

完全公开

鸿云智算大模型一体产机
产品规格书
(AWS-P2&P4)

2025 年 1 月 22 日 首次发布

深圳市诺亚鸿云信息技术有限公司

● 版权声明

本文中出现的任何文字叙述、文档格式、插图、图片、方法、过程等内容，除另有特别注明， 版权均归深圳市诺亚鸿云信息技术有限公司所有，受到有关产权及版权法保护。任何个人、机构未经深圳市诺亚鸿云信息技术有限公司的书面授权许可，不得以任何方式复制或引用本文的任何片段。

修订记录

版本	状态	修订理由和内容摘要	修订人	批准人	修订日期
v1.0	C	创建《鸿云智算大模型一体机（AWS-P2&P4）产品规格书》	徐英		

状态：C-创建，A-增加，M-修改，D-删除

AGC 架构 AI 工作站

AWS-P2&P4 (2/4 代表不同产品类型最大支持的 GPU 算力卡数量)



AWS-P2



AWS-P4

简介

AWS-P2/P4 产品采用 AGC (AI computer system with the GPU as its Core) 架构设计, 秉承无主板的设计理念, 支持开放的模型生态系统。其内置底层算力、预置DeepSeek 模型服务、推理环境以及 RAG 环境的生产级解决方案, 致力于为企业客户提供“数据不出域、性能更高效”的本地化开箱即用的 AI 服务新模式。

亮点

架构领先



- 国内首创专为 AI 工作站设计的 GPU 数据加速单元, 提升数倍 AI 性能。
- 无需主板即可实现 AI 工作站模块化生产, 成为国内体积最小的 AI 工作站。
- 超静音设计, 低于 60db, AWS-P2/P4支持桌面级或数据中心级部署。

算力优化



- 针对多样化的 GPU 算力卡以及不同大小的模型, AWS-P2&P4 融合了从 GPU 算力卡规划、推理引擎优化至负载均衡调度优化的全方位链路优化策略, 客户可使用高性价比的大模型推理服务。
- 自主研发趋优推理算法提升 GPU 算力卡推理性能, 相较于未采用该算法之前, 实现 2~3 倍的推理效率。
- 最大支持 PCIE 5.0 协议, x16 双向带宽达到了 128GB/s。

地址: 深圳市龙岗区坂田街道岗头社区天安云谷产业园二期 4 栋 8 层 809 号

网址: www.nyhy-cloud.com



数据安全



全离线环境部署和使用，用户既不关注公有接口，也不担心私有数据泄露，同时也不会有 Token 限制焦虑。



预置 DeepSeek 模型文件和所有运行环境，在数分钟内通过图形化界面启动模型并使用。



支持开放的模型生态系统，实现数据本地化、模型私有化。



配置灵活



最大可支持 2/4 张 GPU 算力卡，兼容全高全长双宽、全高全长单宽以及半高半长单宽等多种规格。



GPU 算力卡免驱动应用，实现模型的自动适应与适配。



支持多类型数据接入，U 盘、NFS、CIFS、S3 等接入类型。

规格

产品型号		AWS-P2	AWS-P4
形态		L（423mm）*W（290mm）*H（150mm）	L（434mm）*W（444mm）*H(160mm)
模型		最大支持 DeepSeep 32B（含）以下模型及其他 AI 大模型	最大支持 DeepSeep 70B（含）以下模型及其他 AI 大模型
控制模组	处理器	工作站数据加速单元集成	工作站数据加速单元集成
	内存	可选配 32GB、64GB 以及 128GB 规格	可选配 32GB、64GB 以及 128GB 规格
	系统盘	配置 1 块 M.2 512GB NVME 硬盘	配置 1 块 M.2 512GB NVME 硬盘
	缓存盘	可选配 1 块 M.2 960GB NVME 硬盘	可选配 1 块 M.2 960GB NVME 硬盘
	数据盘	最大可选配 4 块 2.5 英寸 SATA 接口的固态硬盘，提供 960GB、1.92TB、3.84TB 以及 7.68TB 等多种容量规格供选择。	最大可选配 8 块 2.5 英寸 SATA 接口的固态硬盘，提供 960GB、1.92TB、3.84TB 以及 7.68TB 等多种容量规格供选择。
算力模组	扩展槽	2 * PCIe5.0 x16	4 * PCIe4.0 x16
	GPU 算力卡	最大支持 2 张全高全长双宽、全高全长单宽以及半高半长单宽等多种规格。	最大支持 4 张全高全长双宽、全高全长单宽以及半高半长单宽等多种规格。
网络	网络 1	配置 2 个 10Gbs 光口	配置 2 口 10Gbs 光口
	网络 2	配置 1 个 1Gbps 电口	配置 1 个 1Gbps 电口
监控	前面板	监控 AI 工作站的 IP 地址配置、硬盘存储	监控 AI 工作站的 IP 地址配置、硬盘存储

地址：深圳市龙岗区坂田街道岗头社区天安云谷产业园二期 4 栋 8 层 809 号

网址：www.nyhy-cloud.com

产品型号		AWS-P2	AWS-P4
	显示屏	容量、GPU 算力卡工作状态和温度。	容量、GPU 算力卡工作状态和温度。
电源	电源	配置 1 个 1600W 热插拔电源。	配置 2 个 1600W 热插拔电源。
其他	管理	自主研发 AIOS 操作系统，快速构建推理环境与 RAG 环境，配置高效 VLLM 推理框架（基于开源自主研发）。	自主研发 AIOS 操作系统，快速构建推理环境与 RAG 环境，配置高效 VLLM 推理框架（基于开源自主研发）。
	I/O	2*USB 3.0, 1*HDMI	2*USB 3.0, 1*HDMI
	工作温度	5°C~35°C (41°F~95°F)，符合 ASHRAE Class A1/A2	5°C~35°C (41°F~95°F)，符合 ASHRAE Class A1/A2