AiDD AI+ 软件研发数字峰会
AI+ software Development Digital summit

AI驱动软件研发
全面进入数字化时代

中国·北京 08.18-19

AI+
software
Development
Digital
summit

“Bug”的寻根溯源之旅
自动化软件缺陷定位技术

谢晓园 武汉大学
xxie@whu.edu.cn

科技生态圈峰会 + 深度研习 ——1000 + 技术团队的共同选择

K+峰会

2023K+
全球软件研发行业创新峰会
上海站
会议时间 | 06.09-10

2023K+
全球软件研发行业创新峰会
北京站
会议时间 | 07.21-22

2024K+
全球软件研发行业创新峰会
深圳站
会议时间 | 05.17-18

K+峰会详情

AiDD峰会

会议时间 | 08.18-19
AiDD AI+软件研发数字峰会
北京站

会议时间 | 11.17-18
AiDD AI+软件研发数字峰会
深圳站

AiDD峰会详情

演讲嘉宾

谢晓园

武汉大学计算机学院教授 博士生导师

武汉大学特色化示范性软件学院副院长

武汉大学珞珈青年学者、基金委外国优秀青年学者研究基金获得者。主要研究方向为软件测试、软件缺陷定位与修复、程序分析与切片、智能软件工程等。曾解决了软件缺陷定位领域公式性能评估的瓶颈难题，被软件工程顶级期刊IEEE TSE评为全球软件蜕变测试领域十大代表性研究者之一。录用发表包括软件工程CCF A类在内的论文50余篇。以第一及通讯作者连续两年获国际软件工程顶级会议 (CCF A类) 杰出论文奖。获计算机学会NASAC青年软件创新奖、大陆首个ACM SigEvo HUMIES奖、湖北省科技进步一等奖等学术奖励。担任SCI期刊编委、客座编辑，历任ICSE/MET蜕变测试研讨会PC Chair。担任包括CCF A类会议ASE、ICSE在内的多个国际会议PC members，以及包括CCF A类期刊TSE、TOSEM 和ACM Computing Survey等在内的多个国际知名期刊审稿人。

目录
CONTENTS

PART 1

背景与简介

Background and Introduction

背景

现代社会软件无处不在，关键系统的软件缺陷将造成灾难性损失

2018 - 2019

致命性航空事故

机载MCAS软件缺陷造成两起空难，共造成346人死亡

2022. 12

巨额的经济损失

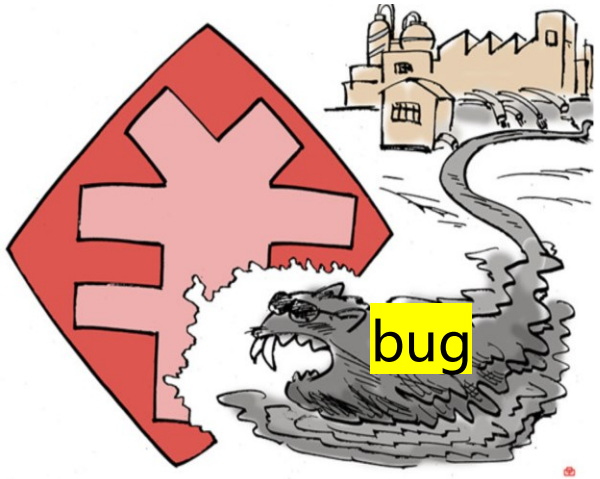

权威机构发布报告称，2022年软件缺陷问题可能使美国经济损失2.41万亿美元

2023. 2

大规模车辆召回

因自动驾驶软件缺陷，特斯拉在全球范围召回近36.3万辆汽车

背景

高质量软件已成为经济社会发展的迫切需求

高效的**软件缺陷定位**

是构筑高质量软件的**重要一环**

背景

发现软件程序错误

耗时、复杂

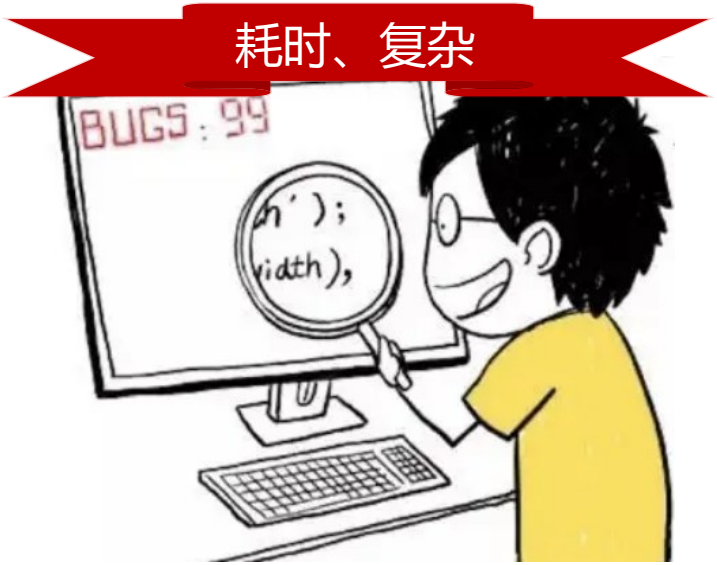

判断导致程序错误的底层缺陷位置或原因

(缺陷定位)

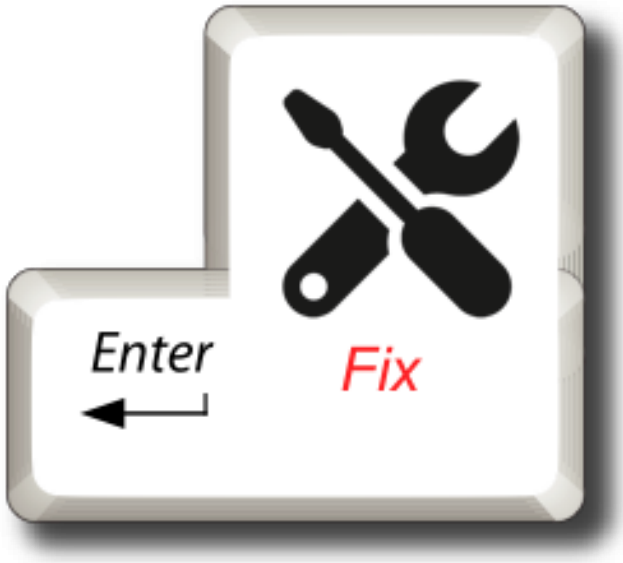

对定位到的缺陷进行修复

软件测试
(Software Testing)

软件调试
(Software Debugging)

背景

软件缺陷的产生不可避免

缺陷定位贯穿整个软件生命周期

人工缺陷定位

✘ 费时费力

✘ 效果不稳定

自动化缺陷定位

√ 智能高效便捷

√ 效果稳定

存在一系列

关键性挑战

自动化代码缺陷定位

当前主流代码级自动化缺陷定位技术

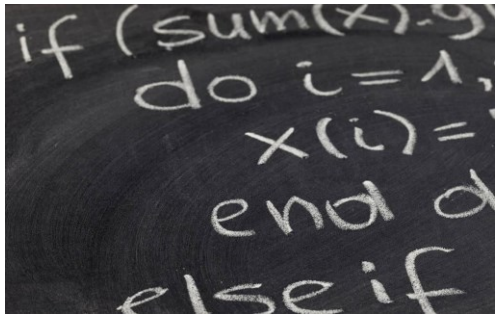

基于统计学的定位技术

基于程序状态的定位技术

基于数据挖掘的定位技术

基于切片的定位技术

基于信息检索的定位技术

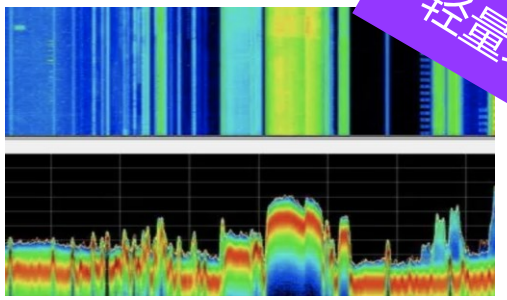

轻量级

基于程序频谱的定位技术(SBFL)

自动化代码缺陷定位

Spectrum-based Fault Localization (SBFL) 流程图

错误程序

测试用例集

运 行

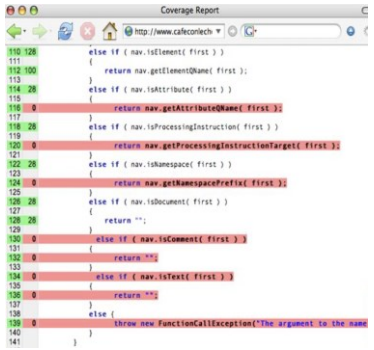

程序覆盖信息
+
测试执行结果

$$TS:(t_1 \quad t_2 \quad t_3 \quad t_4 \quad t_5 \quad t_6) \qquad A_i < a^i_{ef} \quad a^i_{ep} \quad a^i_{nf} \quad a^i_{np} >$$

$$PG:\begin{pmatrix} s_1 \\ s_2 \\ s_3 \\ s_4 \end{pmatrix} \quad MS:\begin{pmatrix} 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 1 & 1 & 1 & 0 & 1 \\ 1 & 1 & 0 & 1 & 1 & 1 \end{pmatrix} \quad MA:\begin{pmatrix} 2 & 4 & 0 & 0 \\ 0 & 1 & 2 & 3 \\ 1 & 3 & 1 & 1 \\ 2 & 3 & 0 & 1 \end{pmatrix}$$

$$RE:(p \quad p \quad p \quad p \quad f \quad f)$$

SBFL的核心

风险值
评估公式

$$e_f - \frac{e_p}{e_p + n_p + 1}$$

Top

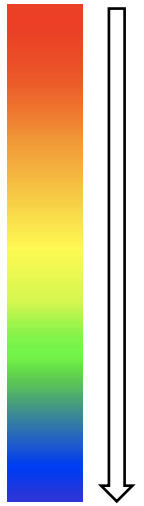

Down

程序实体
风险值排序列表

PART 02
实践中的关键性挑战
Key Challenges in Practice

挑战一：最优风险评估公式构造

挑战①

如何不通过大量实验来设计最优SBFL公式?

挑战②

如何面向Non-testable程序展开缺陷定位?

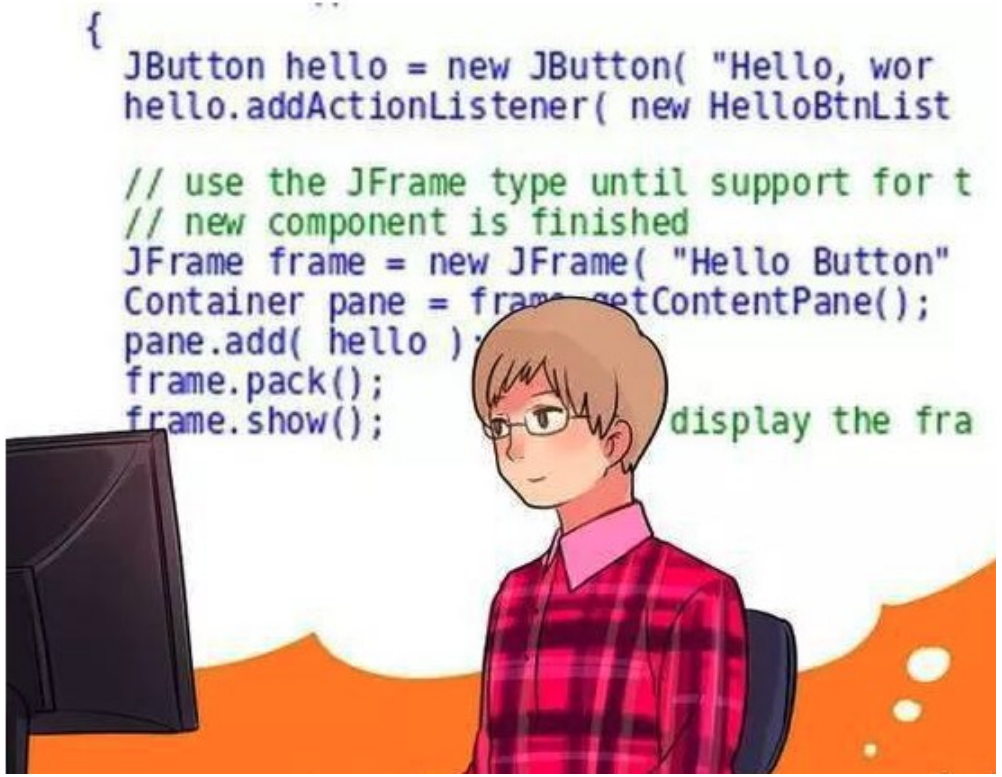

程序员面临的真实调试场景

挑战③

如何在多缺陷环境下更好地定位缺陷?

挑战④

如何在更细粒度下进行缺陷定位?

挑战一：最优风险评估公式构造

数十年来，大量SBFL公式被陆续提出，“最优公式”是目标

$$\begin{cases} -1 & \text{if } N_{CF} < N_F \\ N_S - N_{CS} & \text{if } N_{CF} = N_F \end{cases}$$

$$\frac{N_{CF}+N_{US}}{N_{CF}+N_{US}+2(N_{UF}+N_{CS})}$$

$$N_{CF} - N_{CS}$$

$$\frac{2N_{CF}}{2N_{CF}+N_{UF}+N_{CS}}$$

$$N_{CF} - \frac{N_{CS}}{N_S+1}$$

$$\frac{N_{CF}}{N_F+N_{CS}}$$

$$\frac{N_{CF}}{N_{CF}+2(N_{UF}+N_{CS})}$$

$$\frac{2N_{CF}N_{US}-2N_{UF}N_{CS}}{N_C N_S+N_F N_U}$$

$$\frac{1}{2}\left(\frac{N_{CF}}{N_F}+\frac{N_{CF}}{N_C}\right)$$

$$\frac{N_{CF}}{N}$$

$$\frac{N_{CF}}{N_C}$$

$$\frac{N_{CF}+N_{US}}{N}$$

$$\chi^2 = \frac{(N_{CF}-E_{CF})^2}{E_{CF}} + \frac{(N_{CS}-E_{CS})^2}{E_{CS}} + \frac{(N_{UF}-E_{UF})^2}{E_{UF}} + \frac{(N_{US}-E_{US})^2}{E_{US}}$$

$$\frac{2N_{CF}-N_{UF}-N_{CS}}{2N_{CF}+N_{UF}+N_{CS}}$$

$$\frac{4N_{CF}N_{US}-4N_{UF}N_{CS}-(N_{UF}-N_{CS})^2}{(2N_{CF}+N_{UF}+N_{CS})(2N_{US}+N_{UF}+N_{CS})}$$

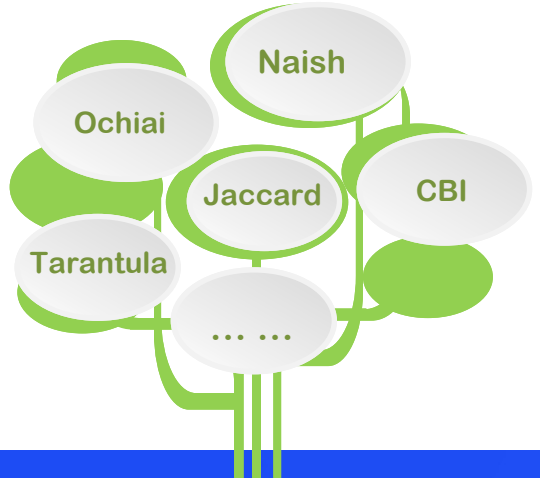

$$\frac{N_{CF}}{N_{CF}+N_{US}+2(N_{UF}+N_{CS})}\left(2(N_{CF}+\sqrt{N_{US}})+\sqrt{N_{CS}}\right)$$

$$N_{CF}\sqrt{|N_{CS}-N_{CF}+N_{UF}-N_{US}|}$$

$$\sqrt{N_{CF}+N_{US}}$$

$$N_{CF} - h, \text{ where } h = \begin{cases} N_{CS} & \text{if } N_{CS} \le 2 \\ 2+0.1(N_{CS}-2) & \text{if } 2 < N_{CS} \le 10 \\ 2.8+0.001(N_{CS}-10) & \text{if } N_{CS} > 10 \end{cases}$$

挑战一：最优风险评估公式构造

采用实验方法确定公式效果：成本高昂，随机性强且泛化性无法保证


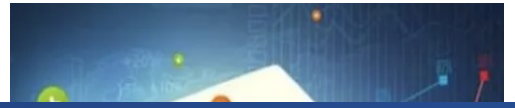
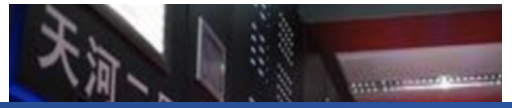

这样的背景下，无法确定真正的“最优公式”

大量的实验程序	复杂的度量指标	较高的硬件门槛	繁琐的数据分析
缺陷样例收集困难 占用大量存储空间	度量角度不一 部分指标合理性不足	实验高度依赖算力 造成不必要的资源浪费	结论仍需人工分析 加重实验人员负担

挑战二：对Non-testable程序的定位

挑战①

如何不通过大量实验来设计最优SBFL公式?

