

缺陷修复技术和 北京大学近期进展

熊英飞

2018

报告人介绍 - 熊英飞

- 2000~2004, 电子科技大学本科
- 2004~2006, 北京大学研究生
 - 导师: 梅宏、杨芙清
- 2006~2009, 日本东京大学博士
 - 导师: 胡振江、武市正人
- 2009~2011, 加拿大滑铁卢大学博士后
 - 导师: Krzysztof Czarnecki
- 2012~, 北京大学“百人计划”研究员 (Tenure-Track)
- 研究方向: 软件分析、编程语言设计

缘起

- 人和Bug的斗争从来没有停止过
- 缺陷检测：到底有没有Bug
 - 从上世纪60年代开始
 - 代表技术：软件测试、软件验证
- 缺陷定位：Bug在哪里
 - 从上世纪90年代开始
 - 代表技术：基于频谱的缺陷定位、统计性调试
- 缺陷修复：自动消除Bug
 - 约从2000年之后开始
 - 代表技术：生成-验证缺陷修复技术

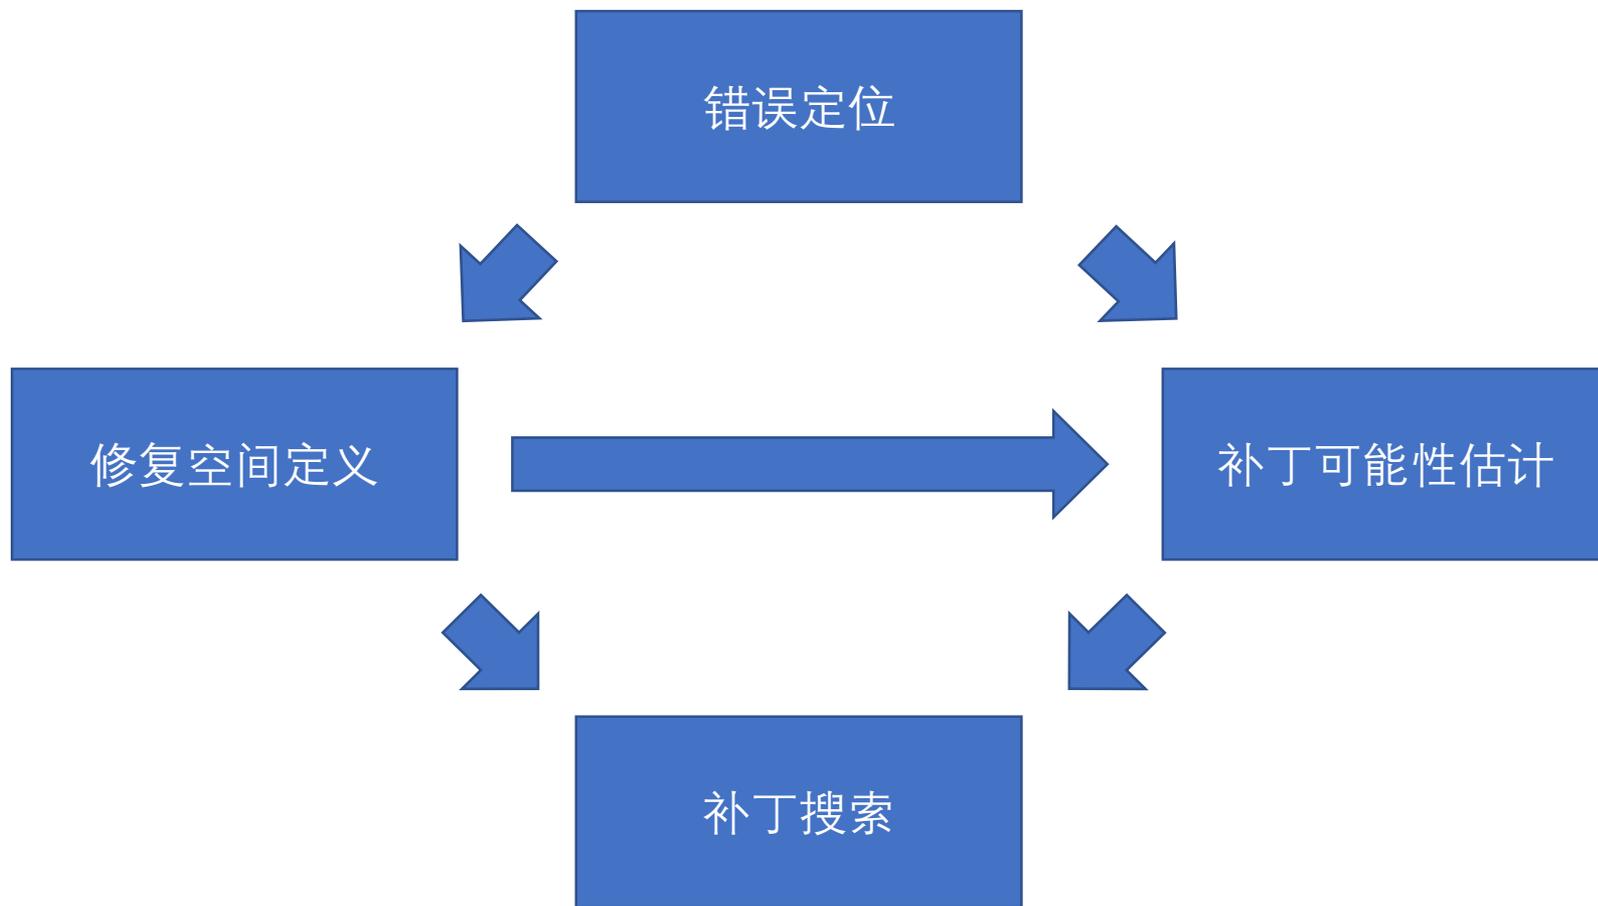
缺陷自动修复定义

输入： 一个程序和其正确性约束， 并且程序不满足正确性约束

输出： 一个补丁， 可以使程序满足约束

研究和实践中考虑最广泛的正确性约束——
软件项目中的测试

缺陷修复四大支柱技术



典型缺陷修复技术: GenProg

错误定位

基于频谱的错误定位

修复空间定义

以下三种操作的组合:

- 在错误语句前插入一条同项目任意语句
- 将错误语句替换成同项目任意语句
- 删除任意语句

补丁可能性估计

通过测试越多越有可能

补丁搜索

遗传算法

缺陷修复三大挑战

