

什么是推理模型？

——让AI像人类一样“思考的秘密”



DeepSeek

什么是推理模型？

目录

- 1、推理模型的定义
- 2、推理模型的工作流程
- 3、推理模型的类型
- 4、推理与通用模型的差异
- 5、如何向模型表达需求




DeepSeek

一、推理模型的定义

推理大模型：推理大模型是指能够在传统的大语言模型基础上，强化推理、逻辑分析和决策能力的模型。它们通常具备额外的技术，比如强化学习、神经符号推理、元学习等，来增强其推理和问题解决能力。

- 例如：DeepSeek-R1，GPT-o3在逻辑推理、数学推理和实时问题解决方面表现突出。



知乎 @小小将




DeepSeek

二、推理模型的工作流程

1. 训练阶段

- 使用大量数据训练模型，调整参数以最小化预测误差。
- 例如：用10万张猫狗图片训练CNN模型，使其能区分猫和狗。



2. 推理阶段

- 步骤：
 - 输入新数据（如用户上传的图片）。
 - 模型对数据特征进行提取和计算。
- 输出结果（如“这是猫，置信度95%”）。



三、推理模型的类型

统计推理 模型模型

基于概率和统计方法（如贝叶斯网络）- 例：垃圾邮件过滤器计算邮件属于垃圾类的概率

混合推理 模型

结合规则、统计和深度学习（如AlphaGo的蒙特卡洛树搜索+神经网络）

深度学习 模型

使用神经网络（如Transformer、CNN）

基于规则 模型

依赖人工设定的逻辑规则（如专家系统）- 例：医疗诊断系统根据症状匹配疾病规则库



DeepSeek

四、推理与通用模型的差异

非推理大模型：适用于大多数任务，非推理大模型一般侧重于语言生成、上下文理解和自然语言处理，而不强调深度推理能力。此类模型通常通过对大量文本数据的训练，掌握语言规律并能够生成合适的内容，但缺乏像推理模型那样复杂的推理和决策能力。例如：GPT-3、GPT-4（OpenAI），BERT（Google），主要用于语言生成、语言理解、文本分类、翻译等任务。

维度	推理模型	通用模型
优势领域	数学推导、逻辑分析、代码生成、复杂问题拆解	文本生成、创意写作、多轮对话、开放性问答
劣势领域	发散性任务（如诗歌创作）	需要严格逻辑链的任务（如数学证明）
性能本质	专精于逻辑密度高的任务	擅长多样性高的任务
强弱判断	并非全面更强，仅在其训练目标领域显著优于通用模型	通用场景更灵活，但专项任务需依赖提示语补偿能力



五、如何向模型表达需求

需求类型	特点	需求表达公式	推理模型适配策略	通用模型适配策略
1. 决策需求	需权衡选项、评估风险、选择最优解	目标 + 选项 + 评估标准	要求逻辑推演和量化分析	直接建议，依赖模型经验归纳
2. 分析需求	需深度理解数据/信息、发现模式或因果关系	问题 + 数据/信息 + 分析方法	触发因果链推导与假设验证	表层总结或分类
3. 创造性需求	需生成新颖内容（文本/设计/方案）	主题 + 风格/约束 + 创新方向	结合逻辑框架生成结构化创意	自由发散，依赖示例引导
4. 验证需求	需检查逻辑自治性、数据可靠性或方案可行性	结论/方案 + 验证方法 + 风险点	自主设计验证路径并排查矛盾	简单确认，缺乏深度推演
5. 执行需求	需完成具体操作（代码/计算/流程）	任务 + 步骤约束 + 输出格式	自主优化步骤，兼顾效率与正确性	严格按指令执行，无自主优化