

엔트로피 기반 적응형 지식 증류 학습 기술

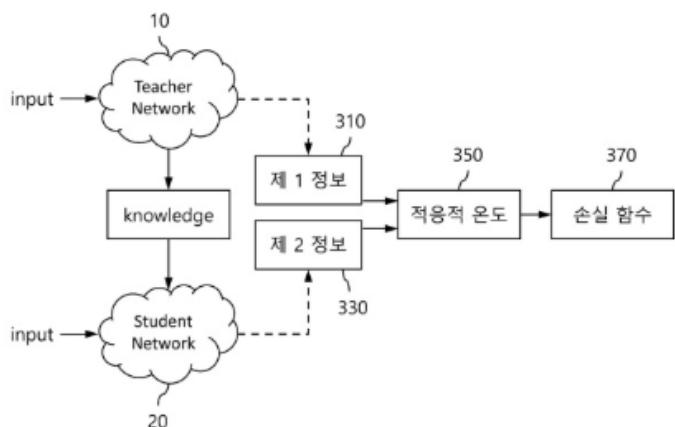
연구개발자: 반도체시스템공학과 한태희 교수

I

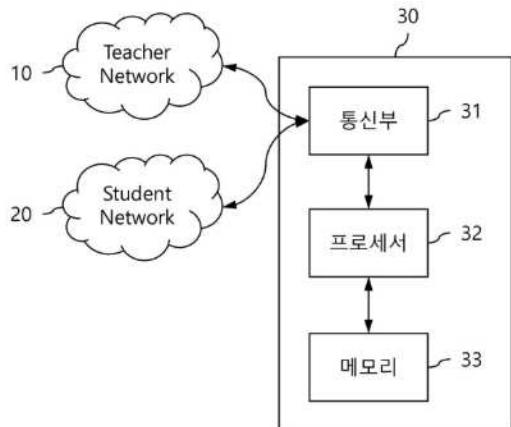
기술 개요

01

기술 요약



[적응적 온도 파라미터]



[지식 증류를 이용하는 신경망 학습 장치를 도시한 블록도]

- 본 기술은 복잡한 교사 모델의 지식을 경량화된 학생 모델에 전달하는 지식 증류 학습 방법에 관한 것으로, 교사 및 학생 네트워크로부터 도출된 정보 엔트로피 간의 거리를 기반으로 증류 손실의 온도 파라미터를 적응적으로 변화시키고, 초기의 불안정한 교사 모델 예측은 소프트 레이블로, 학습이 진행된 후의 신뢰할 수 있는 예측은 하드 레이블을 통해 전달하는 것을 특징으로 함

02

지식재산권 현황

No	발명의 명칭	출원번호	출원일
1	멀티코어 프로세서에서 가상 채널을 활용한 네트워크 캐싱 시스템	2023-0057824	2023.05.03
2	지식 증류를 이용하는 신경망의 학습 방법 및 장치	2022-0126921	2022.10.05

엔트로피 기반 적응형 지식 증류 학습 기술

03

기술의 우수성

▪ 적응적 온도 스케줄링

-기존 고정 온도 파라미터의 한계를 극복하고, 정보 엔트로피 기반의 거리를 활용해 온도 파라미터를 실시간 최적화

▪ 경량 모델 성능 극대화

-이진화 신경망(BNN) 등 극한으로 경량화된 학생 모델의 정확도 손실을 최소화하고 성능을 향상

▪ 온라인 지식 증류 최적화

-학습 초기(고온/소프트 레이블)부터 후기(저온/하드 레이블)까지 지식 전달의 강도를 적응적으로 조절하여 학습 안정성 및 효율을 극대화

▪ 양자화 격차 해소

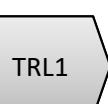
-교사-학생 네트워크 간의 양자화 격차를 인지하고 적절한 성능 차이를 유지하도록 유도하여 지식 전달의 품질 확보

▪ 손실 함수 정교화

-쿨백-라이블러 발산(KL divergence)과 정보 엔트로피를 활용한 선형 결합 손실 함수를 통해 KD 학습의 안정성을 확보

04

기술 개발 완성도



기초이론/실험



실용목적 개념 정립



기능 및 개념 검증



시제품 제작/성능평가



파일럿 현장 테스트



상용모델 개발/성능평가



시제품 인증/표준화



사업화

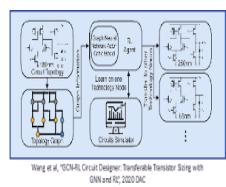
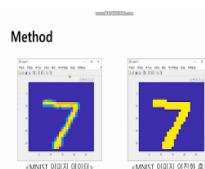
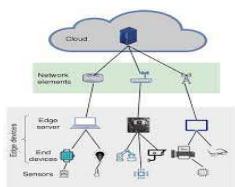
엔트로피 기반 적응형 지식 증류 학습 기술

