

昆仑芯 P800 产品介绍


成为划时代，全球领先的智能计算公司



昆仑芯 P800

产品概述

昆仑芯的P800是具有革命性的AI加速产品系列，旨在加速**生成式人工智能**发展所需要的**并行训练和推理**基础设施，赋能AI算法研究和开发者，解锁人工智能潜力。该创新产品具有业界领先的性能、可扩展性和兼容性，适合从预训练，微调到大模型推理等广泛的应用场景



P800 OAM

产品规格

产品型号	P800 OAM 模组
支持精度	FP32/FP16/BF16; INT16/INT8
显存	96GB
主机设备互联	PCIe 5.0x16
节点内设备互联	XPU Link
散热方式	被动
Form Factor	OAM 模组 (OAI-OAM 标准) 160.74mm * 164.01mm * 101.00mm
服务器集成	昆仑芯认证的OEM合作伙伴 单机内集成8个OAM 模组
节点间互联协议	RDMA: ROCE-v2/IB



01 高计算性能

大内存高带宽架构支持Transformer Engine。大模型训练性能与国外某厂商竞品相当，大模型推理性能是国外某厂商竞品的1.2倍。

02 零迁移成本

与主流AI框架兼容，大幅降低迁移新平台的成本。开发者可以快速将P800集成到客户系统中，提高AI应用的开发速度。

03 技术自主

对生成式AI业务，AI算法和DL框架快速发展有深入理解。全自研IP包括通用计算和张量计算等核心技术。能根据市场和技术发展对芯片架构进行快速迭代。

04 可靠运行

经过国内规模最大的生成式AI业务的充分验证，昆仑芯P800表现出高度的稳定性和可靠性，确保AI应用的连续运行和高效执行。

05 支持大规模并行

支持万卡大规模AI集群。节点内多芯和节点间协同能处理超大规模的AI并行任务。支持数据并行，模型并行，流水线并行，专家并行，序列并行等万亿大模型训练所需的分布式并行策略。

昆仑芯 P800 适配服务器




HARDWARE

主机类型	Intel CPU: SPR/EMR	国产化CPU: C86
机型名称	H3C、ZTE、浪潮	H3C、ZTE、浪潮、中科可控
整机功耗*	7-8KW（以实际配置为准）	7.5-8.5KW（以实际配置为准）
网络	DCN：10G光口/25G光口/100GB光口智能网卡 HPN：200G光口/400G光口，支持IB/RoCE-v2协议	
操作系统	Ubuntu（20.04*等）、CentOS（CentOS 8等） 国产Linux操作系统（麒麟kylin等）	
昆仑芯软件栈	XPU SDK	
认证适配厂商	H3C/中兴/浪潮/中科可控	
* 正常机房环境下，满载典型功耗 ~6KW		




软件栈

AI算法和应用开发者在构建AI应用和业务的过程中，需要一套成熟的编程语言，以及完善的软件工具集来快速迭代开发任务。昆仑芯SDK可以提供从底层驱动环境到上层模型转换等全栈的软件工具。




零迁移成本

SOFTWARE



迁移中用户代码不变，迁移后保证高效性能



大模型支持列表



SOFTWARE

Llama 7/13/65B

Llama2 7/13/70B

Llama3 8/70B

Qwen 7/14B

Qwen1.5 7/14/32/72B

ChatGLM 1/2/3 6B

GLM 10/130B

Baichuan 7/13B

Baichuan2 /13B

Aquila

Gemma 7B

Mistral 7B

Mixtral 8x7B

Bloom/Bloomz 7/176B

GPT-3 175B

GPT-NeoX 20B

CodeGeeX2 6B

Gemma 7B

InternLM 1/2 7/20B

LinSeer

YI 6/34B

Eva 14B

Stable Diffusion 2.1

Stable Diffusion XL

Sora(DiT/SiT)

文心一言系列模型



预训练场景

PreTrain

基础模型

微调场景

Post-PreTrain

SFT

PEFT

行业模型

多任务模型

场景模型

推理场景

Inference

推理模型

模型 100B +

P800

模型 70B

P800

模型 7/13B

P800


R480

R200

千卡训练集群 混合并行



NETWORK



数据并行 DP
allreduce 同步梯度
通信量和模型规模正相关
每个step一次通信

流水线并行 PP
点到点 正向传激活 反向传播梯度
通信量和层间交互相关
每个step数次通信

张量并行 TP
allreduce同步矩阵乘结果
通信量和batchsize相关
每个step几十次通信

注：上图使用交换机兼容RoCEv2，支持128 x 400G 连接能力

THANK YOU

让计算更智能

成为划时代，全球领先的智能计算公司