- 正确率：由于测试的不完备性，通过测试的缺陷未必是正确的，导致缺陷修复技术很难达到较高的准确率
- 召回率：由于补丁的多样性，很难定义出准确的修复空间，或者在修复空间中很难定位到准确的补丁。
- 修复效率：目前技术修复一个缺陷往往需要数小时

北京大学的近期工作

错误定位

集成错误定位方法
大幅提升错误定位正确率
[arXiv:1803.09939]

修复空间定义

通过分析历史补丁和项目代码来准确刻画修复空间
显著提升修复召回率
[ISSTA18]

补丁可能性估计

通过将生成过程分解来应用机器学习
显著提升修复正确率
[ICSE17(引用第二多),GI18,ICSE18]

补丁搜索

通过计算重用减少重复计算
显著提升修复效率
[ISSTA17(Distinguished Paper)]

北京大学的近期工作

错误定位

集成错误定位方法
大幅提升错误定位正确率
[arXiv:1803.09939]

修复空间定义

通过分析历史补丁和项目代码来准确刻画修复空间
显著提升修复召回率
[ISSTA18]

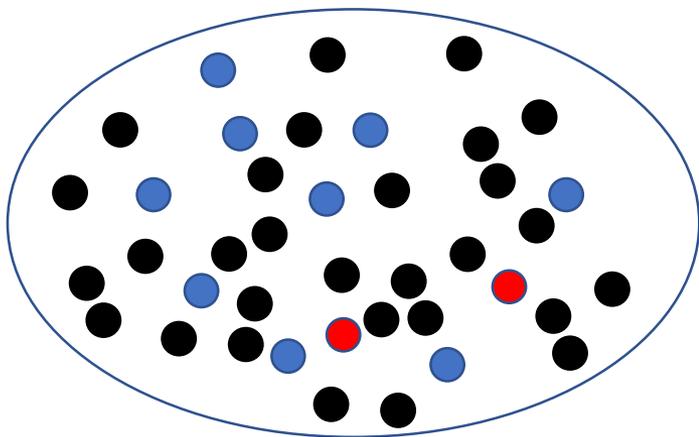
补丁可能性估计

通过将生成过程分解来应用机器学习
显著提升修复正确率
[ICSE17(引用第二多),GI18,ICSE18]

补丁搜索

通过计算重用减少重复计算
显著提升修复效率
[ISSTA17(Distinguished Paper)]

典型修复空间



- 不满足规约的补丁
- 满足规约但错误的补丁
- 正确的补丁

空间较大

更可能包含正确补丁 (召回率 \uparrow)

