

PR #32078 完整报告

sgl-project/sglang

[feat] Opt-in flat response format for prompt top logprobs

合并时间: 2026-07-27 14:44

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/32078>

执行摘要

- 一句话: 新增 opt-in 扁平 top logprobs 响应格式, 序列化性能提升 1.9 倍
- 推荐动作: 值得精读。该 PR 以极小侵入性实现了显著的序列化性能提升, 设计决策清晰 (opt-in、null_prefix 处理、缓存复用), 且与后续优化形成递进路径。可作为服务端响应格式优化的参考案例, 尤其适合对序列化开销敏感的团队借鉴。

功能与动机

大量使用 prompt top logprobs 的工作负载 (RL teacher、蒸馏、离线评分) 中, 响应序列化占据请求延迟的很大比例。嵌套格式每位置每 topk 生成小列表, `json.dumps` 类型分派开销大, 且 `null` 文本槽位对批量消费者无用。两个长同质数组消除了所有三个问题, 客户端可直接用 `np.asarray(...).reshape(shape)` 消费。PR body 提供的基准测试 (32768 位置、k=2) 显示: 嵌套格式往返 102.7ms, 扁平格式 55.1ms (1.9 倍), payload 大小从 2,417,567 字节降至 1,827,898 字节。

实现拆解

1. 请求参数扩展 (`io_struct.py`): 在 `GenerateReqInput` 类中添加 `return_flat_raw_top_logprobs: bool = False` 字段。在 `normalize_batch_and_arguments` 的 `_validate_inputs` 中增加检查: 若开启扁平格式同时设置了 `multi_item_delimiter_indices`, 则抛出 `ValueError`, 因为多条目评分会产生不连续的 top logprobs 行, 无法用 `(shape, null_prefix)` 表示。此外, 在 `__getitem__` 中传播该标志, 确保 batch 拆分后每个子请求也携带该设置。
2. 状态缓存 (`tokenizer_manager.py`): 在 `ReqState` 数据类中添加两个缓存字段 `input_top_logprobs_flat_fields: Optional[Dict]` 和 `input_top_logprobs_flat_num_rows: int` (默认 -1), 用于跨预填充 chunk 复用扁平化结果, 避免 streaming decode chunk 重复构建。
3. 扁平化构造函数 (`tokenizer_manager.py`, 新增模块级函数 `_build_flat_input_top_logprobs_fields`): 接收 `input_top_logprobs_val`、`input_top_logprobs_idx` 列表和 `top_logprobs_num`。先扫描前导 null 行 (`None` 或空) 计入 `null_prefix`, 然后提取有效行; 校验有效行的长度等于 k (第一个有效行长度或 `top_logprobs_num` 提供的兜底值), 若出现非 null 但长度不等的行则抛出 `ValueError`, 因为这种不规则模式无法通过 `(shape, null_prefix)` 映射。最终生成四个字段: `input_top_logprobs_val_flat` (一维浮点列表)、`input_top_logprobs_idx_flat` (一维整数

列表)、`input_top_logprobs_shape` (`[rows, k]`)、`input_top_logprobs_null_prefix` (前导无效位置数)。

4. 主路径集成 (`tokenizer_manager.py`, 修改 `TokenizerManager.add_logprob_to_meta_info` 方法) : 在原有嵌套路径分支旁新增条件: 当 `state.obj.return_flat_raw_top_logprobs` 为 `True` 时, 调用 `_build_flat_input_top_logprobs_fields` 构建扁平字段, 将其直接写入 `meta_info`, 并跳过对 `state.input_top_logprobs` (分割化的 `detokenize` 版本) 的后续更新, 因为扁平格式不需要文本解码。构建的结果缓存在 `state.input_top_logprobs_flat_fields`, 仅当累积更多预填充 `chunk` 导致行数增加时才重建。
5. 单元测试 (`test/registered/unit/managers/test_flat_raw_top_logprobs.py`, 新增306行) : 通过 `_TokenizerManagerStub` 代理真实管理器的 `add_logprob_to_meta_info` 方法, 避免全量初始化。覆盖场景包括: 标志默认关闭且有效、批量传播、多条目拒绝; 扁平 vs 嵌套数值等价性及索引公式重建 ($(i - \text{null_prefix}) * k + j$); 全 `null` 行返回 `shape [0, k]`; 不规则 `null` (非前缀空行) 被 `builder` 拒绝; 还有环境门控的序列化基准测试。

关键文件:

- `python/sglang/srt/managers/tokenizer_manager.py` (模块 管理器; 类别 `source`; 类型 `core-logic`; 符号 `_build_flat_input_top_logprobs_fields`, `add_logprob_to_meta_info`) : 核心实现文件: 新增 `_build_flat_input_top_logprobs_fields` 函数负责将嵌套行拍平为同质数组并计算元信息; 修改 `add_logprob_to_meta_info` 方法根据 `opt-in` 标志选择扁平或嵌套路径; 在 `ReqState` 中添加缓存字段以复用跨 `chunk` 的扁平化结果。
- `python/sglang/srt/managers/io_struct.py` (模块 请求定义; 类别 `source`; 类型 `core-logic`; 符号 `GenerateReqInput.return_flat_raw_top_logprobs`, `GenerateReqInput._validate_inputs`) : 请求结构体定义: 添加 `return_flat_raw_top_logprobs` 字段及其默认值, 并在 `_validate_inputs` 中增加与多条目评分的不兼容检查, 确保不合法的配置在早期即被拒绝。
- `test/registered/unit/managers/test_flat_raw_top_logprobs.py` (模块 单元测试; 类别 `test`; 类型 `test-coverage`; 符号 `_TokenizerManagerStub`, `_make_state`, `_add_logprob_meta_info`, `TestFlatRawTopLogprobsValidation`) : 完整的单元测试套件 (306 行), 通过 `_TokenizerManagerStub` 模拟 `TokenizerManager` 的 `logprob` 方法, 覆盖标志验证、批量传播、多条目拒绝、扁平与嵌套数值等价、全 `null` 行处理、不规则行拒绝等场景, 并包含环境门控基准测试, 确保实现正确性。

关键符号: `_build_flat_input_top_logprobs_fields`,

`TokenizerManager.add_logprob_to_meta_info`, `GenerateReqInput._validate_inputs`

关键源码片段

`python/sglang/srt/managers/tokenizer_manager.py`

核心实现文件: 新增 `_build_flat_input_top_logprobs_fields` 函数负责将嵌套行拍平为同质数组并计算元信息; 修改 `add_logprob_to_meta_info` 方法根据 `opt-in` 标志选择扁平或嵌套路径; 在 `ReqState` 中添加缓存字段以复用跨 `chunk` 的扁平化结果。

```
def _build_flat_input_top_logprobs_fields(    input_top_logprobs_val:
List[Optional[List[float]]],    input_top_logprobs_idx: List[Optional[List[int]]],
```

```

top_logprobs_num: int, ) -> Dict[str, Any]: """构建扁平化 prompt top logprob 响应字段。
`input_top_logprobs_shape` 是字面量 `[rows, k]` 数组形状。
`input_top_logprobs_null_prefix` 计数前导无效位置（无 top logprobs 的位置）， 这些位置
在数组之前，有效位置 i 的 entry j 位于 `flat[(i - null_prefix) * k + j]`。 """
num_rows = len(input_top_logprobs_val)
null_prefix = 0
# 扫描前导空行（None 或空列表）， 计入 null_prefix
while null_prefix < num_rows and not
input_top_logprobs_val[null_prefix]:
    null_prefix += 1
val_rows =
input_top_logprobs_val[null_prefix:]
idx_rows = input_top_logprobs_idx[null_prefix:]
# k 取第一个有效行长度，若全空则 fallback 到 top_logprobs_num
k =
len(val_rows[0]) if val_rows else top_logprobs_num
for offset, row in
enumerate(val_rows):
    if row is None or len(row) != k:
        # 不规则行（非前导空行、长度不一致）无法用 (shape, null_prefix) 表示
        raise ValueError(
            "return_flat_raw_top_logprobs requires rectangular top logprob "
            f"rows with nulls only in the leading prefix; row{null_prefix+offset}"
            f"has{NoneifrowisNoneelseslen(row)}entries (expected{k})."
        )
    fields: Dict[str, Any] = {}
    fields["input_top_logprobs_val_flat"] = [v for row in val_rows for v in row]
    fields["input_top_logprobs_idx_flat"] = [i for row in idx_rows for i in row]
fields["input_top_logprobs_shape"] = [len(val_rows), k]
fields["input_top_logprobs_null_prefix"] = null_prefix
return fields # 在
add_logprob_to_meta_info 中，约第 2264 行附近
if top_logprobs_num > 0:
    use_flat =
state.obj.return_flat_raw_top_logprobs # type: ignore[union-attr]
if use_flat:
    # 扁平路径：跳过 detokenize，直接构建扁平字段并缓存
    if
state.input_top_logprobs_flat_fields is None or \
len(state.input_top_logprobs_val) != state.input_top_logprobs_flat_num_rows:
state.input_top_logprobs_flat_fields = _build_flat_input_top_logprobs_fields(
    state.input_top_logprobs_val,
    state.input_top_logprobs_idx,
    top_logprobs_num,
)
state.input_top_logprobs_flat_num_rows =
len(state.input_top_logprobs_val)
meta_info.update(state.input_top_logprobs_flat_f
ields)
else:
    # 嵌套路径（原逻辑）：detokenize 后写入 input_top_logprobs
if len(state.input_top_logprobs_val) > len(state.input_top_logprobs):
state.input_top_logprobs.extend(
    self.detokenize_top_logprobs_tokens(
        state.input_top_logprobs_val[len(state.input_top_logprobs):],
state.input_top_logprobs_idx[len(state.input_top_logprobs):],
return_text_in_logprobs,
)
meta_info["input_top_logprobs"]
= state.input_top_logprobs

