

PR #32223 完整报告

sgl-project/sglang

[perf] Assemble flat prompt top logprobs scheduler-side as numpy arrays

合并时间: 2026-08-01 09:00

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/32223>

执行摘要

- 一句话: 调度器侧扁平化 prompt top logprobs 数组, 两跳 IPC 省约 30ms
- 推荐动作: 值得精读。三个设计点尤其值得借鉴: (1) 把数据面“组装前移 + 可选字段 + 默认 None”的兼容策略——新字段只对 opt-in 请求非 None, 未使用方 wire 不变; (2) 共享校验原语 `build_flat_input_top_logprobs_arrays` 在 scheduler 与 tokenizer 两个进程复用, 保证 fallback 语义一致; (3) 提交了 env-gated 的可复现序列化 microbench。需要留意的是 ch-wan 提出的缓存遮蔽与 idx 校验两个未解决的健壮性问题, 未来若把 flat 格式扩展到 MIS 或其他请求路径, 应先补齐这些防御。

功能与动机

PR body 明确指出: 即便 #32078/#31960 已让 response 侧序列化变便宜, scheduler 仍把 prompt top logprobs 以嵌套的逐位置 Python 列表形式放在 `BatchTokenIDOutput/BatchStrOutput` 里跨两跳 ZMQ (scheduler → detokenizer → tokenizer manager) 传输。实测数据: 32768 位置、k=2 时嵌套形式 `pickle.dumps` 5.0ms + `pickle.loads` 10.3ms、1.12MB; 扁平 f32/i32 数组仅 0.03ms + 0.03ms、0.53MB。作者估算每跳省约 15ms、两跳共约 30ms, 且发生在服务器两个最忙的单例事件循环上。

实现拆解

按以下 5 步拆解:

1. 共享转换原语下沉到 `io_struct`: `python/sglang/srt/managers/io_struct.py` 新增 `build_flat_input_top_logprobs_arrays`, 把嵌套行统一转换为 `(float32 [rows,k], int32 [rows,k], null_prefix)` 三元组, 并校验“仅前导 null、每行长度均为 k”的矩形约束, 不满足时抛 `ValueError`。同时 `TokenizedGenerateReqInput` 增加 `return_flat_raw_top_logprobs` 布尔位, 随 `GenerateReqInput` → `TokenizedGenerateReqInput` → `Req` 一路传递 (`scheduler.py` 构造 `Req` 时透传, `schedule_batch.py` 的 `ReqLogprob` 增加三个 flat 字段用于承载数组)。
2. scheduler 侧组装: `python/sglang/srt/managers/scheduler_components/logprob_result_processor.py` 在 `add_input_logprob_return_values` 的 `relevant_tokens_len` 断言之后新增 `_flatten_input_top_logprobs`, 对 opt-in 请求调用共享原语; 成功则清空嵌套行 (后续 batch 输出只带数组), 失败则保留嵌套格式并打 WARNING, 语义与 tokenizer manager 既有 fallback 完全对齐。

3. IPC 线格式扩展: BatchTokenIDOutput/BatchStrOutput 增加 input_top_logprobs_val_flat / idx_flat / null_prefix 三个可选字段; output_streamer.py 在 _GenerationStreamAccumulator 中收集这三个字段, 并仅在 batch 中存在 opt-in 请求时 (has_input_top_logprobs_flat) 才写入 payload, 普通路径保持 None, 从而对未使用方 wire 完全不变; multi_tokenizer_mixin.py 与 detokenizer_manager.py 分别按索引拆分 / 透传字段。
4. tokenizer 侧消费: tokenizer_manager.py 的 convert_logprob_style 把数组中转到 ReqState.input_top_logprobs_scheduler_flat (三者成组赋值); add_logprob_to_meta_info 优先走新函数 _build_flat_input_top_logprobs_fields_from_arrays (b64 模式 tobytes() 后 base64, 非 b64 模式 tolist()), 并复用 input_top_logprobs_flat_fields 缓存; 行版 _build_flat_input_top_logprobs_fields 改为复用同一原语做合法性检查, 但非 b64 分支仍从原始行 flatten, 以保持旧路径 JSON 数值的 float64 精度。
5. 测试配套: test/registered/unit/managers/test_flat_raw_top_logprobs.py 新增 28 个用例 (+367 行), 覆盖 flag on/off 行为差异、分块 prefill 与一次性 prefill 结果一致、参差行 fallback (assertLogs 验证告警)、from-arrays 与 from-rows 逐字段等价 (flat / b64 / 全 null)、pickle 与 msgpack 双传输 roundtrip、默认 None wire 检查, 并提交了一个环境变量门控的序列化 microbench。

关键文件:

- python/sglang/srt/managers/tokenizer_manager.py (模块 分词管理; 类别 source; 类型 core-logic; 符号 _build_flat_input_top_logprobs_fields_from_arrays, add_logprob_to_meta_info, convert_logprob_style): tokenizer 侧消费 scheduler 数组的核心: 新增 _build_flat_input_top_logprobs_fields_from_arrays, ReqState.input_top_logprobs_scheduler_flat 状态, 并在 add_logprob_to_meta_info / convert_logprob_style 中接入数组路径, 同时保留嵌套回退。
- python/sglang/srt/managers/scheduler_components/logprob_result_processor.py (模块 概率输出; 类别 source; 类型 dependency-wiring; 符号 _flatten_input_top_logprobs): scheduler 侧组装入口: 新增 _flatten_input_top_logprobs, 在 prefill 长度断言后把嵌套行转数组并清空嵌套列表, 是性能收益的起点。
- python/sglang/srt/managers/io_struct.py (模块 传输结构; 类别 source; 类型 core-logic; 符号 build_flat_input_top_logprobs_arrays): 共享转换原语 build_flat_input_top_logprobs_arrays 与两个 batch 输出结构的新增可选字段定义, 是整个数据面契约所在, 两个进程共用同一套矩形性校验。
- python/sglang/srt/managers/scheduler_components/output_streamer.py (模块 输出流; 类别 source; 类型 core-logic): 负责把 Req 上的 flat 数组收集进 batch payload, 并用 has_input_top_logprobs_flat 保证普通请求 wire 不变。
- test/registered/unit/managers/test_flat_raw_top_logprobs.py (模块 概率输出; 类别 test; 类型 test-coverage; 符号 _make_logprob_processor, TestSchedulerFlatAssembly, test_flat_arrays_replace_nested_rows, test_chunked_matches_one_shot): 28 个新增测试用例, 覆盖 scheduler 组装 (flag on/off、chunked 与 one-shot 等价、参差 fallback)、tokenizer 两条路径逐字段等价、

pickle/msgpack roundtrip 与默认 None wire 检查, 另有 env-gated 序列化 bench。

- python/sclang/srt/managers/schedule_batch.py (模块 请求批次; 类别 source; 类型 core-logic) : ReqLogprob 增加三个 flat 字段、Req.__init__ 接收并保存 return_flat_raw_top_logprobs, 是请求级状态传递的底座。

关键符号: build_flat_input_top_logprobs_arrays, _flatten_input_top_logprobs, _build_flat_input_top_logprobs_fields_from_arrays, add_logprob_to_meta_info, convert_logprob_style

关键源码片段

python/sclang/srt/managers/tokenizer_manager.py

tokenizer 侧消费 scheduler 数组的核心: 新增 _build_flat_input_top_logprobs_fields_from_arrays、ReqState.input_top_logprobs_scheduler_flat 状态, 并在 add_logprob_to_meta_info / convert_logprob_style 中接入数组路径, 同时保留嵌套回退。

```
def _build_flat_input_top_logprobs_fields_from_arrays(
    val_arr: np.ndarray,
    idx_arr: np.ndarray,
    null_prefix: int,
    return_b64: bool = False,
) -> Dict[str, Any]:
    """从 scheduler 侧组装好的 [rows, k] 数组构造 flat 响应字段。

    与行版 `_build_flat_input_top_logprobs_fields` 共享同一套字段语义
    (shape / null_prefix / flat / b64), 保证两条组装路径产出的 JSON
    结构逐字段一致。b64 模式用 dtype 标记字段, 便于以后调整位宽。
    """
    fields: Dict[str, Any] = {}
    if return_b64:
        # native-endian 连续二进制 + base64; dtype 标记由客户端解释
        fields["input_top_logprobs_val_flat_b64"] = pybase64.b64encode(
            val_arr.tobytes()
        ).decode("utf-8")
        fields["input_top_logprobs_idx_flat_b64"] = pybase64.b64encode(
            idx_arr.tobytes()
        ).decode("utf-8")
        fields["input_top_logprobs_val_flat_b64_dtype"] = "float32"
        fields["input_top_logprobs_idx_flat_b64_dtype"] = "int32"
    else:
        # 非 b64: 展平为普通列表, 与旧行版 JSON 结构保持一致
        fields["input_top_logprobs_val_flat"] = val_arr.reshape(-1).tolist()
        fields["input_top_logprobs_idx_flat"] = idx_arr.reshape(-1).tolist()
        fields["input_top_logprobs_shape"] = [val_arr.shape[0], val_arr.shape[1]]
        fields["input_top_logprobs_null_prefix"] = null_prefix
    return fields
```