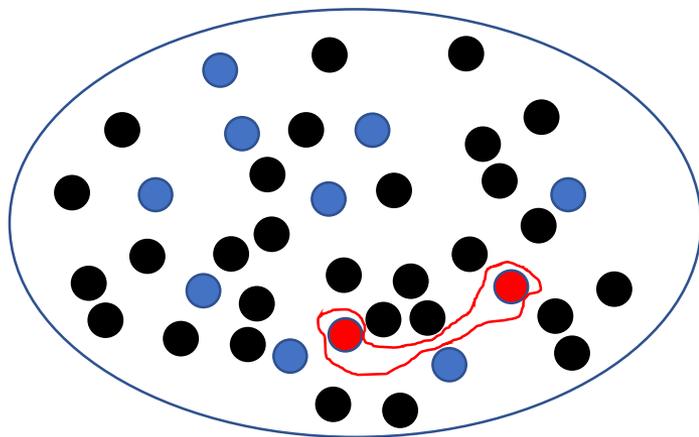
包含正确补丁时, 更难定位到正确补丁 (正确率 \downarrow 召回率 \downarrow)

更不可能包含正确补丁 (召回率 \downarrow)

包含正确补丁时, 更容易定位到正确补丁 (正确率 \uparrow 召回率 \uparrow)

空间较小

理想修复空间



- 不满足规约的补丁
- 满足规约但错误的补丁
- 正确的补丁

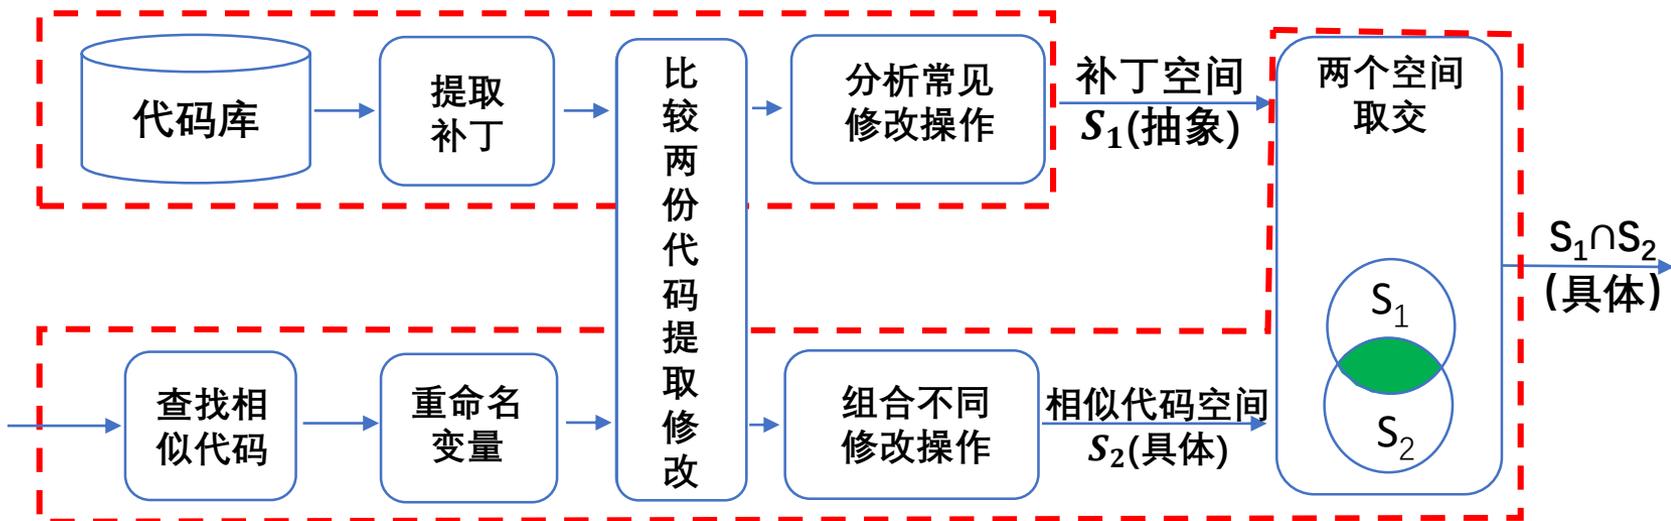
- 尽可能包含正确的补丁
- 尽可能不包含错误补丁，特别是能满足规约的错误补丁

SimFix——基本思路

- 从两个数据源刻画修复空间
- 已有补丁
 - 某些操作比其他操作更可能是修复操作
 - 更可能是修复操作：将<改成<=
 - 更不可能是修复操作：删除整个for语句块
 - 从已有补丁中可以统计出操作的信息
- 项目其他代码
 - 相似逻辑往往在一个项目中多次实现
 - 寻找错误代码和相似代码之间的差异可以更好的修复缺陷