挑战②

如何面向Non-testable程序展开缺陷定位?

程序员面临的真实调试场景

挑战③

如何在多缺陷环境下更好地定位缺陷?

挑战④

如何在更细粒度下进行缺陷定位?

挑战二：对Non-testable程序的定位

测试执行结果是动态缺陷定位的必要信息

错误程序

测试用例

- 测试输入
- 预期结果

有时不可得

运 行

缺陷定位

后续流程

……

$$TS:(t_1 \quad t_2 \quad \dots \quad t_m)$$

$$PG:\begin{pmatrix} s_1 \\ s_2 \\ \cdot \\ \cdot \\ \cdot \\ s_n \end{pmatrix} \quad MS:\begin{pmatrix} 1/0 & 1/0 & \dots & 1/0 \\ 1/0 & 1/0 & \dots & 1/0 \\ & \cdot & & \\ & \cdot & & \\ & \cdot & & \\ 1/0 & 1/0 & \dots & 1/0 \end{pmatrix}$$

$$RE:(p/f \quad p/f \quad \dots \quad p/f)$$

进而造成定位所需信息缺失

无法进行

挑战三：多缺陷环境下的定位

挑战①

如何不通过大量实验来设计最优SBFL公式?

挑战②

如何面向Non-testable程序展开缺陷定位?

程序员面临的真实调试场景

挑战③

如何在多缺陷环境下更好地定位缺陷?

挑战④

如何在更细粒度下进行缺陷定位?

挑战三：多缺陷环境下的定位

过于理想
实验中常见

单缺陷环境下

所有的失败测试用例均对应同一个缺陷，指向清晰明显。

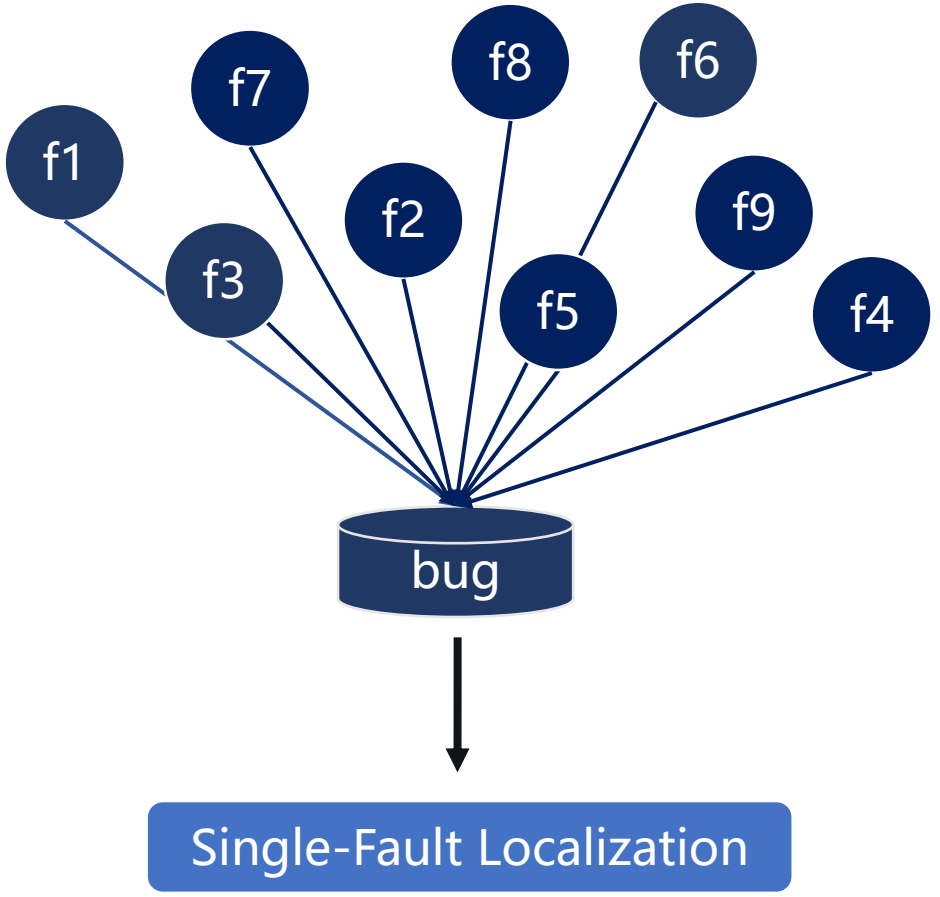

缺陷定位具有良好环境

挑战三：多缺陷环境下的定位

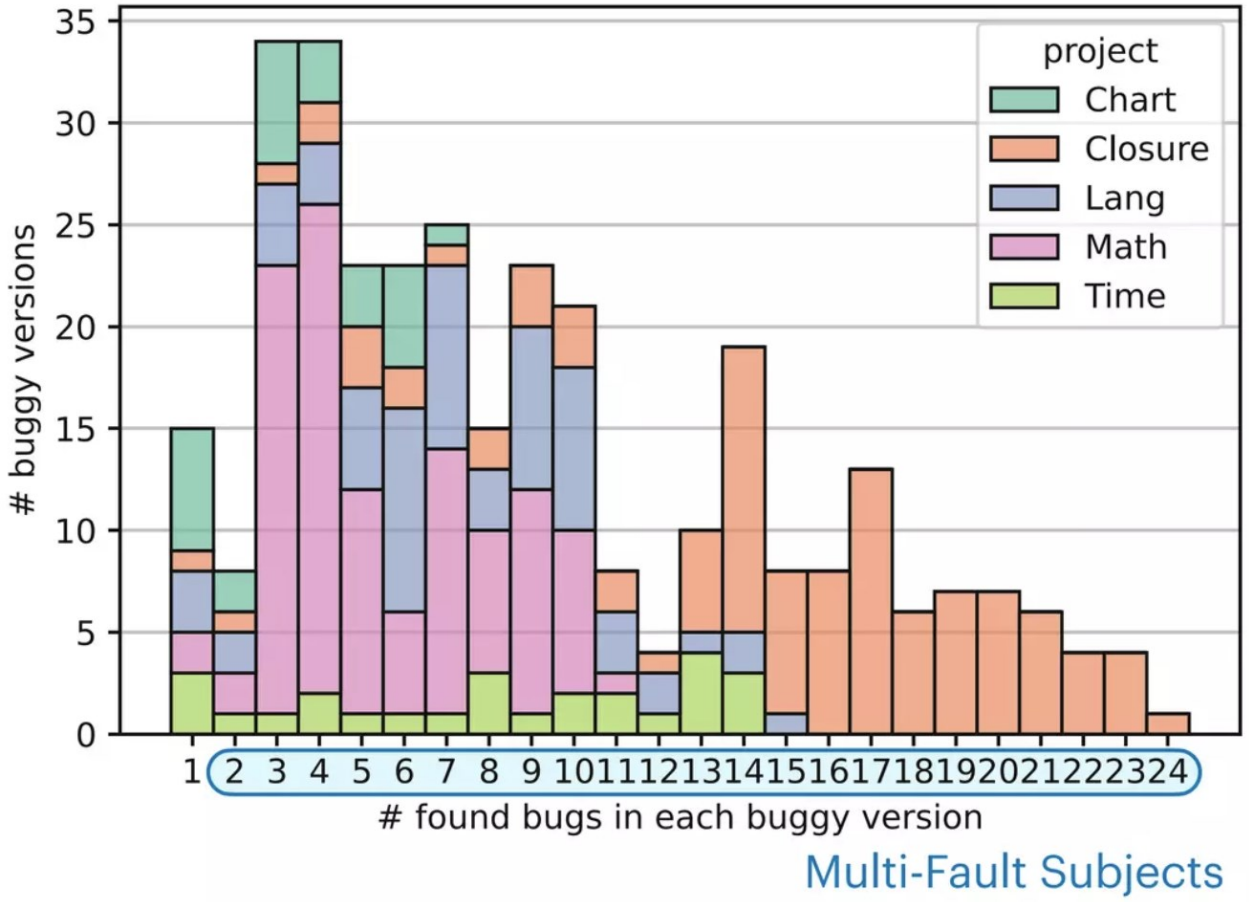

对现实开源工程的调研表明：

真实编程实践中，**95.4%**的错误程序都含有不止一处缺陷[1]。

[1] Ang Y, Chen L, Tian Y, et al. Searching for multi-fault programs in defects4j[C] //SSBSE 2021: 153-158.

挑战三：多缺陷环境下的定位

普遍存在
工业环境常态

多缺陷环境下

各个失败测试用例对应不同缺陷，指向混乱复杂。

给定位造成很大干扰

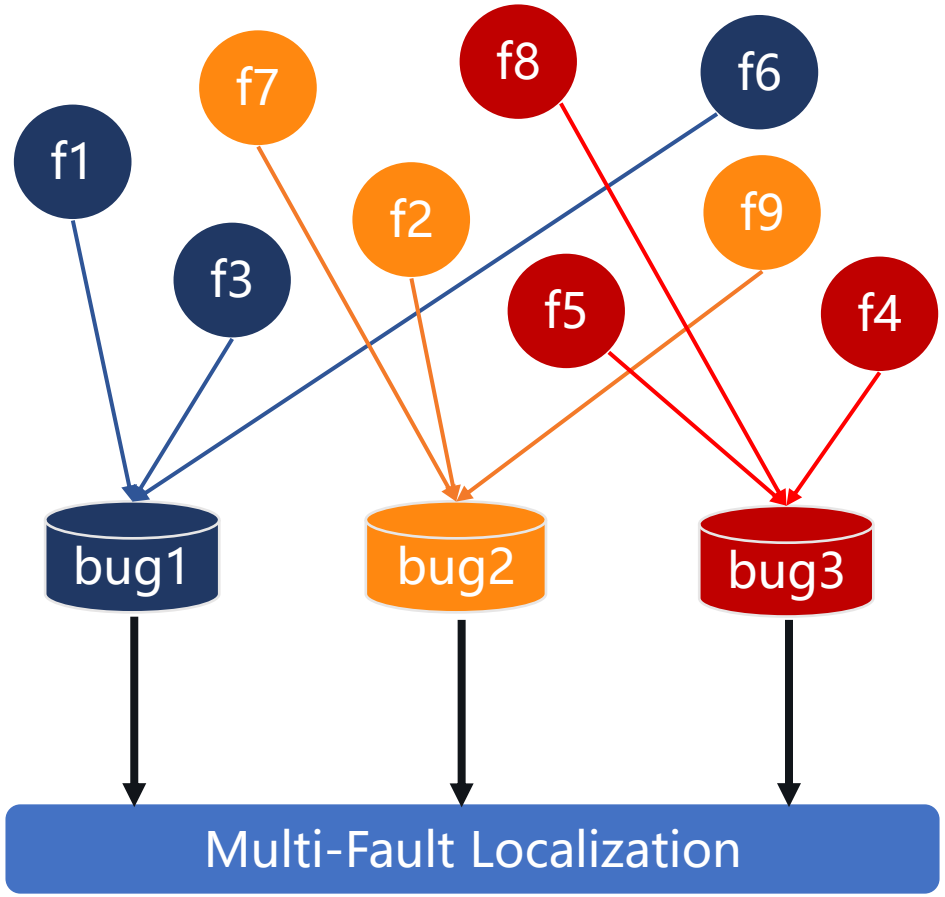

挑战四：细粒度缺陷定位

挑战①

如何不通过大量实验来设计最优SBFL公式?

挑战②

如何面向Non-testable程序展开缺陷定位?

程序员面临的真实调试场景

挑战③

如何在多缺陷环境下更好地定位缺陷?

挑战④

如何在更细粒度下进行缺陷定位?

挑战四：细粒度缺陷定位

Why it matters ?

较粗粒度定位结果

文件：范围过大

函数：范围仍较大

语句：难以理解缺陷根因

Faulty Position

≠

Root Cause

即便准确定位到缺陷位置，程序员仍需理解缺陷的根因

细粒度定位结果

例如变量：

直接锚定错误根因

进一步减少人工排查成本

有效引导缺陷修复

挑战四：细粒度缺陷定位

Why is it difficult?

程序运行态信息

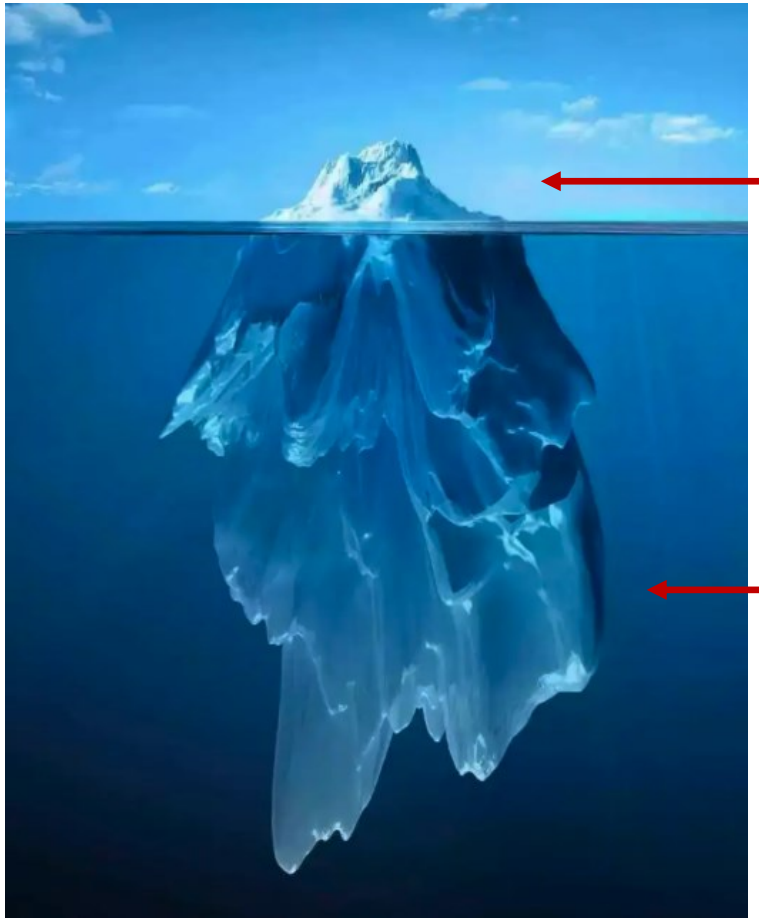

较为浅表的覆盖信息
(Coverage)

易于获取
目前应用最为广泛

更丰富、更深层的信息
对缺陷定位有极大增益

难以挖掘
尚未得到足够应用

PART 03
解决思路及效果
Solutions and Efficacy

解决思路

思路①

SBFL公式理论分析框架及最优公式生成技术

挑战②

如何面向Non-testable程序展开缺陷定位?

程序员面临的真实调试场景

挑战③

如何在多缺陷环境下更好地定位缺陷?

挑战④

如何在更细粒度下进行缺陷定位?

思路一：SBFL公式理论分析框架及最优公式生成技术

风险评估公式 (risk evaluation formula R)

mapping A_i into the risk value of statement s_i

SBFL最核心的组成部分

$$TS:(t_1 \quad t_2 \quad t_3 \quad t_4 \quad t_5 \quad \cdots) \quad A_i < a^i_{ef} \; a^i_{ep} \; a^i_{nf} \; a^i_{np} >$$

$$PG:\begin{pmatrix} s_1 \\ s_2 \\ s_3 \\ s_4 \end{pmatrix} \quad MS:\begin{pmatrix} 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 1 & 1 & 1 & 0 & 1 \\ 1 & 1 & 0 & 1 & 1 & 1 \end{pmatrix} \quad MA:\begin{pmatrix} 2 & 4 & 0 & 0 \\ 0 & 1 & 2 & 3 \\ 1 & 3 & 1 & 1 \\ 2 & 3 & 0 & 1 \end{pmatrix}$$

$$RE:(p \quad p \quad p \quad p \quad f \quad f)$$

$$\text{Tarantula} = \frac{\frac{e_f}{e_f+n_f}}{\frac{e_p}{e_p+n_p}+\frac{e_f}{e_f+n_f}}.$$

所有语句风险值降序排列，依次排查程序缺陷

- Expense metric (E)：须被检查语句的比例，The lower, the better

$s_{i1}, s_{i2}, \ldots \ldots, s_{ik}\ s_f, s_{k+2}, \ldots \ldots s_n$

$Expense = (k+1) / n$

Yue X, Qian T Y, Kun F. et al. A theoretical analysis of the risk evaluation formulas for spectrum-based fault localization[J]. ACM Transactions on software engineering and methodology (TOSEM), 2013, 22(4): 1-40.

