

PR #37222 完整报告

sgl-project/sglang

[Rust] Keep sampling and scheduler wire schemas in sync

合并时间: 2026-09-01 03:31

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/37222>

执行摘要

- 一句话: Rust 采样与线上结构对齐 Python, 新增双语言 lockstep 测试
- 推荐动作: 值得精读。核心值得学习的是 lockstep 测试模式: 用最少的成本把一个位置型协议约束在 Python 单元测试里, 适合推广到其他 Rust/Python 双实现结构。需要注意该方案依赖源码文本与相对路径, 长期建议改由构建期生成 schema 或共享常量来消除脆弱性。

功能与动机

PR body 明确指出: Close Rust/Python sampling parity gaps and make positional wire-schema drift fail in Python unit tests。这是 stack #37223 中的第 3 个 PR。Rust 服务器正在逐步复刻 Python 侧 SamplingParams 的 post_init→normalize→verify 语义; 若两边在空 grammar、structural_tag、custom_params 类型或字段顺序上不一致, 同一个 HTTP 请求在 Rust 与 Python 服务器下会产生不同的 400 响应或不同的调度行为。

实现拆解

实现按 5 步展开, 核心都在 rust/sglang-server/src/message/sampling.rs, 配套测试落在两个 Python 单元测试文件:

1. 空 grammar 归一化: 在 SamplingParams::post_init() 末尾新增循环, 把 json_schema、regex、ebnf、structural_tag 四个字段的空字符串全部置为 None, 与 Python __post_init__ 行为一致, 避免空字符串被下游 is_not_none 误判为已设置的约束, 从而触发多余的互斥校验或走入错误分支。
2. verify() 校验顺序与互斥规则对齐: 把 beam_width < 1 的检查从函数尾部提前到温度校验之前, 与 Python verify 的错误报告优先级一致; 同时把 structural_tag 纳入 grammar 互斥计数, 错误消息更新为 Only one of json_schema, regex, ebnf, or structural_tag can be set。
3. custom_params 类型收紧: 字段类型从 Option<serde_json::Value> 改为 Option<BTreeMap<String, CustomParamValue>>, 并新增 CustomParamValue 与 JsonScalar 两个 #[serde(untagged)] 枚举, 只允许标量、标量列表、字符串键对象, 拒绝嵌套对象与嵌套列表, 匹配 Python 侧 CustomParamValue 的形状。
4. Rust 回归测试: 在 sampling.rs 的测试模块新增 3 个用例, 分别覆盖空 grammar 归一化、structural_tag 互斥、custom_params 接受 / 拒绝边界。

5. Python lockstep 测试: `test_sampling_params.py` 新增

`test_rust_sampling_schema_stays_in_lockstep`, 用正则从 Rust 源码提取 `pub struct SamplingParams` 的字段列表, 与 Python msgspec 的 `__struct_fields__` 做全等比较; `test_io_struct.py` 新增 `test_rust_tokenized_generate_schema_stays_in_lockstep`, 提取 `TokenizedGenerateReqInput<'a>` 字段并断言其必须是 Python 字段的前缀, 且 Python 侧被 Rust 省略的字段都带默认值。两个文件同步补充了 `re` 与 `pathlib.Path` 导入。

关键文件:

- `rust/sglang-server/src/message/sampling.rs` (模块 采样参数; 类别 `source`; 类型 `core-logic`; 符号 `empty_grammar_constraints_are_unset`, `structural_tag_is_mutually_exclusive_with_other_grammars`, `custom_params_matches_python_shape`): 核心源码文件: 归一化空 grammar、把 `structural_tag` 纳入互斥校验、提前 `beam_width` 校验, 并将 `custom_params` 从任意 JSON 收紧为与 Python 形状一致的有界类型, 同时新增 3 个 Rust 回归测试。
- `test/registered/unit/managers/test_io_struct.py` (模块 线上结构; 类别 `test`; 类型 `test-coverage`; 符号 `test_rust_tokenized_generate_schema_stays_in_lockstep`): 新增 `TokenizedGenerateReqInput` 的跨语言 lockstep 测试: 解析 Rust `io_struct.rs` 中的字段, 断言 Rust 字段是 Python msgspec 结构的前缀, 且被省略的 Python 尾部字段都必须带默认值。
- `test/registered/unit/sampling/test_sampling_params.py` (模块 采样参数; 类别 `test`; 类型 `test-coverage`; 符号 `test_rust_sampling_schema_stays_in_lockstep`): 新增 `SamplingParams` 的跨语言 lockstep 测试: 从 Rust 源码提取 `pub struct SamplingParams` 的全部字段, 与 Python msgspec 的 `__struct_fields__` 做全等比较, 确保字段集合与顺序完全一致。