SimFix——方法概览

1. 离线挖掘阶段



2. 在线修复阶段

北京大学的近期工作

错误定位

集成错误定位方法
大幅提升错误定位正确率
[arXiv:1803.09939]

修复空间定义

通过分析历史补丁和项目代码来准确刻画修复空间
显著提升修复召回率
[ISSTA18]

通过计算重用减少重复计算
显著提升修复效率
[ISSTA17(Distinguished Paper)]

补丁搜索

补丁可能性估计

通过将生成过程分解来应用机器学习
显著提升修复正确率
[ICSE17(引用第二多),GI18,ICSE18]

补丁正确性估计

- 已有工作：设计启发式规则
 - 通过测试的数量
 - 与原来补丁的语法距离
 - 与原来补丁的语义距离
 - 准确率较低
- 已有工作：应用机器学习
 - 传统机器学习
 - 补丁空间很大且不固定，无法应用
 - Learning-to-rank
 - 补丁复杂多变，难以准确提取特征

我们的工作: Learning to synthesize

- 将原来补丁的生成分成若干步骤
- 采用机器学习估计每一步正确的概率
- 最后概率是所有概率的乘积

例子：修复条件错误

条件错误是很常见的

```
lcm = Math.abs(a+b);  
+ if (lcm == Integer.MIN_Value)  
+   throw new ArithmeticException();
```

缺少边界检查

```
- if (hours <= 24)  
+ if (hours < 24)  
    withinOneDay=true;
```

条件过强或者过弱

能否生成正确的条件来替换错误的条件？

搜索空间

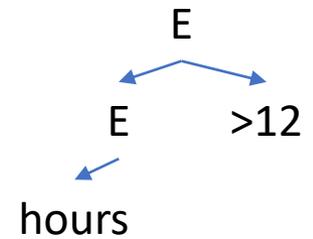
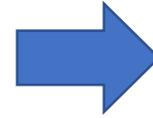
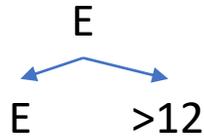
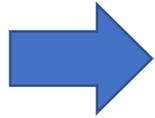
- 通过条件表达式的语法来定义
- $E \rightarrow E > 12$
 - | $E > 0$
 - | $E + E$
 - | *hours*
 - | *value*
 - | ...

搜索过程

- 搜索过程是按某种顺序展开语法树的过程

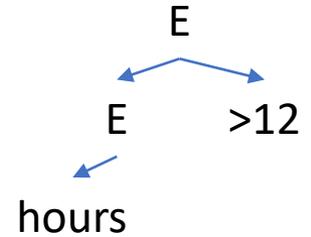
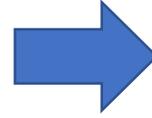
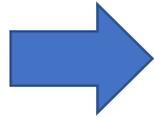
- 自顶向下

E



- 自底向上

hours



通过转换语法来表达搜索顺序

Grammar	Top-down Rules	Bottom-up Rules
$E \rightarrow E \text{ "+" } E$	$E^D \Rightarrow E \rightarrow E^D \text{ "+" } E^D$	$E^U \Rightarrow E^U \rightarrow E \text{ "+" } E^D$ $E^U \Rightarrow E^U \rightarrow E^D \text{ "+" } E$
$E \rightarrow E \text{ ">12"}$	$E^D \Rightarrow E \rightarrow E^D \text{ ">12"}$	$E^U \Rightarrow E^U \rightarrow E \text{ ">12"}$
$E \rightarrow \text{"hours"}$	$E^D \Rightarrow E \rightarrow \text{"hours"}$	$\text{"hours"}^D \Rightarrow E^D \rightarrow \text{"hours"}$

Creation Rules

- $\Rightarrow E^D$ // starting from the root
- $\Rightarrow E^{DU}$ // starting from a middle node
- $\Rightarrow \text{"hours"}^U$ // starting from a leaf

Ending Rule

$$E^U \Rightarrow E$$

基于机器学习的概率估计

- 给定一个符号，训练机器学习模型估计该符号按不同方式展开的概率
 - $E^D \Rightarrow E \rightarrow E^D \text{ "+" } E^D$
 - $E^D \Rightarrow E \rightarrow E^D \text{ ">12"}$
 - $E^D \Rightarrow E \rightarrow \text{"hours"}$
- 特征提取可以针对不同符号单独设计
- 定理：当规则集合无歧义时，补丁的概率等于组成补丁的所有重写规则各自概率的乘积

在条件修复上的初步结果 [ICSE17]

