

PR #2067 完整报告

THUDM/slime

[algo] Add CISPO advantage estimator (MiniMax-M1)

合并时间: 2026-06-15 15:08

原文链接: <http://prhub.com.cn/THUDM/slime/pull/2067>

执行摘要

- 一句话: 新增 CISPO 优势估计器, 保留裁剪 token 的梯度
- 推荐动作: 值得精读。实现简洁, 与现有架构无缝集成, 是研究 RL 损失裁剪策略的优秀示例。关注点: stop-gradient 的写法、配置警告的用法、测试的梯度路由验证方法。

功能与动机

PPO/GRPO 风格裁剪中, 重要性采样比率超出 clip band 的 token 贡献零梯度, 因为裁剪后的代理损失 $\min(r \cdot A, \text{clip}(r) \cdot A)$ 完全杀死了该 token 的更新。MiniMax-M1 (<https://arxiv.org/abs/2506.13585>) 指出, 在 off-policy 更新下, 这些不成比例的低概率 "fork" token (如 *However*、*Recheck*、*Wait*) 恰好是推理 RL 需要梯度的推理分支。CISPO 通过 stop-gradient 裁剪 IS 权重, 使每个 token 的梯度都通过 log_probs 流动。slime 目前没有 CISPO 支持。

实现拆解

1. 核心损失函数: 在 `slime/utils/ppo_utils.py` 中新增 `compute_cispo_loss`, 使用 `ratio_truncated.detach()` 实现 stop-gradient, 公式为 $-\text{sg}(\text{clip}(\text{ratio}, 1 - \text{eps_clip}, 1 + \text{eps_clip_high})) * \text{advantages} * \text{log_probs}$ 。
2. 集成到训练流程: 在 `slime/backends/megatron_utils/loss.py` 中导入 `compute_cispo_loss`, 在 `policy_loss_function` 中添加 `if args.advantage_estimator == "cispo"` 分支; 同时在 `compute_advantages_and_returns` 中将 "cispo" 加入 grpo 返回和标准化路径。
3. 配置与验证: 在 `slime/utils/arguments.py` 中将 "cispo" 加入 `--advantage-estimator` 的 choices, 并在 `slime_validate_args` 中增加警告: 当 `eps_clip < 1.0` 时提醒 canonical 单边设置。
4. Rollout 奖励处理: 在 `slime/ray/rollout.py` 的 `_post_process_rewards` 中将 "cispo" 加入需要进行 group normalization 和 std normalization 的 estimator 列表。
5. 测试: 新增 `tests/test_cispo_loss.py`, 包含两个参数化测试: 验证 loss 值与闭形式匹配、验证梯度仅流经 log_probs 而不经 IS ratio 路径。
6. 基础设施与文档: 在 `.github/workflows/pr-test.yml.j2` 中将测试文件加入 CPU 测试矩阵, 生成更新 `pr-test.yml`; 中英文使用文档添加 `cispo` 的简要说明。

关键文件:

- slime/utils/ppo_utils.py (模块 损失函数; 类别 source; 类型 core-logic; 符号 compute_cispo_loss) : 新增 compute_cispo_loss 函数, 实现 CISPO 核心损失计算
- slime/backends/megatron_utils/loss.py (模块 损失集成; 类别 source; 类型 core-logic) : 将 compute_cispo_loss 导入并集成到 policy_loss_function 和 compute_advantages_and_returns 中
- slime/utils/arguments.py (模块 配置; 类别 source; 类型 core-logic) : 将 cispo 加入 --advantage-estimator 选项, 添加配置验证警告
- slime/ray/rollout.py (模块 Rollout; 类别 source; 类型 core-logic) : 将 cispo 加入 reward group normalization 和 std normalization 的条件列表
- tests/test_cispo_loss.py (模块 测试; 类别 test; 类型 test-coverage; 符号 test_compute_cispo_loss_matches_closed_form_surrogate, test_compute_cispo_loss_gradient_flows_only_through_log_probs) : 新增 CPU 测试, 验证 CISPO 损失闭形式匹配和梯度路由正确性
- .github/workflows/pr-test.yml (模块 CI; 类别 infra; 类型 infrastructure) : 将 test_cispo_loss.py 加入 CPU 测试矩阵

关键符号: compute_cispo_loss, test_compute_cispo_loss_matches_closed_form_surrogate, test_compute_cispo_loss_gradient_flows_only_through_log_probs

关键源码片段

slime/utils/ppo_utils.py

新增 compute_cispo_loss 函数, 实现 CISPO 核心损失计算

```
# slime/utils/ppo_utils.py (新增)
```

```
@torch.compile(dynamic=True)
def compute_cispo_loss(
    ppo_kl: torch.Tensor,
    log_probs: torch.Tensor,
    advantages: torch.Tensor,
    eps_clip: float,
    eps_clip_high: float,
):
    """CISPO 损失来自 MiniMax-M1 (https://arxiv.org/abs/2506.13585, Eq. 4-5):
    ``-sg(clip(ratio, 1 - eps_clip, 1 + eps_clip_high)) * advantages * log_probs``.
```

与 PPO 不同, IS 比率在 stop-gradient 下载剪, 梯度流经 ``log\_probs``, 因此裁剪 token 仍然贡献梯度。边界复用 ``compute\_policy\_loss`` 的 delta-from-1 约定; canonical CISPO 禁用下界 (``eps\_clip >= 1.0``)。

```
"""
```

```
ratio = (-ppo_kl).exp() # 计算重要性采样比率 exp(-KL)
# 在 stop-gradient 下载剪比率
ratio_truncated = torch.clamp(ratio, min=1.0 - eps_clip, max=1.0 + eps_clip_high)
# 损失 = - 裁剪比率 (停止梯度) * 优势 * log_prob, 梯度只传回 log_prob
pg_losses = -ratio_truncated.detach() * advantages * log_probs
```

```

# clipfrac: 标记哪些 token 的原始比率超出了 band (非 PPO 的 loss 影响裁剪)
clipfrac = (ratio_truncated != ratio).float()
return pg_losses, clipfrac