思路一：SBFL公式理论分析框架及最优公式生成技术

定义：环境无关的任意两个公式之间的关系

- 公式 R_1 **优于** 公式 R_2 ($R_1 \rightarrow R_2$)
  - 如果在**任意**程序、任意错误语句、任意测试执行情况下，公式 R_1 给出的Expense值**永远小于等于**公式 R_2 给出的Expense值，则称 R_1 优于 R_2
- 公式 R_1 与公式 R_2 **等价** ($R_1 \leftrightarrow R_2$)
  - 如果在**任意**程序、任意错误语句、任意测试执行情况下，公式 R_1 给出的Expense值**永远等于**公式 R_2 给出的Expense值，则称 R_1 等价于 R_2

定义：最优公式 Maximality

- F 是所有公式的全集。对于一个公式 $R_1 \in F$，如果任意一个与其不相同的公式 $R_2 \in F$均满足“如果 $R_2 \rightarrow R_1$ 则有 $R_2 \leftrightarrow R_1$”，那么 R_1 称为 F 中的maximal。

思路一：SBFL公式理论分析框架及最优公式生成技术

给定一套测试用例集和一个公式R，待测程序$PG=\{s_1, s_2, \ldots, s_n\}$可以被划分为三个子集：

- S_B^R：　风险值比错误语句s_f的要高，排序在s_f之前的语句
- S_F^R：　风险值与错误语句s_f的相同，与s_f排序相同的语句
- S_A^R：　风险值比错误语句s_f的要低，排序在s_f之后的语句

$$S_B^R = \{s_i \in S | R(s_i) > R(s_f), 1 \le i \le n\}$$
$$S_F^R = \{s_i \in S | R(s_i) = R(s_f), 1 \le i \le n\}$$
$$S_A^R = \{s_i \in S | R(s_i) < R(s_f), 1 \le i \le n\}$$

只与R的定义有关

公式之间优劣关系：集合包含关系，是真正决定定位效果的关键因素

思路一：SBFL公式理论分析框架及最优公式生成技术

Theorem 1：给定两个公式, 如果其对应的程序语句子集存在关系 $S_B^{R_1} = S_B^{R_2}, S_F^{R_1} = S_F^{R_2}, S_A^{R_1} = S_A^{R_2}$, 则 $R_1 \leftrightarrow R_2$ ， 也即 $R_2 \rightarrow R_1$ 且 $R_1 \rightarrow R_2$

思路一：SBFL公式理论分析框架及最优公式生成技术

Theorem 2： 给定两个公式，如果其对应的程序语句子集存在关系$S_B^{R_1} \subseteq S_B^{R_2}$，$S_A^{R_2} \subseteq S_A^{R_1}$，则$R_1 \rightarrow R_2$

Theorem 3： 给定两个公式， 如果其对应的程序语句子集存在关系$S_B^{R_1} \subsetneq S_B^{R_2}$，$S_A^{R_2} \subsetneq S_A^{R_1}$，则$R_1 \rightarrow R_2$ ， 且$R_2 \nrightarrow R_1$， 即R_1 严格优于R_2

Theorem 4： 给定两个公式， 如果其对应的程序语句子集存在反例使得相对应的子集间无确定包含关系，则$R_1 \nrightarrow R_2$，且$R_2 \nrightarrow R_1$

思路一：SBFL公式理论分析框架及最优公式生成技术

Theorem 5: 对于任意公式R ∈ F, 当且仅当 $\boldsymbol{U_R = \emptyset}$ 时，R为maximal

- $U_R = \emptyset$ 是 maximality 的充要条件
- 性质: 如果$U_{R1} = U_{R2} = \emptyset$，并且$P_{R1} = P_{R2}$，那么$R_2 \leftrightarrow R_1$
- 性质: 如果$U_{R1} = U_{R2} = \emptyset$，并且$P_{R1} \neq P_{R2}$，那么$R_2 \nleftrightarrow R_1$

将平面上每个<e_{if}, e_{ip}>点映射到三维空间Risk Value轴的相应高度

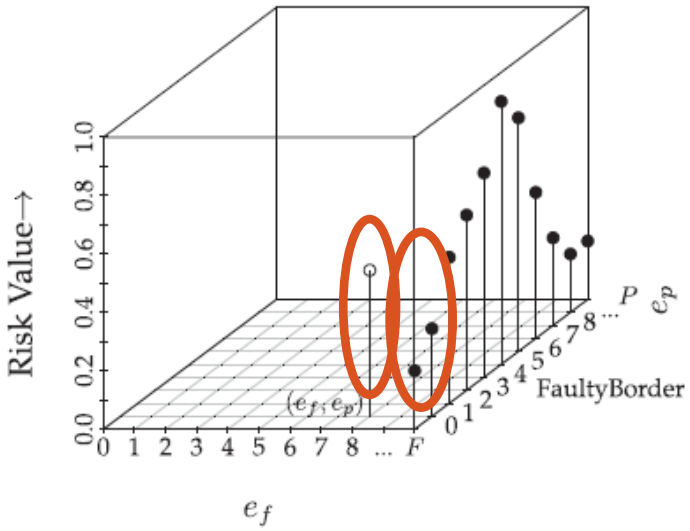

思路一：SBFL公式理论分析框架及**最优公式生成技术**

使用GP来自动生成最优风险值评估公式

Operator Node	Definition
gp_add(a, b)	a + b
gp_sub(a, b)	a - b
gp_mul(a, b)	ab
gp_div(a, b)	1 if $b = 0$, $\frac{a}{b}$ otherwise
gp_sqrt(a)	$\sqrt{\lvert a \rvert}$

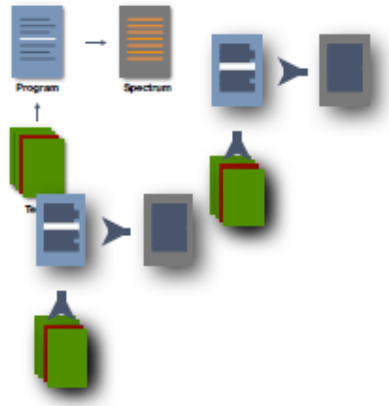

Seed Data

$$e_f^2(2e_p + 2e_f + 3n_p)$$

$$e_f^2(e_f^2 + \sqrt{n_p})$$

$$\cdots$$

GP13

GP2

GP3

GP19

$$\text{fitness}(\tau, B, P) = \frac{1}{n}\sum_{i=1}^{n} E(\tau, p_i, b_i) \text{ (to be minimised)}$$

$$E(\tau, p, b) = \frac{\text{Ranking of } b \text{ according to } \tau}{\text{Number of statements in } p} * 100$$

Yoo S, Xie X, Kuo F C, et al. Human competitiveness of genetic programming in spectrum-based fault localisation: Theoretical and empirical analysis[J]. ACM Transactions on Software Engineering and Methodology (TOSEM), 2017, 26(1): 1-30.

思路一：SBFL公式理论分析框架及**最优公式生成技术**

公式最优化效果 (实践)：

Annual "Humies" Awards
For Human-Competitive Results
Produced By Genetic And Evolutionary Computation

14th Annual ACM SIGEVO HUMIES Awards

GP生成的最优公式
效果显著优于现有公式

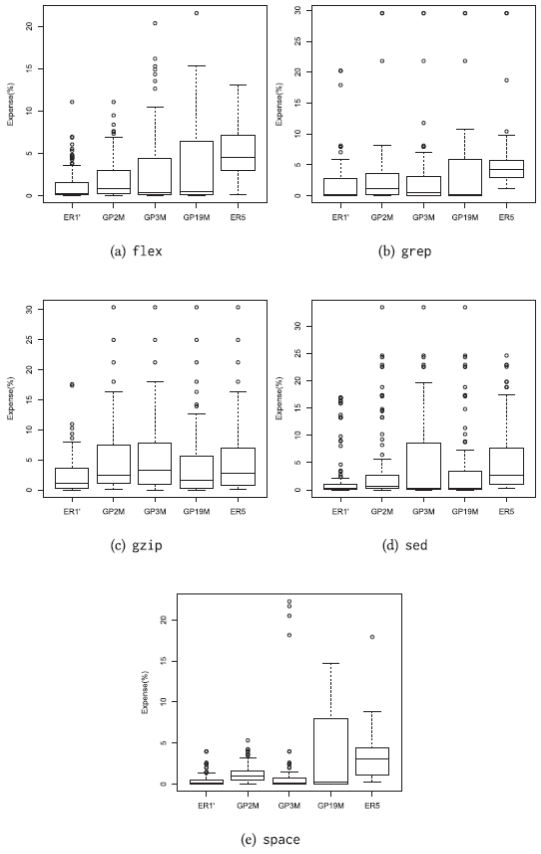

GP13 是“practical greatest” formula

GP生成		人工设计
自动化	初始种群生成	了解任务背景
	↓	↓
	适应度评估	研究公式原理
	↓	↓
无人工干预	选 择	手动设计公式
	↓	↓
一次生成多个公式	交叉、复制、变异	验证公式语法是否合理
	↓	↓
	下一代	人工分析结论
		需大量人工参与
		一次设计一个公式

解决思路

思路①

SBFL公式理论分析框架及最优公式生成技术

思路②

Test oracle缺失环境下的缺陷定位技术

程序员面临的真实调试场景

挑战③

如何在多缺陷环境下更好地定位缺陷?

挑战④

如何在更细粒度下进行缺陷定位?

思路二：Test Oracle缺失环境下的缺陷定位技术

Test Oracle与Oracle问题

Test Oracle 验证输出结果正确性的机制

Oracle Problem Oracle不可得或应用Oracle成本高昂

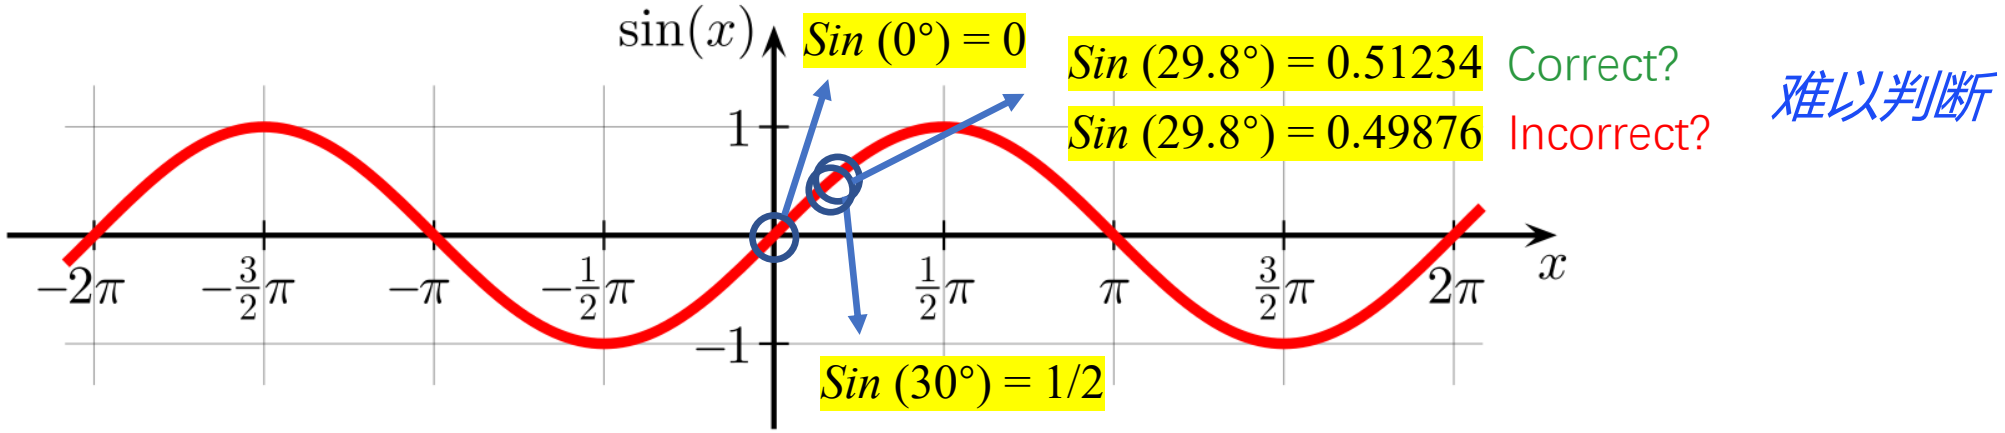

难以判断

思路二：Test Oracle缺失环境下的缺陷定位技术

解决Test oracle缺失的技术：
蜕变测试 (Metamorphic Testing)

29.8°

初始测试用例
(source test case)：
{x, f(x)}

根据现有策略生成
初始测试用例
如Random testing

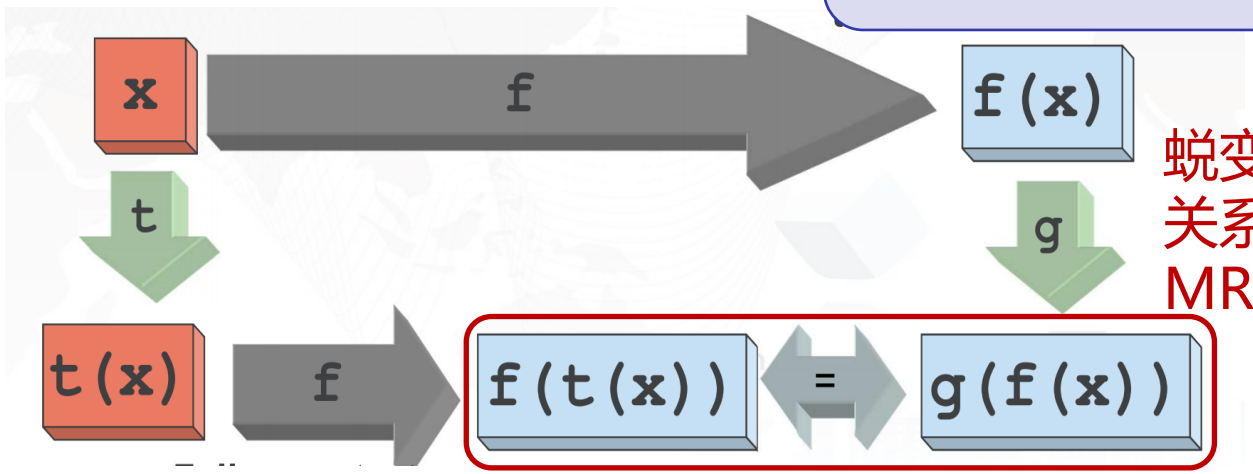

蜕变
关系
MR

待测程序的一种内在属性
涉及多个<输入, 输出>对

Sin (x) = Sin (x + 360°)

389.8°

根据初始测试用例，
按照MR来构造后续
测试用例

后续测试用例
(follow-up test case)：
{t(x), f(t(x))}

分别执行初始测试用例和后续
测试用例，检查它们的输出是
否符合MR的定义

思路二：Test Oracle缺失环境下的缺陷定位技术

如何利用MT思想解决Oracle缺失环境下的缺陷定位？

~~传统SBFL：一条失效测试用例的执行轨迹中一定包含了faulty statement~~

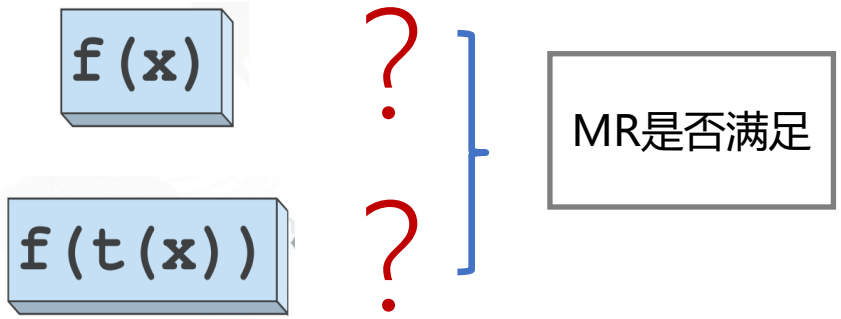

改进SBFL：绑定于同一个MR的一组测试用例，如果其执行结果不满足MR定义，则至少其中一条测试执行轨迹包含了faulty statement

解决方案：将蜕变关系和传统的程序切片结合，构造蜕变切片：Metamorphic slice (MSlice)

$$e\_mslice(MR,T^S)=\left(\bigcup_{i=1}^{ks} e\_slice(t_i^S)\right)\cup\left(\bigcup_{i=1}^{kf} e\_slice(t_i^F)\right)$$

$$d\_mslice(v,MR,T^S)=\left(\bigcup_{i=1}^{ks} d\_slice(v,t_i^S)\right)\cup\left(\bigcup_{i=1}^{kf} d\_slice(v,t_i^F)\right)$$

Xie X, Wong W E, Chen T Y, et al. Metamorphic slice: An application in spectrum-based fault localization[J]. Information and Software Technology, 2013, 55(5): 866-879.

思路二：Test Oracle缺失环境下的缺陷定位技术

如何利用MT思想解决Oracle缺失环境下的缺陷定位?

