

PR #35298 完整报告

sgl-project/sglang

[Fix] DCP: advertise the logical KV-event block size

合并时间: 2026-08-19 11:55

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/35298>

执行摘要

- 一句话: 修复 DCP 下 KV 事件块大小广告错误, 路由命中率从 0 恢复
- 推荐动作: 值得精读。三个亮点: 一是 " 契约与实现漂移导致静默故障 " 的根因分析范式——命中率恰好为 0 且本地指标健康是强信号; 二是 " 必要不充分校验 " 的取舍——讨论中确认 `tp_size % dcp_size` 既不必要 (`dist init` 已兜底) 也不充分 (真正分组维度是 `attn_tp_size`), 最终放弃; 三是跨仓库协同修复同一契约问题的协作方式, 可作为公共接口设计的参考。

功能与动机

PR body 明确指出问题的严重性与隐蔽性: "KV events are chunked by the tree's page size, so they go out at the logical width. `/server_info`'s `kv_events` descriptor advertised the physical `page_size`. A KV-aware router honoring the documented contract... hashes requests at a width no emitted block can ever match. Stores apply cleanly, every lookup misses, and the router's KV hit rate is silently exactly 0 while all local metrics look healthy." 也就是说, DCP 下路由缓存命中率静默归零, 但本地指标一切正常, 属于典型的契约与实际实现漂移导致的隐蔽故障。

实现拆解

1. 新增逻辑宽度属性: 在 `python/sglang/srt/server_args.py` 的 `ServerArgs` 上增加只读属性 `kv_event_block_size`, 实现为 `self.page_size * self.dcp_size`。该公式必须与 `mem_cache/kv_cache_configurator.py` 中分配器构建页宽、`mem_cache/kv_cache_builder.py` 中 radix tree 继承页宽保持一致, 避免三处定义漂移。
2. 修正描述器广告值: `describe_kv_events_publisher()` 返回的 `block_size` 从 `page_size` 改为 `self.kv_event_block_size`, 并同步更新 docstring 中的 wire contract 说明; 同时明确 `dp_size` 故意不按 DCP 缩放, 因为 DCP 是在 rank 内分片而非新增 publisher。该函数还保留了原先的若干防御性返回 `None` 分支 (空配置、非法 `page_size`、协议非 tcp、端口非法等), 防止占位 `block_size` 再次造成静默未命中。
3. 放弃多余的参数校验: 早期版本在 `_handle_dcp_validation` 中加入 `tp_size % dcp_size` 的 guard, review 中发现真正需要校验的是随后才解析的 `attn_tp_size`, 且 `parallel_state.py` 在 `dist init` 时已抛出 `RuntimeError("tensor_model_parallel_size (N) must be divisible by decode_context_parallel_size (M)")`, 因此最终移除该 guard, 避免重复且不充分的检查。

4. 测试配套：在 test/registered/unit/server_args/test_server_args.py 新增 TestDcpKvEventContract，覆盖 DCP (page_size=64, dcp_size=4 期望 block_size=256) 与非 DCP (期望保持 64) 两条路径，并覆盖 page_size=1 + dcp_size 的边界形态（分配器仍按 dcp_size 分页）；测试在 main 上红、修复后绿。

关键文件：

- python/sclang/srt/server_args.py (模块 服务配置；类别 source；类型 core-logic；符号 kv_event_block_size)：核心修复文件：新增 kv_event_block_size 属性并修正 describe_kv_events_publisher 的广告值，是本次契约纠偏的入口。
- test/registered/unit/server_args/test_server_args.py (模块 单元测试；类别 test；类型 test-coverage；符号 TestDcpKvEventContract, test_kv_events_descriptor_reports_logical_block_size, test_kv_event_block_size_widens_a_single_token_page)：新增 TestDcpKvEventContract 单测，锁死 DCP 与非 DCP 两条路径的 block_size 契约，防止回归。

关键符号：kv_event_block_size, describe_kv_events_publisher,
test_kv_events_descriptor_reports_logical_block_size,
test_kv_event_block_size_widens_a_single_token_page

关键源码片段

python/sclang/srt/server_args.py

核心修复文件：新增 kv_event_block_size 属性并修正 describe_kv_events_publisher 的广告值，是本次契约纠偏的入口。

```
# server_args.py —— 新增逻辑宽度属性：DCP 下事件实际发出宽度
@property
def kv_event_block_size(self) -> int:
    """KV 事件的实际发出宽度：DCP 下 radix tree 以
    ``page_size * dcp_size`` 分页（见 mem_cache/kv_cache_builder.py），
    事件也按该逻辑宽度分块，因此必须与分配器公式保持一致。
    """
    return self.page_size * self.dcp_size

def describe_kv_events_publisher(self) -> Optional[dict]:
    """构造 /server_info 中 kv_events 描述，供 KV-aware 路由器订阅。
    契约关键约束：subscribers MUST hash prompts at block_size。
    """
    # 惰性导入，避免加载 server_args 时顶层引入 disaggregation / zmq
    from sclang.srt.disaggregation.kv_events import KVEventsConfig

    raw = self.kv_events_config
    page_size = self.page_size
    # page_size 非法时返回 None：占位 block_size 会让路由器按错误粒度
    # 哈希，造成静默 KV 未命中，宁可明确告知无 publisher
    if not raw or page_size is None or page_size <= 0:
```

```

        return None
    try:
        cfg = KVEventsConfig.from_cli(raw)
    except Exception:
        # 配置损坏时服务器启动已失败，此处保持 /server_info 可访问
        return None
    if cfg.publisher == "null" or not cfg.endpoint:
        return None
    if not cfg.endpoint.startswith("tcp://"):
        return None

    # 端点 host/port 解析过程略去，逻辑与
    # ZmqEventPublisher.offset_endpoint_port 对齐

    return {
        "publisher": cfg.publisher,
        "endpoint_host": host,
        "endpoint_port_base": port,
        "topic": cfg.topic,
        # 关键修正：原实现广告物理 page_size, DCP 下路由器哈希宽度
        # 与任何实际发出的 block 都不匹配，命中率静默为 0
        "block_size": self.kv_event_block_size,
        # dp_size 故意不乘 dcp_size: DCP 在 rank 内分片，不新增 publisher
        "dp_size": self.dp_size,
    }
}

