

PR #30096 完整报告

sgl-project/sglang

[DFLASH] Support grammar-constrained decoding in speculative verify

合并时间: 2026-07-25 19:36

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/30096>

执行摘要

- 一句话: DFLASH 推测解码支持语法约束解码
- 推荐动作: 值得精读。设计决策清晰: 利用线性链退化树复用现有 EAGLE 机制, 代码改动小但效果显著。同时暴露跨算法维护的挑战。

功能与动机

DFLASH 之前返回 HTTP 400 拒绝任意语法约束请求, 导致无法用于 tool_choice, response_format 等结构化输出场景, PR 描述指出这是非常常见的服务路径。

实现拆解

1. 修改请求验证: validate_dflash_request 移除硬性拒绝逻辑, 改为根据 spec_algorithm.supports_grammar_overlap() 条件判断, 为 DFLASH 启用语法支持, DSPARK 仍被拒绝。
2. 新增线性链树构造: 在 GrammarTree 类中添加 from_linear_chain 类方法, 根据 draft_tokens 形状生成 retrieve_next_token 和 retrieve_next_sibling 张量, 模拟 EAGLE 树退化形态。
3. 集成验证流程: 在 DFlashWorkerV2.forward_batch_generation 中, 当 batch.has_grammar 时调用 from_linear_chain 构建树, 在目标模型前向后调用 build_grammar_vocab_mask 生成掩码, 并在 apply_dflash_verify_logits_adjustments 之后应用 apply_vocab_mask 到 next_token_logits。
4. 测试配套: 添加单元测试验证线性链遍历行为 (正常顺序和语法拒绝停止); 添加集成测试覆盖 json_schema 和 regex 请求; 调整测试类继承以复用 SpecGrammarKit。

关键文件:

- python/sglang/srt/speculative/dflash_worker_v2.py (模块 推测解码; 类别 source; 类型 core-logic): 核心验证路径, 新增语法掩码构建和应用逻辑。
- python/sglang/srt/speculative/dflash_utils.py (模块 推测解码; 类别 source; 类型 core-logic; 符号 validate_dflash_request): 修改请求验证函数, 移除对语法约束的硬性拒绝。
- python/sglang/srt/speculative/spec_utils.py (模块 推测解码; 类别 source; 类型 core-logic; 符号 from_linear_chain): 新增 GrammarTree.from_linear_chain 方法, 为链式验证算法提供退化树。

- python/sclang/srt/managers/scheduler.py (模块 调度器; 类别 source; 类型 dependency-wiring) : 调用 validate_dflash_request 时传入 spec_algorithm 参数。
- test/registered/unit/spec/test_spec_utils_traverse_tree.py (模块 测试; 类别 test; 类型 test-coverage; 符号 _chain, test_linear_chain_visits_all_positions_in_order, test_linear_chain_stops_at_grammar_reject) : 新增线性链单元测试, 验证 from_linear_chain 和 traverse_tree 的正确性。
- test/registered/spec/dflash/test_dflash.py (模块 测试; 类别 test; 类型 test-coverage ; 符号 TestDFlashServerBase, test_grammar_logprob_count_matches_completion_tokens) : 新增集成测试, 验证 DFLASH 服务器对 json_schema 和 regex 请求的正确响应。
- python/sclang/srt/speculative/dflash_info.py (模块 推测解码; 类别 source; 类型 dependency-wiring) : 导入调整, 可能涉及类型注解。
- python/sclang/srt/speculative/spec_info.py (模块 推测解码; 类别 source; 类型 core-logic) : 可能添加 supports_grammar_overlap 方法或修改枚举。

关键符号: validate_dflash_request, GrammarTree.from_linear_chain, DFlashWorkerV2.forward_batch_generation, build_grammar_vocab_mask, apply_vocab_mask

关键源码片段

python/sclang/srt/speculative/dflash_worker_v2.py

核心验证路径, 新增语法掩码构建和应用逻辑。

```
# 导入新增的语法工具
from sclang.srt.speculative.spec_utils import (
    GrammarTree,
    assign_req_to_token_pool_func,
    build_grammar_vocab_mask,
)

# forward_batch_generation 方法签名新增 grammar_barrier 参数
class DFlashWorkerV2:
    def forward_batch_generation(
        self,
        batch: ScheduleBatch,
        on_publish=None,
        grammar_barrier=None, # 新增: 语法屏障回调
    ) -> GenerationBatchResult:
        # ... 省略预填充和草稿生成部分 ...

        # 在草稿生成后、目标模型前向之前, 构造线性链树
        grammar_tree = (
            GrammarTree.from_linear_chain(draft_tokens) if batch.has_grammar else None
        )

        # 目标模型前向 ...
        # 在目标模型前向后、采样之前, 构建并应用词汇掩码
```

```

vocab_mask = None
if batch.has_grammar:
    if grammar_barrier is not None:
        grammar_barrier() # 等待上一批次语法 FSM 推进完成
    vocab_mask = build_grammar_vocab_mask(
        reqs=batch.reqs,
        verify_input=verify_input,
        tree=grammar_tree,
        sampling_info=batch.sampling_info,
        device=logits_output.next_token_logits.device,
    )

# 应用 DFLASH 验证 logits 调整 (温度、top-k 等)
if sampling_info is not None:
    apply_dflash_verify_logits_adjustments(...)

# 在 argmax/ 采样之前应用语法掩码
if vocab_mask is not None:
    verify_input.grammar.apply_vocab_mask(
        logits=logits_output.next_token_logits,
        vocab_mask=vocab_mask,
    )
# 之后的 accept 步骤读取被掩码的 logits, 确保语法合规