三步替换，摆脱了对Test Oracle的依赖，使得输出结果得以补全

每一个单个测试用例 t_i → 蜕变测试用例组 g_i

t_i的执行切片 → g_i的执行蜕变切片

单个测试用例的通过或失败 → 蜕变测试用例组对MR的遵循或违反

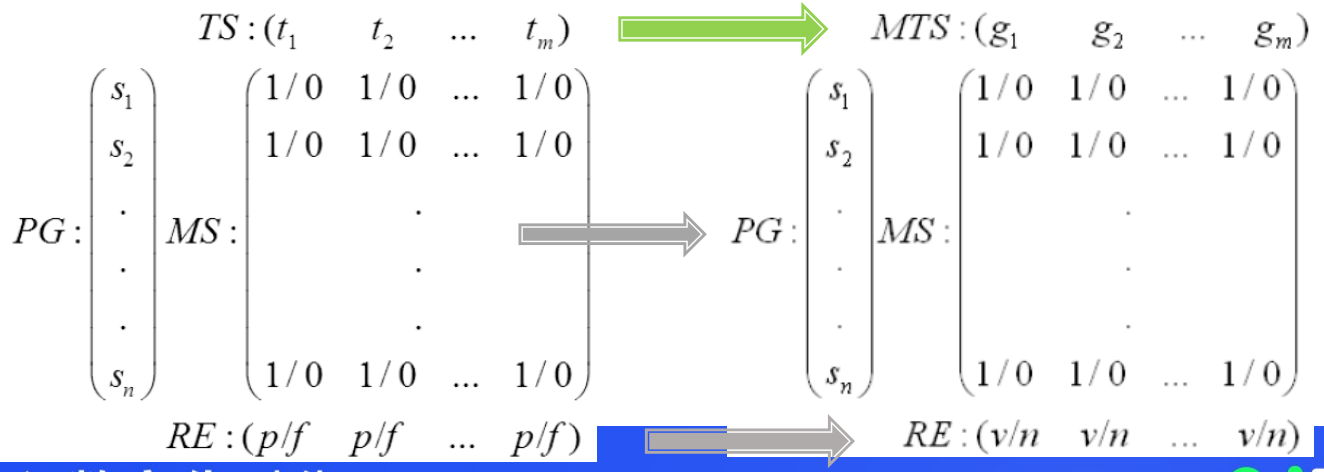

思路二：Test Oracle缺失环境下的缺陷定位技术

MSlice成功实现了Oracle缺失条件下的高效缺陷定位

补全了缺失的频谱信息，与高度依赖Oracle的传统SBFL技术相比，实现了几乎无损的缺陷定位效果。

SBFL **without** Oracle ≈ SBFL **with** Oracle

Summarized results. (The paired Wilcoxon-Signed-Rank Test)

Comparison		BETTER	WORSE	SIMILAR
MS vs. S-ST	T	4	2	3
	O	0	4	5
	J	0	4	5
MS vs. S-FT	T	3	1	5
	O	1	5	3
	J	1	4	4
MS vs. S-AT	T	3	2	4
	O	0	4	5
	J	0	4	5

思路二：Test Oracle缺失环境下的缺陷定位技术

MSlice大幅突破了传统SBFL的使用瓶颈

- **彻底摆脱**Test Oracle的限制
- 将SBFL的应用环境**扩大到**被Oracle问题困扰的测试调试中
- **极大拓展**传统缺陷定位技术的灵活性和可用性

解决思路

思路①

SBFL公式理论分析框架及最优公式生成技术

思路②

Test oracle缺失环境下的缺陷定位技术

程序员面临的真实调试场景

思路③

基于失效聚类的软件多缺陷隔离技术

挑战④

如何在更细粒度下进行缺陷定位?

思路三：基于失效聚类的软件多缺陷隔离技术

多缺陷问题普遍存在于工业环境软件开发中

多缺陷环境下

各个失败测试用例对应不同缺陷，指向混乱复杂。

造成传统SBFL的有效性下降 [1-4]

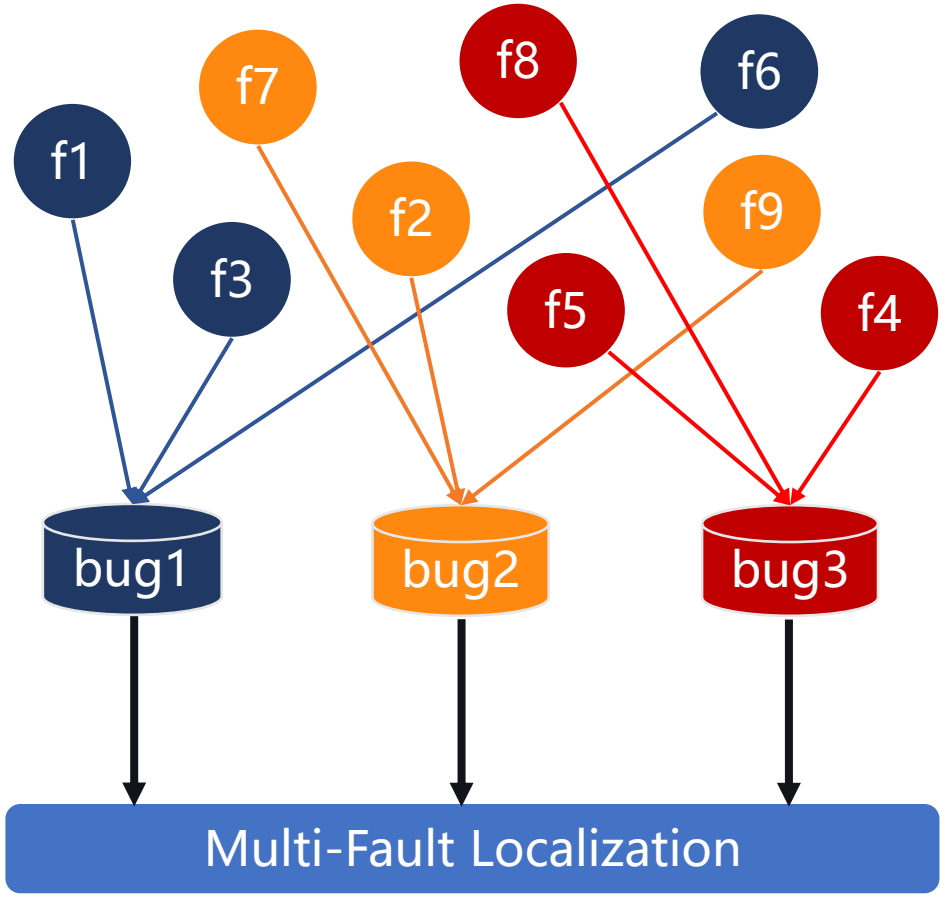

[1] Wong W E, Gao R, Li Y, et al. A survey on software fault localization[J]. IEEE Transactions on Software Engineering, 2016, 42(8): 707-740.

[2] Gao R, Wong W E. MSeer - An Advanced Technique for Locating Multiple Bugs in Parallel[J]. IEEE Transactions on Software Engineering, 2019, 45(03): 301-318.

[3] Yi Song, Xiaoyuan Xie, Xihao Zhang, et al. *Evolving Ranking-Based Failure Proximities for Better Clustering in Fault Isolation.* ASE' 22

[4] Yi Song, Xiaoyuan Xie, Quanming Liu, Xihao Zhang and Xi Wu. *A Comprehensive Empirical Investigation on Failure Clustering in Parallel Debugging.* Journal of Systems and Software (JSS), 2022, 193: 111452

思路三：基于失效聚类的软件多缺陷隔离技术

解决多故障定位问题的三种基本思路：

- One-bug at a time

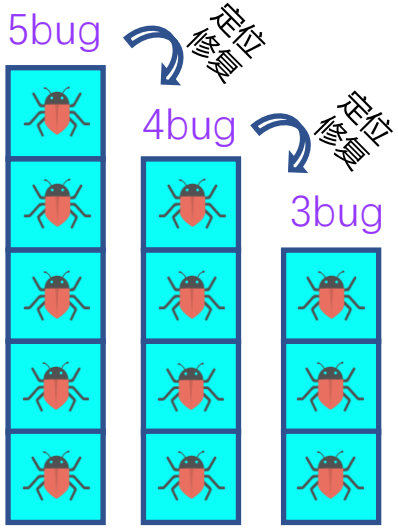

一次处理一个缺陷

- Multiple-bug at a time

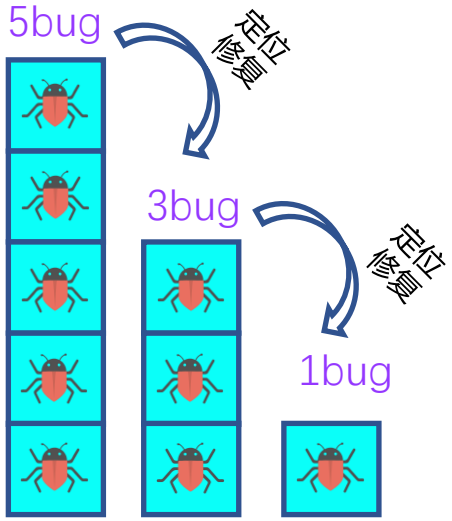

一次处理多个缺陷

忽略失败测试用例和缺陷之间复杂的映射关系

重复定位修复过程，直到所有测试用例均通过

- **Parallel debugging**

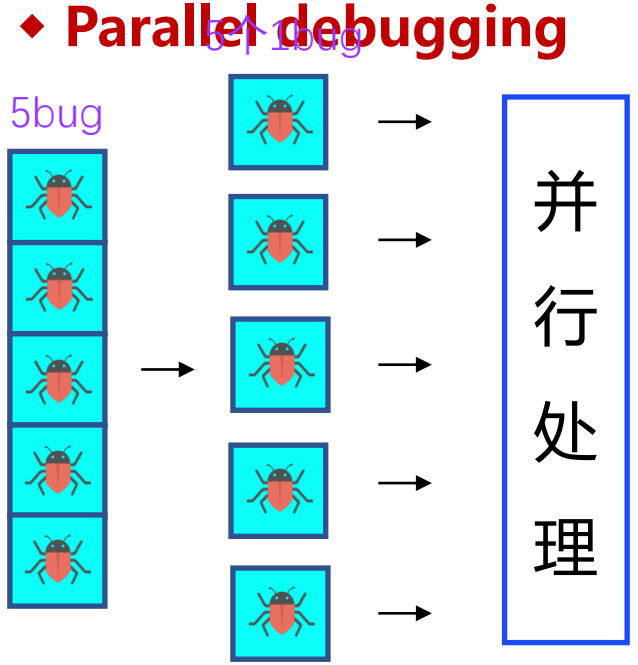

分析失败测试用例和缺陷之间复杂的映射关系

将一整个多缺陷定位任务隔离成多个单缺陷定位任务

不同程序员分别处理不同子任务

思路三：基于失效聚类的软件多缺陷隔离技术

Parallel Debugging

并行调试的核心在于如何恰当地对软件异常行为 (通常为失败测试用例) 根据其缺陷根因进行划分。这一过程也称为**Failure Indexing (失效索引)**。

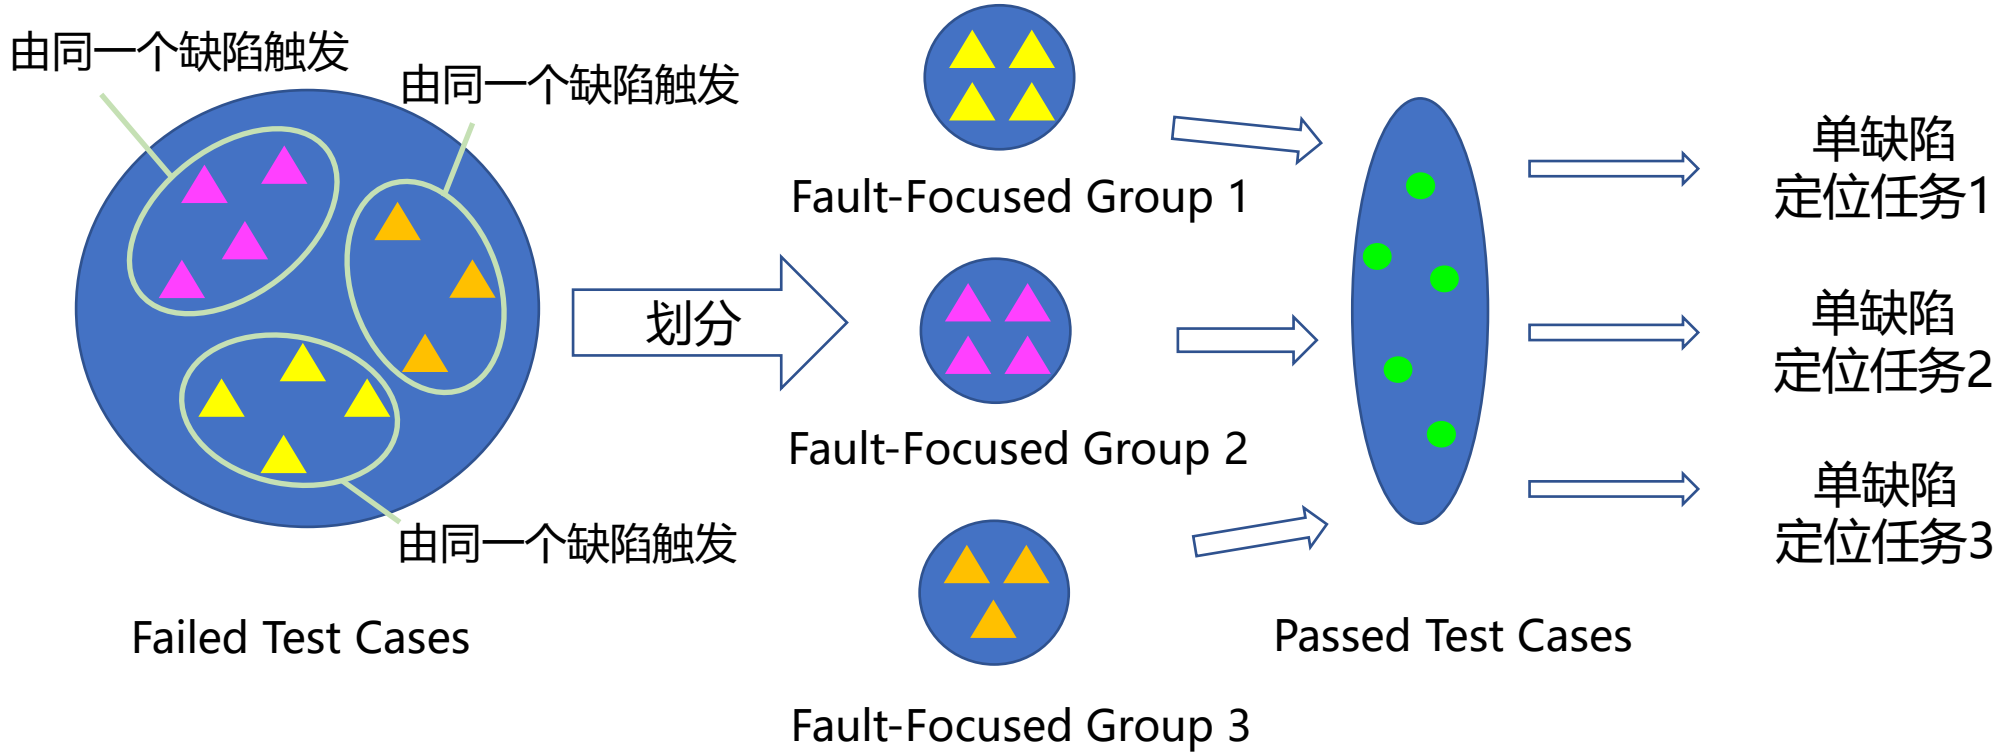

思路三：基于失效聚类的软件多缺陷隔离技术

失效索引过程

核心

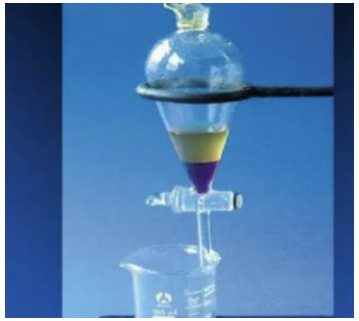

Fingerprinting Function

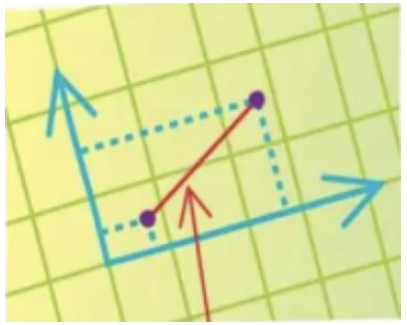

Distance Metric

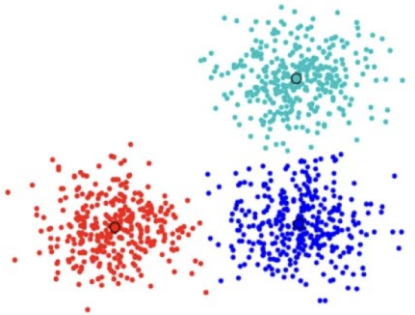

Clustering Algorithm

也称**Failure Proximity (失效近似度)**

如何准确提取失效行为的特征，从而对其进行数学化、形式化的建模和表征？

如何对已经被二次表征的失效行为进行相似性度量，以判断其是否由同一个缺陷触发？

如何基于上游距离信息，对所有失效行为进行聚类，以实现对缺陷的隔离？

思路三：基于失效聚类的软件多缺陷隔离技术

当前六种主流的Failure Proximity

Fingerprinting Function	Distance Metric
Failure Point-based Failure Proximity (FP)	0-1 distance
Stack Trace-based Failure Proximity (ST)	0-1 distance or edit distance
Code Coverage-based Failure Proximity (CC)	Jaccard, Euclid distance, etc.
Predicate Evaluation-based Failure Proximity (PE)	Euclidean distance
Dynamic Slicing-based Failure Proximity (DS)	Jaccard distance
Statistical Debugging-based Failure Proximity (SD)	Kendall tau distance

