

# PR #34816 完整报告

sgl-project/sglang

[Perf] Publish the WAR read-done event at DSPARK verify

合并时间: 2026-08-14 15:46

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/34816>

## 执行摘要

- 一句话: DSPARK 在 verify 发布 WAR read-done, 提升重叠调度
- 推荐动作: 值得精读, 尤其是 SharedReadBoundary.IN\_REPLAY 与 POST\_REPLAY 的语义差异, 以及推测解码算法相位 (draft\_extend / target\_verify) 如何与调度器 WAR 屏障对接。建议与 DSpark 系列近期修复 (#34782、#34759) 一起阅读, 理解 DSpark 单步 decode 同步开销的持续优化脉络。评审时可关注 spec\_info.py 中与 is\_dflash\_family 重复的判定, 建议后续清理或补充注释说明。

## 功能与动机

PR body 说明: DSPARK 没有 draft\_extend 阶段 (其 draft 在 verify 图内采样), 因此 is\_war\_publish\_phase() 对 DSPARK 从不返回 true, 调度器的 WAR 屏障退化为每个 decode 步骤的整轮 forward 粗粒度等待 (coarse whole-forward wait), 限制了重叠调度器的 launch-ahead。修复思路是像 DFLASH 一样在 verify 阶段发布 read-done, 同时明确 POST\_REPLAY 例外只面向可断图 (breakable-graph) verify 的段间重读, 而 DSPARK 使用完整不可断图, 应当走图内 IN\_REPLAY 记录路径。

## 实现拆解

1. 相位判定调整 (python/sglang/srt/speculative/spec\_info.py): 修改 SpeculativeAlgorithm.is\_war\_publish\_phase(), 把 DSPARK 显式并入发布相位判定 (self.is\_dflash\_family() or self.is\_dspark())。由于 is\_dflash\_family() 本身已包含 is\_dspark(), 这一处在语义上等价, 主要价值是显式化「DSPARK 的 verify 就是最后一个共享读阶段」这一意图, 并防止未来 dflash 家族范围调整时 DSPARK 被遗漏。结果: DSPARK 在 forward\_mode.is\_target\_verify() 时被认定为 WAR read-done 发布相位。
2. 后端读边界调整 (python/sglang/srt/layers/attention/deepseek\_v4\_backend.py): DeepseekV4AttnBackend.shared\_read\_boundary() 在 target\_verify 分支中针对 DSPARK 返回 SharedReadBoundary.IN\_REPLAY, 其他算法维持 POST\_REPLAY。理由: POST\_REPLAY 例外是给可断图 verify 跨图段重读共享状态用的; DSPARK 的 verify 重放单个完整、不可断的 CUDA 图, 遵循 out-graph/in-graph init 契约, read-done 可以在图内 (IN\_REPLAY) 记录, 从而配合上游调度器提前解除 WAR 读依赖。
3. 协同效果: 两处改动分别作用于「调度器在哪个相位发布 read-done 事件」与「后端在图内还是图后记录事件」, 共同消除 DSPARK 每步 decode 的整轮 forward 等待, 恢复 overlap 调度器的 launch-ahead。

4. 测试配套：本次未新增测试文件，回归保障依赖既有 DSPARK/DSV4 测试（`test_basic_sanity_dspark.py`、`test_dspark_kernel_parity.py`、`test_unified_radix_cache_kl_dsv4.py`），作者通过 `/rerun-test` 验证全部通过。

关键文件：

- `python/sglang/srt/speculative/spec_info.py`（模块 推测解码；类别 source；类型 core-logic；符号 `is_war_publish_phase`）：核心相位判定函数 `is_war_publish_phase` 的修改点，决定调度器在哪个相位发布 WAR read-done 事件；虽然与 `is_dflash_family` 语义重叠，但显式化了 DSPARK 的发布相位，是整个修复的语义入口。
- `python/sglang/srt/layers/attention/deepseek_v4_backend.py`（模块 注意力后端；类别 source；类型 core-logic；符号 `DeepseekV4AttnBackend.shared_read_boundary`）：`shared_read_boundary` 对 DSPARK 的 `target_verify` 返回 `IN_REPLAY` 而非默认的 `POST_REPLAY`，使 read-done 记录可以落在图内，这是本次性能收益的实际落点，也是风险最集中的位置。

关键符号：`is_war_publish_phase`, `shared_read_boundary`

## 关键源码片段

### `python/sglang/srt/speculative/spec_info.py`

核心相位判定函数 `is_war_publish_phase` 的修改点，决定调度器在哪个相位发布 WAR read-done 事件；虽然与 `is_dflash_family` 语义重叠，但显式化了 DSPARK 的发布相位，是整个修复的语义入口。

```
def is_dflash_family(self) -> bool:
    # DFLASH 与 DSPARK 共用同一族 verify 路径
    return self.is_dflash() or self.is_dspark()

def is_war_publish_phase(self, forward_mode) -> bool:
    # 一个步骤中最后一个读取共享缓冲区的阶段负责发布 WAR read-done 事件。
    # DSPARK 没有独立的 draft_extend 阶段：其 draft 直接在 verify 图内采样，
    # 因此 verify 就是这个最后阶段，需要在这里发布 read-done。
    # 注：is_dflash_family() 已包含 DSPARK，此处显式列出是为了强调意图，
    # 后续若调整 dflash 家族范围，DSPARK 的发布相位判定仍保持独立可见。
    if self.is_dflash_family() or self.is_dspark():
        return forward_mode.is_target_verify()
    # 其余算法（EAGLE 族等）以 draft_extend_v2 作为最后一个共享读阶段
    return forward_mode.is_draft_extend_v2()
```

