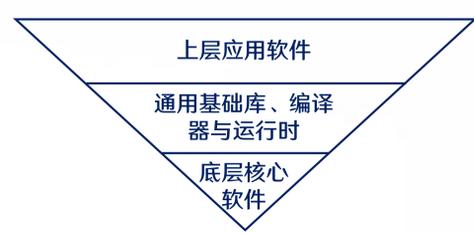


基于开源软件演化历史的 RISC-V 架构适配相关问题挖掘与分析技术研究

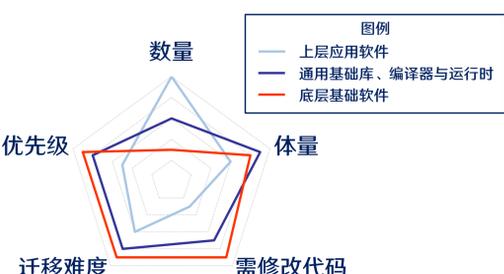
张世新, 孟鑫, 燕季薇, 严俊, 朱家鑫, 王伟

软件工程技术研究开发中心 zhangshixin@otcaix.iscas.ac.cn

研究背景



待适配 RISC-V 架构软件性质“倒三角”结构



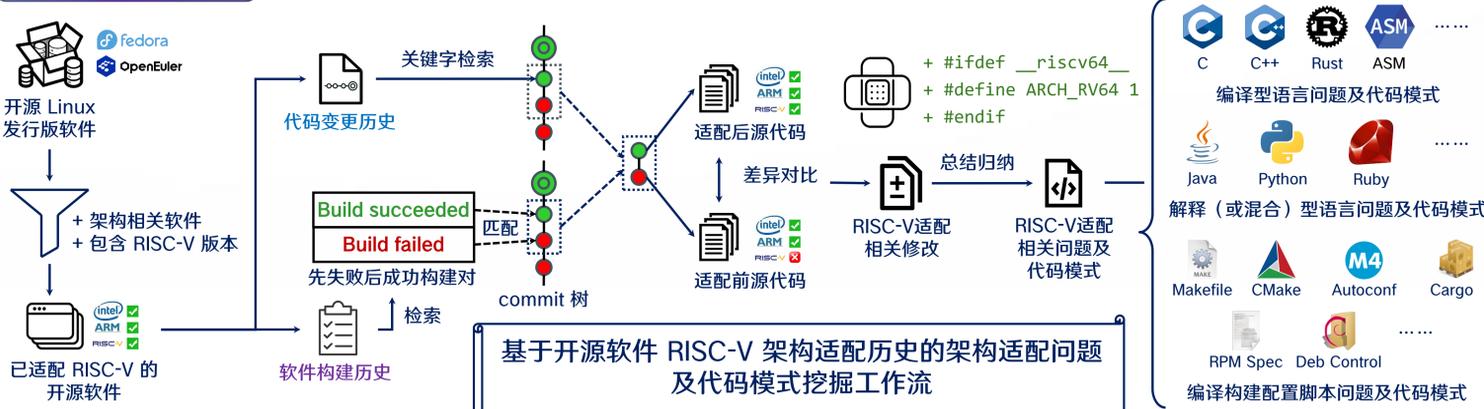
待适配 RISC-V 架构的各类软件整体特点雷达图

待适配 RISC-V 架构的各类软件整体特点

软件类型	数量	体量	需修改代码	适配难度	优先级	额外要求
上层应用软件	多	不定	少且零散	一般或较低	较低	功能正常
通用基础库、编译器与运行时	一般	大	较多且复杂	高	高	可靠性高
底层核心软件	少	大	多且复杂	高	高	可靠性高

- RISC-V 作为近年的新兴指令集，具有开源开放的优势和广阔的应用前景
- 将已支持现有指令集架构（如 X86、ARM 等）的开源软件迁移适配 RISC-V 架构，是快速丰富 RISC-V 软件生态的重要途径，目前开源社区已有大量实践
- 软件在新指令集架构上的适配是一个“层层依赖、环环相扣”的过程
- 不同性质的软件具有不同特点，其架构适配难度、优先级和额外要求存在差异
- 如何从已适配 RISC-V 架构的软件中挖掘并分析迁移适配相关问题、总结归纳解决方案，以指导未来其它软件的 RISC-V 架构迁移适配工作？