已被证明效果最优

思路三：基于失效聚类的软件多缺陷隔离技术

Statistical Debugging (SD)-based Failure Proximity将一个失效行为表征为一个语句风险值排序列表

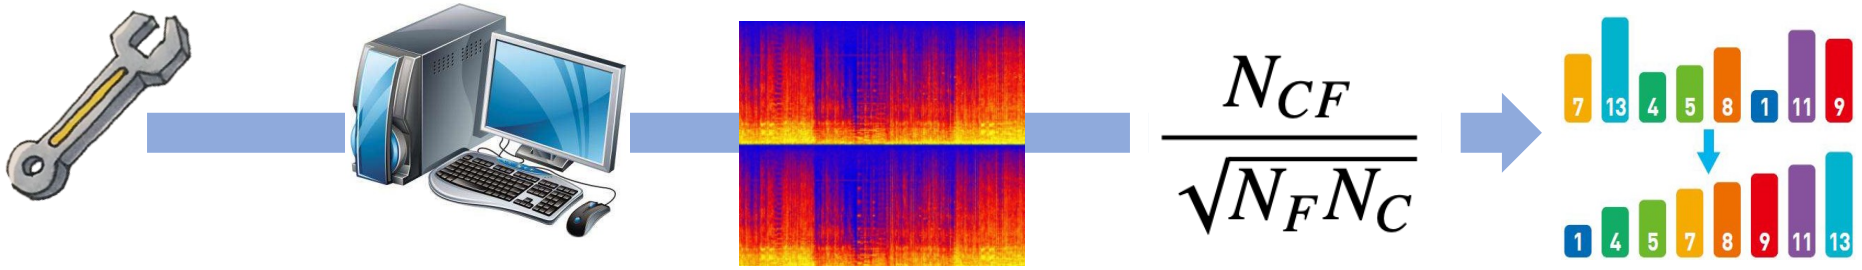

单个失败测试用例

\+ 成功测试用例

待测程序

频谱信息

(Coverage)

SBFL公式

语句排序列表

思路三：基于失效聚类的软件多缺陷隔离技术

当前SD-based Failure Proximity的代表性技术 MSeer

现有众多风险值评估公式几乎都是为缺陷定位设计，

在失效索引环境下，这些公式的效果和其缺陷定位效果一致吗？

Gao R, Wong W E. MSeer—An Advanced Technique for Locating Multiple Bugs in Parallel[J]. IEEE Transactions on Software Engineering, 2019, 45(7): 690-709.

思路三：基于失效聚类的软件多缺陷隔离技术

发现SBFL公式的失效索引能力和缺陷定位能力并不一致

Versus R_1 / R_2	Group1	Group2	Group3	Group4	Group5	Group6	Group7	Group8	Group9	Group10	Group11	Group12
Group1		✓✓✓✓			✓✓✓✓	✓✓✓✓			✓✓✓✓		✓✓✓✓	✓✓✓✓
Group2					✓✓✓✓	✓✓✓✓			✓✓✓✓		✓✓✓✓	✓✓✓✓
Group3	✓✓✓✓	✓✓✓✓			✓✓✓✓	✓✓✓✓	✓✓✓✓	✓✓✓	✓✓✓✓	✓ ✓	✓✓✓✓	✓✓✓✓
Group4	✓✓✓✓	✓✓✓✓	✓✓✓✓		✓✓✓✓	✓✓✓✓	✓✓✓✓	✓✓✓✓	✓✓✓✓	✓✓✓✓	✓✓✓✓	✓✓✓✓
Group5											✓✓✓✓	✓✓✓✓
Group6					✓✓✓✓				✓✓✓✓		✓✓✓✓	✓✓✓✓

如何获得失效索引环境下适用的风险评估公式
进一步提升MSeer能力？

R	FMI	JC	PR	RR
Group1	116.79	96.96	117.77	75.23
Group2	131.3	110.28	134.2	88.81
Group3	80.33	68.71	74.97	60.98
Group4	53.12	45.68	52.83	41.44
Group5	148.82	125.06	137.75	100.96
Group6	135.83	112.8	134.65	93.75
Group7	107.87	89.29	108.51	68.92
Group8	93.32	77.02	88.58	60.39
Group9	138.59	114.87	137.33	95
Group10	83.33	66.85	81.36	51.4
Group11	155.55	130.36	154.95	120.39
Group12	**164.33**	**139.62**	**170.15**	**120.47**

在缺陷定位任务中表现良好的公式，

在失效索引任务中并不一定同样好。

Yi Song, Xiaoyuan Xie, Quanming Liu, Xihao Zhang and Xi Wu. *A Comprehensive Empirical Investigation on Failure Clustering in Parallel Debugging*. In Journal of Systems and Software (JSS), 2022, 193: 111451.

思路三：基于失效聚类的软件多缺陷隔离技术

基于演化的多缺陷隔离评估公式自动生成算法

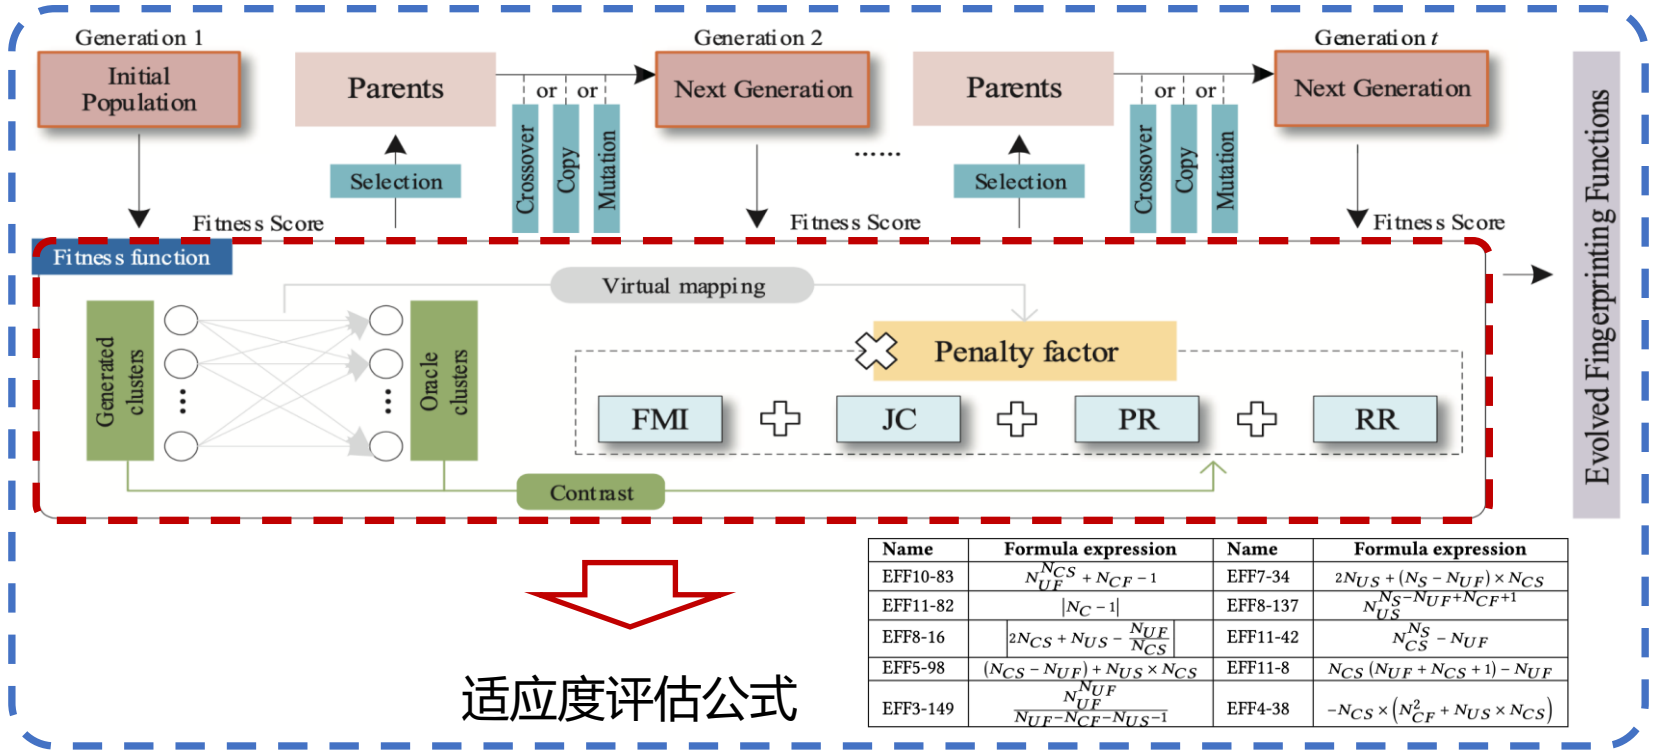

Name	Formula expression	Name	Formula expression
EFF10-83	$N_{UF}^{N_{CS}} + N_{CF} - 1$	EFF7-34	$2N_{US} + (N_S - N_{UF}) \times N_{CS}$
EFF11-82	$\lvert N_C - 1 \rvert$	EFF8-137	$N_{US}^{N_S - N_{UF} + N_{CF} + 1}$
EFF8-16	$\left\lvert 2N_{CS} + N_{US} - \frac{N_{UF}}{N_{CS}} \right\rvert$	EFF11-42	$N_{CS}^{N_S} - N_{UF}$
EFF5-98	$(N_{CS} - N_{UF}) + N_{US} \times N_{CS}$	EFF11-8	$N_{CS}(N_{UF} + N_{CS} + 1) - N_{UF}$
EFF3-149	$\frac{N_{UF}^{N_{UF}}}{N_{UF} - N_{CF} - N_{US} - 1}$	EFF4-38	$-N_{CS} \times \left(N_{CF}^2 + N_{US} \times N_{CS}\right)$

Algorithm 1 Evolution Framework

Input:
the size of population ***n***, the maximum tree depth of EFF ***d***, fitness function ***FF***, the size of selected parents ***p***, crossover rate ***c***, copy rate ***o***, mutation rate ***m***, stopping criterion ***SC***

Output:
evolved fingerprinting function

1: ***IP*** ← ***n*** randomly initialized EFFs within the constraint of ***d***
2: ***CP*** ← ***IP***
3: **repeat**
4: ***FS*** ← ***FF(CP)***
5: ***PA*** ← Selecting ***p*** individuals in ***CP*** according to ***FS***
6: ***NG*** ← crossover, copy, or mutate individuals in ***PA*** with ***c***, ***o***, and ***m***, respectively
7: ***CP*** ← ***NG***
8: **until** ***SC*** == True

Algorithm 2 Fitness Function

Input:
an *r*-bug faulty version, an evolved fingerprinting function ***EFF***, distance metric ***DM***, the faults number estimation strategy ***EN***, the medoids initialization strategy ***IM***, clustering algorithm ***CA***

Output:
fitness score

1: Utilize ***EFF*** to convert failed test cases into ranking lists
2: Calculate distances between ranking lists using ***DM***
3: Employ ***EN*** to get the predicted number of faults *k*
4: **If** *k* != *r*:
5: set ***FS*** to be zero
6: **Elif** *k* == *r*:
7: Leverage ***IM*** to initialize medoids and running ***CA***
8: Obtain *Total_metrics* and *PenaltyFactor* by calculating and analyzing four external metrics
9: set ***FS*** to be *Total_metrics* times *PenaltyFactor*

Yi Song, Xiaoyuan Xie, Xihao Zhang, et al. *Evolving Ranking-Based Failure Proximities for Better Clustering in Fault Isolation.* ASE' 22

思路三：基于失效聚类的软件多缺陷隔离技术

基于演化的多缺陷隔离评估公式自动生成算法

		EFF10-83	EFF7-34	EFF11-82	EFF8-137	EFF8-16	EFF11-42	EFF5-98	EFF11-8	EFF3-149	EFF4-38
按缺陷数量分子情况 2-bug	FV_e	60 (22.45%)	58 (18%)	68 (38.78%)	64 (30.61%)	27	45	23	32	45	66 (34.69%)
	Sum_{FS}	182.82 (21.75%)	180.15 (19.97%)	214.3 (42.71%)	186.88 (24.45%)	85.7	139.07	75.27	96.37	137.46	210.8 (40.38%)
3-bug	FV_e	60 (50.00%)	45 (12.50%)	48 (20.00%)	44 (10.00%)	48 (20.00%)	46 (15.00%)	37	37	47 (17.50%)	43 (7.50%)
	Sum_{FS}	154.69 (43.64%)	124.43 (15.54%)	128.43 (19.26%)	120.27 (11.68%)	123.14 (14.35%)	121.93 (13.22%)	99.85	98.53	125.11 (16.18%)	119.21 (10.70%)
4-bug	FV_e	45 (2.27%)	44	30	34	45 (2.27%)	31	61 (38.64%)	33	33	19
	Sum_{FS}	108.16 (2.43%)	104.3	71.9	82.03	111.95 (6.02%)	78.05	147.46 (39.65%)	80.59	82.63	48.55
5-bug	FV_e	43 (30.30%)	32	24	26	49 (48.48%)	33	36 (9.09%)	56 (69.70%)	26	11
	Sum_{FS}	103.05 (32.86%)	74.99	54.37	59.4	118.42 (52.68%)	81.2 (4.69%)	87.54 (12.87%)	133.92 (72.67%)	63.98	26.46
按缺陷类型分子情况 TypeA	FV_e	73 (87.18%)	62 (58.97%)	54 (38.46%)	55 (41.03%)	62 (58.97%)	43 (10.26%)	57 (46.15%)	58 (48.72%)	46 (17.95%)	39
	Sum_{FS}	191.64 (94.74%)	171.41 (74.18%)	155.58 (58.09%)	153.72 (56.20%)	162.3 (64.92%)	116.26 (18.14%)	148.79 (51.19%)	149.95 (52.37%)	127 (29.05%)	116.32 (18.20%)
TypeP	FV_e	69 (50.00%)	52 (13.04%)	57 (23.91%)	53 (15.22%)	57 (23.91%)	65 (41.30%)	57 (23.91%)	51 (10.87%)	43	46
	Sum_{FS}	179.34 (40.03%)	138.12 (7.85%)	150.89 (17.82%)	143.81 (12.29%)	148.62 (16.05%)	177.19 (38.35%)	149.79 (16.96%)	135.99 (6.18%)	118.67	134.78 (5.24%)
TypeH	FV_e	66 (17.86%)	65 (16.07%)	59 (5.36%)	60 (7.14%)	50	47	43	49	62 (10.71%)	54
	Sum_{FS}	177.74 (19.57%)	174.33 (17.28%)	162.53 (9.34%)	151.05 (1.61%)	128.29	126.8	111.54	123.47	163.51 (10.00%)	153.93 (3.55%)
总情况 All	FV_e	208 (50.72%)	179 (29.71%)	170 (23.19%)	168 (21.74%)	169 (22.46%)	155 (12.32%)	157 (13.77%)	158 (14.49%)	151 (9.42%)	139 (0.72%)
	Sum_{FS}	548.72 (47.41%)	483.86 (29.99%)	468.99 (25.99%)	448.58 (20.51%)	439.21 (17.99%)	420.25 (12.90%)	410.12 (10.18%)	409.41 (9.99%)	409.18 (9.93%)	405.02 (8.81%)

