

# PR #44938 完整报告

vllm-project/vllm

[Rust Frontend] Support prompt-only completions

合并时间: 2026-06-17 14:38

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/44938>

## 执行摘要

此 PR 为 Rust 前端 `/v1/completions` 路由增加 prompt-only 请求支持, 即当 `echo=true` 且 `max_tokens=0` 时返回 prompt 本身, 不暴露生成 token。内部降级为一个 token 驱动引擎后隐藏, 与 Python 行为对齐。

## 功能与动机

该 PR 是 [Rust Frontend Feature Parity \(#44280\)](#) 的一部分。Python vLLM 已支持 `echo=true` 时 `max_tokens=0` 的 prompt-only completions, Rust 前端需补齐此能力以消除功能差距。

## 实现拆解

1. 验证层放宽约束 (`validate.rs`) : 将 `max_tokens=0` 的拒绝条件改为 `!echo`, 接受 `echo=true` 组合。
2. 请求转换层降级 (`convert.rs`) : 检测 `echo=true && max_tokens==0` 并设置 `prompt_only` 标志, 强制 `max_tokens=1` 以驱动引擎; 调整 `prompt_logprobs` 启用条件。
3. 主路由层响应处理 (`completions.rs`) : 根据 `prompt_only` 调整 `text`、`token_ids`、`logprobs`、`usage`, 隐藏内部 token。
4. 辅助函数: 新增 `prompt_only_logprobs_to_openai` 和 `prompt_logprobs_to_maps`。
5. 测试: 在 `validate.rs` 和 `convert.rs` 中添加单元测试。

## 关键源码片段

[rust/src/server/src/routes/openai/completions/convert.rs](#)

请求转换层, 检测 `prompt_only` 条件并设置标志, 将 `max_tokens` 替换为 1 以驱动引擎。

```
// detect prompt-only condition: echo=true and max_tokens=0
let prompt_only = request.echo && request.max_tokens == Some(0);

// override max_tokens to 1 so the engine can run
let max_tokens = if prompt_only { Some(1) } else { request.max_tokens };

// enable prompt_logprobs for streaming prompt-only case
let prompt_logprobs = request.prompt_logprobs.or(if request.echo && (!request.stream ||
prompt_only) {
```

```
    logprobs
  } else {
    None
  });
```

## 评论区精华

- tahsintunan指出 completion\_tokens 计数差异（Rust 初版 0 vs Python 1），作者更新为匹配 Python（completion\_tokens=1）。
- tahsintunan建议清理不可达分支，作者重构并共享 logprobs 处理。
- BugenZhao要求为流式 prompt\_only 分支加注释，作者已补充。
- chatgpt-codex-connector建议隐藏 token\_ids 和 usage，作者对 token\_ids 置空，但 usage 保留计数 1 以匹配 Python。

## 风险与影响

- 兼容性风险：completion\_tokens=1 与 Python 行为一致，无破坏性变更。
- 日志风险：启用 enable\_log\_requests 时可能暴露内部 token 计数，影响有限。
- 回归风险：验证逻辑放宽，但单元测试覆盖充分。
- 影响范围：仅限于 Rust 前端 /v1/completions，功能对齐。

## 关联脉络

此 PR 是 Rust Frontend Feature Parity 路线图中的关键步骤，与 #44382 (abort\_requests)、#45848 (反序列化修复) 等共同完善 Rust 前端。关联 Issue #44280 追踪整体进度。