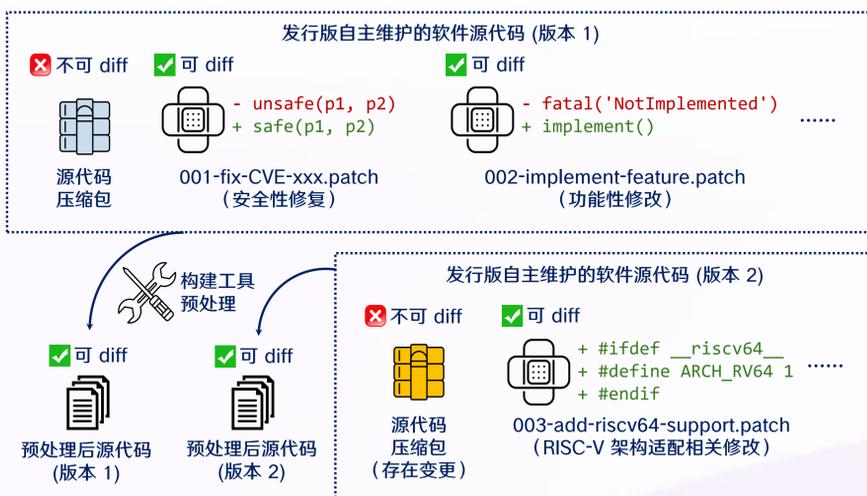
技术方案



- 开源 Linux 操作系统发行版自主管理的开源软件仓库和构建平台中，包含软件在各种指令集架构下的最新版本制品包及源代码
- 软件的代码变更历史和构建历史中，包含软件针对 RISC-V 架构适配的修改和构建结果，其中蕴含专业开发者的迁移适配知识
- 通过关键字检索和“先失败后成功”构建对匹配的方式，从软件源代码的 commit 树中匹配出适配 RISC-V 架构前后的源代码
- 对匹配到的源代码进行差异对比，得到 RISC-V 适配相关修改，进一步按照编程语言的性质归纳总结架构适配问题和代码模式

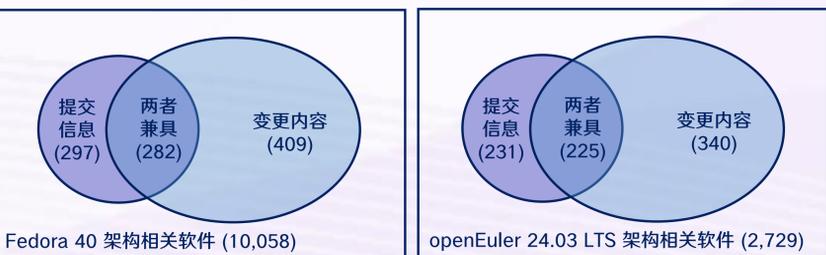
源代码差异对比失效问题及解决方法

- 一般源码仓库：直接包含源代码文件
- 发行版源码仓库：源代码压缩包 + 补丁文件
- 从发行版仓库中提取软件源代码时，可能面临源代码差异对比失效的问题，即无法直接通过版本控制工具对比源代码压缩包中发生的变更
- 解决方案：模仿软件构建系统行为，将选定的版本内软件源代码压缩包展开，按照构建配置应用补丁文件，使压缩包内发生的源代码变更可通过版本控制工具进行对比
- 初步实验效果：95% 以上的软件均可正常处理



源代码差异对比失效问题及解决方法示意图

应用效果



开源软件 RISC-V 架构适配相关修改的识别效果

- 在 Fedora 40 RISC-V 版本提供的 23,614 款软件中，识别到 10,058 款架构相关软件，其中共有 424 款包含 RISC-V 架构相关修改的软件
- 在 openEuler 24.03 LTS RISC-V 版本提供的 6,012 款软件中，识别到 2,729 款架构相关软件，其中共有 346 款包含 RISC-V 架构相关修改的软件

开源软件 RISC-V 架构适配相关问题及代码模式总结

基于目前收集的开源软件 RISC-V 指令集架构适配相关修改内容，已总结形成“三大类七小类”软件源代码中常见的 RISC-V 架构适配问题和解决方案

- 编译型语言常见问题：内联汇编、Intrinsics 函数、内存对齐、其它要素
- 解释（或混合）型语言常见问题：Native 库、生成代码或编译配置
- 编译构建配置脚本常见问题：架构相关编译参数、架构特有软件依赖关系



RISC-V 架构适配目标代码定位辅助工具效果示意图