- 数据集： Defects4J上的四个项目
 - Time, Lang, Math, Chart
 - 总共224个缺陷

85%[ICSE18, 基于补丁性质的过滤]

Approach	Correct	Incorrect	Precision	Recall
ACS	18	5	73.9%	7.5%
jGenProg	5	22	18.5%	2.2%
Nopol	5	30	14.3%	2.2%
xPAR	3	₋₄	₋₄	1.3% ²
HistoricalFix ¹	10(16) ³	₋₄	₋₄	4.5%(7.1%) ^{2,3}

北京大学的近期工作

错误定位

集成错误定位方法
大幅提升错误定位正确率
[arXiv:1803.09939]

修复空间定义

通过分析历史补丁和项目代码来准确刻画修复空间
显著提升修复召回率
[ISSTA18]

补丁可能性估计

通过将生成过程分解来应用机器学习
显著提升修复正确率
[ICSE17(引用第二多),GI18,ICSE18]

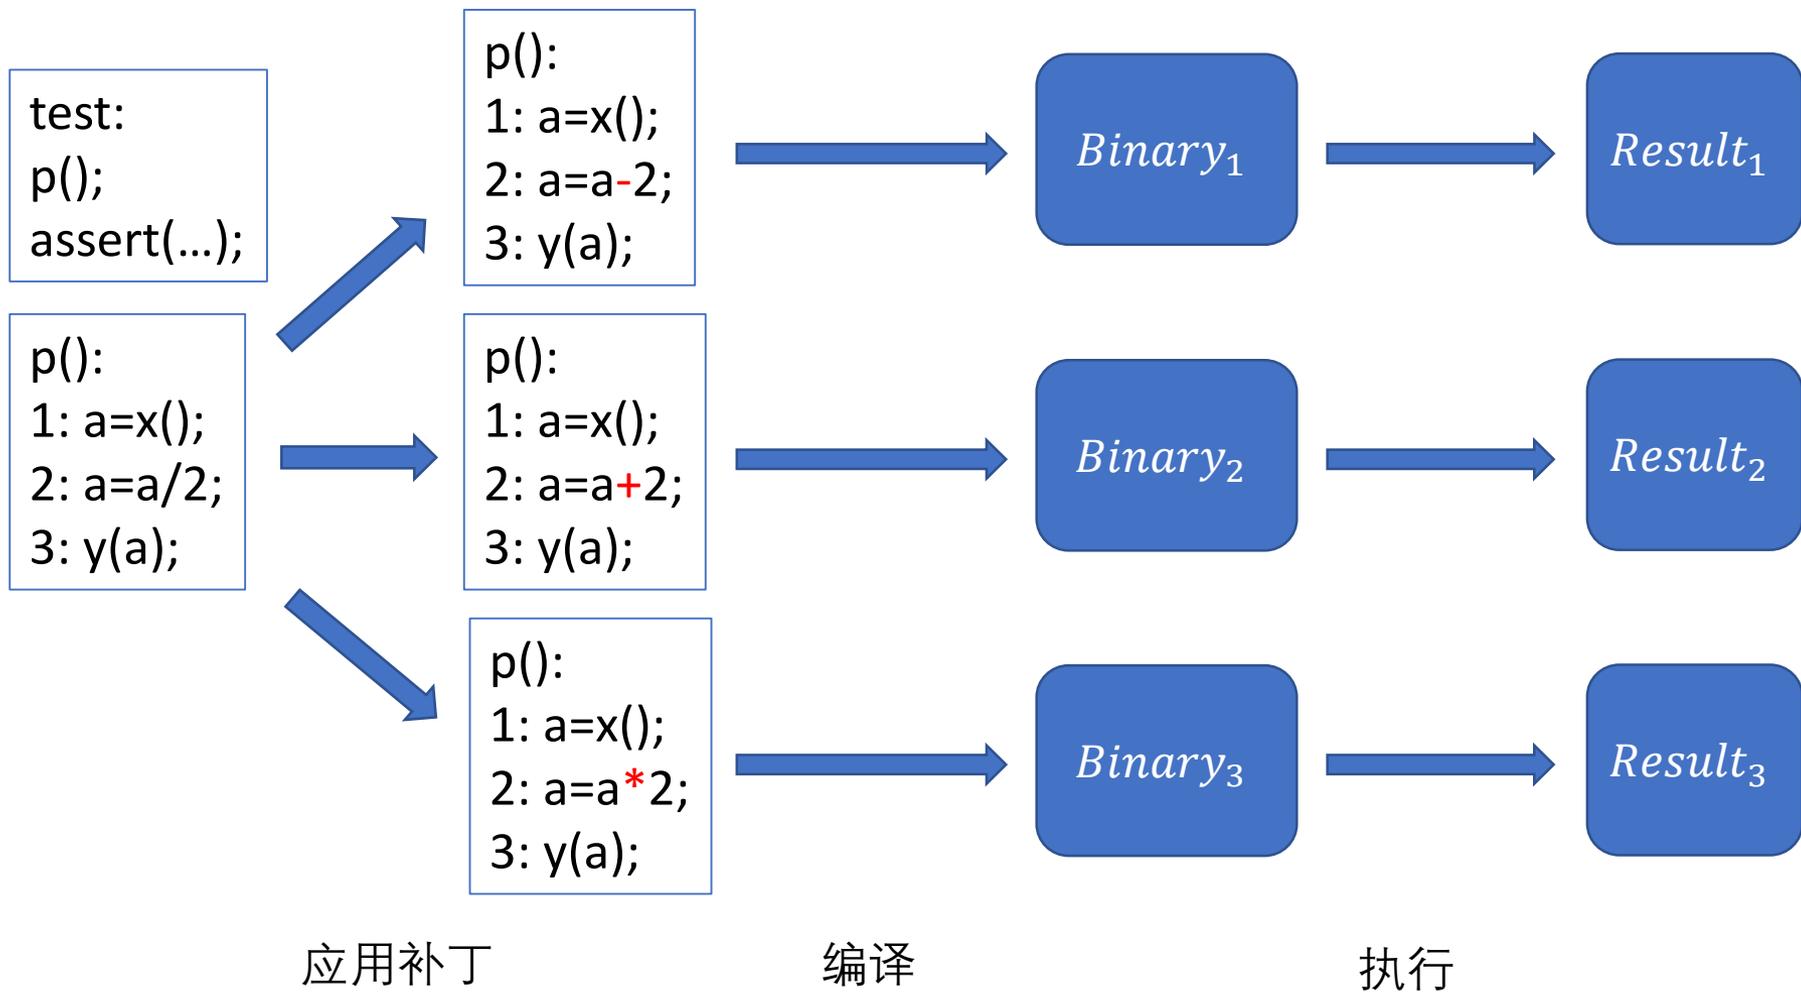
通过计算重用减少重复计算
显著提升修复效率
[ISSTA17(Distinguished Paper)]