```

python/sglang/srt/speculative/dflash_utils.py

修改请求验证函数, 移除对语法约束的硬性拒绝。

```

# 新增导入
from sglang.srt.speculative.spec_info import SpeculativeAlgorithm

# 修改后的验证函数
def validate_dflash_request(
    req: Req, enable_overlap: bool, spec_algorithm: SpeculativeAlgorithm
) -> Optional[str]:
    if req.return_logprob:
        return "DFLASH speculative decoding does not support return_logprob yet."
    if enable_overlap and req.return_hidden_states:
        return "DFLASH speculative decoding does not support return_hidden_states yet."

# 语法支持由 verify-time 位掩码和语法屏障共同提供
if not spec_algorithm.supports_grammar_overlap() and (
    req.sampling_params.json_schema is not None
    or req.sampling_params.regex is not None
    or req.sampling_params.ebnf is not None
    or req.sampling_params.structural_tag is not None
):
    return (
        f"{spec_algorithm.name} speculative decoding does not support "
        "grammar-constrained decoding yet."
    )

```

```
)  
return None
```

python/sglang/srt/speculative/spec_utils.py

新增 GrammarTree.from_linear_chain 方法，为链式验证算法提供退化树。

```
class GrammarTree:  
    # ... 已有 from_device, from_host ...  
  
    @classmethod  
    def from_linear_chain(cls, verify_ids_2d: torch.Tensor) -> GrammarTree:  
        """  
        为链式验证算法构造退化树：节点 i 的唯一子节点是 i+1。  
  
        verify_ids_2d 形状为 (bs, chain_len)，列 0 是已提交 token。  
        链接关系由形状固定，只需复制 token ID 到主机。  
        """  
  
        bs, chain_len = verify_ids_2d.shape  
        # 子节点索引：除最后一列外指向下一列，最后一列无子节点  
        next_token = torch.full((bs, chain_len), -1, dtype=torch.int64)  
        next_token[:, :-1] = torch.arange(1, chain_len, dtype=torch.int64)  
        # 无兄弟节点  
        next_sibling = torch.full((bs, chain_len), -1, dtype=torch.int64)  
        return cls.from_device(next_token, next_sibling, verify_ids_2d)
```

评论区精华

shanemort1982 指出该 PR 同时移除了对 DSPARK 的保护 (`validate_dflash_request` 共享)，但掩码仅添加在 DFLASH 路径，可能导致 DSPARK 静默输出无约束结果。作者已创建 #31753 单独修复 DSPARK，本 PR 仅聚焦 DFLASH。

- DSPARK 覆盖不全 (design): 作者确认并在 #31753 中单独修复 DSPARK，本 PR 仅针对 DFLASH。

风险与影响

- 风险：
 1. DSPARK 覆盖缺失：共享验证函数被修改但 DSPARK 未获得掩码，需配合 #31753 使用。
 2. 性能开销：语法掩码构建和 GPU 复制很小（链长通常 ≤ 8 ），且与目标前向重叠，影响可控。
 3. 兼容性：需确保 SpeculativeAlgorithm 所有枚举值覆盖 `supports_grammar_overlap()` 方法。
 - 影响：用户侧：之前被拒绝的语法约束请求现在可正常工作并保持推测加速。系统侧：验证路径新增条件分支，仅在有语法约束时执行。团队侧：需与 DSPARK 修复 PR 配合部署。
 - 风险标记：DSPARK 覆盖缺失，核心路径变更，需配合后续 PR

关联脉络

- PR #31753 [DSPARK] Grammar-constrained decoding, incl. tool_choice=auto: 该 PR 修复了本 PR 遗留的 DSPARK 语法支持问题，是本 PR 的延伸。
- PR #32393 [Spec] Share the grammar mask build and verify-tree staging across spec workers: 后续优化，进一步整合 grammar mask 构建逻辑，与本 PR 的复用方向一致。