

# PR #31753 完整报告

sgl-project/sglang

[DSPARK] Grammar-constrained decoding, incl. tool\_choice=auto

合并时间: 2026-07-25 20:20

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/31753>

## 执行摘要

- 一句话: DSPARK 推测解码支持语法约束与 tool\_choice=auto
- 推荐动作: 值得精读的 PR。它展示了如何在 speculative decoding 的 verify 阶段无缝集成 grammar mask, 以及如何通过 step1 (显式 grammar) 和 step2 (隐式 tool\_choice) 分步解决实际生产问题。特别关注 fold\_eligible 与 CUDA graph 交互的设计决策, 以及 supports\_grammar\_overlap 方法的多态扩展。

## 功能与动机

DSPARK speculative decoding 之前对携带 grammar 约束的请求 (如 response\_format、json\_schema、regex、ebnf) 返回 HTTP 400 拒绝。实际上 DSPARK 的 target verify 路径已经具备应用 vocab mask 的能力, 只是缺少 admission 守卫释放和 mask 应用。该 PR 是 #30096 (DFLASH 语法约束) 的配对补充, 同时解决了生产环境中 tool\_choice=auto 下标记泄露的问题。

## 实现拆解

1. 解除 admission 封锁 (python/sglang/srt/speculative/dflash\_utils.py):  
validate\_dflash\_request 移除 spec\_algorithm 参数和  
spec\_algorithm.supports\_grammar\_overlap() 的检查, 不再拒绝 DSPARK 的 grammar 请求 (DFLASH 仍拒绝)。同步更新调度器 (python/sglang/srt/managers/scheduler.py) 调用处, 去掉 spec\_algorithm 参数。
2. verify 阶段应用 vocab mask (python/sglang/srt/speculative/dspark\_components/dspark\_worker\_v2.py): 在 \_forward\_decode 中, 当 batch.has\_grammar 时, 构建 GrammarTree.from\_linear\_chain (DSPARK 为线性验证树), 调用 build\_grammar\_vocab\_mask 生成掩码, 并通过 draft\_input.grammar.apply\_vocab\_mask 应用到 next\_token\_logits。同时修改 fold\_eligible 条件, 排除 batch.has\_grammar 的 batch, 强制走 eager path 使得 mask 生效。
3. 扩展数据类 (python/sglang/srt/speculative/dflash\_info\_v2.py):  
DFlashDraftInputV2 新增 grammar 字段 (类型 BaseGrammarObject), 用于在 verify 过程中记录 grammar 对象。
4. 语法重叠能力声明 (python/sglang/srt/speculative/spec\_info.py):  
supports\_grammar\_overlap 从 is\_dflash() 改为 is\_dflash\_family(), 使 DSPARK 与 DFLASH 一样上报支持 grammar 重叠。

5. 函数调用自动约束（第二个 commit，涉及 `function_call_parser`）：  
`should_constrain_auto` 支持 DFLASH-family spec algorithm，通过 detector 暴露的 structural tag 触发 mask，解决 `tool_choice=auto` 下的标记泄露问题。
6. 测试配套（`test/registered/core/test_basic_sanity_dspark.py`）：添加 `JSONConstrainedMixin` 和 `SpecGrammarKit` 组合，以及一个被跳过的 `test_grammar_logprob_count_matches_completion_tokens` 因 admission 阶段拒绝 `return_logprob`。同时存在 CPU 单元测试 `test_dflash_validate_request.py` 验证 admission 行为。

关键文件：

- `python/sglang/srt/speculative/dspark_components/dspark_worker_v2.py`（模块 推测解码；类别 source；类型 core-logic；符号 `forward_batch_generation`, `_forward_decode`）：  
核心实现文件：在 `_forward_decode` 中添加 grammar mask 逻辑，修改 `fold_eligible` 排除 grammar batch，新增 `grammar_barrier` 参数。是整个功能的关键。
- `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`）：定义 admission 检验函数 `validate_dflash_request`，移除对 DSPARK 的 grammar 拒绝逻辑，使得 grammar 请求能被调度到 DSPARK worker。
- `test/registered/core/test_basic_sanity_dspark.py`（模块 集成测试；类别 test；类型 test-coverage；符号 `test_grammar_logprob_count_matches_completion_tokens`）：集成测试：通过 mixin 组合 `JSONConstrainedMixin` 和 `SpecGrammarKit` 确保 DSPARK 能够处理 grammar 请求，并新增被跳过的 `test_grammar_logprob_count_matches_completion_tokens` 作为已知限制的标记。

关键符号：`validate_dflash_request`, `forward_batch_generation`, `_forward_decode`, `supports_grammar_overlap`, `should_constrain_auto`

