

PR #28105 完整报告

sgl-project/sglang

[Spec] Move ``prepare_for_draft`` to ``EagleDraftWorkerBase``

合并时间: 2026-06-13 08:42

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/28105>

执行摘要

- 一句话: 将 `prepare_for_draft` 移到 `EagleDraftWorkerBase`
- 推荐动作: 此 PR 值得所有关注 speculative decoding 开发的工程师阅读。它清晰展示了如何通过移动方法实现职责分离这一常见重构模式。重点关注 `base_spec_worker.py` 中新增的 `prepare_for_draft` 方法和 `duplicate_prefix_tail_to_draft_branches` 函数。建议后续合并 `gemini-code-assist` 提议的类型注解改进, 以进一步提升代码质量。

功能与动机

根据 PR 描述, 构建 draft forward batch 是 worker 的行为责任, 不应由 `spec_info` 数据类承载。将 `prepare_for_draft` 移到 worker 基类能使职责划分更清晰, 有利于后续的维护和扩展。

实现拆解

1. 在 `base_spec_worker.py` 中新增 `duplicate_prefix_tail_to_draft_branches` 函数和 `EagleDraftWorkerBase.prepare_for_draft` 方法, 并引入必要的类型导入 (如 `ReqToTokenPool`, `ModelRunner`, `EAGLEDraftCudaGraphRunner`, `EagleDraftInput`) 。
2. 从 `eagle_info_v2.py` 中删除上述函数及对应的导入语句 (如 `ModelRunner`, `assign_draft_cache_locs_contiguous`, `EAGLEDraftCudaGraphRunner` 等), 消除重复定义, 并将 `EagleDraftInputV2Mixin` 简化。
3. 更新 `eagle_worker_v2.py` 和 `multi_layer_eagle_worker_v2.py` 中 draft 方法的调用, 将 `draft_input.prepare_for_draft(...)` 替换为 `self.prepare_for_draft(draft_input, ...)`, 并将 `draft_input` 作为第一个参数传递。
4. 所有逻辑维持原样, 仅改变调用者和方法所处位置, 测试套件已通过确认无回归。

关键文件:

- `python/sglang/srt/speculative/base_spec_worker.py` (模块 规约解码; 类别 source; 类型 core-logic; 符号 `duplicate_prefix_tail_to_draft_branches`, `prepare_for_draft`): 核心变更文件, 新增了 `duplicate_prefix_tail_to_draft_branches` 函数和 `prepare_for_draft` 方法, 并更新了导入关系, 是重构的目的地。
- `python/sglang/srt/speculative/eagle_info_v2.py` (模块 规约解码; 类别 source; 类型 core-logic; 符号 `duplicate_prefix_tail_to_draft_branches`, `prepare_for_draft`): 原定义所在文件, 被删除 `prepare_for_draft` 和 `duplicate_prefix_tail_to_draft_branches`, 减少

了模块耦合。

- `python/sglang/srt/speculative/eagle_worker_v2.py` (模块 规约解码; 类别 `source`; 类型 `core-logic`) : 调用者文件, 改为调用 `self.prepare_for_draft`, 反映了新职责归属。
- `python/sglang/srt/speculative/multi_layer_eagle_worker_v2.py` (模块 规约解码; 类别 `source`; 类型 `core-logic`) : 另一个调用者文件, 同样改为调用 `self.prepare_for_draft`, 保持一致性。

关键符号: `duplicate_prefix_tail_to_draft_branches`, `prepare_for_draft`, `prepare_for_draft_extend`

评论区精华

gemini-code-assist 机器人提出了三点类型安全建议:

- 为 `token_to_kv_pool` 添加 `KVCache` 类型注解 (`base_spec_worker.py` 第 11 行)
 - 将 `cuda_graph_runner` 参数类型标记为 `None` 可选 (`base_spec_worker.py` 第 174 行)
 - 对 `can_cuda_graph` 使用 `bool()` 包装以确保严格布尔值 (`base_spec_worker.py` 第 261 行)
- 这些建议均未在本次 PR 中采纳, 但指出了可进一步提升代码健壮性的方向。
- 添加 `KVCache` 类型注解 (style): 未采纳, 当前未使用类型注解。
 - 为 `token_to_kv_pool` 添加 `KVCache` 类型注解 (style): 未采纳。
 - `cuda_graph_runner` 类型标记为可选 (style): 未采纳。
 - 对 `can_cuda_graph` 使用 `bool()` 包装 (style): 未采纳。

风险与影响

- 风险: 本次重构为纯代码移动, 未涉及任何逻辑更改, 且所有已有测试 (包括 `spec` 解码相关测试) 均已通过, 回归风险极低。但需注意 `prepare_for_draft` 所在的基类 `EagleDraftWorkerBase` 现在同时承担 `prepare_for_draft` 和 `prepare_for_draft_extend` 两个核心方法, 将来子类若覆盖其中之一可能引入不一致。此外, `gemini-code-assist` 建议的类型安全问题虽未解决, 但实际运行时不受影响。
- 影响: 本次变更为纯重构, 对用户和系统行为无任何可见影响。团队内部可受益于更清晰的职责划分: `worker` 类完全掌控 `draft` 前向批处理的构建流程, `spec_info` 仅作为纯数据容器。后续若需扩展新类型的 `draft worker`, 只需继承基类并重写相关方法即可。与 `multi_layer_eagle_worker_v2.py` 等子类的兼容性已通过测试验证。
- 风险标记: 无行为变更, 纯代码移动, 测试已通过

关联脉络

- PR #28093 [Spec] Move draft-extend prep to EagleDraftWorkerBase; unify `prepare_for_*` names: 同一系列重构, 将另一个核心方法 `prepare_for_draft_extend` 也移到了基类并统一命名, 本 PR 是其延续。
- PR #28081 [refactor] Fold FrozenKVMTPCudaGraphRunner onto the shared `DecodeCudaGraphRunner` base: 同为 `speculative decoding` 子系统的重构, 改进基类共享性, 与本 PR 目标一致。