补丁搜索

补丁搜索

- 现有缺陷修复技术常常需要花费数小时搜索补丁
- 补丁确认：补丁搜索过程中最耗时的部分
 - 应用补丁，检查是否所有测试都通过
- 能否加速该过程？

补丁确认过程



编译的冗余

```
p():  
1: a=x();  
2: a=a-2;  
3: y(a);  
x():  
...  
y():  
...
```

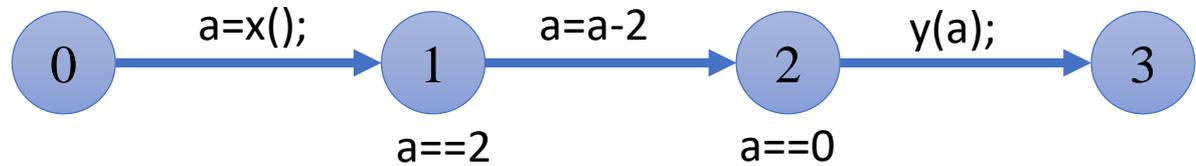
```
p():  
1: a=x();  
2: a=a+2;  
3: y(a);  
x():  
...  
y():  
...
```

```
p():  
1: a=x();  
2: a=a*2;  
3: y(a);  
x():  
...  
y():  
...
```

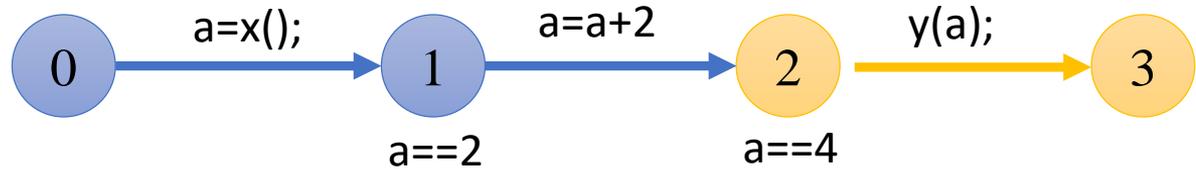
- x()和y()在三个版本中完全一样，但是被编译了三次

运行的冗余

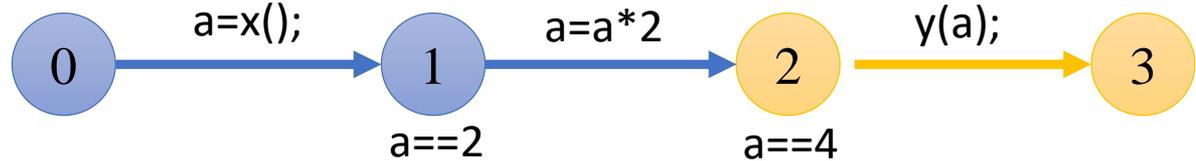
```
1: a=x();  
2: a=a-2;  
3: y(a);
```