关键符号: `post_init`, `verify`, `empty_grammar_constraints_are_unset`, `structural_tag_is_mutually_exclusive_with_other_grammars`, `custom_params_matches_python_shape`, `test_rust_sampling_schema_stays_in_lockstep`, `test_rust_tokenized_generate_schema_stays_in_lockstep`

关键源码片段

`rust/sglang-server/src/message/sampling.rs`

核心源码文件: 归一化空 grammar、把 `structural_tag` 纳入互斥校验、提前 `beam_width` 校验, 并将 `custom_params` 从任意 JSON 收紧为与 Python 形状一致的有界类型, 同时新增 3 个 Rust 回归测试。

```
// =====
// CustomParamValue: 与 Python srt/sampling/sampling_params.py 中的
// `CustomParamValue` 一一对应, 只接受标量、标量列表、字符串键对象,
// 拒绝嵌套对象与嵌套列表, 保证两边对同一请求给出相同解析结果。
// =====
#[derive(Debug, Clone, PartialEq, Serialize, Deserialize)]
#[serde(untagged)]
pub enum CustomParamValue {
    Null(),
```

```

    Bool(bool),
    Signed(i64),
    Unsigned(u64),
    Float(f64),
    String(String),
    List(Vec<JsonScalar>),
    Object(BTreeMap<String, JsonScalar>),
}

```

/// `List` 与 `Object` 变体内部使用的标量类型。

```

#[derive(Debug, Clone, PartialEq, Serialize, Deserialize)]
#[serde(untagged)]
pub enum JsonScalar {
    Null(()),
    Bool(bool),
    Signed(i64),
    Unsigned(u64),
    Float(f64),
    String(String),
}

```

```

fn post_init(&mut self) {
    // Python `__post_init__` 的 guard: 已 normalized 的请求直接返回,
    // 否则第二次 normalize 会把 stop 别名清掉, 导致停止词全部失效。
    if self.is_normalized {
        return;
    }
    // ..... stop / stop_token_ids / temperature / top_k 的处理与 base 一致 .....

    // 与 Python 对齐: 空字符串形式的 grammar 等价于“未设置”。
    // 若保留空字符串, 下游 `is_not_none` 会误判约束存在, 从而
    // 触发多余的互斥校验或在调度器里走错分支。
    for constraint in [
        &mut self.json_schema,
        &mut self.regex,
        &mut self.ebnf,
        &mut self.structural_tag,
    ] {
        if constraint.as_deref() == Some("") {
            *constraint = None;
        }
    }
}

```

```

fn verify(&self, vocab_size: u64) -> Result<(), Error> {
    // beam_width 校验前移到开头: Python `verify` 先报 beam_width 再
    // 报 temperature, Rust 侧保持同序, 错误消息优先级才能一致。
    if let Some(beam_width) = self.beam_width
        && beam_width < 1

```

```

{
    return Err(bad(format!(
        "beam_width must be at least 1, got {beam_width}."
    )));
}
// ..... temperature / top_p / min_p / top_k / penalty 等校验与 base 一致 .....

// Grammars 互斥: structural_tag 也参与计数, 与 Python 一致;
// 任何两个 grammar 同时设置都会得到 400。
let grammars = [
    &self.json_schema,
    &self.regex,
    &self.ebnf,
    &self.structural_tag,
]
.iter()
.filter(|g| g.is_some())
.count();
if grammars > 1 {
    return Err(bad(
        "Only one of json_schema, regex, ebnf, or structural_tag can be set".into(),
    ));
}
}

```

test/registered/unit/managers/test_io_struct.py

新增 TokenizedGenerateReqInput 的跨语言 lockstep 测试: 解析 Rust io_struct.rs 中的字段, 断言 Rust 字段是 Python msgspec 结构的前缀, 且被省略的 Python 尾部字段都必须带默认值。

```

def test_rust_tokenized_generate_schema_stays_in_lockstep(self):
    """Rust 与 Python 的调度器输入结构必须保持字段前缀一致。"""
    rust_path = (
        Path(__file__).resolve().parents[4]
        / "rust/sglang-server/src/message/io_struct.rs"
    )
    source = rust_path.read_text()
    start = source.index("pub(super) TokenizedGenerateReqInput<'a> {")
    end = source.index("\n    }\n", start)
    # 前两个字段是 Rust 侧固定前缀, 后面由正则从源码中提取。
    rust_fields = (
        "rid",
        "http_worker_ipc",
        *re.findall(r"^\s*([a-z][a-z0-9_]*):", source[start:end], re.MULTILINE),
    )
    python_fields = TokenizedGenerateReqInput.__struct_fields__

    # Rust 字段必须等于 Python 字段的前缀 (Rust 可省略 Python 尾部
    # 带默认值的字段), 这样调度器按位置读取时不会错位。

