

RebelServer™

Powering AI Inference
Efficiently and at Scale



RebelServer는 Rebellions의 통합 하드웨어 및 소프트웨어 기반 AI 추론 솔루션을 구성하는 핵심 인프라로, 네 가지 핵심 가치에 기반해 설계되었습니다.



Sovereign AI

기존 공랭식 데이터센터에 추가 전력이나 냉각 설비 없이 즉시 배포 가능합니다. 온프레미스 환경에서 데이터 주권, 보안, 운영 전반에 대한 완전한 통제를 제공합니다.



Ease of Use

오픈소스 프레임워크 및 산업 표준 도구와 자연스럽게 통합됩니다. 벤더 종속성 없이 기존 역량을 그대로 활용할 수 있으며, 별도의 학습 없이 즉시 적용 가능합니다.



Optimized for Production Tokenomics

랙 단위 아키텍처를 기반으로 와트당 성능을 극대화합니다. AI 추론 워크로드에 최적화된 효율을 제공합니다.



Production-Proven Solution

기업 및 공공기관의 실제 운영 환경에 대규모로 배포되어 검증되었습니다. 안정적으로 AI 워크로드를 지원합니다.

성능과 에너지 효율을 동시에 확보하여, 급증하는 전력 소비와 운영 비용 등 AI 추론 환경의 주요 과제를 해결합니다. 또한, 차세대 에이전트형 및 추론 모델 구축을 위한 기반을 제공

하며, MoE(Mixture of Experts) 구조, 다양한 규모의 모델, 그리고 언어·비전·음성을 포함한 멀티모달 기능을 유연하게 통합할 수 있습니다.

Spec

Form Factor	5U (8x RebelCard™)
CPU	2x AMD EPYC 9355 (32C 64T, 3.55GHz, 280W) [EPYC 5th Gen]
Memory	1.5TB (24x 64GB DDR5)
Disk	OS: 1.92TB NVMe × 2 Data (KV Cache): 1.92TB NVMe × 2
Network	4x 400G 1-Port QSFP112-DD 1x 100G 2-Port QSFP56 1x 10G/25G 2-Port SFP28 (OCP 3.0)
Power Supply	6x 2700W
Typical/Max Power Draw	4-6kW/7kW * Theoretical maximum power consumption based on specifications. Actual power consumption will not exceed 7 kW, typically hovering around 4-6kW at most under practical workloads.
Support	Comes with 3-year business standard hardware and software support
Weight	Gross Weight: 100 lbs (45.3 kg) / Net Weight: 65.6 lbs (29.7kg)
Operating Temperature Range	Operating Temperature: 10°C to 35°C (50°F to 95°F) Non-operating Temperature: -40°C to 60°C (-40°F to 140°F) Operating Relative Humidity: 8% to 90% (non-condensing) Non-operating Relative Humidity: 5% to 95% (non-condensing)

성능과 효율의 극대화

RebelServer는 FP16 기준 1 petaFLOPs, FP8 기준 2 petaFLOPs의 처리 성능을 제공하여 AI 성능, 확장성, 효율의 한계를 확장합니다.

하나의 서버는 8개의 RebelCards로 구성되며, 각 카드에는 Rebel100™ 칩이 탑재되어 있습니다. 해당 칩은 UCle-Advanced 인터커넥트를 활용한 4개의 칩렛 기반 SoC 구조로 설계되었으며, 144GB의 HBM3E 메모리를 통해 대규모·고복잡도 AI 추론 워크로드를 안정적으로 처리합니다.

사용 편의성

RebelServer에 통합된 Rebellions Software Stack은 사용자 배포 및 운영 요구사항을 지원합니다.

- 클라우드 네이티브 환경 지원
- 오픈소스 프레임워크 및 산업 표준 도구와의 통합
- 고성능 분산 추론
- 다양한 모델 지원
- Rebellions 하드웨어 전 세대에 걸친 일관된 사용자 경험 제공

Rebellions Cloud Native Stack은 프로덕션 규모의 클라우드 오케스트레이션을 지원합니다. Rebellions Inference Stack은 세 가지 핵심 구성 요소로 이루어집니다.

- vLLM, PyTorch, Triton과 공동 설계된 추론 엔진
- 고속 인터커넥트와 특화된 소프트웨어 라이브러리를 통합한 고성능 분산 추론
- 사전 검증 및 최적화된 다양한 모델로 구성된 모델 카탈로그로, 즉시 프로덕션 환경에 배포하거나 AI 워크로드 개발 및 최적화를 위한 기준(reference)으로 활용 가능