python/sglang/srt/managers/scheduler_components/logprob_result_processor.py

scheduler 侧组装入口：新增 `_flatten_input_top_logprobs`，在 prefill 长度断言后把嵌套行转数组并清空嵌套列表，是性能收益的起点。

```
def _flatten_input_top_logprobs(self, req: Req) -> None:
    """把嵌套的 prompt top logprob 行替换为 flat 数组。

    仅对 opt-in 了 return_flat_raw_top_logprobs 的请求生效，使 batch
    输出只携带两个 ndarray，而不是 num_positions * k 个 Python 列表，
    从而压低 scheduler → detokenizer 这条 ZMQ 链路的序列化开销。
    """
    if req.logprob.top_logprobs_num <= 0:
        return
    try:
        (
            req.logprob.input_top_logprobs_val_flat,
            req.logprob.input_top_logprobs_idx_flat,
            req.logprob.input_top_logprobs_flat_null_prefix,
        ) = build_flat_input_top_logprobs_arrays(
            req.logprob.input_top_logprobs_val,
            req.logprob.input_top_logprobs_idx,
            req.logprob.top_logprobs_num,
        )
    except ValueError as e:
        # 无法用 (shape, null_prefix) 表达的行（例如多条目打分）：
        # 保留嵌套格式，与 tokenizer manager 侧的 fallback 语义一致。
        logger.warning(
            "Falling back to nested input top logprobs for rid=%s: %s",
            req.rid,
            e,
        )
    return
    # 组装成功后清空嵌套行，后续 batch 输出只携带数组；该调用发生在
    # prefill 长度校验之后，因此不会破坏 relevant_tokens_len 断言。
    req.logprob.input_top_logprobs_val = []
    req.logprob.input_top_logprobs_idx = []
```

python/sglang/srt/managers/io_struct.py

共享转换原语 `build_flat_input_top_logprobs_arrays` 与两个 batch 输出结构的新增可选字段定义，是整个数据面契约所在，两个进程共用同一套矩形性校验。

```
def build_flat_input_top_logprobs_arrays(
    input_top_logprobs_val: List[Optional[List[float]]],
    input_top_logprobs_idx: List[Optional[List[int]]],
    top_logprobs_num: int,
) -> Tuple[np.ndarray, np.ndarray, int]:
    """把嵌套的逐位置 top logprob 行转换为 flat 数组格式。
```

```

返回 (float32 值数组 [rows, k], int32 token id 数组 [rows, k],
null_prefix)。开头的 null 行计入 null_prefix 并从数组中剔除。
行必须满足: 只有前导 null、且每行长度都为 k, 否则抛 ValueError
(例如 multi-item scoring 的稀疏 delimiter 行无法用 shape 表达)。
"""
num_rows = len(input_top_logprobs_val)
null_prefix = 0
# 统计前导 null 行, 这些位置没有 top logprobs, 由 null_prefix 承载
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:]
# 空行集合时以 top_logprobs_num 作为 k, 保证 shape 仍为 [0, k]
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:
        # 中间空行或参差长度无法由 (shape, null_prefix) 表达, 必须显式失败
        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 {None if row is None else len(row)} entries (expected {k})."
        )
val_arr = np.asarray(val_rows, dtype=np.float32).reshape(len(val_rows), k)
idx_arr = np.asarray(idx_rows, dtype=np.int32).reshape(len(idx_rows), k)
# 注意: 目前只对 val 行做矩形性校验, idx 行默认与 val 行形态一致;
# review 已指出该假设未加固, 参差 idx 可能抛出非 ValueError 异常。
return val_arr, idx_arr, null_prefix

```

评论区精华

review 中核心交锋如下:

chatgpt-codex-connector[bot] (P2, 正确性): `--enable-mis` 场景下 `delimiter-only` 的稀疏行若恰好是矩形, 会通过 `build_flat_input_top_logprobs_arrays` 的校验, 随后嵌套行被清空, 响应暴露 `null_prefix=0`、`shape=[num_delimiters, k]`, 客户端会把它们错误重建为位置 `0..N-1`。

sshleifer (作者回复): 已在 #32078 (db2f53b3a2) 于请求校验层直接拒绝 MIS + flat, 理由是 `multi_item_delimiter_indices` 在 `GenerateReqInput` 上可见, 入口处快速失败能同时保护 scheduler 侧组装与 tokenizer 侧 builder, 而不是依赖只能“偶尔”生效的内部 null 检查。

ch-wan (正确性建议): `add_logprob_to_meta_info` 的 `scheduler-flat` 分支只在 `flat_fields is None` 时构建, 但如果早先的流式 chunk 走过嵌套路径并缓存了空字段 (`num_rows == 0`), 后来 chunk 再设置 `input_top_logprobs_scheduler_flat` 时缓存已非 `None`, 真实数组永远不会被编码, 形成静默空 payload。建议在 `convert_logprob_style` 赋值时清空缓存。

ch-wan（健壮性建议）：`build_flat_input_top_logprobs_arrays` 只校验 `val` 行，`idx` 行直接 `reshape`，若形态不匹配会抛出非 `ValueError` 的异常，逃出 `_flatten_input_top_logprobs` 的 `catch`；最终代码未加镜像校验。

ch-wan（两个 nit）：`b64` 文档声称 `little-endian` 但 `tobytes()` 是 `native endian`；三个平行列表（`val / idx / null_prefix`）缺少越界防御。

