

PR #48107 完整报告

vllm-project/vllm

[Rust][Benchmark] Port in vllm-bench

合并时间: 2026-07-17 14:25

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/48107>

执行摘要

PR #48107 将原先独立仓库的 Rust 基准测试工具 `vllm-bench` 整体移植到 vLLM 主仓库的 `rust/src/bench/` 下, 新增约 17k 行 Rust 代码, 提供与 Python 版 `vllm bench serve` 对等的在线吞吐测试能力, 支持多后端、多数据集、多轮对话、SLO 验证等特性。该 PR 为后续深度集成和统一 CLI 奠定了基础。

功能与动机

PR body 直接指向 <https://github.com/vllm-project/vllm-bench>, 表明其目的就是将已经独立开发的 vllm-bench 工具迁入主仓库, 以实现代码统一管理、简化 CI 流程、降低双份维护成本。

实现拆解

1. 项目结构创建: 在 rust/ 工作空间中新增 bench 子 crate, 配置 Cargo.toml 依赖 (tokio、request、clap、indicatif、tiktoken-rs 等) 并注册为工作空间成员; 更新 .pre-commit-config.yaml 以包含 Rust 格式化检查。
2. 核心模块实现:
 - cli.rs: 通过 clap 定义 Cli 结构体, 枚举 BackendKind (vllm/openai/openai-chat/embeddings/rerank 等)、DatasetName (random/sharegpt/sonnet/hf/custom 等)、LoraAssignment 等。
 - config.rs: BenchConfig 从 Cli 构建并验证, RangeRatio 支持两种格式的随机范围 (单一浮点或 JSON 对象), 并增加与 Python 版语义对齐的错误提示。
 - benchmark.rs: run_benchmark 函数驱动完整基准周期, 包含 DNS 预解析 (避免高并发下 DNS 失败)、SpecDecode 指标采集、速率控制、进度条显示和“稳态”检测。
 - multi_turn.rs: 支持多轮对话评估, 可自动从服务器获取模型并截断历史到 max_model_len。
 - datasets/: 包括 HF 数据集在线下载 (hf_dataset.rs)、随机生成 (random.rs/random_mm.rs)、ShareGPT/Sonnet 解析等, 其中 hf_dataset.rs 可自动检测列格式 (chat/text/combined) 并支持分页。
 - output/json.rs: build_result_json 严格对齐 Python 输出 schema, 确保结果通用。
 - metrics/: calculator.rs 计算 TTFT/TPOT/ 吞吐量等指标, steady_state.rs 通过滑动窗口自动选择稳定测量区。
 - sweep.rs: 支持并发度和请求率的自动扫描 (sweep)。
 - tiktoken.rs: 封装 tiktoken-rs 实现 token 化, 支持文件加载和内置 BPE。

3. 构建与代码风格修复: BugenZhao 提交了 fmt with nightly config、fix lint & tweak deps、Add missing SPDX header 等, 使项目满足仓库 CI 要求。
4. 内联测试: 各关键模块附有少量 #[cfg(test)] 测试, 如 benchmark.rs 中 test_filter_requests_by_max_model_len_* 和 multi_turn.rs 中 test_valid_prefix_len_for_max_model_len_with_history。

rust/src/bench/src/benchmark.rs

基准测试核心入口, 包含 DNS 预解析、请求调度、进度跟踪、SpecDecode 统计等关键逻辑。

```
/// Pre-resolve the hostname in `base_url` and pin all resolved IPs on the
/// client builder via [`request::ClientBuilder::resolve_to_addrs`]. This
/// avoids repeated DNS lookups under high concurrency which can cause
/// transient "Temporary failure in name resolution" errors while preserving
/// happy-eyeballs and multi-A failover.
///
/// Skipped when:
/// - URL parse fails
/// - host is already an IP
/// - host is a loopback name (resolved from `/etc/hosts`, no DNS pressure
///   and dual-stack ambiguity between `127.0.0.1` and `::1` breaks
///   IPv4-only servers like vLLM)
/// - resolution fails
pub fn pre_resolve_dns(
    base_url: &str,
    mut builder: request::ClientBuilder,
) -> request::ClientBuilder {
    let parsed = match url::Url::parse(base_url) {
        Ok(u) => u,
        Err(_) => return builder, // 无法解析 URL 时跳过
    };
    let host = match parsed.host_str() {
        Some(h) => h,
        None => return builder, // 无 host 时跳过
    };
    // 如果已经是 IP, 跳过预解析
    if host.parse:::<std::net::IpAddr>().is_ok() {
        return builder;
    }
    // 避免解析 localhost (IPv4/IPv6 双栈问题)
    let host_lower = host.to_ascii_lowercase();
    if host_lower == "localhost"
        || host_lower == "ip6-localhost"
        || host_lower.ends_with(".localhost")
    {
        return builder;
    }
    let port = parsed.port_or_known_default().unwrap_or(80);
    let addr_str = format!("{host}:{port}");
```

```

match std::net::ToSocketAddrs::to_socket_addrs(&addr_str) {
    Ok(addrs) => {
        // 分离 IPv4 和 IPv6, 优先 IPv4
        let mut v4 = Vec::new();
        let mut v6 = Vec::new();
        for addr in addrs {
            if addr.is_ipv4() {
                v4.push(addr);
            } else {
                v6.push(addr);
            }
        }
        v4.extend(v6); // IPv4 排前
        if !v4.is_empty() {
            let ips: Vec<_> = v4.iter().map(|a| a.ip()).collect();
            println!("Pre-resolved {host} -> {ips:?}");
            builder = builder.resolve_to_addrs(host, &v4);
        }
    }
    Err(e) => {
        eprintln!("Warning: DNS pre-resolution for '{host}' failed: {e}");
    }
}
builder
}