II

기술 동향

01

기술응용분야



[엣지 AI 디바이스]

스마트폰, IoT 센서 등 저사양/저전력 환경의 AI 모델 경량화/배포

[자율주행 로봇]

실시간 처리와 저지연이 필수적인 임베디드 시스템용 고속 AI칩 개발

[클라우드/서버 경량화]

LLM 등 대규모 모델의 서비스 비용 절감

[이진화 신경망 활용]

메모리/계산 속도가 중요한 초경량 이진화 신경망 성능 향상

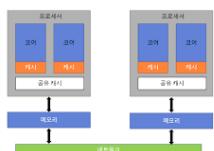
[AI 반도체 설계]

경량화된 신경망 구조에 최적화된 저전력 AI 칩 개발 및 IP 확보

02

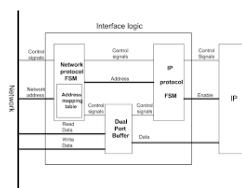
기술 동향

[~2015]



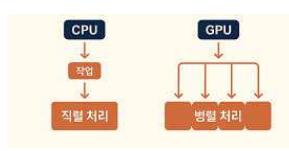
멀티코어 증가

[2016~2020]



NoC 구조 확산

[2020~현재]



AI·Batch 연산 확대

[향후 전망]



고성능 CPU-AI 칩 중심

인공지능 시장은 거대 모델의 운영 효율성 및 비용 부담 증가로 인해 신경망 압축 및 경량화 기술이 핵심 경쟁 분야로 부상하고 있고, 적응적 온도 파라미터를 통해 지식 증류의 근본적인 한계를 해결하여, 저사양 엣지 디바이스에서도 고성능 AI 모델을 구현할 수 있는 기술적 우위를 제공함

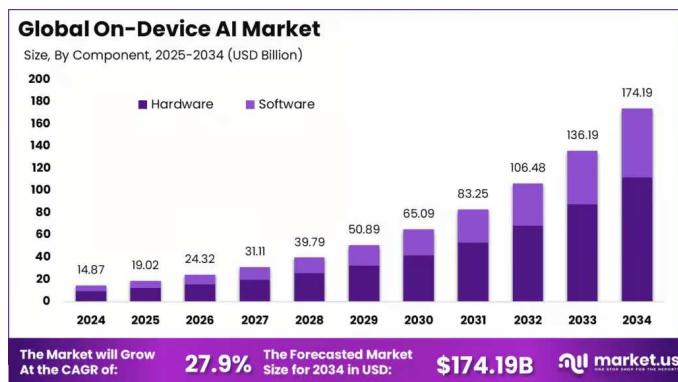
엔트로피 기반 적응형 지식 증류 학습 기술

III

시장 동향

01

시장규모



02

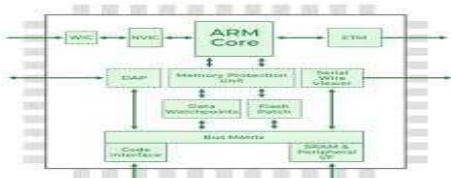
주요 시장 참여자



[NVIDIA 社 GPU, TensorRT, CUDA 제품]



[Qualcomm 社 Snapdragon 기술]



[ARM 社 ARM Architecture 기술]

- 글로벌 온디바이스 AI 시장은 2024년 148억 7천만 달러에서 2034년 1,741억 9천만 달러로 성장할 것으로 예상되며, 2025년부터 2034년까지 연평균 성장률 27.9% 규모로 성장할 것으로 예상됨

- 클라우드 및 자율주행용 고성능 AI 칩 제조사. AI 모델의 경량화 및 최적화 도구를 제공

- 모바일 및 엣지 디바이스용 AI 칩 선두 주자. 온디바이스 AI에 최적화된 경량 모델 기술 개발 주도

- 모바일 및 임베디드 시스템의 핵심 아키텍처 제공. 저전력 AI 연산 및 경량화 기술 표준화에 기여

기술 이전 상담 및 문의