最终 ch-wan 以 APPROVED 合入，后四条建议未在最终 patch 中看到对应修改，属于“讨论后接受的已知边界”。

- MIS + flat 组合会丢失 delimiter 位置映射 (correctness): sshleifer 在 #32078 (db2f53b3a2) 于请求校验层直接拒绝 MIS + flat，入口处快速失败同时保护 scheduler 与 tokenizer 两侧。
- scheduler-flat 缓存可能被嵌套路径早先缓存遮蔽，导致静默空 payload (correctness): 建议在 `convert_logprob_style` 赋值 `scheduler_flat` 时清空缓存；最终 patch 未见修改，属讨论后接受的已知边界。
- `build_flat_input_top_logprobs_arrays` 只校验 `val` 行，`idx` 行可抛非 `ValueError` 异常 (correctness): 最终代码仍只校验 `val` 行，建议未被采纳。
- `b64` 文档声称 `little-endian` 但编码为 `native-endian` (documentation): 作为 nit 提出，未在最终 patch 中看到修改。
- 三个平行列表（`val / idx / null_prefix`）缺少越界防御 (correctness): 建议用断言或降级处理；当前 streamer 保证三者成组追加，风险被接受。

风险与影响

- 风险：
 - 静默空 payload 风险 (`tokenizer_manager.py add_logprob_to_meta_info`)：ch-wan 指出的缓存遮蔽问题未被修复——若流式时序出现“先走嵌套路径缓存空字段、后收到 scheduler 数组”的情况，`input_top_logprobs_flat_fields` 非 `None` 会跳过数组编码，响应缺 flat 字段且无异常。当前 streamer 通常 prefill 后首个流式 chunk 就发送 `input_logprobs`，实际触发概率低，但属于静默失败。
 - `idx` 校验缺失 (`io_struct.py build_flat_input_top_logprobs_arrays`)：只对 `input_top_logprobs_val` 做矩形校验，`idx` 行未校验，`np.asarray(...).reshape(...)` 可能抛 `TypeError` 或非预期 `ValueError`，而 `_flatten_input_top_logprobs` 只捕获 `ValueError`，其他异常会逃出批量结果循环。
 - 浮点精度差异：非 `b64` 的 JSON 数值经 scheduler 数组路径会做 `float32` 舍入，与旧路径 `float64` 列表并非逐位一致；作者论证 logprobs 本就以 `float32` 计算，属 no-op，但严格讲输出字节可能不同。
 - 路径不完整覆盖：`session / EPD / PP` 请求不传递 flag，降级为旧嵌套路径，响应一致但拿不到 IPC 收益。
 - 传输安全：默认 pickle 走 protocol-5 buffer、msgpack 路径经 msgspec 的 ndarray 钩子编码解码 (`routed_experts` 先例)，roundtrip 测试已覆盖；big-endian 主机上 `b64` 二进制为 `native-endian`，与文档描述存在偏差。

- 影响：对用户：return_flat_raw_top_logprobs / _b64 的响应字段结构不变，行为兼容；长 prompt + top logprobs 请求（如 32k 位置）可获得约 30ms 每请求的事件循环 CPU 节省与约减半的 IPC payload (1.12MB → 0.53MB)。对系统：收益集中在 detokenizer 与 tokenizer manager 两个最忙单例 loop，且只对 opt-in 请求生效；普通请求 wire 逐字节不变，回归面受控。对团队：组装与校验逻辑收敛到 build_flat_input_top_logprobs_arrays 单一原语，两个进程共享同一语义，后续调整 dtype 或扩展格式只需改一处；测试把两条组装路径的字段级等价性固化下来，降低未来改动风险。
- 风险标记：IPC 数据面变更，缓存遮蔽致静默空 payload, idx 校验缺失，异常类型逃逸风险，旧路径行为保持

关联脉络

- PR #31960 Flat raw prompt top logprobs response format (predecessor): 本 PR 的直接前置：flat raw top logprobs 响应格式与 tokenizer 侧行版组装由此引入，本 PR 在其基础上把组装前移到 scheduler。
- PR #32078 Flat raw prompt top logprobs tokenizer-side assembly + MIS validation (predecessor): PR body 明确引用：response 侧序列化由它做便宜，且其中 db2f53b3a2 在请求校验层拒绝 MIS + flat，是本 PR 讨论中 MIS 守卫的落点。
- PR #29799 support rust sglang server: 同属降低进程间数据面（scheduler/detokenizer/tokenizer）序列化开销的优化脉络，本 PR 是纯 Python 侧的同类努力。