönfeld et al. 2019)	50.6	54.4	59.6	62.2	64.0	71.3	76.6	79.0	41.8	52.7	66.5	76.7
DA-VAE (Schönfeld et al. 2019)	49.2	54.6	58.8	60.8	68.0	73.0	75.6	76.8	68.6	77.1	81.8	81.3
CADA-VAE (Schönfeld et al. 2019)	55.2	59.2	63.0	64.9	69.6	73.7	78.1	80.2	73.6	78.9	81.9	85.0
DRAGON (Samuel, Atzmon, and Chechik 2021)	55.3	59.2	63.5	**67.8**	67.1	69.1	76.7	81.9	-	-	-	-
MVCN (ours)	**57.3**	**61.6**	**65.4**	**67.8**	**69.9**	**76.4**	**81.2**	**82.2**	**77.1**	**83.5**	**87.4**	**87.7**

[0069]

[0071] 도 4는 본 발명의 일 실시예에 따른 혼동 행렬을 종래기술과 비교하기 위한 도면이다.

[0072] 도 4는 본 발명에서 제안된 방법을 적용한 결과(도 4(b))와 적용하지 않은 결과(도 4(a))에 대한 혼동 행렬(confusion matrix)을 나타낸다. 도 4와 같이, 정규화 기법을 적용하지 않은 선형 분류기가 베이스 데이터를 노블 클래스로 잘못 분류하는 경향이 있지만, 정규화를 적용한 경우는 그렇지 않는 것을 확인할 수 있다. 이러한 결과는 기존 미세조정된 분류기에서 노블 클래스의 결정 경계가 불필요하게 커진다는 것을 알려준다. 하지만, 본 발명에서 제안된 방법을 적용한 분류기는 노블 클래스와 베이스 클래스에 대해 혼동하지 않는 것을 확인할 수 있다.

[0074] 도 5는 본 발명의 일 실시예에 따른 베이스 클래스와 노블 클래스의 가중치 분포를 나타내는 도면이다.

[0075] 도 5는 본 발명에서 제안된 방법을 적용한 경우(도 5(b))와 적용하지 않은 경우(도 5(a))의 베이스 클래스와 노블 클래스의 가중치 분포를 보여준다. 본 발명에서 제안된 방법이 기존 분류기보다 62배 작은 μ_{novel}을 가지는 것을 통해, 평균 이동 현상을 해결하고 베이스 클래스와 노블 클래스 간의 균형 잡힌 평균을 갖는 것을 확인할 수 있다. 또한, 도 5는 정규화 후에 $\bar{\sigma}_{base}$와 $\bar{\sigma}_{novel}$가 거의 동일해지는 것을 확인할 수 있고, 이는 노블이나 베이스 클래스에 대한 편향(bias)이 없음을 의미한다.

[0077] 이상에서 설명된 장치는 하드웨어 구성요소, 소프트웨어 구성요소, 및/또는 하드웨어 구성요소 및 소프트웨어 구성요소의 조합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치 및 구성요소는, 예를 들어, 프로세서, 콘트롤러, ALU(arithmetic logic unit), 디지털 신호 프로세서(digital signal processor), 마이크로컴퓨터, FPGA(field programmable gate array), PLU(programmable logic unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 하나 이상의 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(OS) 및 상기 운영 체제 상에서 수행되는 하나 이상의 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로

설명된 경우도 있지만, 해당 기술분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(processing element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 콘트롤러를 포함할 수 있다. 또한, 병렬 프로세서(parallel processor)와 같은, 다른 처리 구성(processing configuration)도 가능하다.

[0078] 소프트웨어는 컴퓨터 프로그램(computer program), 코드(code), 명령(instruction), 또는 이들 중 하나 이상의 조합을 포함할 수 있으며, 원하는 대로 동작하도록 처리 장치를 구성하거나 독립적으로 또는 결합적으로(collectively) 처리 장치를 명령할 수 있다. 소프트웨어 및/또는 데이터는, 처리 장치에 의하여 해석되거나 처리 장치에 명령 또는 데이터를 제공하기 위하여, 어떤 유형의 기계, 구성요소(component), 물리적 장치, 가상 장치(virtual equipment), 컴퓨터 저장 매체 또는 장치에 구체화(embody)될 수 있다. 소프트웨어는 네트워크로 연결된 컴퓨터 시스템 상에 분산되어서, 분산된 방법으로 저장되거나 실행될 수도 있다. 소프트웨어 및 데이터는 하나 이상의 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.

[0079] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.

[0080] 이상과 같이 실시예들이 비록 한정된 실시예와 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가진 자라면 상기의 기재로부터 다양한 수정 및 변형이 가능하다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다.

[0081] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.

