Mixture of Experts (MoE)

DeepSeek MOE 论文走读

ZOMI

Contents

视频目录大纲

- MoE 混合专家
  - MoE 基本介绍 (4)
  - MoE 前世今生 (5)
  - MoE 核心工作
    - 奠基工作：Adaptive Mixtures of Local Experts
    - LSTM MoE：Outrageously Large Neural Networks ...
    - GShard: Scaling Giant Models with Conditional ...
    - Switch Transformers: Scaling to Trillion Parameter Models ...
    - GLaM: Efficient Scaling of Language Models with Mixture ...
    - ST-MoE: Designing Stable and Transferable Sparse Exp
  - MoE 架构原理 (3)
  - 大模型遇上 MoE (4)
  - 手撕 MoE 代码 (5)
  - MoE 的未来 (2)

DeepSeek MOE

基本介绍

- DeepSeekMOE 是一种创新的混合专家（Mixture of Experts, MoE）模型架构，旨在通过细分割专家和共享专家策略，提高专家专业化程度，减少冗余，并在参数扩展时控制计算成本。其核心目标是在保持高性能的同时，显著降低计算资源消耗。

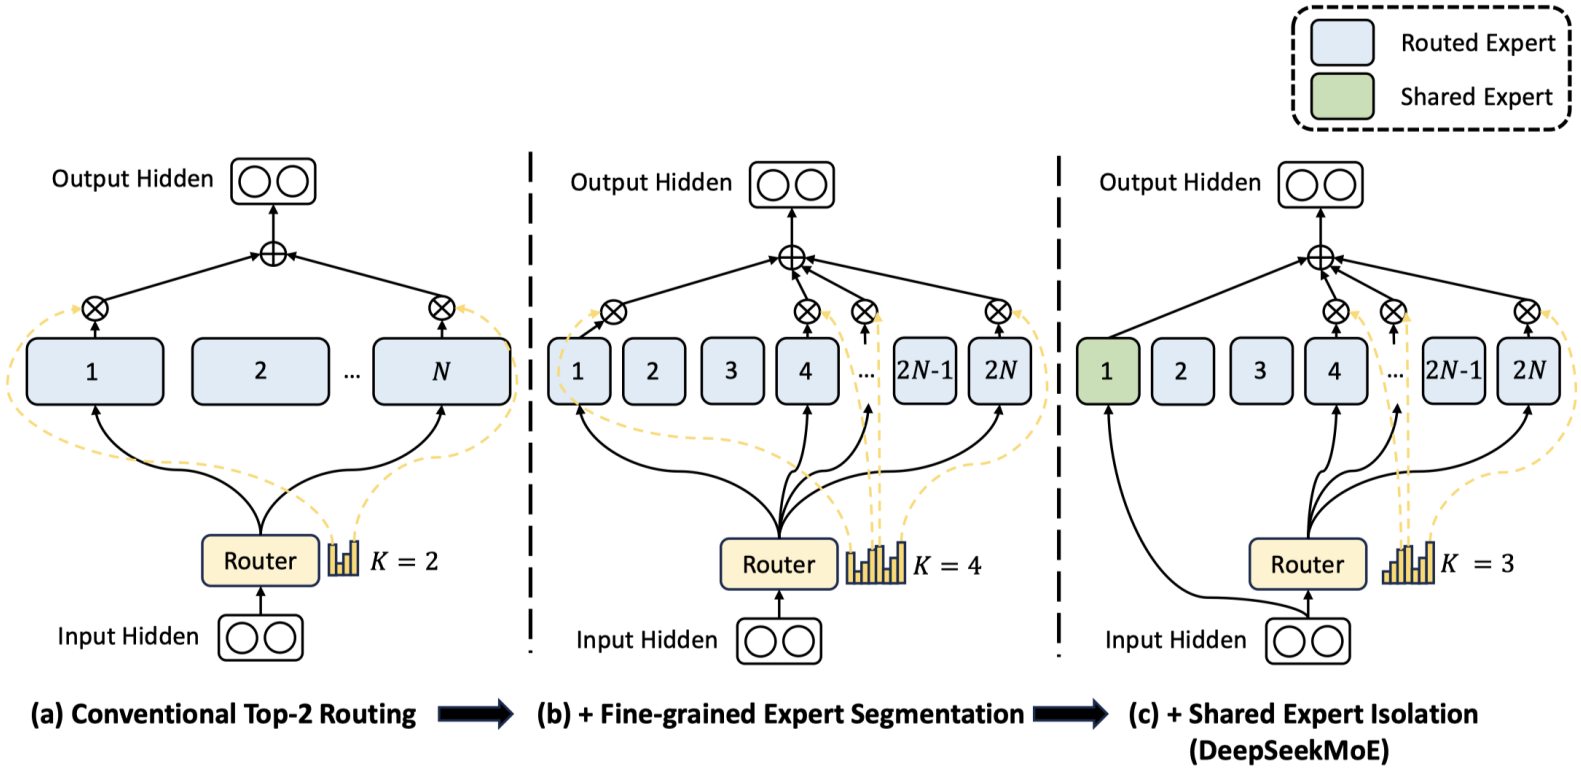

