

《Deepseek R1 本地部署完全手册》

版权归：HomeBrew Ai Club

作者wechat：samirtan

版本：V2.0

更新日期：2025年2月8日

一、简介

Deepseek R1 是支持复杂推理、多模态处理、技术文档生成的高性能通用大语言模型。本手册为技术团队提供完整的本地部署指南，涵盖硬件配置、国产芯片适配、量化方案、云端替代方案及完整671B MoE模型的Ollama部署方法。

核心提示：

- 个人用户**：不建议部署32B及以上模型，硬件成本极高且运维复杂。
- 企业用户**：需专业团队支持，部署前需评估ROI（投资回报率）。

二、本地部署核心配置要求

1. 模型参数与硬件对应表

模型参数	Windows 配置要求	Mac 配置要求	适用场景
1.5B	<ul style="list-style-type: none">- RAM: 4GB- GPU: 集成显卡/现代CPU- 存储: 5GB	<ul style="list-style-type: none">- 内存: 8GB (M1/M2/M3)- 存储: 5GB	简单文本生成、基础代码补全
7B	<ul style="list-style-type: none">- RAM: 8-10GB- GPU: GTX 1680 (4-bit量化)- 存储: 8GB	<ul style="list-style-type: none">- 内存: 16GB (M2 Pro/M3)- 存储: 8GB	中等复杂度问答、代码调试
14B	<ul style="list-style-type: none">- RAM: 24GB- GPU: RTX 3090 (24GB VRAM)- 存储: 20GB	<ul style="list-style-type: none">- 内存: 32GB (M3 Max)- 存储: 20GB	复杂推理、技术文档生成
32B+	企业级部署 (需多卡并联)	暂不支持	科研计算、大规模数据处理

2. 算力需求分析

模型	参数规模	计算精度	最低显存需求	最低算力需求
DeepSeek-R1 (671B)	671B	FP8	≥890GB	2*XE9680 (16*H20 GPU)
DeepSeek-R1-Distill-70B	70B	BF16	≥180GB	4*L20 或 2*H20 GPU

三、国产芯片与硬件适配方案

1. 国内生态合作伙伴动态

企业	适配内容	性能对标 (vs NVIDIA)
华为昇腾	昇腾910B原生支持R1全系列，提供端到端推理优化方案	等效A100 (FP16)
沐曦GPU	MXN系列支持70B模型BF16推理，显存利用率提升30%	等效RTX 3090
海光DCU	适配V3/R1模型，性能对标NVIDIA A100	等效A100 (BF16)

2. 国产硬件推荐配置

模型参数	推荐方案	适用场景
1.5B	太初T100加速卡	个人开发者原型验证
14B	昆仑芯K200集群	企业级复杂任务推理
32B	壁仞算力平台+昇腾910B集群	科研计算与多模态处理

四、云端部署替代方案

1. 国内云服务商推荐

平台	核心优势	适用场景

硅基流动	官方推荐API, 低延迟, 支持多模态模型	企业级高并发推理
腾讯云	一键部署+限时免费体验, 支持VPC私有化	中小规模模型快速上线
PPIO派欧云	价格仅为OpenAI 1/20, 注册赠5000万tokens	低成本尝鲜与测试

2. 国际接入渠道 (需魔法或外企上网环境🚫)

- 英伟达NIM: 企业级GPU集群部署 ([链接](#))
- Groq: 超低延迟推理 ([链接](#))

五、完整671B MoE模型部署 (Ollama+Unsloth)

1. 量化方案与模型选择

量化版本	文件体积	最低内存+显存需求	适用场景
DeepSeek-R1-UD-IQ1_M	158 GB	≥200 GB	消费级硬件 (如Mac Studio)
DeepSeek-R1-Q4_K_M	404 GB	≥500 GB	高性能服务器/云GPU

下载地址:

- [HuggingFace模型库](#)
- [Unsloth AI官方说明](#)

2. 硬件配置建议

硬件类型	推荐配置	性能表现 (短文本生成)
消费级设备	Mac Studio (192GB统一内存)	10+ token/秒
高性能服务器	4×RTX 4090 (96GB显存+384GB内存)	7-8 token/秒 (混合推理)

3. 部署步骤 (Linux示例)

1. 安装依赖工具:

```
# 安装llama.cpp (用于合并分片文件)
/bin/bash -c "$(curl -fsSL
https://raw.githubusercontent.com/Homebrew/install/HEAD/install.sh)"
brew install llama.cpp
```