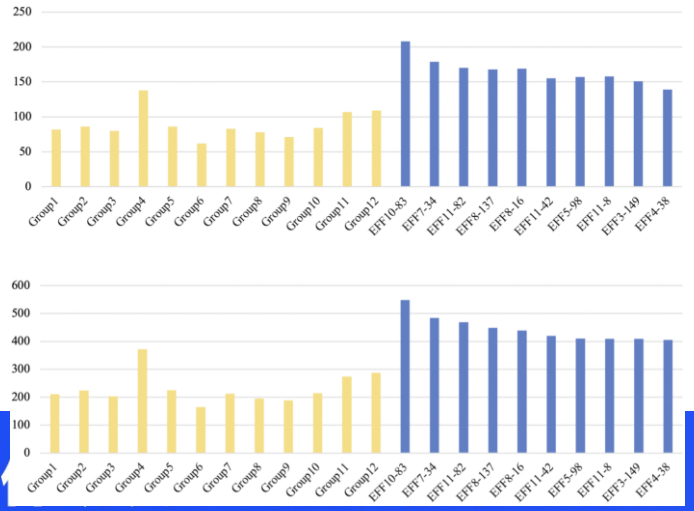

关于Fv_e (公式准确预估缺陷数量的能力)：

相比SOTA，增长幅度从0.72%到50.72%不等

关于SUM_{FS} (公式将失效按照缺陷根因进行归类的能力)：

相比SOTA，增长幅度从8.81%到47.41%不等

解决思路

思路①

SBFL公式理论分析框架及最优公式生成技术

思路②

Test oracle缺失环境下的缺陷定位技术

程序员面临的真实调试场景

思路③

基于失效聚类的软件多缺陷隔离技术

思路④

面向变量的细粒度软件缺陷定位技术

思路四：面向变量的细粒度软件缺陷定位技术

现有缺陷定位技术大多面临粒度粗糙问题

文件/函数粒度：给出File/Function的含错风险排序，程序员需自行进入File/Function内部手动定位缺陷位置。

语句粒度：给出语句的含错风险排序。尽管排查空间大大缩小，但即便给定错误语句，程序员也难以理解缺陷根因。

变量粒度：给出程序变量的含错风险排序。直接锚定缺陷根因所在，所给结果具有良好的解释能力。

思路四：面向变量的细粒度软件缺陷定位技术

IsoVar – 变量粒度级别的缺陷定位代表性技术

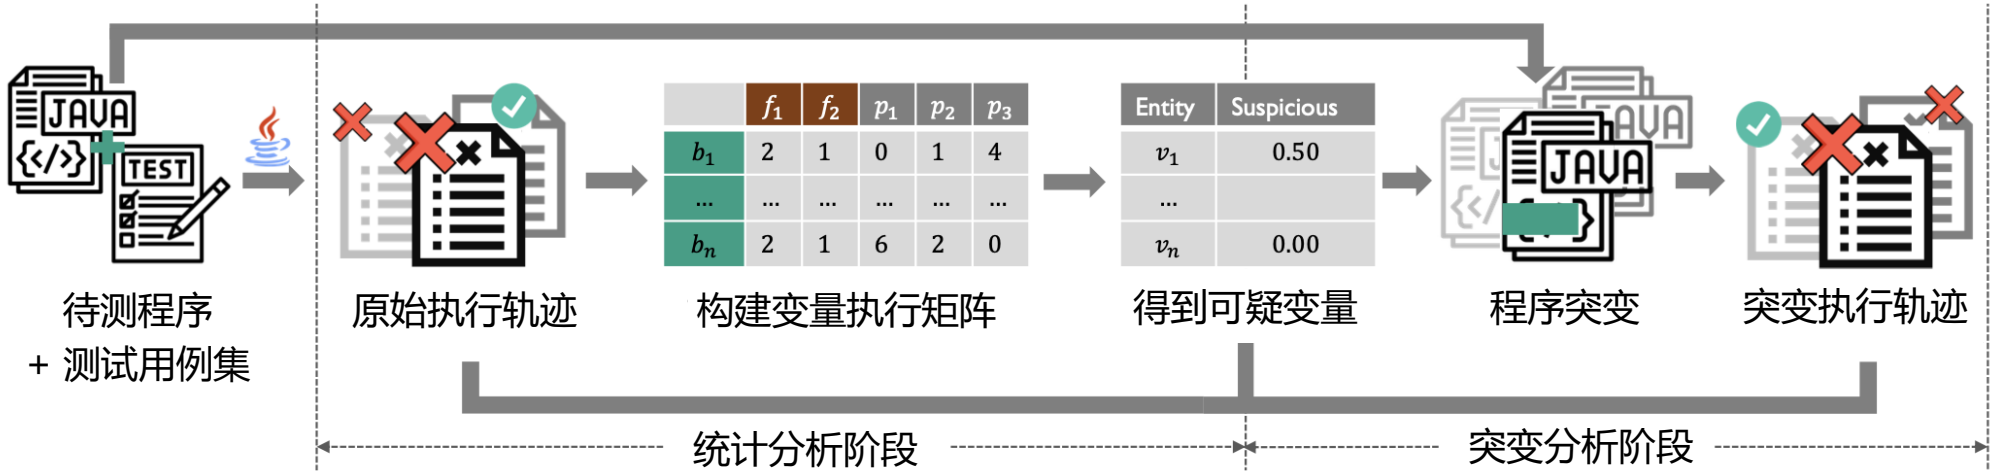

IsoVar方法流程图

思路四：面向变量的细粒度软件缺陷定位技术

IsoVar统计分析阶段：根据覆盖信息初步计算变量与失败执行的关联

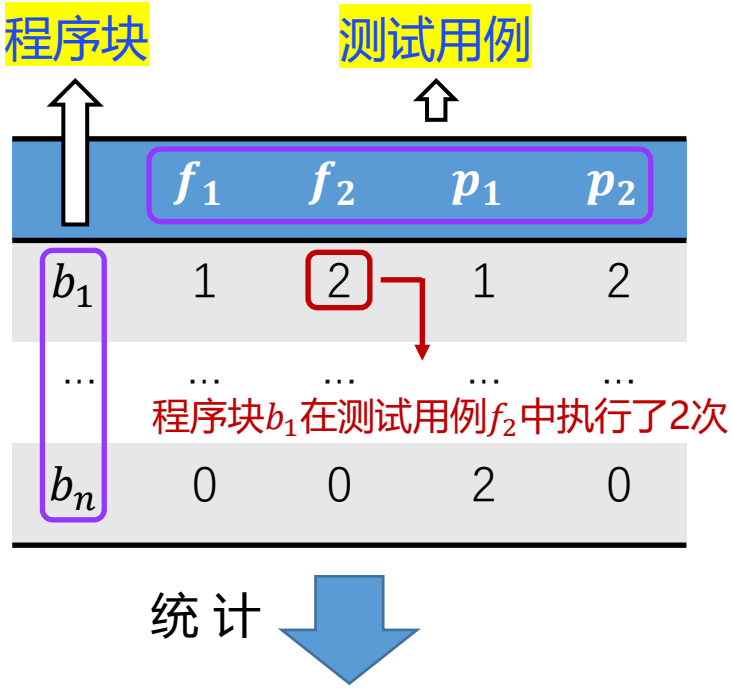

变量在失败测试用例中出现的平均频率

变量在通过测试用例中出现的平均频率

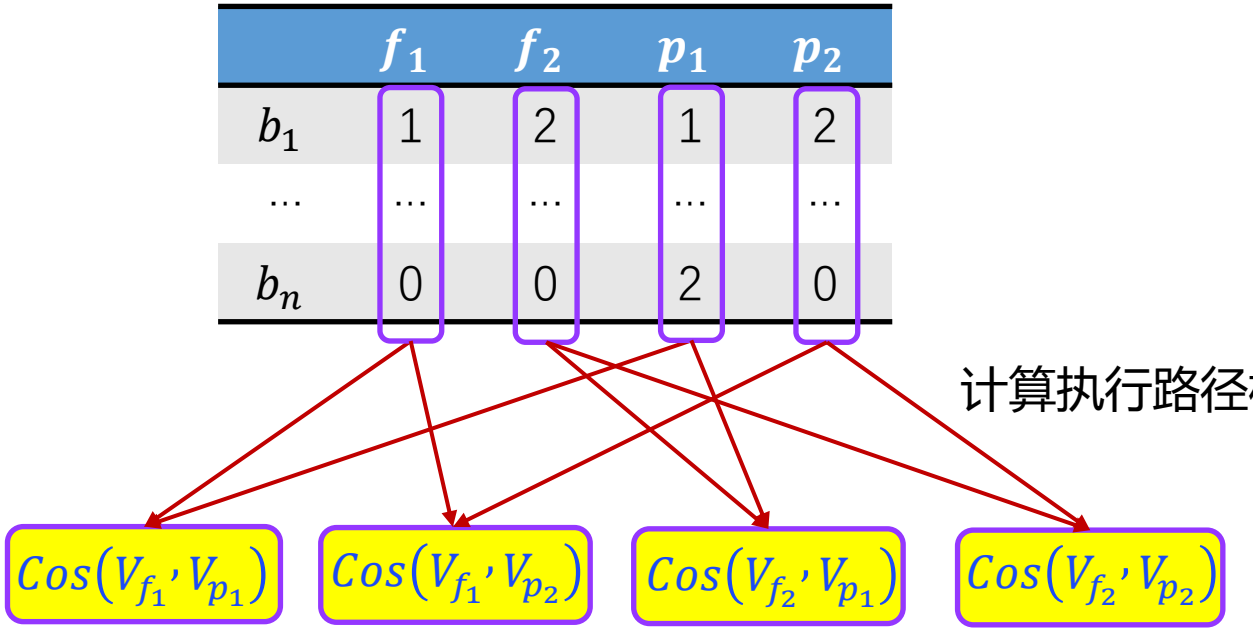

$$Sim_{<f,p>} = \frac{\sum_{i=1\to n}^{j=1\to m} Cos(V_{f_i}, V_{p_i})}{mn}$$

初步计算得到：

各个变量是缺陷根因的可能性大小

思路四：面向变量的细粒度软件缺陷定位技术

IsoVar突变分析阶段：进一步隔离出真正导致缺陷的变量

Assumption：对错误相关变量进行突变会对失败执行产生较大影响，而对通过执行的影响较小。

	f_1	f_2	p_1	p_2
b_1	1	2	1	2
…	…	…	…	…
b_n	0	0	2	0

突变操作

	f_1	f_2	p_1	p_2
b_1	2	1	1	2
…	…	…	…	…
b_n	2	0	1	0

$\overline{I_f}(m)$：突变m对失败测试用例造成的平均影响

$\overline{I_p}(m)$：突变m对通过测试用例造成的平均影响

$fitness(v)$：突变m对执行路径造成的综合影响

$$\overline{I_f}(m) = \frac{\sum_{i=1\to n} 1 - Cos(V_{f_i}, V_{f_{i'}})}{n}$$

$$\overline{I_p}(m) = \frac{\sum_{i=1\to m} 1 - Cos(V_{p_i}, V_{p_{i'}})}{m}$$

$$fitness(v) = \overline{I_f}(m) - \beta\overline{I_p}(m), m \in \mathcal{M}(v)$$

思路四：面向变量的细粒度软件缺陷定位技术

IsoVar结果汇总阶段

数据分析阶段结果：

$$Sus(v) = \frac{Freq_f}{Freq_f + Freq_p} - Sim_{<f,p>}$$

+

突变分析阶段结果：

$$\overline{fitness(v)} = 1 - \frac{\sum_{m \in \mathcal{M}(v)} fitness(v)}{|\mathcal{M}(v)|}$$

=

综合结果：

$$isolation(v) = Sus(v) + \gamma \overline{fitness(v)}$$

思路四：面向变量的细粒度软件缺陷定位技术

IsoVar效果

	MAP						MRR						Top-1		Top-5		Top-10	
Projects	VFL_{ochi}	VFL_{tar}	VFL_{bar}	$IsoVar_s$	$IsoVar_{sm}$	Imp%	VFL_{ochi}	VFL_{tar}	VFL_{bar}	$IsoVar_s$	$IsoVar_{sm}$	Imp%	VFL_{och}	$IsoVar_{sm}$	VFL_{och}	$IsoVar_{sm}$	VFL_{och}	$IsoVar_{sm}$
Time	0.238	**0.268**	0.265	0.251	0.267	12.2%	0.252	0.252	0.251	0.321	**0.330**	31.0%	3	**4**	8	**13**	15	15
Chart	0.319	0.295	0.337	0.366	**0.377**	18.2%	0.317	0.254	0.295	0.380	**0.416**	31.2%	4	**6**	13	**14**	14	**15**
Lang	0.422	0.387	0.410	0.447	**0.451**	6.9%	0.415	0.359	0.375	0.485	**0.486**	17.1%	15	**18**	33	**38**	38	**43**
Math	0.265	0.254	0.272	0.270	**0.274**	3.4%	0.258	0.234	0.251	0.291	**0.295**	14.3%	12	**17**	39	**40**	**50**	48
Closure	0.154	0.121	0.152	**0.162**	0.160	3.9%	0.180	0.146	0.171	**0.210**	0.201	11.7%	12	**14**	25	**34**	39	**42**
Mockito	0.269	0.246	0.250	0.250	**0.273**	1.5%	0.271	0.239	0.242	0.275	**0.276**	1.8%	7	**8**	10	10	14	14
FasterXML	0.140	0.105	0.204	0.241	**0.263**	87.9%	0.181	0.162	0.252	0.321	**0.344**	90.1%	3	**5**	8	**11**	12	**15**
Spoon	0.151	0.103	0.148	0.184	**0.187**	23.8%	0.238	0.159	0.212	0.242	**0.249**	4.6%	7	**10**	**19**	18	22	**23**
Traccar	0.273	0.200	0.296	0.382	**0.384**	40.7%	0.316	0.271	0.298	0.385	**0.427**	35.1%	5	**11**	16	**20**	25	**28**
Summary	0.239	0.211	0.244	0.264	**0.270**	13.0%	0.259	0.220	0.247	0.302	**0.309**	19.3%	68	**93**	**171**	**198**	229	**243**

VFL_{ochi}, VFL_{tar} and VFL_{bar} denote the variants based on Ochiai, Tarantula and Barinel. $IsoVar_s$: results of statistical analyses; $IsoVar_{sm}$: results combining two analysis. The MAP and MRR in the Summary row indicates the weighted average, with the weight being the number of bugs per project.

MAP在 0.16-0.45 之间，MRR在 0.25-0.49 之间

思路四：面向变量的细粒度软件缺陷定位技术

变量级缺陷定位结果可视化工具VVS-FFL：

使用变量值序列作为runtime profile进行定位，在MAP和MRR上平均优于IsoVar 20.8%和10.7%

将定位结果进行可视化展示，在IDE中进行代码高亮，直接提示开发者需要检查的位置（可配置）

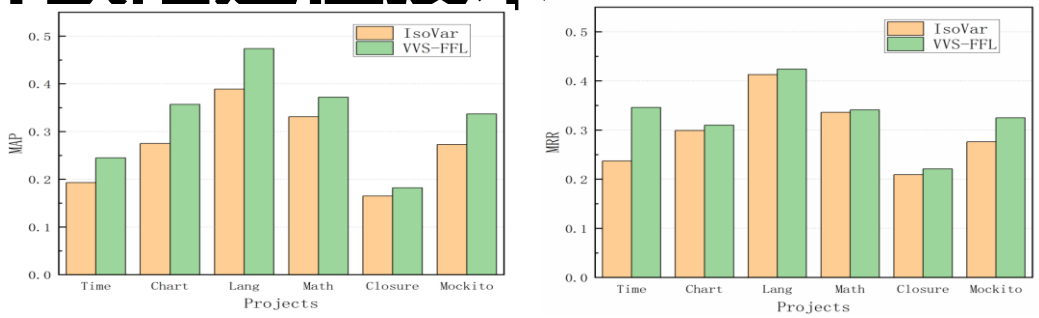

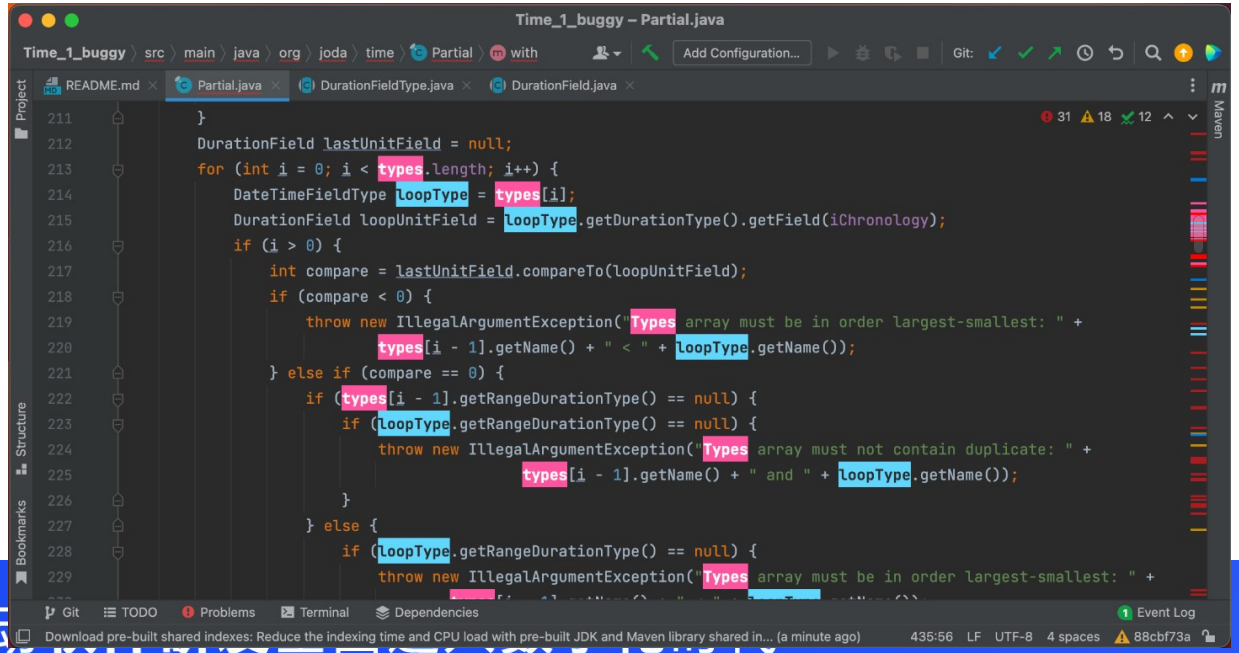


```
Partial(Partial partial, int[] values) {
    this.iChronology = partial.iChronology;
    this.iTypes = partial.iTypes;
    this.iValues = values;
}

Partial(Chronology chronology, DateTimeFieldType[] types, int[] values) {
    this.iChronology = chronology;
    this.iTypes = types;
    this.iValues = values;
}

public int size() { return this.iTypes.length; }

public Chronology getChronology() { return this.iChronology; }

protected DateTimeField getField(int index, Chronology chrono) { return this.iTypes[index].getField(chrono); }

public DateTimeFieldType getFieldType(int index) { return this.iTypes[index]; }

public DateTimeFieldType[] getFieldTypes() {
    return (DateTimeFieldType[])((DateTimeFieldType[])this.iTypes.clone());
}
```

```
public void validate(ReadablePartial partial, int[] values) {
    int size = partial.size();

    int i;
    int value;
    DateTimeField field;
    for(i = 0; i < size; ++i) {
        value = values[i];
        field = partial.getField(i);
        if (value < field.getMinimumValue()) {
            throw new IllegalFieldValueException(field.getType(), value, field.getMinimumValue(), (Number)null);
        }

        if (value > field.getMaximumValue()) {
            throw new IllegalFieldValueException(field.getType(), value, (Number)null, field.getMaximumValue());
        }
    }

    for(i = 0; i < size; ++i) {
        value = values[i];
        field = partial.getField(i);
        if (value < field.getMinimumValue(partial, values)) {
            throw new IllegalFieldValueException(field.getType(), value, field.getMinimumValue(partial, values), (Numb
```