```

test/registered/unit/server_args/test_server_args.py

新增 TestDcpKvEventContract 单测，锁死 DCP 与非 DCP 两条路径的 block_size 契约，防止回归。

```

class TestDcpKvEventContract(CustomTestCase):
    """DCP 将 radix tree 页宽扩为 page_size * dcp_size, 广告的
    KV 事件块大小必须反映该逻辑宽度。"""

    KV_EVENTS = '{"publisher":"zmq","topic":"kv","endpoint":"tcp://*:5557"}'

    def test_kv_events_descriptor_reports_logical_block_size(self):
        # 广告物理 page_size 会让路由器按错误宽度哈希，命中率静默归零
        args = ServerArgs(
            model_path="dummy",
            tp_size=4,
            dcp_size=4,
            page_size=64,
            kv_events_config=self.KV_EVENTS,
        )
        # DCP 下逻辑宽度为 64 * 4 = 256
        self.assertEqual(args.describe_kv_events_publisher()["block_size"], 256)
        # 非 DCP 场景宽度保持不变，行为不受影响
        args = ServerArgs(

```

```
        model_path="dummy", page_size=64, kv_events_config=self.KV_EVENTS
    )
    self.assertEqual(args.describe_kv_events_publisher()["block_size"], 64)

def test_kv_event_block_size_widens_a_single_token_page(self):
    # page_size=1 + DCP 也是真实部署形态：分配器仍按 dcp_size 分页
    args = ServerArgs(model_path="dummy", tp_size=8, dcp_size=8, page_size=1)
    self.assertEqual(args.kv_event_block_size, 8)
```

评论区精华

Review 中的核心交锋集中在三处：

1. 参数校验的必要性与充分性：alexnailes 质疑 $tp_size \% dcp_size$ 检查 "really this is that tp_size split by the number of attention heads, does this matter here?"——因为真正参与分组的其实是 $attn_tp_size$ （在 handler 运行后才解析），且 `parallel_state.py` 已有 `dist init` 校验。作者确认后移除 guard，并在 PR body 中感谢 alexnailes 的质疑。
 2. API 形态：alexnailes 询问 `kv_event_block_size` 是否应使用 `@property`，作者采纳并改为 `property`。
 3. 文档风格：kpham-sgl 建议精简新属性的 `docstring`，作者按要求完成。
- $tp_size \% dcp_size$ 参数校验是否必要且充分 (design): 作者确认 `parallel_state.py` 在 `dist init` 时会抛出 `RuntimeError` (tp_size 必须整除 dcp_size)，该 guard 既非必要也非充分，最终移除。
 - `kv_event_block_size` 的 API 形态 (style): 作者改为 `@property`，作为派生自 `page_size` 与 `dcp_size` 的只读计算属性。
 - 新属性 `docstring` 精简 (documentation): 作者按要求精简，保留核心信息（宽度公式与出处）。

风险与影响

- 风险：
 1. 非 DCP 场景： $dcp_size=1$ 时 $kv_event_block_size == page_size$ ，行为完全不变，回归风险极低。
 2. 公式耦合风险： $kv_event_block_size = page_size * dcp_size$ 硬编码在 `server_args.py`，若未来分配器或 radix tree 的页宽公式变化（如引入显存对齐、分页因子调整），需要同步修改，否则会再次漂移；建议长期将该公式抽取为单一来源。
 3. 下游订阅方同步：sgl-router 的 `BlockSizeOracle` 与 Dynamo 集成需要拉取新的逻辑宽度；旧版本订阅方若已按物理宽度缓存，本次变更会改变其行为——但按 PR body 证据，修复前命中率本就是 0，实际无存量损失。
 4. 测试范围：单测只覆盖描述器返回值，未自动验证真实 ZMQ wire 上 `BlockStored.block_size` 与描述器一致；不过 PR body 提供了 4x H200 的端到端实测数据作为补充证据。
- 影响：

1. 对用户 / 系统: DCP 部署下 KV-aware 路由 (sgl-router、Dynamo) 的命中率从静默 0 恢复至理论上限 (实测 6 个 1686-token 提示词从 0/6 恢复到 4.2857/6), 直接提升缓存复用与吞吐; 同时揭穿了 " 本地指标正常 " 的假象。
2. 对团队: 为 KV 事件契约补充了文档化说明 (dp_size 为何不缩放、block_size 的语义), 降低后续订阅方误用概率; Dynamo 侧同步修复 (ai-dynamo/dynamo#12765) 表明该契约已成为跨仓库公共接口。
3. 影响范围: 仅作用于 /server_info 描述器和新增属性, 不触碰分配器、radix tree 与 ZMQ 发布逻辑, 回归面小。 - 风险标记: DCP 路由命中率回归, 页宽公式跨文件耦合, 下游订阅方需同步, 依赖既有 dist init 校验

关联脉络

- PR #12765 fix(sglang): use DCP-aware KV event block size: ai-dynamo/dynamo 仓库对同一问题的消费端修复: Dynamo 集成直接读取 server_args.page_size 导致事件转换器拒绝 DCP 块。本 PR 修复引擎侧广告契约, 使任何遵守契约的订阅方无需自带 DCP 感知。