```

test/registered/unit/managers/test_flat_raw_top_logprobs.py

完整的单元测试套件（306 行），通过 `_TokenizerManagerStub` 模拟 `TokenizerManager` 的 `logprob` 方法，覆盖标志验证、批量传播、多条目拒绝、扁平与嵌套数值等价、全 null 行处理、不规则行拒绝等场景，并包含环境门控基准测试，确保实现正确性。

```

class TestFlatAssembly(CustomTestCase):
    """验证 _build_flat_input_top_logprobs_fields 的正确性。"""

    def test_flat_matches_nested_rows(self):

```

```

# 模拟 4 个 prompt 位置，前 1 个为空，后 3 个各含 k=2 个 top logprobs
val_rows = [None, [-0.1, -2.5], [-0.3, -1.5], [-0.05, -4.0]]
idx_rows = [None, [11, 22], [33, 44], [55, 66]]
fields = _build_flat_input_top_logprobs_fields(val_rows, idx_rows, top_logprobs_num=2)

# 验证元信息
self.assertEqual(fields["input_top_logprobs_shape"], [3, 2]) # 3 个有效行
self.assertEqual(fields["input_top_logprobs_null_prefix"], 1) # 前 1 个空行

# 验证扁平数组内容：跳过前导空行，依次连接有效行
expected_vals = [-0.1, -2.5, -0.3, -1.5, -0.05, -4.0]
expected_idxxs = [11, 22, 33, 44, 55, 66]
self.assertEqual(fields["input_top_logprobs_val_flat"], expected_vals)
self.assertEqual(fields["input_top_logprobs_idx_flat"], expected_idxxs)

# 验证索引公式：位置 i 的 entry j 位于 flat[(i - null_prefix) * k + j]
rows, k = fields["input_top_logprobs_shape"]
null_prefix = fields["input_top_logprobs_null_prefix"]
flat_val = fields["input_top_logprobs_val_flat"]
self.assertEqual(len(flat_val), rows * k)
for i in range(null_prefix, null_prefix + rows):
    start = (i - null_prefix) * k
    self.assertEqual(flat_val[start: start + k], val_rows[i])

def test_all_null_rows(self):
    # 所有行均为 null，应返回 shape [0, k] 和空数组
    fields = _build_flat_input_top_logprobs_fields([None], [None], top_logprobs_num=2)
    self.assertEqual(fields["input_top_logprobs_shape"], [0, 2])
    self.assertEqual(fields["input_top_logprobs_null_prefix"], 1)
    self.assertEqual(fields["input_top_logprobs_val_flat"], [])
    self.assertEqual(fields["input_top_logprobs_idx_flat"], [])

def test_rejects_null_row_after_prefix(self):
    # 非前导空行（如第 3 行为 None）应该被拒绝
    with self.assertRaisesRegex(ValueError, "leading prefix"):
        _build_flat_input_top_logprobs_fields(
            [None, [-0.1, -2.5], None, [-0.3, -1.5]],
            [None, [11, 22], None, [33, 44]],
            top_logprobs_num=2,
        )

```

评论区精华

该 PR 没有收到实质性 review comments，仅由维护者 Qiaolin-Yu 直接批准合并。主要设计决策（opt-in 扁平格式、null_prefix 表示、不支持多条目、后续 base64 编码）由作者在 PR body 中详细阐述，未引发额外争论。

- 无实质讨论 (other): 直接合并

风险与影响

- 风险:

1. 仅覆盖 prompt 侧: 新标志仅影响 input_top_logprobs (prompt 侧), output 侧保持嵌套格式, 可能让用户误以为全面扁平化。需在文档中明确。
2. 多条目评分不兼容: 若用户同时启用 return_flat_raw_top_logprobs 和多条目, 会在验证阶段抛出 ValueError, 不会静默产生错误输出。
3. 消费者依赖: 扁平字段不包含文本 (text), 要求消费者已具备 token 解码能力或不需要文本。若消费者需要文本, 需继续使用嵌套格式。
4. 默认行为不变: 标志默认 False, 旧客户端不受影响, 升级安全。
5. 测试覆盖完善: 单元测试覆盖了正常路径、边界条件和不合法输入, 回归风险较低。但缺少端到端集成测试 (需后端运行)。- 影响: 用户: 启用 return_flat_raw_top_logprobs 的请求, 响应序列化速度提升约 2 倍 (扁平) 乃至 7.8 倍 (配合 base64), payload 减少 30%-65%, 对于高频 top logprobs 消费工作负载 (RL 训练、离线评估) 显著改善吞吐和延迟。系统: 默认无影响; 新增字段仅在一次函数调用中计算, 逻辑轻量。团队: 代码增量小 (3 文件 +407/-9), 维护成本低; 设计与后续 base64 编码 (#31960) 直接兼容, 为渐进优化留出空间。

- 风险标记: opt-in 特性, 多条目不兼容, 输入侧仅 prompt

关联脉络

- PR #31960 [feat] Add base64 binary encoding for flat top logprobs: stacked follow-up : 在扁平格式基础上进一步减少 payload 大小, 使往返时间从 55ms 降至 13ms。PR body 中明确提及。
- PR #31958 [perf] Companion performance improvement for prompt top logprobs: 配套性能优化 PR, 与本次扁平化协同提升整体效率。PR body 中提及。