PART 04
其他辅助技术
Other Related Techniques

其他辅助技术 (1)：基于信息检索的缺陷定位

Information Retrieval-based Fault Localization (IRFL)

IRFL

一般研究框架

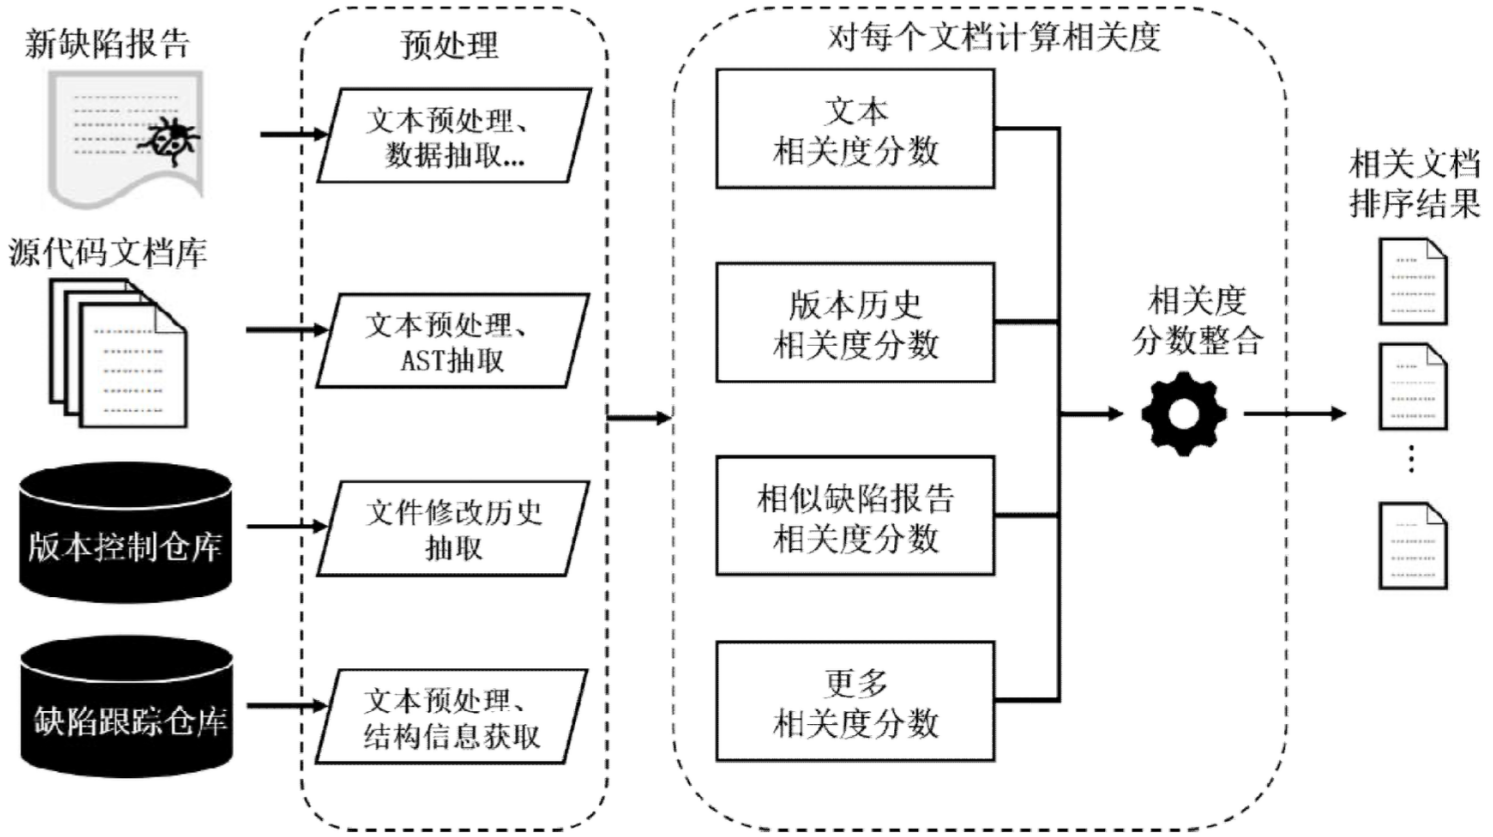

张贺, 张佳瑞, 夏鑫, 等. 基于信息检索的软件缺陷定位技术研究进展[J]. 软件学报, 2020, 31(8): 2432-2452.

其他辅助技术 (1)：基于信息检索的缺陷定位

Information Retrieval-based Fault Localization (IRFL)

IRFL技术的

不同定位粒度

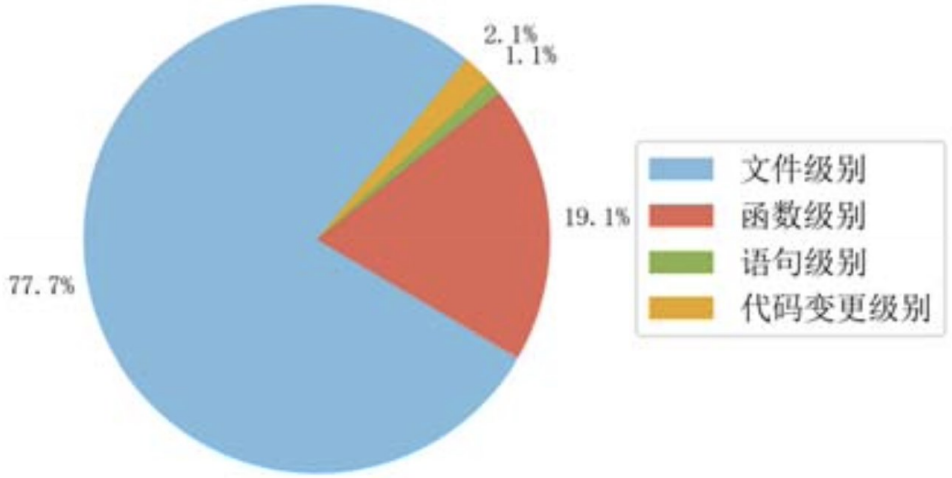

和SOTA相比，我们的新方法：

在Accuracy@1、MAP、MRR 上分别提升 21.0%、21.3%、17.10%

最高分别为 0.851、0.862、0.898

李政亮, 陈翔, 蒋智威, 顾庆. 基于信息检索的软件缺陷定位方法综述[J]. 软件学报, 2021, 32(2): 247−276.

其他辅助技术 (1)：基于信息检索的缺陷定位

准确理解缺陷报告十分重要

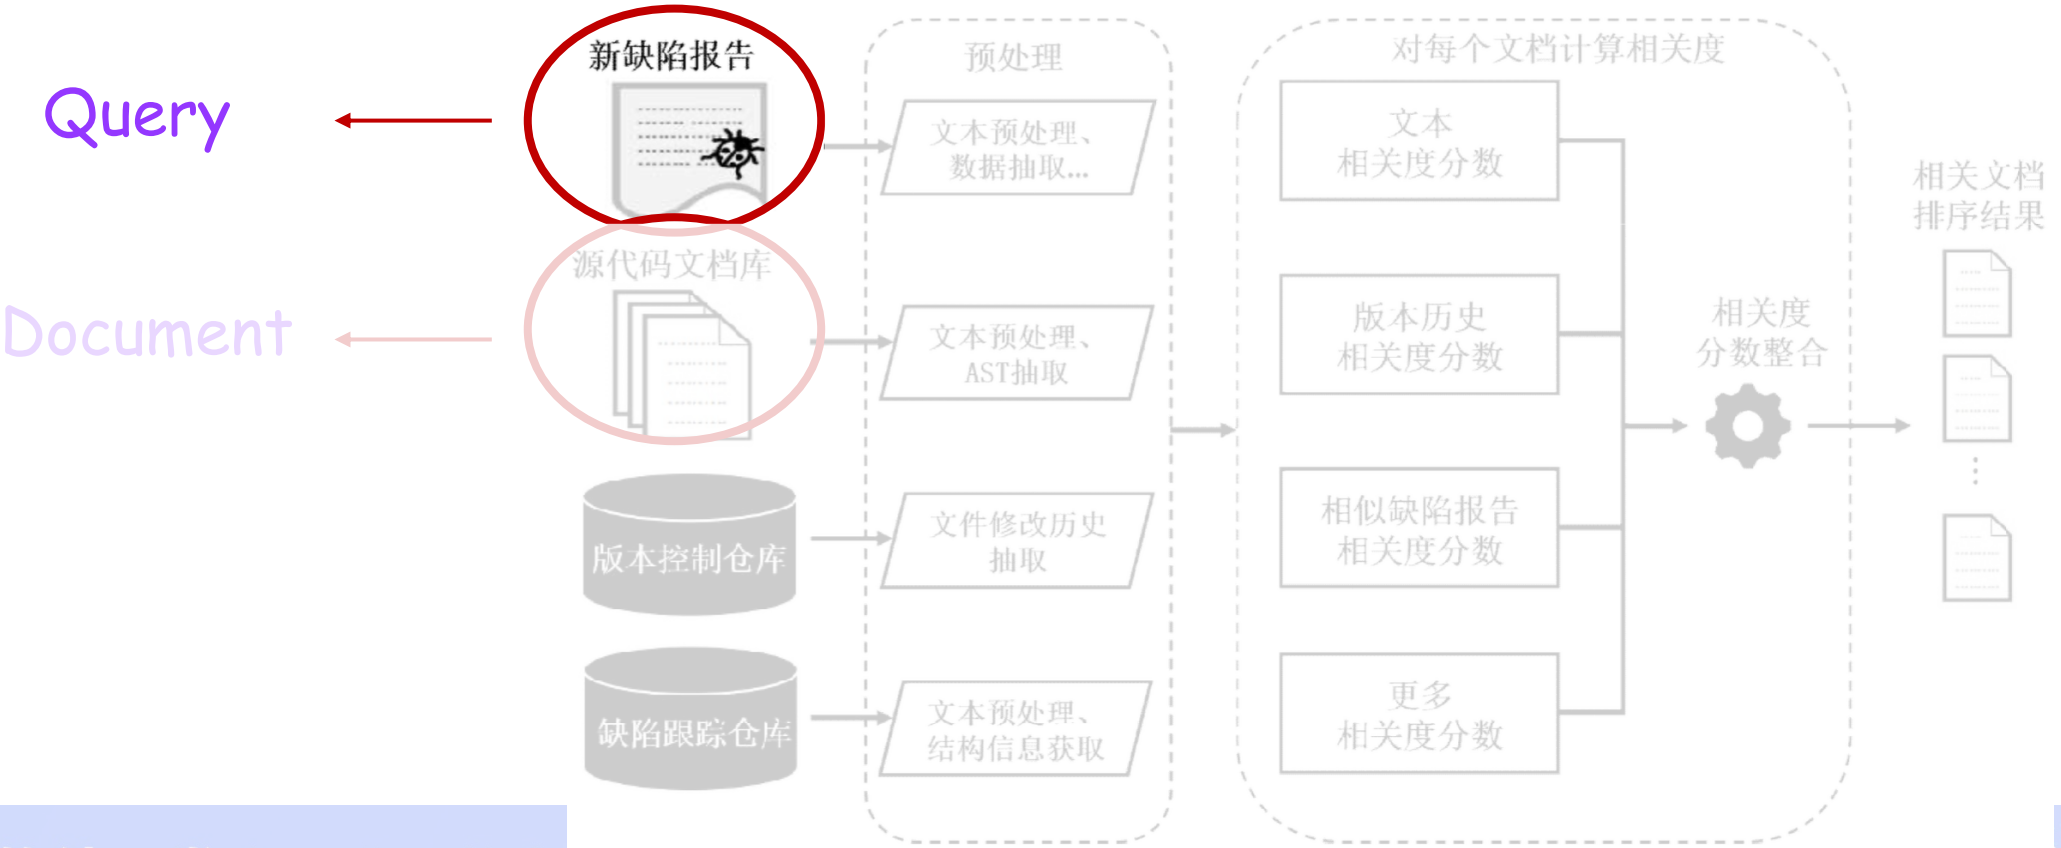

其他辅助技术 (2)：系统级缺陷报告理解 – 标题

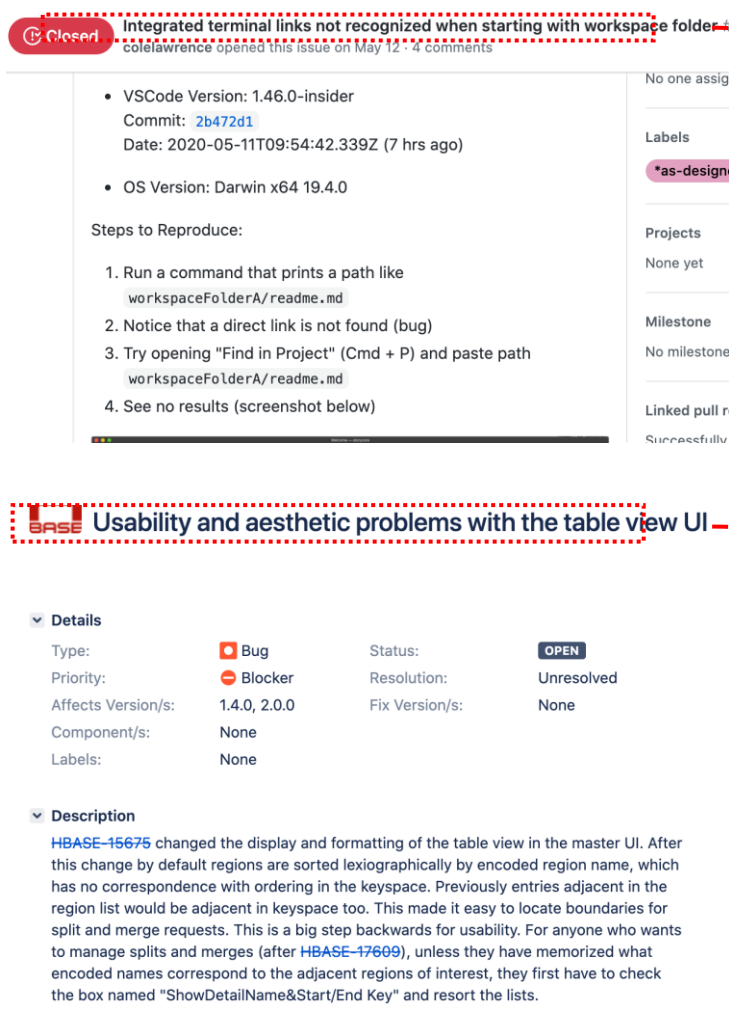

缺陷报告 (单条)

