

PR #27610 完整报告

sgl-project/sglang

Avoid scattered assignment of extend_input_len and fill_len by merging them into
Req.extend_range

合并时间: 2026-06-25 08:33

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/27610>

执行摘要

- 一句话: 合并 extend_input_len/fill_len 为 Req.extend_range, 消除分散赋值
- 推荐动作: 值得精读。该 PR 展示了如何通过强类型消除隐式语义二义性, 是 Req 数据结构走向更不可变、更能防御错误的良好模式。推荐跟进后续 PR #27611 (内联 property) 和 #27616 (先决条件) 了解完整演进链。

功能与动机

原实现中 extend 范围被拆分为两个独立赋值的字段, 且 start 从未显式存储, 通过 `len(prefix_indices) + extend_input_len` 重建绝对位置, 在 Disagg decode + HiCache (committed prefix 不等于 `len(prefix_indices)`) 以及 Mixed-batch running reqs (decode 步骤的 KV 未折叠进 `prefix_indices`) 两种场景下会得出错误值。

实现拆解

1. 定义 Range 类型: 在 `python/sglang/srt/utils/common.py` 新增 `Range(NamedTuple)`, 包含 start、end 字段和只读 length 属性。
2. 改造 Req 核心字段: 在 `python/sglang/srt/managers/schedule_batch.py` 中将 `self.fill_len: int` 和 `self.extend_input_len: int` 替换为 `self.extend_range: Optional[Range] = None`; 添加 `dllm_initialized: bool = False` 用于 DLLM 首次轮标志。将旧字段改为 @property 只读属性, 派生自 extend_range; 新增 `set_extend_range(start, end)` 统一设置 range 并自动重算 `extend_logprob_start_len`。
3. 替换所有写入点: 在 `schedule_policy.py`、`scheduler_pp_mixin.py`、`disaggregation/decode.py`、`scheduler.py`、`dllm/mixin/req.py` 等 6 个源文件中, 将原来分散的 `set_extend_input_len + fill_len =` 配对改为一条 `set_extend_range(start, end)`。DLLM 部分的 `_init_fill_ids_for_dllm` 不再写 `fill_len` 而是设置 `dllm_initialized = True`。
4. 同步测试适配: 修改了 `test_hispase_unit.py` (新增 `_FakeReq` 用 `extend_range` 模拟 property)、`test_decode_radix_lock_ref.py`、`test_prefill_adder.py`、`test_unified_radix_cache_unittest.py`、`test_scheduler_chunked_req_gate.py` 共 5 个测试文件, 使其 mock 或直接适配新接口。
5. 修复后续发现的 crash: 在 `scheduler.py` 的 `cache_unfinished_req` 断言中添加 `extend_range is None` 守卫, 避免 decode 阶段 range 为 None 时触发属性访问异常。

关键文件：

- python/sglang/srt/managers/schedule_batch.py (模块 调度器；类别 source；类型 core-logic；符号 fill_len, extend_input_len, set_extend_range, set_extend_input_len) : 核心数据结构 Req 的改动所在，定义新字段、property、set_extend_range 和日志逻辑调整。
- python/sglang/srt/utils/common.py (模块 通用工具；类别 source；类型 core-logic；符号 Range, length) : 定义 Range 新类型，供全局使用。
- test/registered/unit/managers/test_hispase_unit.py (模块 测试；类别 test；类型 test-coverage；符号 _FakeReq, fill_len, extend_input_len) : 测试文件中的 mock Req 改为基于 extend_range 的 property，验证新接口在 HiSparse 路径下的正确性。

关键符号：Range.length, Req.fill_len, Req.extend_input_len, Req.set_extend_range, Req._recompute_extend_logprob_start_len