2. 下载并合并模型分片：

```
llama-gguf-split --merge DeepSeek-R1-UD-IQ1_M-00001-of-00004.gguf  
DeepSeek-R1-UD-IQ1_S.gguf
```

3. 安装Ollama：

```
curl -fsSL https://ollama.com/install.sh | sh
```

4. 创建Modelfile：

```
FROM /path/to/DeepSeek-R1-UD-IQ1_M.gguf  
PARAMETER num_gpu 28 # 每块RTX 4090加载7层（共4卡）  
PARAMETER num_ctx 2048  
PARAMETER temperature 0.6  
TEMPLATE "<|end_of_thinking|>{{ .Prompt }}<|end_of_thinking|>"
```

5. 运行模型：

```
ollama create DeepSeek-R1-UD-IQ1_M -f DeepSeekQ1_Modelfile  
ollama run DeepSeek-R1-UD-IQ1_M --verbose
```

4. 性能调优与测试

- **GPU利用率低：**升级高带宽内存（如DDR5 5600+）。
- **扩展交换空间：**

```
sudo fallocate -l 100G /swapfile  
sudo chmod 600 /swapfile  
sudo mkswap /swapfile  
sudo swapon /swapfile
```

六、注意事项与风险提示

1. 成本警示：

- **70B模型：**需3张以上80G显存显卡（如RTX A6000），单卡用户不可行。
- **671B模型：**需8xH100集群，仅限超算中心部署。

2. 替代方案：

- 个人用户推荐使用云端API（如[硅基流动](#)），免运维且合规。

3. 国产硬件兼容性：

需使用定制版框架（如昇腾CANN、沐曦MXMLLM）。

七、附录：技术支持与资源

- 华为昇腾：[昇腾云服务](#)
- 沐曦GPU：[免费API体验](#)
- 李锡涵博客：[完整部署教程](#)


结语

Deepseek R1 的本地化部署需极高的硬件投入与技术门槛，**个人用户务必谨慎**，企业用户应充分评估需求与成本。通过国产化适配与云端服务，可显著降低风险并提升效率。技术无止境，理性规划方能降本增效！

手册更新与反馈：如有补充或修正，请联系文档作者，接入细节请阅读详细文档[硅基流动社区](#)。

全球企业个人渠道附表

1. 秘塔搜索：<https://metaso.cn>
2. 360纳米AI搜索：<https://www.n.cn/>
3. 硅基流动：<https://cloud.siliconflow.cn/i/OBklluwO>
4. 字节跳动火山引擎：<https://console.volcengine.com/ark/region:ark+cn-beijing/experience>
5. 百度云千帆：<https://console.bce.baidu.com/qianfan/modelcenter/model/buildIn/list>
6. 英伟达NIM：<https://build.nvidia.com/deepseek-ai/deepseek-r1>
7. Groq：<https://groq.com/>
8. Fireworks：<https://fireworks.ai/models/fireworks/deepseek-r1>
9. Chutes：<https://chutes.ai/app/chute/>
10. Github：<https://github.com/marketplace/models/azureml-deepseek/DeepSeek-R1/playground> 
11. POE：<https://poe.com/DeepSeek-R1> 
12. Cursor：<https://cursor.sh/> 
13. Monica：<https://monica.im/invitation?c=ACZ7WJJ9> 
14. Lambda：<https://lambdalabs.com/> 
15. Cerebras：<https://cerebras.ai> 
16. Perplexity：<https://www.perplexity.ai> 
17. 阿里云百炼：<https://api.together.ai/playground/chat/deepseek-ai/DeepSeek-R1>

 为需要魔法或外企上网环境

芯片企业支持附图

支持DeepSeek模型的国内AI芯片企业动态（智东西制表）		
日期	企业	官宣标题
2月1日	 华为	首发！硅基流动x华为云联合推出基于昇腾云的DeepSeek R1&V3推理服务！
2月1日	 沐曦	Gitee AI联合沐曦首发全套DeepSeek R1千问蒸馏模型，全免费体验！
2月4日	 天数智芯	一天适配！天数智芯联合Gitee AI正式上线DeepSeek R1模型服务
2月4日	 摩尔线程	致敬DeepSeek：以国产GPU为基，燎原中国AI生态之火
2月4日	 海光信息	DeepSeek V3和R1模型完成海光DCU适配并正式上线
2月4日	 华为	昇腾原生：潞晨科技推出基于昇腾算力的DeepSeek R1系列推理API及云镜像服务
2月5日	 沐曦	DeepSeek-V3满血版在国产沐曦GPU首发体验上线
2月5日	 华为	昇腾蛇年开工送大礼，DeepSeek系列新模型正式上线昇腾社区
2月5日	 海光信息	海光DCU成功适配DeepSeek-Janus-Pro多模态大模型
2月5日	 壁仞科技	DeepSeek R1在壁仞国产AI算力平台发布，全系列模型一站式赋能开发者创新
2月5日	 太初元基	基于太初T100加速卡2小时适配DeepSeek-R1系列模型，一键体验，免费API服务
2月5日	 云天励飞	DeepEdge10已完成DeepSeek R1系列模型适配
2月6日	 燧原科技	燧原科技实现全国各地智算中心DeepSeek的全量推理服务部署
2月6日	 昆仑芯	国产AI卡Deepseek训练推理全版本适配、性能卓越，一键部署等您来（附文档下载方式）

