

PR #20977 完整报告

sgl-project/sglang

[HiCache] Add CP support for HiCache

合并时间: 2026-04-10 17:52

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/20977>

执行摘要

- 一句话: 为 HiCache 添加注意力上下文并行 (CP) 支持, 确保缓存键正确生成。
- 推荐动作: 建议技术管理者和工程师精读此 PR, 特别关注 mooncake_store.py 中的缓存键生成逻辑和设计讨论。这有助于理解在异构并行设置下如何维护缓存一致性。

功能与动机

根据 PR 描述, 此变更主要为支持 Qwen3 CP + Hicache, 因为 MLA 模型在使用 HiCache 时会复用 CP rank 0 的数据, 因此无需区分键, 但需要将 CP 信息整合到缓存系统中以确保正确性。

实现拆解

1. 添加 CP 参数到配置类: 在 python/sglang/srt/mem_cache/cache_init_params.py 的 CacheInitParams 类和 python/sglang/srt/mem_cache/hicache_storage.py 的 HiCacheStorageConfig 类中添加 attn_cp_rank 和 attn_cp_size 字段, 为参数传递提供基础。
2. 传递参数到控制器和缓存: 在 python/sglang/srt/managers/scheduler.py 的 init_cache_with_memory_pool 方法中, 将 attn_cp_rank 和 attn_cp_size 传递给 CacheInitParams; 在 python/sglang/srt/mem_cache/hiradix_cache.py 的 __init__ 方法中接收并存储这些参数, 并传递给 HiCacheController。
3. 调整缓存键生成逻辑: 在 python/sglang/srt/mem_cache/storage/mooncake_store/mooncake_store.py 的 __init__ 方法中, 添加 attn_cp_rank 和 attn_cp_size, 并修改 mha_suffix 和 mla_suffix 的生成, 当启用 PP 或 CP 时包含 CP rank。
4. 更新监控指标标签: 在 python/sglang/srt/mem_cache/hiradix_cache.py 的 _apply_storage_runtime_config 方法中, 将 attn_cp_rank 和 attn_cp_size 添加到 metrics 标签, 以便监控。

关键文件:

- python/sglang/srt/mem_cache/storage/mooncake_store/mooncake_store.py (模块 缓存存储; 类别 source; 类型 core-logic; 符号 init): 这是缓存存储的核心逻辑文件, 直接处理缓存键生成, 变更最多且涉及控制流调整。
- python/sglang/srt/managers/cache_controller.py (模块 缓存控制; 类别 source; 类型 entrypoint; 符号 init, _generate_storage_config): 作为 HiCache 的控制器入口, 负责

管理缓存存储，变更添加了 CP 参数到初始化和配置生成。

- python/sglang/srt/mem_cache/hiradix_cache.py (模块 缓存树; 类别 source; 类型 core-logic; 符号 init, _apply_storage_runtime_config) : 作为 HiCache 的核心逻辑层, 负责初始化缓存控制器并传递 CP 参数, 同时更新监控指标。
- python/sglang/srt/managers/scheduler.py (模块 调度器; 类别 source; 类型 core-logic ; 符号 init_cache_with_memory_pool) : 作为调度器, 负责初始化缓存参数, 变更将 CP 信息传递给 CacheInitParams。
- python/sglang/srt/mem_cache/cache_init_params.py (模块 缓存参数; 类别 source; 类型 data-contract; 符号 CacheInitParams) : 定义了缓存初始化参数的基类, 变更添加 CP 字段以支持参数传递链条。
- python/sglang/srt/mem_cache/hicache_storage.py (模块 存储配置; 类别 source; 类型 data-contract; 符号 HiCacheStorageConfig) : 定义了缓存存储配置的数据类, 变更添加 CP 字段以扩展配置信息。

关键符号: CacheInitParams.init, HiCacheStorageConfig.init, HiCacheController.init, MooncakeStore.init, HiRadixCache.init, Scheduler.init_cache_with_memory_pool

关键源码片段

[python/sglang/srt/mem_cache/storage/mooncake_store/mooncake_store.py](#)

这是缓存存储的核心逻辑文件, 直接处理缓存键生成, 变更最多且涉及控制流调整。

```
def __init__(self, storage_config=None, ...):
    # ... 其他初始化代码 ...
    if storage_config is not None:
        self.is_mla_backend = storage_config.is_mla_model
        self.local_rank = storage_config.tp_rank
        self.pp_rank = storage_config.pp_rank
        self.pp_size = storage_config.pp_size
        self.attn_cp_rank = storage_config.attn_cp_rank # 新增: 注意力 CP rank
        self.attn_cp_size = storage_config.attn_cp_size # 新增: 注意力 CP size
        self.enable_storage_metrics = storage_config.enable_storage_metrics
    else:
        self.is_mla_backend = False
        self.local_rank = 0
        self.pp_rank = 0
        self.pp_size = 1
        self.attn_cp_rank = 0 # 默认值
        self.attn_cp_size = 1 # 默认值

    self.enable_pp = self.pp_size > 1
    self.enable_cp = self.attn_cp_size > 1 # 新增: 检查 CP 是否启用
    if self.enable_pp or self.enable_cp: # 逻辑调整: PP 或 CP 启用时包含所有秩
        self.mha_suffix = f"{self.local_rank}_{self.pp_rank}_{self.attn_cp_rank}"
        self.mla_suffix = f"{self.pp_rank}_{self.attn_cp_rank}"
    else:
        self.mha_suffix = f"{self.local_rank}"
```

```
self.mla_suffix = ""  
# ... 后续代码，例如处理 should_split_heads 等 ...
```

评论区精华

reviewer stmatengss 提出是否应分别检查 `enable_pp` 和 `enable_cp`，或者当仅启用 PP 时 `attn_cp_rank` 应为默认值 0。作者 ShangmingCai 回复表示，如果支持异构设置，可能应让 suffix 始终包含所有秩，即使为 0，并考虑将 pp size 和 cp size 也加入 suffix。这揭示了设计决策中的权衡。

- 缓存键生成中的 PP 和 CP 检查 (design): 作者 ShangmingCai 回复表示，如果支持异构设置，可能应该让 suffix 始终包含所有秩，即使为 0，并考虑将 pp size 和 cp size 也加入 suffix。

风险与影响

- 风险：技术风险包括：
 1. 缓存一致性风险：如果 CP 模式下缓存键生成不正确，可能导致数据不一致或错误缓存命中。
 2. 兼容性问题：新增参数可能影响现有配置，尤其是在未启用 CP 时默认值的处理。
 3. 缺少测试覆盖：从变更文件看，没有直接对应的测试文件更新，可能缺乏对 CP 支持的全面验证。
 4. 与 PR #20460 的协调：讨论中提到需要同步缓存状态，可能存在未解决的依赖。
 - 影响：对用户影响：使用 CP 并启用 HiCache 的用户（如 Qwen3 模型）将受益于更好的缓存支持，可能提升推理性能。对系统影响：扩展了 HiCache 的功能范围，使其更适应并行设置。对团队影响：需要关注与相关 PR（如 #20460）的集成，确保缓存状态同步问题得到解决。
 - 风险标记：缓存一致性风险，兼容性问题，缺少测试覆盖

关联脉络

- PR #20460 未知：在 Issue 评论中被提及，涉及缓存状态同步，与本 PR 的 CP 支持相关，可能需要协调以完善功能。