```

rust/src/bench/src/config.rs

配置解析核心，定义了 BenchConfig、RangeRatio、GoodputConfig 等关键类型，实现 CLI 到配置的转换与验证。

```

/// Range ratio for sampling input/output lengths, matching Python
/// `vllm bench serve`: lengths are drawn uniformly from [len*(1-r), len*(1+r)].
/// A single float applies to both; the JSON form '{"input": r1, "output": r2}'
/// controls them independently. Each ratio must be in [0, 1).
#[derive(Debug, Clone, Copy, PartialEq)]
pub struct RangeRatio {
    pub input: f64,
    pub output: f64,
}

impl RangeRatio {
    /// Parse `--random-range-ratio`: a bare float or a JSON object with
    /// "input" and "output" keys.
    pub fn parse(raw: &str) -> Result<Self> {
        let trimmed = raw.trim();
        let (input, output) = if let Ok(v) = trimmed.parse::<f64>() {
            (v, v) // 单个浮点数，输入输出共用
        } else {
            // 尝试解析 JSON 对象

```

```

let v: serde_json::Value = serde_json::from_str(trimmed).map_err(|_| {
    BenchError::Config(format!(
        "Invalid --random-range-ratio '{raw}': expected a float or \
        '{{\"input\": r1, \"output\": r2}}'"
    ))
})?;
let obj = v.as_object().ok_or_else(|| {
    BenchError::Config(
        "--random-range-ratio JSON form must be an object with \
        'input' and 'output' keys"
        .into(),
    )
})?;
// 从对象中提取 input 和 output
let get = |key: &str| -> Result<f64> {
    obj.get(key).and_then(|v| v.as_f64()).ok_or_else(|| {
        BenchError::Config(format!(
            "--random-range-ratio JSON form must contain a numeric '{key}' key"
        ))
    })
};
(get("input")?, get("output")?)
};
// 验证范围在 [0,1) 内
for (name, r) in [("input", input), ("output", output)] {
    if !(0.0..1.0).contains(&r) {
        let hint = if r == 1.0 {
            " NOTE: semantics now match Python vllm bench serve — lengths are \
            sampled from [len*(1-r), len*(1+r)] and 0.0 means fixed length. \
            The old Rust-only default 1.0 ([len*r, len]) is no longer valid."
        } else {
            ""
        };
        return Err(BenchError::Config(format!(
            "--random-range-ratio {name} ratio must be in [0, 1), got {r}.{hint}"
        )));
    }
}
Ok(Self { input, output })
}
// ... input_bounds, output_bounds, is_fixed 等方法省略
}

```

评论区精华

BugenZhao 在审批时肯定了这个移植，并指出后续改进方向：

“Great to see this! We can make some follow-up changes to integrate the **bench** entry point more tightly with the existing **vllm-rs**, and try to reuse more components

between them.” 这表明当前为初步移植，后续将推动与现有 Rust 模块（vllm-rs）的深度融合和组件复用。

风险与影响

风险：

- 新增大量 Rust 代码（~17k 行）增加构建时间和 CI 缓存压力。
- 与 Python 版基准测试的功能对等需要持续维护，输出 JSON schema 的同步更新可能出现疏漏。
- 多后端适配可能随 vLLM API 演进而滞后。

影响：

- 用户：获得一个与 Python 版功能一致且性能更优的基准测试工具，支持多轮对话和多种数据集。
- 系统：扩展了 Rust 代码库，增加编译依赖，但工具高度模块化，风险可控。
- 团队：需要 Rust 维护能力，但统一了基准测试的实现入口，减少双份维护。

关联脉络

本 PR 是 vllm-bench 从独立仓库迁入的第一步，后续可能通过关联 PR 合并 CLI 入口、复用 vllm-rs 的 HTTP 客户端和 tokenizer 组件。历史 PR 中未发现直接关联项，但仓库中已有 `rust/` 模块（如 `vllm-rs`），未来可能演进为统一的 Rust 工具集。