```

```

self.assertEqual(python_fields[: len(rust_fields)], rust_fields)
self.assertTrue(
    all(
        default is not msgspec.NODEFAULT
        for default in TokenizedGenerateReqInput.__struct_defaults__[
            len(rust_fields) :
        ]
    ),
    "Rust may omit only a defaulted suffix of the Python wire schema",
)

```

test/registered/unit/sampling/test_sampling_params.py

新增 SamplingParams 的跨语言 lockstep 测试：从 Rust 源码提取 pub struct SamplingParams 的全部字段，与 Python msgspec 的 __struct_fields__ 做全等比较，确保字段集合与顺序完全一致。

```

def test_rust_sampling_schema_stays_in_lockstep(self):
    """Rust 字段必须与 Python msgspec 的 SamplingParams 字段完全一致。"""
    rust_path = (
        Path(__file__).resolve().parents[4]
        / "rust/sglang-server/src/message/sampling.rs"
    )
    source = rust_path.read_text()
    start = source.index("pub struct SamplingParams {")
    end = source.index("\n}")

    /// The `generate`", start)
    rust_fields = tuple(
        re.findall(
            r"^\s*pub ([a-z][a-z0-9_]*):",
            source[start:end],
            re.MULTILINE,
        )
    )
    # 位置型 wire schema: 字段顺序本身就是协议的一部分。
    # 任何一侧增删字段或调整顺序都会让该断言直接失败。
    self.assertEqual(SamplingParams.__struct_fields__, rust_fields)

```

评论区精华

本 PR 没有实质性的 review 讨论：merrymercy 两次在 review 中评论 approve，rainj-me 最终 APPROVED。Issue 评论主要是 CI 重跑记录，最初多组目标测试失败，经过三轮 /rerun-test 后全部通过。github-actions[bot] 的典型记录为：Results for /rerun-test test/registered/rust/test_run_rust_tests.py test/registered/core/test_srt_endpoint.py test/registered/vlm/test_rust_native_mm_e2e.py test/registered/vlm/test_rust_native_mm_mmmu.py: 前两轮 🐛，最终 🟢。未发现与本次 parity 改动直接相关的回归。

- CI rerun 与测试稳定性 (testing): 最终所有目标测试全绿, 未发现与本次 parity 改动直接相关的回归; 失败原因在上下文中未标注。
- 合并前自审与 approval (other): 无实质性争议, 直接合并。

风险与影响

- 风险:
 1. custom_params 类型收紧: Rust 侧不再接受任意 JSON, 嵌套 list 与嵌套 object 会解析失败并返回 400; 若此前有调用方依赖旧行为发送嵌套结构, Rust server 会新增拒绝路径, 但该拒绝与 Python 类型边界一致。
 2. 空 grammar 归一化语义变化: 空字符串从已设置约束变为未设置, 改变请求语义, 需确保与 Python 完全一致后再合并。
 3. verify 校验顺序变化: beam_width 与 temperature 同时非法时返回的错误消息改变, 可能影响依赖错误文本的客户端。
 4. lockstep 测试脆弱性: 测试依赖源码字符串标记 (如 pub struct SamplingParams {}) 与相对路径 Path(__file__).resolve().parents[4], Rust 大重构或测试文件移动会让测试直接失败或解析到错误位置。
 5. 影响面相对有限: 改动只落在新增的 Rust server 路径, Python 主路径未被触碰。- 影响: 影响范围集中在 rust/sglang-server 的采样参数与调度器线上输结构。对用户而言, Rust server 处理空 grammar、嵌套 custom_params、structural_tag 与其他 grammar 并存时, 行为会与 Python 对齐。对团队而言, lockstep 测试成为维护双实现的第一道防线, 字段位置漂移会在 Python 单元测试阶段立即失败, 而不是到端到端测试才暴露。CI 影响: 两个测试文件均已注册到 CPU/GPU/XPU 网格, 新增测试为纯文件解析与字符串比较, 没有额外模型加载成本。- 风险标记: custom_params 类型收紧可能拒绝旧请求, 空 grammar 语义归一化行为变化, 错误消息优先级随校验顺序改变, lockstep 测试依赖 Rust 源码文本与相对路径, 影响面集中在 Rust 服务器路径

关联脉络

- PR #37226 [Rust] Simplify request defaults and document batch header ABI: 同一 rust-server-cleanup stack 的第 4/4 个 PR, 继续精简 Rust 请求结构与文档化 batch header ABI, 与本 PR 共享 rust/sglang-server 的线上结构代码路径。