云厂商智算企业支持附图

官宣支持DeepSeek模型的国内云服务及智算企业动态（智东西制表）		
日期	企业	官宣标题
1月28日	 无问芯穹	无问芯穹Infini-AI异构云现已上架DeepSeek-R1-Distill，国产模型与异构云的绝妙组合
1月28日	 PPIO派欧云	重磅！DeepSeek-R1上线PPIO派欧算力云
1月28日	 硅基流动	SiliconCloud上线DeepSeek多模态模型：Janus-Pro-7B来了
2月1日	 华为云	首发！硅基流动x华为云联合推出基于昇腾云的DeepSeek R1&V3推理服务！
2月1日	 硅基流动	首发！硅基流动x华为云联合推出基于昇腾云的DeepSeek R1&V3推理服务！
2月1日	 天翼云	神秘“东方力量”集结！DeepSeek-R1模型在天翼云上架！

2月2日		腾讯云	一键部署，3分钟调用！DeepSeek-R1登陆腾讯云
2月2日		云轴科技	首发！ZStack智塔支持DeepSeek V3/R1/ Janus Pro，多种国产CPU/GPU可私有化部署
2月2日		PPIO派欧云	PPIO派欧算力云接入DeepSeek全模型，价格仅OpenAI o1 1/20，注册即送5000万tokens！
2月3日		阿里云	3步，0代码！一键部署DeepSeek-V3、DeepSeek-R1
2月3日		百度智能云	百度智能云千帆全面支持DeepSeek-R1/V3调用，价格超低
2月3日		超算互联网	超算互联网上线DeepSeek系列模型，提供超智融合算力支持
2月4日		腾讯云	一键部署+限免体验！腾讯云上架DeepSeek系列模型
2月4日		硅基流动	全家桶来了！硅基流动上线加速版DeepSeek-R1蒸馏模型
2月4日		火山引擎	全尺寸DeepSeek模型登陆火山引擎！
2月4日		青云科技	限时免费，一键部署！基石智算正式上线DeepSeek-R1系列模型
2月4日		算力互联	国产GPU与DeepSeek加速适配，算力互联携手天数智芯推出DeepSeek-R1模型服务
2月4日		京东云	一键部署！京东云全面上线DeepSeek-R1/V3
2月4日		超算互联网	再上新 来超算互联网DeepSeek一下！
2月5日		联通云	“哪吒闹海”！联通云上架DeepSeek-R1系列模型！
2月5日		PPIO派欧云	PPIO假期战报：99.9%可用性！连夜支持满血版DeepSeek，助力客户轻松应对流量高峰
2月5日		并济科技	并济科技携手燧原科技完成DeepSeek全量推理服务国产化部署，加速智算中心生态建设
2月5日		优刻得	优刻得基于国产芯片适配DeepSeek全系列模型
2月5日		移动云	全版本、全尺寸、全功能！移动云全面上线DeepSeek
2月6日		青云科技	持续上线DeepSeek！基石智算Janus-Pro-7B文生图模型来了
2月6日		神州数码	3分钟部署高性能AI模型DeepSeek，神州数码助力企业智能化转型
2月6日		天翼云	国产AI生态新突破！“息壤”+DeepSeek王炸组合来了！
2月6日		并行科技	服务器繁忙？并行科技助您DeepSeek自由！
2月6日		优刻得	优刻得私有云上线DeepSeek系列模型
2月7日		浪潮云	浪潮云率先发布671B DeepSeek大模型一体机解决方案
2月7日		北京超算	北京超算xDeepSeek：双擎爆燃，驱动千亿级AI创新风暴

注：厂商支持图表版权归智东西