

PR #29103 完整报告

sgl-project/sglang

[AMD] Feat/dsv4 aiter reduce scatter decode

合并时间: 2026-06-26 04:45

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/29103>

执行摘要

- 一句话: DSV4 decode 用 `reduce_scatter` 替代 `all_reduce`
- 推荐动作: 该 PR 值得精读, 特别是以下设计点: 1) 平台条件默认值的实现 (`_default_hip + _resolve_default`), 避免了模块加载时引入 `torch` 依赖; 2) 在 `reduce_scatter_tensor` 中插入自定义通信尝试的扩展模式; 3) `gather` 与 `reduce_scatter` 的互斥条件设计。建议后续补充集成测试和 CUDA 图场景的专项测试。

功能与动机

在 DeepSeek-V4 DP-attention TP-MoE decode 路径 (`MAX_LEN padding`, 无 EP, `tp_size == attn_dp_size`) 中, MoE combine 之前使用 MoE 内部 `post-experts all_reduce (aiter cross_device_reduce_2stage)` 后跟 `dp_scatter`。All_reduce 移动约 2 倍于 `reduce_scatter` 的字节。本 PR 将其替换为等分 `reduce_scatter`, 使用 `aiter` 自定义 (ROCm) 或 RCCL 内核, 以降低通信开销。

实现拆解

1. `environ.py`: 添加环境变量 `SGLANG_DP_USE_REDUCE_SCATTER`, 默认值通过懒检测函数 `_default_hip` 动态确定 (ROCm/HIP 返回 True, 否则 False); 并在 `EnvField` 中增加 `_resolve_default` 方法支持可调用默认值, 避免模块加载时导入 `torch`。
2. `parallel_state.py`: 在 `GroupCoordinator.reduce_scatter_tensor` 中新增尝试 `aiter` 自定义 `reduce_scatter` 的分支 `_maybe_aiter_reduce_scatter`, 条件包括平台 (HIP)、`env` 开启、`aiter` 可用、输入输出连续且形状满足等分要求; 当 CUDA 图捕获时正确处理已注册 / 未注册缓冲区; 失败时回退到 RCCL。
3. `dp_attention.py`: 修改 `is_dp_gather_active()`, 增加 `not _DpGatheredBufferWrapper.is_dp_max_padding()` 条件, 确保 `gather` 对仅在 `SUM_LEN` 模式下启用, 与 `MAX_LEN` 下的等分 `reduce_scatter` 互斥。
4. `deepseek_v4.py`: 在 `forward` 中引入 `_use_reduce_scatter` 变量, 当满足 `MAX_LEN decode`、`tp==dp`、无 EP 且 `gather` 不活跃时启用; 将原 `_use_gather_pair` 重命名为 `_use_reduce_scatter`; 在 MoE 调用时传递 `use_reduce_scatter=True` 跳过内部 `all_reduce`, 并在 `combine` 阶段调用 `dp_reduce_scatter_tensor` (会路由到 `parallel_state` 的新逻辑)。

关键文件:

- python/sglang/srt/distributed/parallel_state.py (模块 分布式通信; 类别 source; 类型 core-logic; 符号 _has_aiter_custom_reduce_scatter, _maybe_aiter_reduce_scatter) : 核心通信方法 reduce_scatter_tensor 添加 aiter 自定义 reduce_scatter 路径, 新增 _maybe_aiter_reduce_scatter 和 _has_aiter_custom_reduce_scatter 方法, 是本次变更的枢纽。
- python/sglang/srt/envron.py (模块 环境变量与配置; 类别 source; 类型 dependency-wiring; 符号 _default_hip, _resolve_default) : 新增 SGLANG_DP_USE_REDUCE_SCATTER 环境变量及其平台条件默认值, 引入 callable default 支持, 为后续平台特性提供通用机制。
- python/sglang/srt/models/deepseek_v4.py (模块 模型实现; 类别 source; 类型 data-contract) : 模型前向逻辑中引入 _use_reduce_scatter 控制 decode 路径的 combine 策略, 修改 MoE 调用参数和 combine 分支, 是实际收益发生的位置。
- python/sglang/srt/layers/dp_attention.py (模块 DP 注意力层; 类别 source; 类型 core-logic) : is_dp_gather_active() 增加 MAX_LEN 排除条件, 使 gather 对仅用于 SUM_LEN 模式, 确保与 reduce_scatter 路径互斥。

关键符号: _has_aiter_custom_reduce_scatter, _maybe_aiter_reduce_scatter, _default_hip, _resolve_default, is_dp_gather_active