### `python/sglang/srt/layers/attention/deepseek_v4_backend.py`

`shared_read_boundary` 对 DSPARK 的 `target_verify` 返回 `IN_REPLAY` 而非默认的 `POST_REPLAY`，使 read-done 记录可以落在图内，这是本次性能收益的实际落点，也是风险最集中的位置。

```
class DeepseekV4AttnBackend(AttentionBackend, C4IndexerBackendMixin,
                             CompressorBackendMixin):
```

```

use_captured_forward_metadata_for_breakable_cuda_graph: bool = True
supports_ragged_verify_graph: bool = True
needs_cpu_seq_lens: bool = False

def shared_read_boundary(self, forward_mode: ForwardMode) -> SharedReadBoundary:
    # 可断图 (breakable-graph) verify 在多个图段之间会重读共享状态,
    # 因此默认把 WAR read-done 边界放在图重放完成之后 (POST_REPLAY) 。
    # DSPARK 的 verify 重放单个完整、不可断的 CUDA 图,
    # 遵守 out-graph/in-graph init 契约, 可以沿用基类的 IN_REPLAY 边界,
    # 使 read-done 记录落在图内, 提前解除调度器的读依赖。
    if forward_mode.is_target_verify():
        if self.model_runner.spec_algorithm.is_dspark():
            return SharedReadBoundary.IN_REPLAY
        return SharedReadBoundary.POST_REPLAY
    return super().shared_read_boundary(forward_mode)

```

## 评论区精华

本 PR 没有 review 评论, 唯一互动是作者发起的两次 /rerun-test 与 CI bot 回报:

test\_dspark\_kernel\_parity.py (1-gpu-5090) 与 test\_unified\_radix\_cache\_kl\_dsv4.py (4-gpu-h100) 通过, 随后 test\_basic\_sanity\_dspark.py (1-gpu-h100) 也通过, 作为无新增单测时的回归保障。

- CI 回归验证 (无 review 讨论) (testing): 三个 DSPARK/DSV4 相关测试全部通过, 作为无新增单测时的回归保障。

## 风险与影响

- 风险:

1. 回归风险 (核心路径): 改动位于 decode 热路径 (overlap 调度器的 WAR 屏障语义 + DSV4 注意力后端)。如果 DSPARK 的 verify 图实际并未严格遵循 out-graph/in-graph init 契约, IN\_REPLAY 边界可能导致 read-done 提前发布, 引入写后读竞争, 影响正确性。
2. 测试缺口: 没有直接针对 WAR 屏障发布时机或 shared\_read\_boundary 行为的单元测试, 现有 DSPARK 测试通过并不能覆盖所有时机组合 (如多请求混跑、与其他 overlap 特性叠加)。
3. 语义冗余带来的维护耦合: spec\_info.py 中 or self.is\_dspark() 与 is\_dflash\_family() (其定义为 is\_dflash() or is\_dspark()) 重复。若未来把 DSPARK 移出 dflash 家族定义, 两处判定必须同步修改, 否则会产生行为漂移; 同时这也提示 PR body 所述「is\_war\_publish\_phase 从不返回 true」与实际代码存在出入, 真实收益点更多落在后端 IN\_REPLAY 边界上。- 影响: 影响面集中在 DSPARK (DeepSeek 风格推测解码) 的 decode 步骤: 每个步骤从「整轮 forward 粗粒度等待」变为「verify 相位发布 read-done」, 重叠调度器的 launch-ahead 得以恢复, 预期提升 DeepSeek 系列模型的推测解码吞吐与 GPU 利用率。代码面很小 (2 个文件、8 行新增), 但位于每步 decode 都会执行的调度与注意力后端热路径; 对 DFLASH、EAGLE 等其他推测算法的行为无影响。- 风险标记: 核心 decode 路径变更, 缺少新增测试覆盖, WAR 屏障语义

变更

## 关联脉络

- PR #34782 [Fix] Make the DSpark draft num\_token\_non\_padded host-to-device copy non-blocking: 同为 DSpark 单步 decode 的同步开销优化：前者消除每步 H2D 阻塞拷贝，本 PR 消除每步整轮 forward 粗粒度 WAR 等待，属于同一性能优化脉络。
- PR #34759 [DSpark] Fix EP1 decode performance regression: 同为 DSpark decode 路径性能修复，说明 DSpark 每步 decode 的同步与性能是近期持续关注点。
- PR #34788 [Fix] Restore layer-level DSV4 RoPE policy: 同属 DeepSeek-V4 模型链路修复，涉及 deepseek\_v4 相关后端行为；本 PR 修改的正是 DSV4 注意力后端。