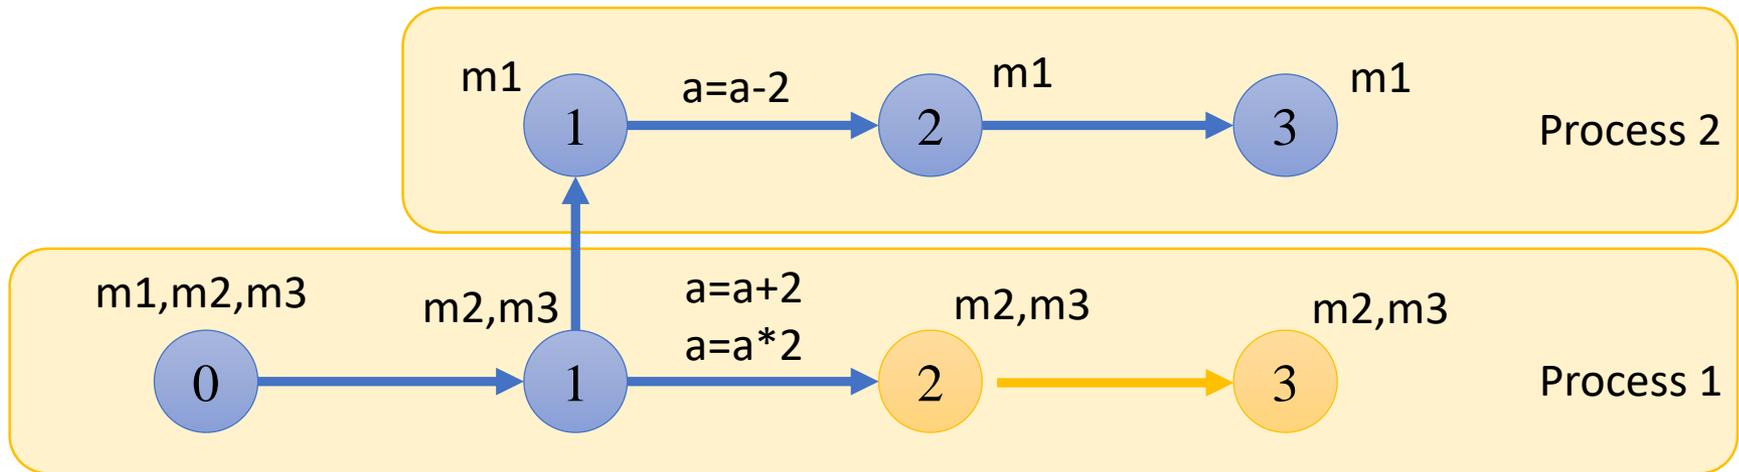
```
1: a=x();  
2: a=a+2;  
3: y(a);
```



```
1: a=x();  
2: a=a*2;  
3: y(a);
```