关键源码片段

python/sglang/srt/distributed/parallel_state.py

核心通信方法 reduce_scatter_tensor 添加 aiter 自定义 reduce_scatter 路径, 新增 _maybe_aiter_reduce_scatter 和 _has_aiter_custom_reduce_scatter 方法, 是本次变更的枢纽。

```
def reduce_scatter_tensor(self, output: torch.Tensor, input: torch.Tensor):
    if _is_npu:
        self._reduce_scatter_tensor(output, input)
    elif self._maybe_aiter_reduce_scatter(output, input):
        # 尝试 aiter 自定义 reduce_scatter 成功则返回
        return
    else:
        # 回退到通用 RCCL/NCCCL reduce_scatter
        reg_reduce_scatter_tensor(output, input, group_name=self.unique_name)

def _maybe_aiter_reduce_scatter(self, output: torch.Tensor, input: torch.Tensor) -> bool:
    # 条件: ROCm/HIP 平台、环境变量 SGLANG_DP_USE_REDUCE_SCATTER 开启、
    # 具有 aiter 自定义 reduce_scatter 能力、输入输出内存连续、
    # 数据类型为 fp32/fp16/bf16
    if not (
        is_hip()
        and envs.SGLANG_DP_USE_REDUCE_SCATTER.get()
        and self._has_aiter_custom_reduce_scatter()
        and input.is_contiguous()
        and output.is_contiguous()
```

```

        and input.dtype in (torch.float32, torch.float16, torch.bfloat16)
    ):
        return False
    ca_comm = self.ca_comm
    # 大小必须通过 should_custom_ar 检查
    if not ca_comm.should_custom_ar(input):
        return False
    # 等分限制: input 行数必须是 output 行数的 world_size 倍
    if input.shape[0] != output.shape[0] * self.world_size:
        return False
    # CUDA 图捕获处理
    if getattr(ca_comm, "_IS_CAPTURING", False):
        if torch.cuda.is_current_stream_capturing():
            ca_comm.reduce_scatter(input, output, registered=True)
        elif is_in_tc_pieewise_cuda_graph():
            ca_comm.reduce_scatter(input, output, registered=False)
        else:
            # 真实 CUDA 图预热阶段: 避免不同的 host 集合通信
            output.zero_()
    return True
    ca_comm.reduce_scatter(input, output, registered=False)
    return True

```

python/sglang/srt/envron.py

新增 SGLANG_DP_USE_REDUCE_SCATTER 环境变量及其平台条件默认值, 引入 callable default 支持, 为后续平台特性提供通用机制。

```

@functools.lru_cache(maxsize=1) def _default_hip() -> bool: """懒检测 ROCm/HIP 平台,
避免模块加载时导入 torch。首次调用时导入 torch 并检查 torch.version.hip; 不可用时返回 False。"""
    try:
        import torch
        return torch.version.hip is not None
    except Exception:
        return False
class EnvField:
    ...
    def _resolve_default(self) -> Any:
        # 支持可调用默认值 (如 _default_hip), 仅当环境变量未设置时计算
        return self.default() if callable(self.default) else self.default
    def get(self) -> Any:
        value = os.getenv(self.name)
        if self._set_to_none:
            assert value == str(None)
        return None if value is None:
            return self._resolve_default() # 改用可调用解析
    try:
        return self.parse(value)
    except ValueError as e:
        default = self._resolve_default()
        warnings.warn(
            f'Invalid value for {self.name}: {e}, using default "{default}"'
        )
        return default (在 Envs 类中添加:
SGLANG_DP_USE_REDUCE_SCATTER = EnvBool(_default_hip))

```

评论区精华

审核者 HaiShaw 批准了 PR, 并要求“请后续添加测试用例”。amd-bot 的 CI 状态评论指出: PR CI 无法执行核心代码路径 (需要夜间测试), AMD PR CI 不完整, 4 个失败均为预存 / 基础设施问题, 本 PR 的功能在 PR CI 中实际上未经测试。合并前已在 ROCm MI300 和 NVIDIA B200 上通过 GSM8K 验证准确率与性能。

- 测试覆盖不足 (testing): 合并前已通过 GSM8K 验证准确率和性能, 但测试需在后续 PR 补充。

风险与影响

- 风险:
 1. 平台覆盖风险: SGLANG_DP_USE_REDUCE_SCATTER 默认仅对 ROCm/HIP 开启, CUDA 平台需手动设为 1 才能使用 (会回退到 RCCL reduce_scatter), 但 CUDA 路径的验证仅在 B200 上进行过一次测试, 覆盖不足。
 2. 复杂条件回退: _maybe_aiter_reduce_scatter 包含多重条件 (HIP、env、aiter 能力、连续性、数据类型、等分形状、CUDA 图状态), 任何一条不满足就回退到 RCCL, 若回退逻辑有误可能导致 double-reduce 或错误结果。
 3. CUDA 图兼容性: 代码对 CUDA 图捕获做了三种分支处理 (已注册、分步捕获、预热), 若判断错误可能触发 host 端集合通信导致图形化失败或性能下降。
 4. 缺少单元测试: 该特性没有对应的单元测试, 依赖手动验证和夜间测试, 回归风险较高。
 - 影响: 对 AMD 用户: decode 阶段通信量减半, 预期显著提升吞吐量 (特别是 small-batch decode 场景)。对 CUDA 用户: 默认无影响, 可手动开启获得类似收益 (但需 NCCL 支持)。对项目团队: 需维护 aiter 自定义 reduce_scatter 内核及其与 RCCL 的桥接逻辑, 增加了分布式通信层的复杂度。对 DeepSeek-V4 模型: 性能优化, 准确性已确认无回归。
 - 风险标记: 仅 AMD 默认开启, 缺少单元测试覆盖, 复杂回退逻辑, CUDA 图兼容性

关联脉络

- 暂无明显关联 PR