

# PR #25980 完整报告

sgl-project/sglang

Fix spec v2 stop output boundary

合并时间: 2026-06-09 15:32

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/25980>

## 执行摘要

- 一句话: 修复 spec v2 停止边界, 确保多 token 接受时输出正确截断
- 推荐动作: 值得精读。展示了如何在推测解码中精确处理 stop 边界, 以及如何通过精细化测试覆盖多种边界情况。特别关注 `_locate_str_stop_finished_len` 的扫描算法和 `trim_matched_stop` 中 `no_stop_trim` 的处理。

## 功能与动机

This PR fixes a stop boundary issue under spec v2. When spec v2 accepts multiple tokens in one step, a stop string may appear before the end of the accepted tokens. In that case, tokens after the matched stop should not be emitted. This is an enhancement to #23802: after the stop match is detected, this PR ensures the final emitted output is cut at the actual stop boundary.

## 实现拆解

1. 抽取 `tail_len` 计算: 在 `schedule_batch.py` 中新增 `_stop_match_tail_len` 方法, 将 `tail_len` 计算逻辑从 `tail_str` 中提取出来, 供后续 `_locate_str_stop_finished_len` 复用。
2. 新增精确定位方法: 新增 `_locate_str_stop_finished_len` 方法, 在新接受 token 范围内逐步 decode 并检查 stop 字符串 / regex, 返回 stop 在 `output_ids` 中的精确结束位置。通过从 `len(token_window) - new_accepted_len + 1` 开始循环, 节省 decode 开销。
3. 修改 finish 检查: 在 `_check_str_based_finish` 中, 当 stop 字符串在 `tail_str` 中匹配时, 调用 `_locate_str_stop_finished_len` 设置 `finished_len`, 确保后续 `output_ids_through_stop` 只包含 stop 之前的 token。
4. 完善 detokenizer 逻辑: 修改 `detokenizer_manager.py` 的 `trim_matched_stop` 方法, 正确处理 `no_stop_trim` 参数: 当 `no_stop_trim=True` 时保留 stop 字符串但截断后续内容, 当 `no_stop_trim=False` 时移除 stop 字符串及其后内容。
5. 测试覆盖: 新增 `test_trim_matched_stop.py` 测试 detokenizer 行为, 增强 `test_stop_str_speculative.py` 测试多种 stop 边界场景 (midchunk、chunk end、跨 token、regex 等), 均注册为 CPU 单元测试。

关键文件:

- `python/sglang/srt/managers/schedule_batch.py` (模块 请求调度; 类别 source; 类型 core-logic; 符号 `_stop_match_tail_len`, `_locate_str_stop_finished_len`, `matched`): 核

心变更：新增 `_stop_match_tail_len` 和 `_locate_str_stop_finished_len` 方法，修改 `_check_str_based_finish` 以设置 `finished_len`，是修复输出边界的主要逻辑。

- `python/sglang/srt/managers/detokenizer_manager.py`（模块 输出处理；类别 `source`；类型 `core-logic`；符号 `trim_matched_stop`）：修改 `trim_matched_stop` 方法，正确处理 `no_stop_trim` 参数，是输出截断的配套变更。
- `test/registered/unit/managers/test_trim_matched_stop.py`（模块 测试；类别 `test`；类型 `test-coverage`；符号 `_trim`, `TestTrimMatchedStop`, `test_no_finished_reason_returns_output`, `test_no_matched_returns_output`）：新增测试文件，全面覆盖 `trim_matched_stop` 在 `spec` 场景下的各种边界情况。
- `test/registered/unit/managers/test_stop_str_speculative.py`（模块 测试；类别 `test`；类型 `test-coverage`；符号 `_make_req`, `test_stop_str_midchunk_finishes`, `test_no_stop_does_not_finish`, `test_stop_str_midchunk`）：增强测试，增加对 `_locate_str_stop_finished_len` 多种分支的测试（`midchunk`、`chunk end`、非 `spec`、跨 `token`、`regex`）。

关键符号：`_stop_match_tail_len`, `_locate_str_stop_finished_len`, `_check_str_based_finish`, `trim_matched_stop`