## 关键源码片段

`python/sglang/srt/speculative/dspark_components/dspark_worker_v2.py`

核心实现文件：在 `_forward_decode` 中添加 grammar mask 逻辑，修改 `fold_eligible` 排除 grammar batch，新增 `grammar_barrier` 参数。是整个功能的关键。

```
# python/sglang/srt/speculative/dspark_components/dspark_worker_v2.py
# 摘要：_forward_decode 中新增 grammar mask 逻辑
```

```
class DSparkWorkerV2(BaseSpecWorker):
    def _forward_decode(
        self, batch: ScheduleBatch, on_publish, grammar_barrier=None
    ) -> GenerationBatchResult:
        # ... 构建 verify_ids_2d, draft_input ...

        # 构建 grammar tree (DSPARK 是线性链，每个位置只有一个子节点)
        grammar_tree = (
            GrammarTree.from_linear_chain(verify_ids_2d) if batch.has_grammar else None
        )
```

```

# fold_eligible 原条件; 现在增加 not batch.has_grammar
# 当有 grammar 时, fold 会跳过 CUDA graph epilogue, 保证 mask 生效
fold_eligible = (
    self._verify_executor.verify_epilogue is not None
    and proposal.folded
    and verify_logits_adjustments_are_noop(sampling_info)
    and self._simulate_acc_len <= 0
    and not batch.has_grammar # 新增: 有 grammar 时强制 eager
)

with self._observers.segment(InfoSegment.TARGET_VERIFY):
    # ... 运行 verify launch ...
    logits_output = target_verify.logits_output

    if batch.has_grammar:
        # grammar barrier 非 None 时等待 host 侧 FSM 前进
        if grammar_barrier is not None:
            grammar_barrier()
        # 构建 vocab mask, 复用 EAGLE/NGRAM 路径的 build_grammar_vocab_mask
        vocab_mask = build_grammar_vocab_mask(
            reqs=batch.reqs,
            verify_input=draft_input,
            tree=grammar_tree,
            sampling_info=sampling_info,
            device=logits_output.next_token_logits.device,
        )
        if vocab_mask is not None:
            draft_input.grammar.apply_vocab_mask(
                logits=logits_output.next_token_logits, vocab_mask=vocab_mask
            )

```

## python/sglang/srt/speculative/dflash\_utils.py

定义 admission 检验函数 `validate_dflash_request`, 移除对 DSPARK 的 grammar 拒绝逻辑, 使得 grammar 请求能被调度到 DSPARK worker。

```

# python/sglang/srt/speculative/dflash_utils.py
# 变更后 validate_dflash_request 签名和逻辑

```

```

def validate_dflash_request(req: Req, enable_overlap: bool) -> Optional[str]:
    """
    检查 DFLASH-family 请求是否可接受。
    现在 DSPARK 的 grammar 请求不被拒绝, 因为 DSPARK worker 支持 mask。
    """
    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."

```

```
# grammar 拒绝检查已移除，因为 DSPARK 支持；DFLASH 仍然不支持，  
# 但 DFLASH 的拒绝由其他机制处理（仍然在 admission 出错时返回错误）。  
return None
```

## 评论区精华

1. `tool_choice=auto` 的补充（作者 shanemort1982）：第一个 commit 只处理了显式 grammar 请求，但 `tool_choice=auto` 不携带 grammar 对象，导致生产环境工具调用出现 5-8 倍泄露。第二个 commit 通过 `should_constrain_auto` 扩展解决了此问题，并附上 7 小时生产验证零泄露的数据。
  2. CI 触发与测试通过（作者与合并者 hnyls2002）：合并者通过 `/rerun-test` 命令执行了特定测试（`test_basic_sanity_dspark.py`、`test_dflash_validate_request.py`、`test_dflash.py`），全部通过。
  3. 重构与冲突解决（hnyls2002 的后续提交）：多次合并 main 分支解决冲突，尤其是 main 上 `FunctionCallParser` 已经重构为使用 `get_auto_tool_call_structural_tag()`，需要适配。前作者（shanemort1982）的 Codex review 也指出需要跟踪最新 main 的变更。
- `tool_choice=auto` 的补充 (other): 合并者接受了此扩展，两个 commit 合并一起发布。
  - CI 测试触发与通过 (testing): CI 测试通过，无新增失败。
  - 与 main 分支的冲突解决 (other): 最终提交 7fd4eb2 中冲突解决，新逻辑适配了 main 的接口。

## 风险与影响

- 风险：
  1. 回归风险：对 DFLASH 的 grammar 拒绝行为无变化（仍拒绝），风险低。DSPARK 的非 grammar 请求路径完全跳过 mask，无性能损失。但 `fold_eligible` 新增条件 `not batch.has_grammar` 可能遗漏某些其他需要 eager 路径的场景，需观察。
  2. 安全 / 正确性：grammar mask 在 eager 路径应用，但如果 mask 构建失败（如 `vocab_mask is None`）则静默跳过，可能输出不合约束的内容。当前处理是 `if vocab_mask is not None`，没有 fallback 到拒绝响应。
  3. 性能：仅在有 grammar 的 batch 中增加一次 vocab mask 构建和应用，开销与 EAGLE 路径一致，但强制退出了 CUDA graph 折叠路径，可能略微降低吞吐。PR 作者评估 negligible。
  4. 兼容性：对非 spec 模式无影响。函数调用自动约束的 `should_constrain_auto` 扩展对非 DFLASH-family 算法无影响。- 影响：用户：DSPARK 部署现在可以使用结构化输出和工具调用，完全解锁 grammar-constrained 场景。对已有 DSPARK 用户是重要功能补全。系统：引入的条件分支与 mask 计算仅影响 grammar 请求，非 grammar 流量零开销。团队：与 #30096 形成完整 DFLASH-family grammar 支持；新增的 grammar 字段和 `should_constrain_auto` 逻辑可能需要在后续 spec 算法中维护。测试新增的 CPU 单元测试是轻量的。
- 风险标记：核心路径变更，语法掩码集成，工具调用约束，CUDA graph 折叠条件修改

## 关联脉络

- PR #30096 [DFLASH] Support grammar-constrained decoding in speculative verify: 本 PR 是 #30096 的 DSPARK 配对实现，共享类似的验证时 mask 机制和 admission 调整。
- PR #30155 [xgrammar] vocab-mask on the multi-layer EAGLE verify path: 使用了相同的 generate\_token\_bitmask / apply\_vocab\_mask 设施。