我们的工作: AccMut

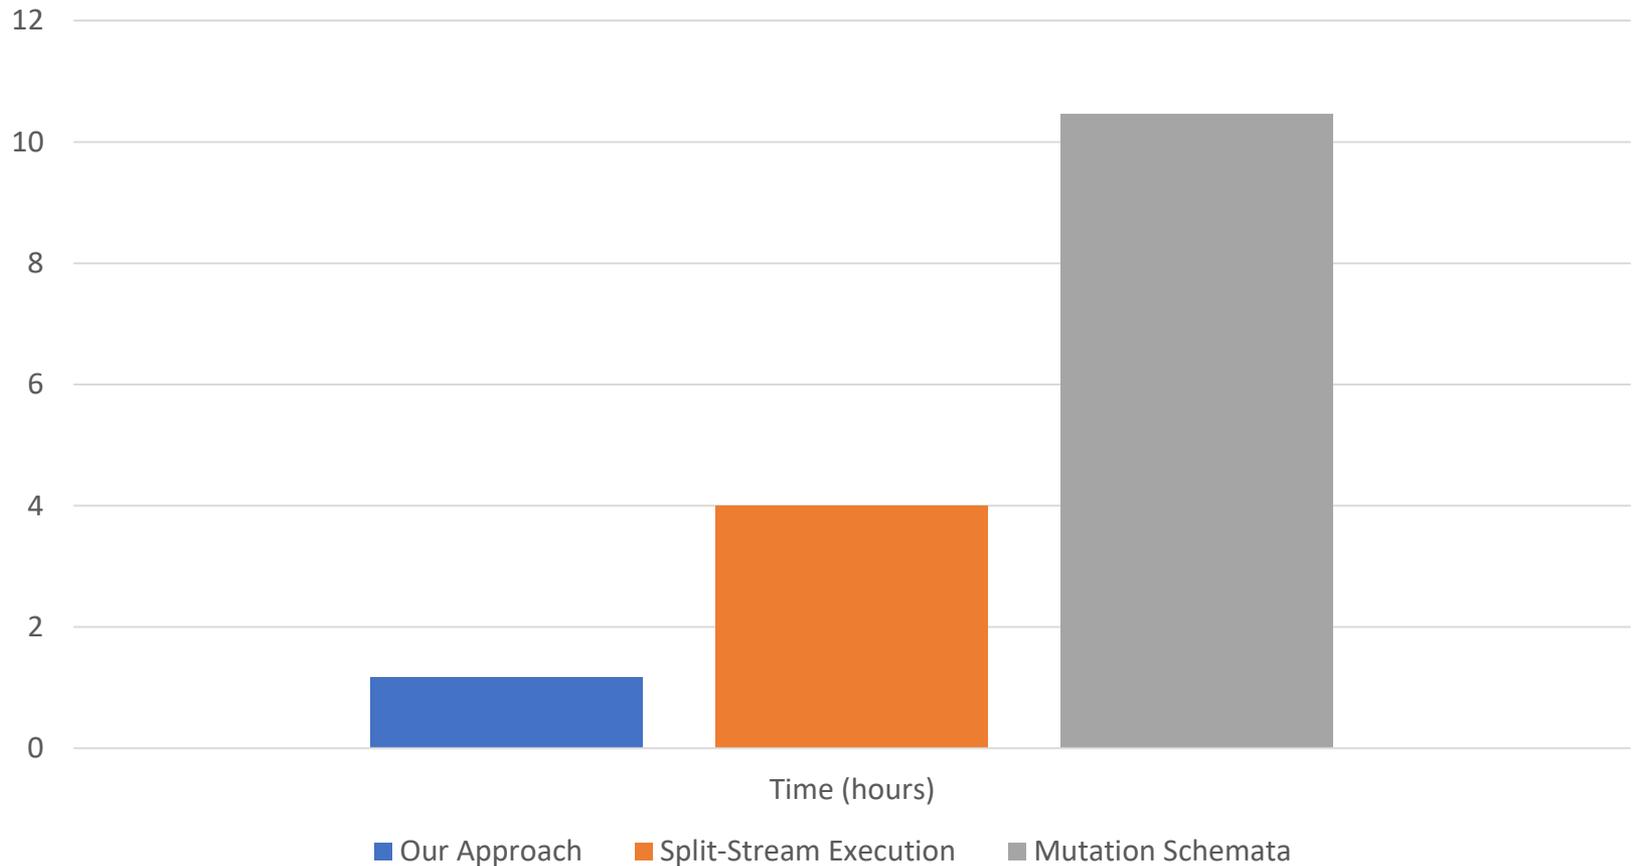


- 将所有补丁编译成一个超程序
- 超程序从一个进程开始执行，代表所有补丁
- 碰见有不同之处，超程序检查并分类不同语句的执行结果
- 对于每个等价结果类创建一个进程执行

如何实现超程序

- 需要保证 额外开销 \ll 去掉的重复计算
- 降低等价状态检查的额外开销
 - 运用抽象解释技术，将检查映射到一个开销较小的抽象域进行
- 降低结果分类的开销
 - 通过设计算法，使得分类算法依赖于一些上限较低的项

方法效果



在变异上模拟的效果：相比已有方法，我们比SSE有2.56倍加速，比MS有8.95倍加速

未来工作：缺陷修复开发框架

- 观察：
 - 学术界大量缺陷修复工作，不断重复实现基本模块
 - 学术界大量的小改进论文，互相之间的关系讨论、效果比较难以完成
 - 工业界实现缺陷修复工具缺乏参考实现
- 目标：
 - 帮助研究人员快速实现缺陷修复工具
 - 快速实验各种技术的不同组合方式
 - 为工业界提供参考实现
 - 集成今天所讲的各项工