도면

도면1

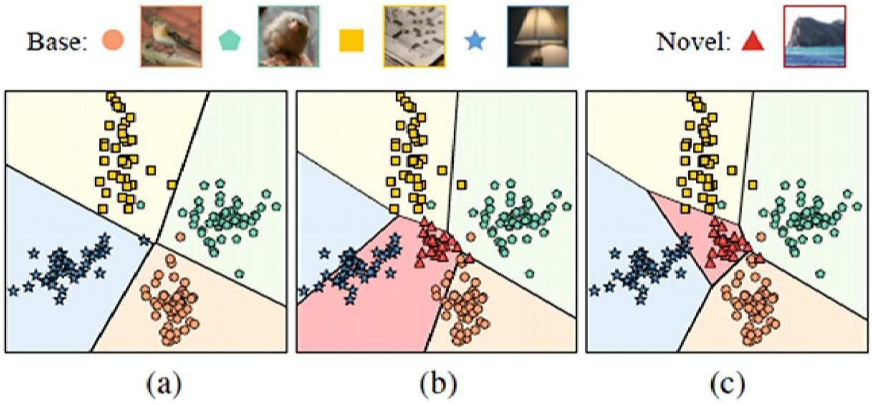

도면2

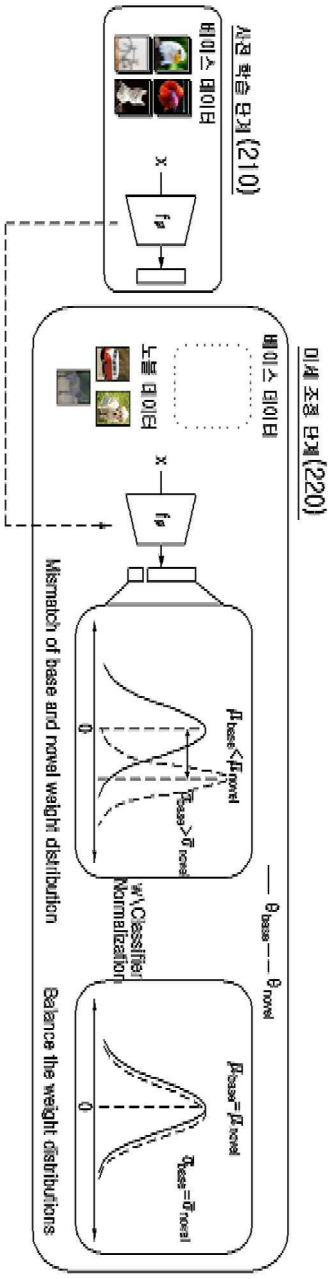
사전 학습 단계(210)
베이스 데이터
미세 조정 단계(220)
베이스 데이터
노블 데이터
Mismatch of base and novel weight distribution
w\Classifier Normalization
Balance the weight distributions

도면3

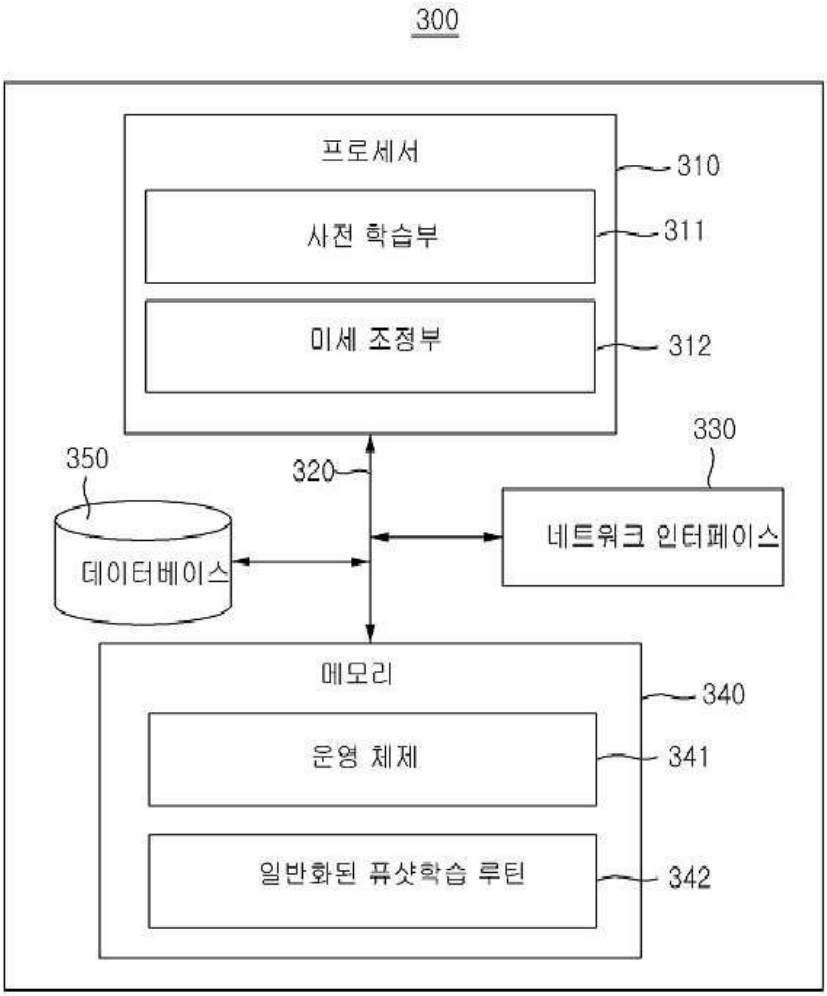
300
프로세서
310
사전 학습부
311
미세 조정부
312
330
350
320
네트워크 인터페이스
데이터베이스
메모리
340
운영 체제
341
일반화된 퓨샷학습 루틴
342