```

tests/test_cispo_loss.py

新增 CPU 测试, 验证 CISPO 损失闭形式匹配和梯度路由正确性

```
# tests/test_cispo_loss.py (新增)
```

```
"""CPU 测试 for compute_cispo_loss (MiniMax-M1, https://arxiv.org/abs/2506.13585)."""
```

```
import math
```

```
import pytest
```

```
import torch
```

```
from slime.utils.ppo_utils import compute_cispo_loss
```

```
NUM_GPUS = 0 # 标记仅 CPU 测试
```

```
# 固定数据
```

```
ADVANTAGES = torch.tensor([1.0, -0.5, 2.0, -1.0])
```

```
LOG_PROBS = torch.tensor([-0.7, -1.2, -0.4, -2.1])
```

```
# 测试用例 : (eps_clip, eps_clip_high, 原始 IS ratios, 裁剪后 ratios)
```

```
CLIP_CASES = [
    pytest.param(0.2, 0.28, [1.0, 1.14, 1.56, 0.4], [1.0, 1.14, 1.28, 0.8], id="ppo_band"),
    pytest.param(1.0, 4.0, [1.0, 3.0, 9.0, 0.4], [1.0, 3.0, 5.0, 0.4], id="wide_minimax_band"),
]
```

```
@pytest.mark.parametrize("eps_clip, eps_clip_high, ratios, clamped", CLIP_CASES)
```

```
def test_compute_cispo_loss_matches_closed_form_surrogate(eps_clip, eps_clip_high, ratios,
clamped):
```

```
    # 构造 ppo_kl = -log(ratio)
```

```
    ppo_kl = -torch.tensor([math.log(r) for r in ratios])
```

```
    pg_losses, clipfrac = compute_cispo_loss(ppo_kl, LOG_PROBS, ADVANTAGES, eps_clip, eps_
clip_high)
```

```
    # 期望损失 : -clamped * advantages * log_probs
```

```
    expected_losses = -torch.tensor(clamped) * ADVANTAGES * LOG_PROBS
```

```
    torch.testing.assert_close(pg_losses, expected_losses, rtol=1e-6, atol=1e-6)
```

```
    # clipfrac 应标记比率离开 band 的位置
```

```
    expected_clipfrac = torch.tensor([float(c != r) for c, r in zip(clamped, ratios, strict=True)])
```

```
    torch.testing.assert_close(clipfrac, expected_clipfrac)
```

```
@pytest.mark.parametrize("eps_clip, eps_clip_high, ratios, clamped", CLIP_CASES)
```

```
def test_compute_cispo_loss_gradient_flows_only_through_log_probs(eps_clip, eps_clip_high,
ratios, clamped):
```

```

# 验证梯度只流经 log_probs, 而非 IS 比率路径
log_ratios = torch.tensor([math.log(r) for r in ratios], requires_grad=True)
ppo_kl = -log_ratios
log_probs = LOG_PROBS.clone().requires_grad_()
pg_losses, _ = compute_cispo_loss(ppo_kl, log_probs, ADVANTAGES, eps_clip, eps_clip_high)
pg_losses.sum().backward()
# log_probs 的梯度应为 -clamped * advantages
torch.testing.assert_close(log_probs.grad, -torch.tensor(clamped) * ADVANTAGES, rtol=1e-6,
atol=1e-6)
# log_ratios 的梯度应为 0 (因为 stop-gradient)
assert log_ratios.grad is None or torch.all(
    log_ratios.grad == 0
), f"CISPO 必须 stop-gradient IS 比率; log_ratios.grad = {log_ratios.grad}"

```

评论区精华

本 PR 无公开的 review 讨论。但从 commit body 和代码结构可以看出设计上的关键决策：复用现有 `--eps-clip` / `--eps-clip-high` 标志，与 GSPO 保持一致的 band 约定；`pg_clipfrac` 在 CISPO 下定义为 band 退出率（非 PPO 的 loss 影响裁剪率）；`slime_validate_args` 对 `eps_clip < 1.0` 给出警告，建议 canonical 单边设置 `--eps-clip 1.0 --eps-clip-high 4.0`。

- 暂无高价值评论线程

风险与影响

- 风险：回归风险：新损失函数仅在 `--advantage-estimator cispo` 时激活，默认不变；但 `rollout.py` 和 `arguments.py` 中的条件列表扩展可能遗漏与其他 estimator 的兼容性测试。性能：`compute_cispo_loss` 使用 `@torch.compile(dynamic=True)`，开销极低。正确性：`stop-gradient` 实现依赖 `ratio_truncated.detach()`，测试覆盖了梯度路由。配置风险：`eps_clip` 默认 0.2 会保留下界裁剪，与 canonical CISPO 单边行为不同，警告可避免误用。
- 影响：用户：研究者和工程师可以通过 `--advantage-estimator cispo` 直接使用新算法，无需额外代码。系统：无破坏性变更，不影响现有训练脚本。团队：维护成本低，代码集中在损失函数和配置层，测试覆盖关键不变性。
- 风险标记：新损失函数分支，配置警告，梯度路由验证，默认行为不变

关联脉络

- 暂无明显关联 PR