背景与动机

- **模型规模扩展的挑战：**
  - 随着模型参数量的增加，计算成本显著上升，限制了模型的扩展。DeepSeekMOE 通过稀疏专家模型（MoE）解决这一问题，仅激活部分参数，从而在保持高性能的同时降低计算开销。
- **专家同质化与负载失衡：**
  - 传统 MoE 模型存在专家同质化和负载失衡问题，部分专家承担过多计算任务，而其他专家利用率低。DeepSeekMOE 通过动态专业化路由（DSR）和专家共享机制，优化专家利用率。

核心架构

- **细分割与共享专家策略：**
  - **细分割专家：**将专家分为多个小组，每个小组专注于特定任务，提高专家专业化程度。
  - **共享专家：**引入共享专家，捕捉通用知识，减少冗余参数。
- **动态专业化路由（DSR）：**
  - DSR 通过门控网络动态选择最相关专家，确保每个输入仅激活少量专家，从而降低计算成本。
  - DSR 还通过负载均衡机制，避免某些专家过载或闲置，确保专家利用率均衡

训练策略

- **三阶段训练流程：**
  - 专家孵化：通过动态课程学习，初步训练专家网络。
  - 专精强化：通过对抗训练，进一步优化专家专业化能力。
  - 协同优化：通过多任务协同训练，提升整体模型性能。
- **训练效率优化：**
  - 采用 FP8 混合精度训练和 DualPipe 算法，显著减少训练时间和通信开销

DeepSeek MOE

- DeepSeekMOE 通过细分割专家、共享专家和动态专业化路由等创新技术，实现了高效的大规模模型训练和推理。其在保持高性能的同时，显著降低了计算成本，为万亿参数时代的大模型发展提供了新的思路。