## 关键源码片段

### `python/sglang/srt/managers/schedule_batch.py`

核心变更：新增 `_stop_match_tail_len` 和 `_locate_str_stop_finished_len` 方法，修改 `_check_str_based_finish` 以设置 `finished_len`，是修复输出边界的主要逻辑。

```
def _locate_str_stop_finished_len(
    self,
    new_accepted_len: int,
    *,
    stop_str: Optional[str] = None,
    stop_regex: Optional[str] = None,
) -> int:
    """将匹配的 stop 字符串/regex 映射到 output_ids 长度（包含 stop）"""
    def matched(text: str) -> bool:
        if stop_str is not None:
            return stop_str in text
        return re.search(stop_regex, text) is not None

    tail_len = self._stop_match_tail_len(new_accepted_len)
    start = len(self.output_ids) - tail_len
    token_window = self.output_ids[start:]

    # 只检查包含至少一个新接受 token 的前缀，因为旧前缀在前一步已检查过
    for token_count in range(
        max(1, len(token_window) - new_accepted_len + 1), len(token_window)
    ):
        if matched(self.tokenizer.decode(token_window[:token_count])):
            return start + token_count
```

```

# 完整窗口已知匹配, 返回全长度 (fallback)
return len(self.output_ids)

def _check_str_based_finish(self, new_accepted_len: int = 1):
    if (
        len(self.sampling_params.stop_strs) > 0
        or len(self.sampling_params.stop_regex_strs) > 0
    ):
        tail_str = self.tail_str(new_accepted_len)
        # 检查 stop 字符串
        if len(self.sampling_params.stop_strs) > 0:
            for stop_str in self.sampling_params.stop_strs:
                stop_str_in_tail = stop_str in tail_str
                if stop_str_in_tail or stop_str in self.decoded_text:
                    self.finished_reason = FINISH_MATCHED_STR(matched=stop_str)
                    if stop_str_in_tail:
                        # 设置精确的 finished_len, 确保后续 token 被截断
                        self.finished_len = self._locate_str_stop_finished_len(
                            new_accepted_len, stop_str=stop_str
                        )
            return True

```

### python/slang/srt/managers/detokenizer\_manager.py

修改 `trim_matched_stop` 方法, 正确处理 `no_stop_trim` 参数, 是输出截断的配套变更。

```

def trim_matched_stop(
    self, output: Union[str, List[int]], finished_reason: Dict, no_stop_trim: bool
):
    if not finished_reason:
        return output

    matched = finished_reason.get("matched", None)
    if not matched:
        return output

    # 处理 stop 字符串
    if isinstance(matched, str) and isinstance(output, str):
        pos = output.find(matched)
        if pos == -1:
            return output
        end = pos + len(matched)
        # no_stop_trim=True 时保留 stop 字符串, False 时移除 stop 及之后内容
        return output[:end] if no_stop_trim else output[:pos]

    # 处理 stop token
    if isinstance(matched, int) and isinstance(output, list):
        if no_stop_trim:
            return output

```

```
# 特殊处理 gpt-oss 工具调用 token
if output[-1] == 200012 and self.is_tool_call_parser_gpt_oss:
    return output
assert len(output) > 0
return output[:-1]
```

```
return output
```

## 评论区精华

在 review 中, gemini-code-assist[bot] 建议优化 `_locate_str_stop_finished_len` 的循环起始点: 由于完整窗口已知匹配且旧前缀已检查过, 只需从包含新接受 token 的前缀开始搜索, 可显著减少 decode 调用。开发者采纳该建议并实现。最终由 hnyls2002 批准合并。

- `_locate_str_stop_finished_len` 性能优化 (performance): 开发者采纳建议并实现。

## 风险与影响

- 风险:

1. 推测解码核心路径变更: 修改了 `schedule_batch.py` 中的 `finish` 检查逻辑, 可能影响非 spec 路径, 但测试覆盖了 `new_accepted_len=1` 的 non-spec 场景。
2. detokenizer 逻辑变更: `trim_matched_stop` 行为变化 (尤其 `no_stop_trim`), 需确保与上游调用兼容。
3. 性能影响: 新增 `decode` 调用可能带来微小开销, 但通过循环优化已控制。
4. 兼容性: 旧版本中多 token 接受后输出可能包含 `stop` 后 token, 此修复会改变行为, 但这是正确的。- 影响: 影响所有使用 `stop` 字符串或 `stop regex` 的请求, 特别是启用推测解码并接受多 token 的场景。对正确性至关重要, 性能影响极小。团队需更新可能依赖之前错误输出行为的测试。新增单元测试可在 CPU CI 中运行, 确保回归。- 风险标记: 推测解码路径变更, 输出截断逻辑变更, `no_stop_trim` 行为变化

## 关联脉络

- PR #23802 fix: stop-string check misses early matches during speculative decoding: 本 PR 是 #23802 的增强, 在早期匹配基础上进一步确保输出边界正确截断。