关键源码片段

python/sglang/srt/managers/schedule_batch.py

核心数据结构 Req 的改动所在，定义新字段、property、set_extend_range 和日志逻辑调整。

```
# python/sglang/srt/managers/schedule_batch.py (partial)

# 旧字段被替换为单一 extend_range
self.extend_range: Optional[Range] = None # None 表示 decode/idle/retract 状态
self.dllm_initialized: bool = False # 替代旧的 fill_len is None 作为 DLLM 首次轮标志

# 保留原属性名作为只读 property，确保所有读端无需改动
@property
def fill_len(self) -> int:
    return self.extend_range.end

@property
def extend_input_len(self) -> int:
    return self.extend_range.length

def set_extend_range(self, start: int, end: int) -> None:
    """统一设置 extend 范围，自动更新 logprob 偏移。"""
    self.extend_range = Range(start, end)
    self._recompute_extend_logprob_start_len()

def _recompute_extend_logprob_start_len(self):
    """根据 extend_range 和 logprob_start_len 计算相对偏移。"""
    if self.logprob_start_len == -1:
        logprob_start_len = len(self.full_untruncated_fill_ids)
    else:
        logprob_start_len = self.logprob_start_len
    self.extend_logprob_start_len = logprob_start_len - self.extend_range.start
```

test/registered/unit/managers/test_hispase_unit.py

测试文件中的 mock Req 改为基于 extend_range 的 property，验证新接口在 HiSparse 路径下的正确性。

```
# test/registered/unit/managers/test_hispase_unit.py (partial)

from sglang.srt.utils.common import Range

class _FakeReq(SimpleNamespace):
    """模拟 Req 的 extend_range 属性，用于单元测试。"""
    @property
    def fill_len(self) -> int:
        return self.extend_range.end

    @property
    def extend_input_len(self) -> int:
        return self.extend_range.length

def _make_req(rid="test-req-0", origin_input_ids=None, output_ids=None):
    # ... 原本使用 SimpleNamespace + set_extend_input_len lambda
    req = _FakeReq(
        rid=rid,
        # ...
    )
    req.set_extend_range = lambda start, end: setattr(req, "extend_range", Range(start, end))
    return req
```

评论区精华

唯一有人参与的讨论是作者自己在 CI 下游 PR #27611 中发现 `cache_unfinished_req` 的断言在 `extend_range is None` 时崩溃，随后在该 PR 中修复并提及。未出现设计层面的争论。

- `cache_unfinished_req` 断言在 `extend_range is None` 时 crash (correctness): 已修复: decode 等非 extend 状态下不再因属性访问而异常。

风险与影响

- 风险:
 1. 行为保持假设风险: 所有写入点都按 `start = end - old_length` 计算，但若存在未覆盖的写入路径（如分叉分支或后续新增代码），可能导致 range 不一致。
 2. DLLM 标志替换风险: `dllm_initialized` 完全替代了旧的 `fill_len is None` 检查，如果任一生命周期路径未设置该标志（如极端 retract 场景），可能导致阶段判断错误。
 3. 测试覆盖风险: 作者注明未手动运行测试，仅依赖 CI；测试覆盖可能不充分（尤其 HiCache 和 mixed-batch 组合场景）。- 影响: 内部接口重构: 影响所有涉及 extend 范围赋值的调度路径，但 property 保持读接口兼容，外部模块无感知。DLLM 模块: 首次轮标志改变，可能与其他依赖 `fill_len` 的遗存代码冲突。测试: 五处测试适配，需确保 mock 行为与真实 Req 一致。影响程度中等，因为改动范围集中但全局调度依赖该数据结

构。 - 风险标记：核心路径变更，DLLM 初始化标志替换，行为保持假设，测试覆盖可能不足

关联脉络

- PR #27611 Inline extend_range accessors and remove the extend_input_len/fill_len properties: 本 PR 的后继：将 extend_range property 内联为直接字段访问，完成字段合并的最终清理。
- PR #27616 Avoid dual semantics of extend_input_len by computing the candidate on the fly: 本 PR 的先决条件：将 init_next_round_input 中的候选长度改为动态计算，消除了 extend_input_len 的双重语义，使本 PR 中的字段合并得以进行。
- PR #27625 Remove Req.extend_logprob_start_len field and make it pure: 进一步重构：移除 extend_logprob_start_len 字段，改为纯自由函数，本 PR 中已开始依赖。