列表视图下的标题

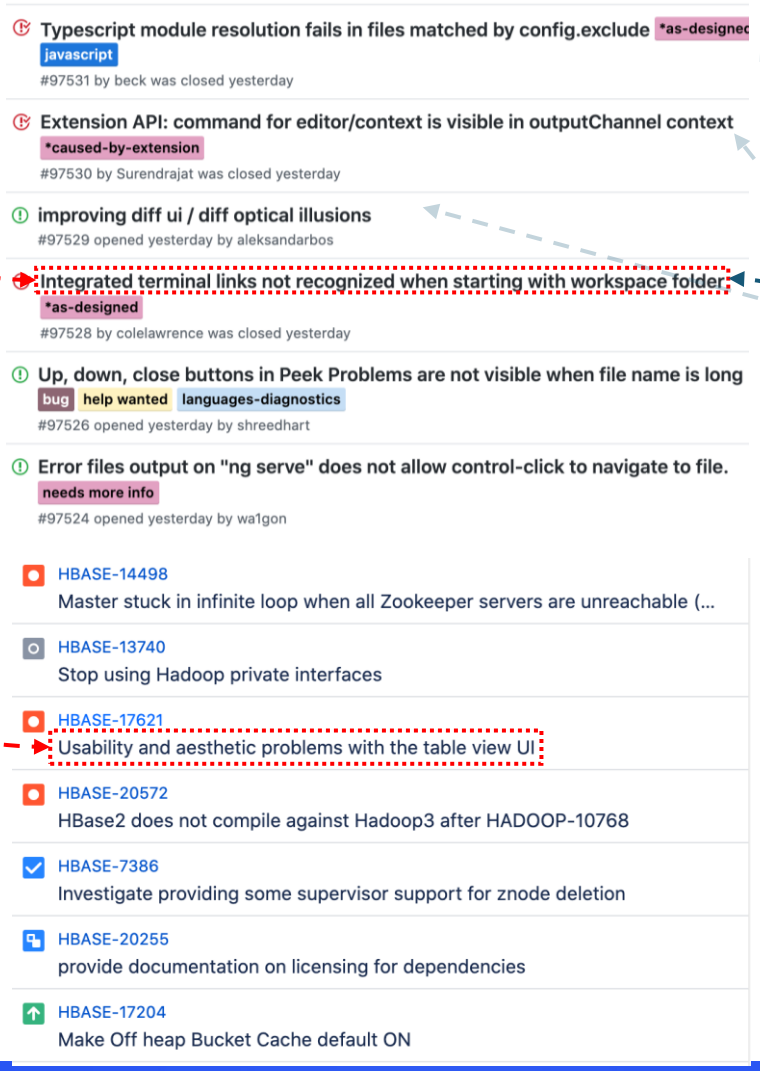

阅读标题

帮助用户在不阅读主体的前提下快速理解缺陷报告：bug分配、初步缺陷定位、根因分析等

列表视图下的标题

缺陷报告 (列表视图)

其他辅助技术 (2)：系统级缺陷报告理解 – 标题

缺陷报告标题撰写的常见原则

- Your title should serve as a concise summary of what the bug is.

—— Testlio

- How would you describe the bug using approximately 10 words?
  This is the first part of your bug report a triager or developer will see.
  A good summary should quickly and uniquely identify a bug report.

—— Mozilla

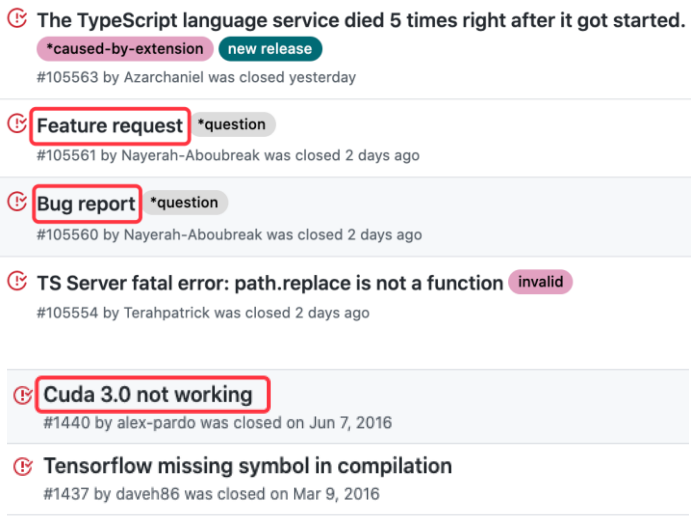

Too short

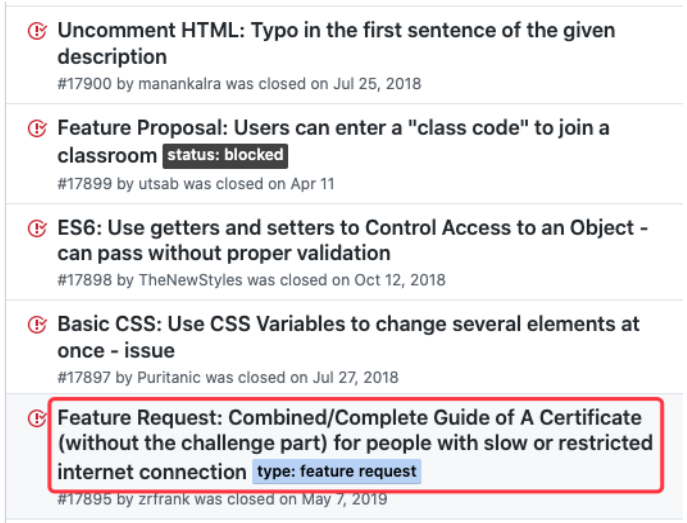

Too many words

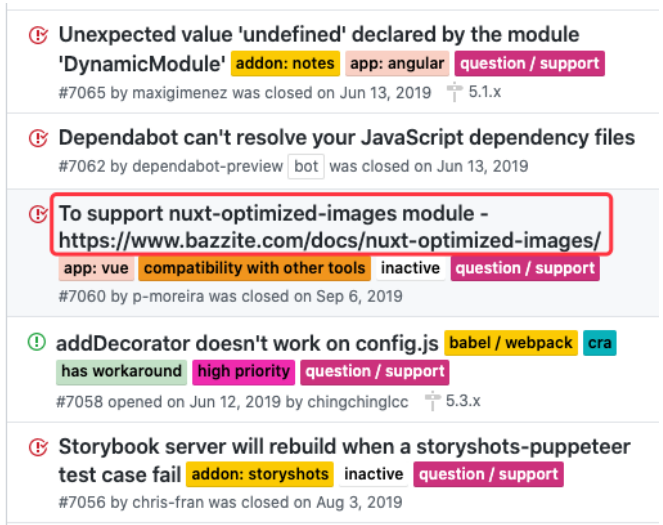

With URLs

现实开发中的常见情况

其他辅助技术 (2)：系统级缺陷报告理解 – 标签

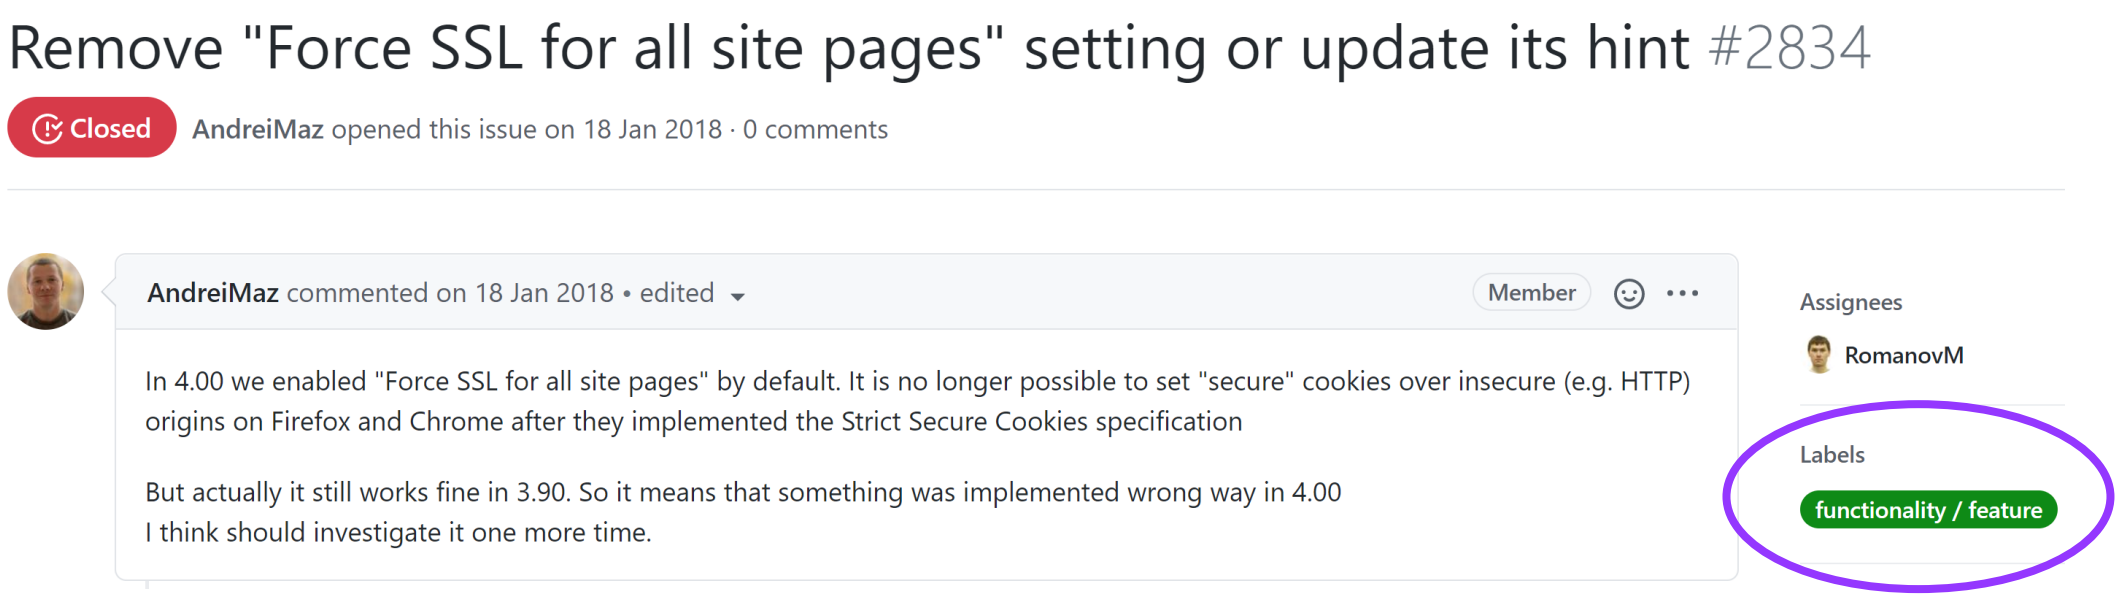

方便对bug进行分类、对属性进行标记等；

可以用于检索等操作

其他辅助技术 (2)：系统级缺陷报告理解 – 标签

现有技术大多是为单标签生成服务

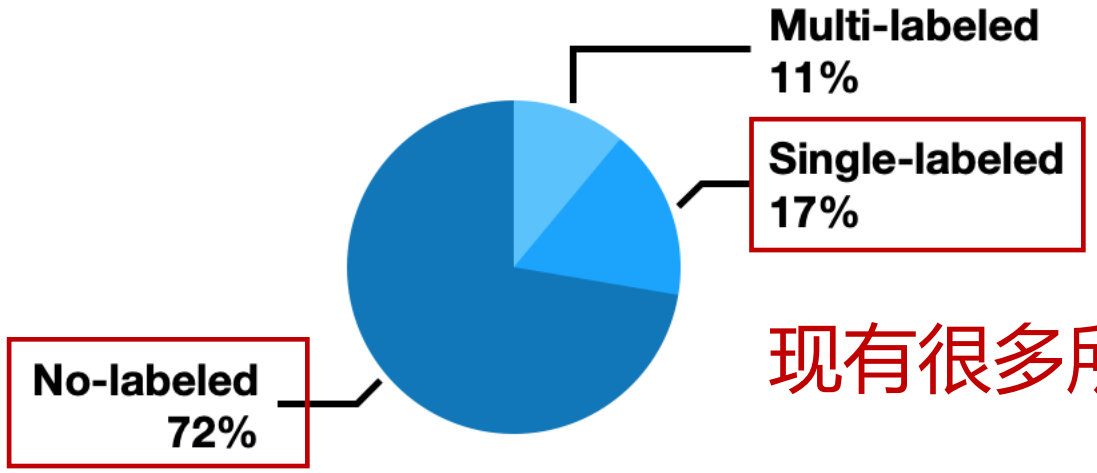

现有很多所谓的单标签其实是不完整的

In year 2018, the amounts of no-labeled issue reports, single-labeled issue reports, and multi-labeled issue reports are 10,862,127, 2,497,953, and 1,656,937, respectively.

其他辅助技术 (2)：系统级缺陷报告理解

标题生成：iTAPE & iTAPE+

- Input: 缺陷报告主体
- Output: 符合当前项目风格的标题

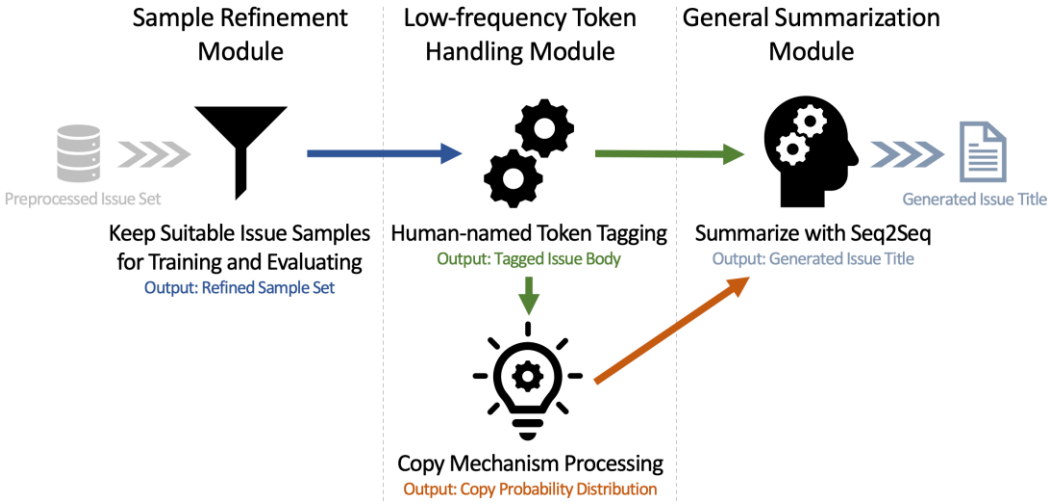

标签生成：MULA & PLPI

- Input: 缺陷报告主体
- Output: 符合当前项目风格的多标签

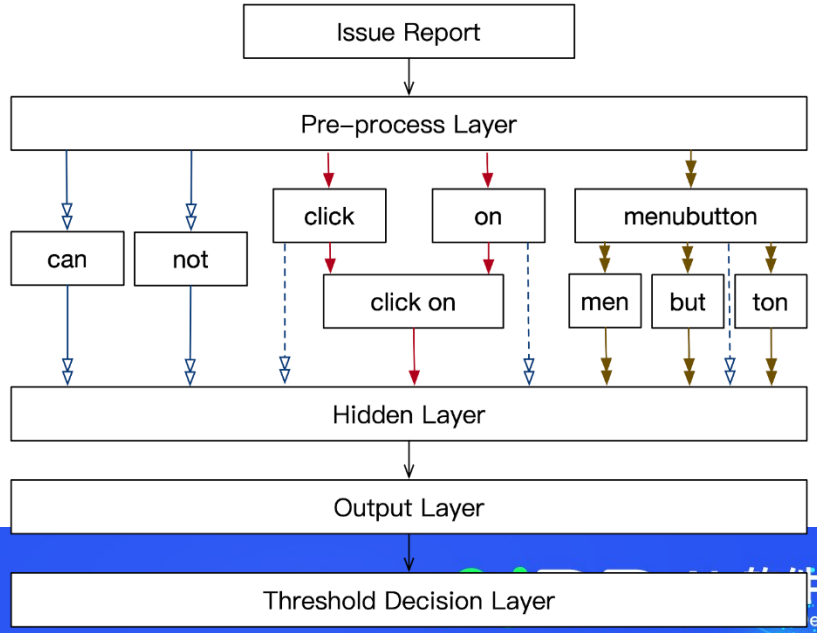

PART 5

总结与展望
Prospects

总结与展望：自动化代码缺陷定位当前研究趋势

所基于信息

- 程序覆盖信息
- 动/静态切片信息
- 程序频谱信息
- 缺陷报告
- 版本历史信息
- 运行时变量信息
- ……

所采用技术

- 程序插桩
- 日志/断言/断点
- 切片技术
- 数据挖掘
- 深度学习
- ……

所面向粒度

- 文件
- 函数
- 代码提交记录
- 基本块
- 语句
- 变量
- ……

总结与展望：自动化代码缺陷定位当前面临挑战

多缺陷问题

Tie难题

代码缺失缺陷

对上述问题的解决

将极大赋能自动化代码缺陷定位技术的落地应用

使其在真实工业环境软件开发中迎来春天

Indexing技术效能仍有待提升。

大幅降低缺陷定位效率。

针对既有代码，难以处理此类情况。

谢谢！