

Intel 18T I5 BMv1 인공지능 테스트 및 활용 정보

NPU(Neural Processing Unit)는 인공지능(AI) 및 머신러닝(ML) 작업에 특화된 전용 프로세서입니다. 주로 딥러닝 모델의 추론(inference) 작업을 가속화하기 위해 설계되었으며, CPU나 GPU보다 효율적으로 계산을 수행할 수 있습니다.

Green 18T I5 BMv1 상품에는 NPU가 탑재되어 있습니다. 일반적으로 AI에 사용되는 고성능 장비의 GPU 서버가 아니기 때문에 서비스를 위한 개발 용도로 사용은 어렵지만 몇가지 관련 정보를 제공해 드리오니 관심 있으신 분은 내용을 확인해 보시기 바랍니다. 추가적인 모듈 설치 및 테스트 요청, 컨설팅 등은 어려우므로 참고용으로만 봐주시면 감사하겠습니다.

1. 드라이버 및 라이브러리 설치

1) Intel NPU 드라이버 및 라이브러리 설치

- 시스템 버전과 커널은 공식 요구 사항에 따라 설치해야 하며, 해당 버전은 아래와 같습니다.
- 운영 체제 및 커널 요구사항: Ubuntu 22.04, 6.8.0-47-generic
- 드라이버 버전: 1.10.0 설치 가이드: [Intel NPU 드라이버 공식 페이지](#)

2) Intel GPU 드라이버 설치

- 설치 가이드: [Intel GPU 드라이버 공식 문서](#)

3) Intel NPU 가속 라이브러리

- 설명: Intel NPU를 사용하여 고속 계산을 수행할 수 있는 Python 라이브러리
- 설치: `pip install intel-npu-acceleration-library`
- GitHub: [NPU 가속 라이브러리](#)

4) OpenVINO GenAI 가속 라이브러리

- 설명: 생성형 AI 모델 실행을 위한 OpenVINO 기반의 C++/Python API 라이브러리
- 설치: `pip install openvino-genai`
- GitHub: [OpenVINO GenAI](#)

2. 성능 테스트 결과 (NPU 와 GPU 비교 테스트)

1) NPU 성능

- 하드웨어: Green 18T I5 BMv1
- 모델: Qwen2-Math-7B
- NPU 테스트: [공식 스크립트](#)
 - ↳ 총 실행 시간: 175.32초
 - ↳ 초당 처리 토큰: 약 1.11 tokens/sec
- NPU와 CPU 비교 테스트: [공식 스크립트](#)
- 모델: TinyLlama-1.1B-Chat-v1.0
 - ↳ NPU: 초당 3 tokens
 - ↳ CPU: 초당 14.27 tokens
- 메모리 사용량
 - ↳ NPU: 약 7GB
 - ↳ CPU: 약 1GB

2) GPU 성능

- 하드웨어: Nvidia T4
- 모델: Qwen2-Math-7B
 - ↳ 총 실행 시간: 15,128.13ms
 - ↳ 초당 처리 토큰: 37.02 tokens/sec

3) 결론

- NPU 가속 라이브러리를 사용할 경우, CPU 의 사용률은 80%. CPU 단독 실행 시 사용률은 30% 정도입니다.
- Qwen 모델 테스트에서 NPU는 초당 약 1 token, TinyLlama 모델에서는 초당 3 tokens, CPU 는 TinyLlama 모델에서 초당 14.27 tokens 를 기록됩니다.
 - ↳ TinyLlama: 메모리 사용량: NPU 로 모델 변환 후 메모리 사용률 약 7GB, CPU 로 변환 후 메모리 사용률은 약 1GB 입니다.
 - ↳ OpenVINO GenAI 라이브러리를 사용하여 변환된 TinyLlama 모델을 처리할 경우, CPU 와 GPU 에서 매우 빠르게 실행됩니다.
- 다중 모달 테스트
 - ↳ NPU: 초당 1.86 tokens
 - ↳ CPU: 초당 0.85 tokens
- 동일한 모델을 NPU 용 Intel NPU Acceleration Library 와 CPU 용 OpenVINO 라이브러리에서 실행하기 위해서는 모델 변환이 필요합니다. 변환 과정에서 발생하는 차이로 인해, 아래 테스트 데이터는 참고용으로만 사용해 주세요.

3. 모델 테스트

1) Intel NPU 가속 라이브러리

- 모델: Qwen2-Math-7B ([스크립트](#))
 - ↳ 결과: NPU: 초당 1.11 tokens / CPU: 초당 14 tokens
- 모델: Intel/Llava-Gemma-2B ([스크립트](#))
 - ↳ 테스트: 이미지 요약 작업 ([이미지](#))
 - ↳ 결과: NPU: 초당 1.86 tokens
- 모델: TinyLlama-1.1B-Chat-v1.0 ([스크립트](#))
 - ↳ 결과: NPU: 초당 3.74 tokens
- 모델: Microsoft/Phi-2 ([스크립트](#))
 - ↳ 결과: NPU: 초당 0.97 tokens
- 모델: microsoft/Phi-3-mini-4k-instruct ([스크립트](#))
 - ↳ 결과: NPU: 초당 1.35 tokens
- 모델: google/flan-t5-small ([스크립트](#))
 - ↳ 결과: 실행 실패

2) OpenVINO GenAI 라이브러리

- 이 라이브러리는 PC 와 노트북에서 실행 가능하며, 자원 소비를 최적화했습니다.
생성 모델을 실행하기 위해 외부 종속성이 필요하지 않으며, 핵심 기능 (예: openvino-tokenizers 를 통한 토큰나이징)을 이미 포함하고 있습니다.
- 모델: NPU 에서 OpenVINO GenAI Flavor 가 적용된 LLM 실행 ([스크립트](#))
 - ↳ 결과: 실행 실패. 관련 문제는 Github 에 보고 됨 ([내용](#))
- 모델: TinyLlama-1.1B-Chat-v1.0 ([스크립트](#))
 - ↳ 결과: NPU 에서 실행되지 않았으나, CPU 와 GPU 에서는 매우 빠르게 실행 되어짐
- 모델: Dreamlike-art/Dreamlike-anime-1.0 ([스크립트](#))
 - ↳ 결과: CPU: real 6m13.358s / user 44m54.039s / sys 0m28.786s
GPU: real 0m36.230s / user 0m14.074s / sys 0m10.571s
NPU: 실행 실패
- 모델: OpenAI/Whisper-base ([스크립트](#))
 - ↳ 결과: CPU: real 0m10.612s / user 0m28.134s / sys 0m3.303s
GPU: real 0m9.046s / user 0m11.476s / sys 0m3.248s
NPU: 실행 실패

3) OpenVINO 라이브러리

- 모델: llava-hf/Llava-1.5-7B-hf ([스크립트](#))
 - ↳ 테스트: 이미지를 텍스트로 요약하는 작업 ([이미지](#))
 - ↳ 결과: CPU: 초당 0.85 tokens
- 모델: TinyLlama/TinyLlama-1.1B-Chat-v1.0 ([스크립트](#))
 - ↳ 결과: CPU: 초당 14.27 tokens

4) 참고 자료

- [Intel NPU Acceleration Library GitHub](#)
- [OpenVINO GenAI GitHub](#)
- [OpenVINO Interactive Tutorials](#)