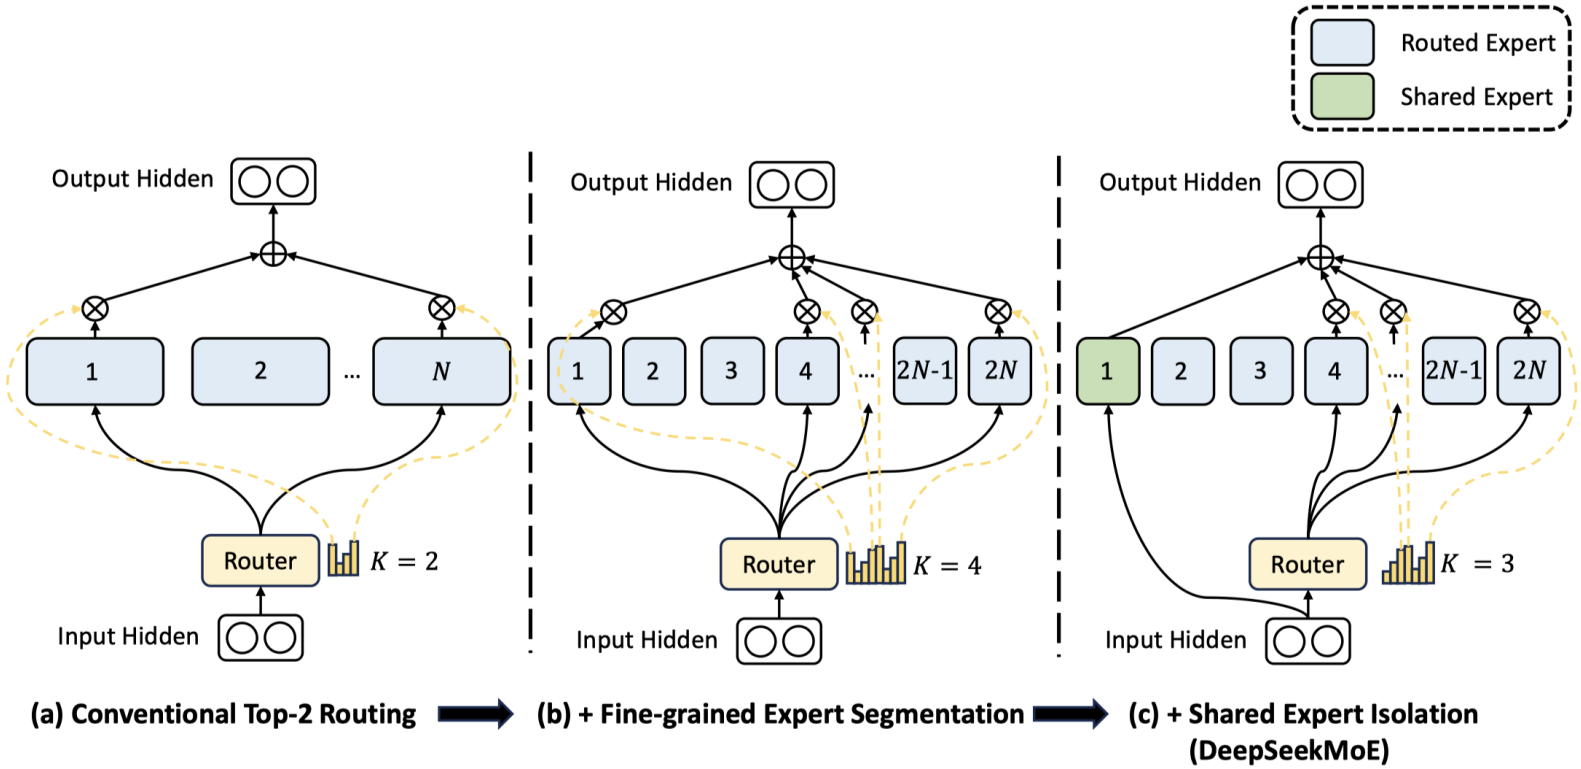

Thank you

把AI系统带入每个开发者、每个家庭、每个组织，构建万物互联的智能世界

Bring AI System to every person, home and organization for a fully connected, intelligent world.

ZOMI

GitHub https://github.com/chenzomi12/AIInfra

引用与参考

- https://mp.weixin.qq.com/s/6kzCMsJuavkZPG0YCKgeig
- https://www.zhihu.com/tardis/zm/art/677638939?source_id=1003
- https://huggingface.co/blog/zh/moe
- https://mp.weixin.qq.com/s/mOrAYo3qEACjSwcRPG7fWw
- https://mp.weixin.qq.com/s/x39hqf8xn1cUlnxEIM0_ww
- https://mp.weixin.qq.com/s/ZXjwnO103e-wXJGmmKi-Pw
- https://mp.weixin.qq.com/s/8Y281VYaLu5jHoAvQVvVJg
- https://blog.csdn.net/weixin_43013480/article/details/139301000
- https://developer.nvidia.com/zh-cn/blog/applying-mixture-of-experts-in-llm-architectures/
- https://www.zair.top/post/mixture-of-experts/
- https://my.oschina.net/IDP/blog/16513157

- PPT 开源：https://github.com/chenzomi12/AIInfra
- 夸克链接：https://pan.quark.cn/s/74fb24be8eff