도면4

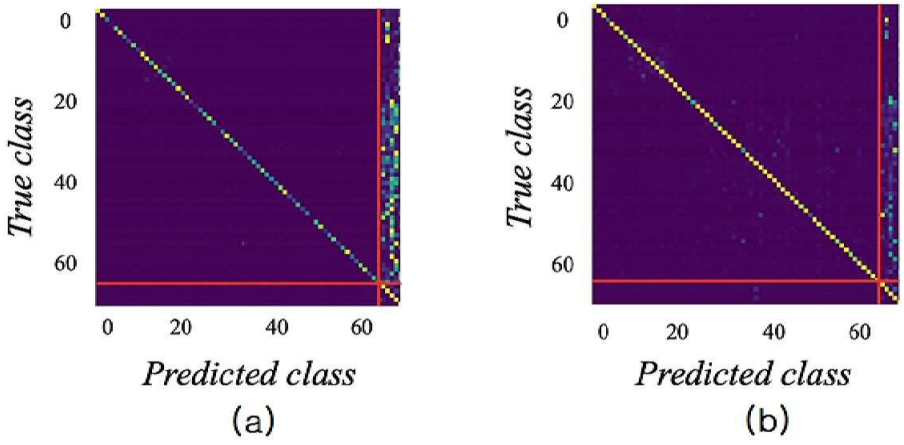
True class
Predicted class
(a)
True class
Predicted class
(b)

도면5

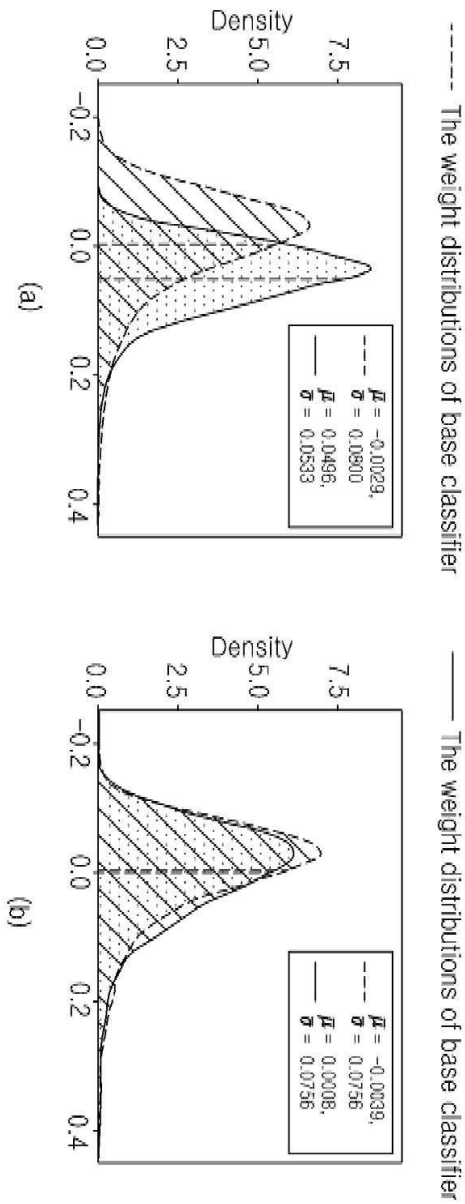
(a)
Density
0.0
2.5
5.0
7.5
−0.2
0.0
0.2
0.4
μ = −0.0029,
σ = 0.0800
μ = 0.0496,
σ = 0.0533
----- The weight distributions of base classifier
(b)
Density
0.0
2.5
5.0
7.5
−0.2
0.0
0.2
0.4
μ = −0.0039,
σ = 0.0756
μ = 0.0008,
σ = 0.0756
—— The weight distributions of base classifier