

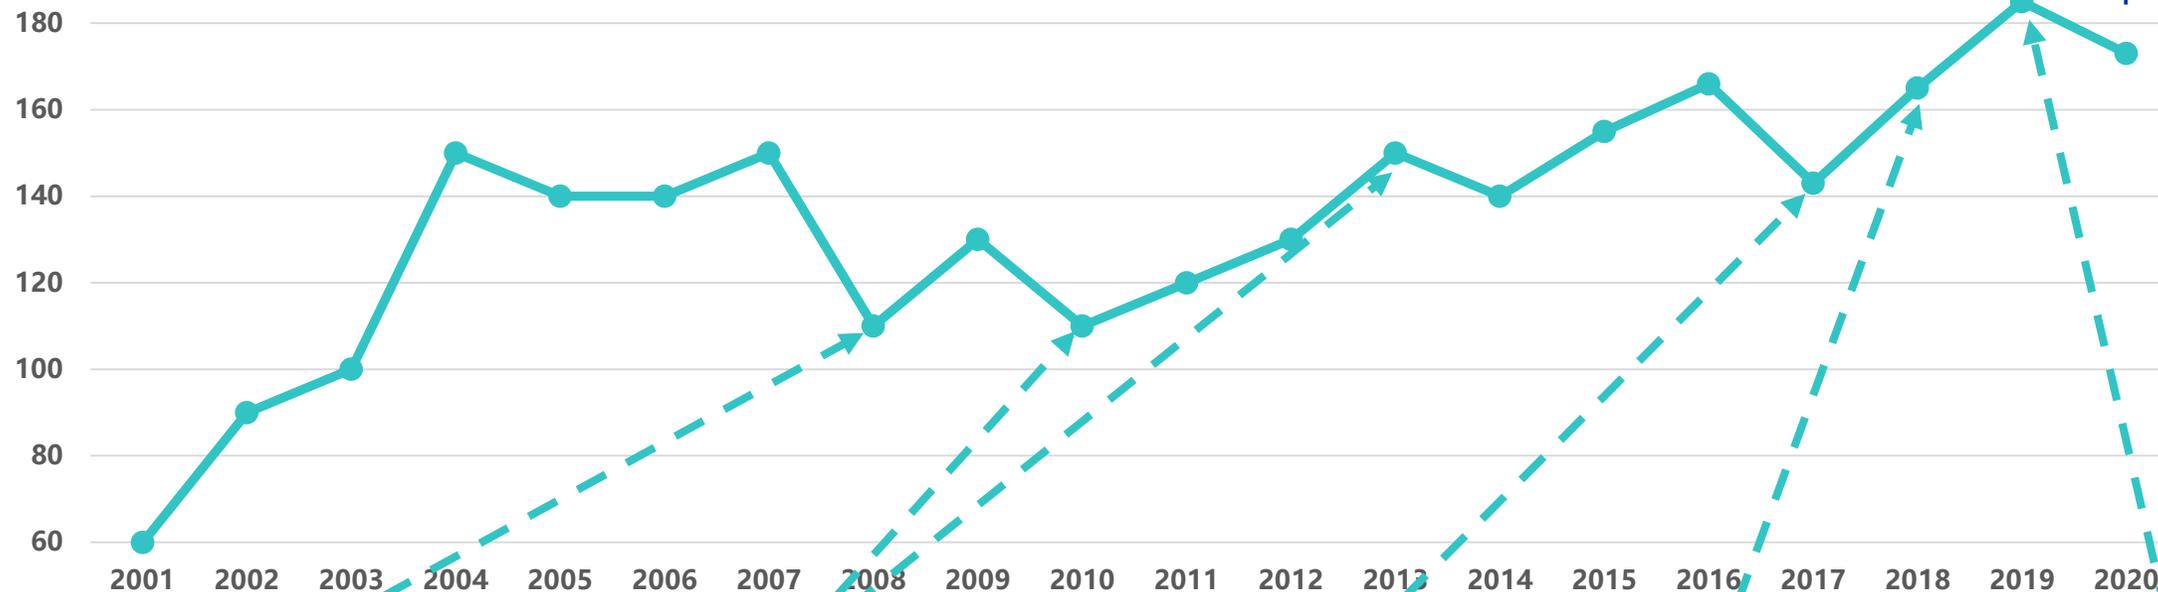


自动反馈优化特性介绍

单位：华为技术有限公司

汇报人：李彦成 黄晓权

反馈优化研究趋势



• 软硬结合的反馈优化提出[1, 2]

- 轻量化全局优化LIPO提出[3]
- 软硬结合反馈优化引入LBR [4, 5] , 并与LIPO结合[5]
- 数据中心profiling框架GWP提出[6]

• AutoFDO框架提出[7]

• 函数布局优化提出[8], 结合硬件profiling和hfsort

• 二进制反馈优化工具BOLT提出[9, 10]

Google团队

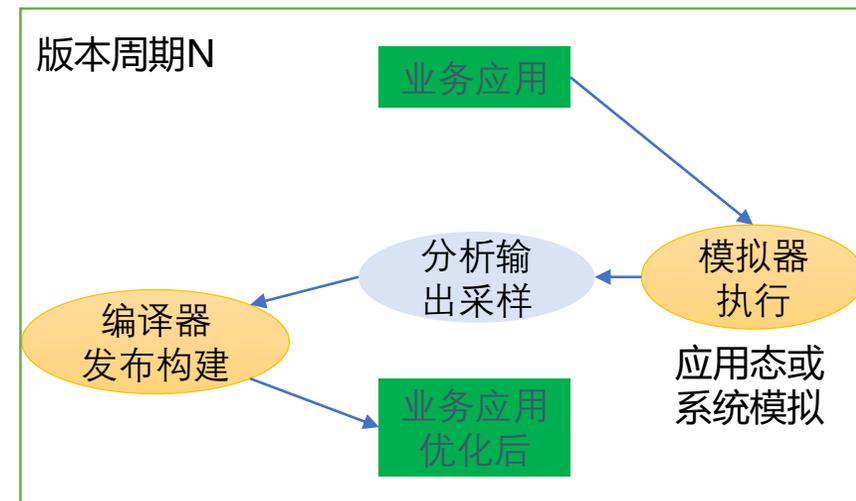
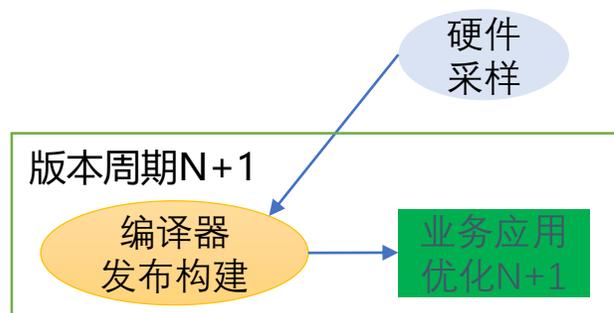
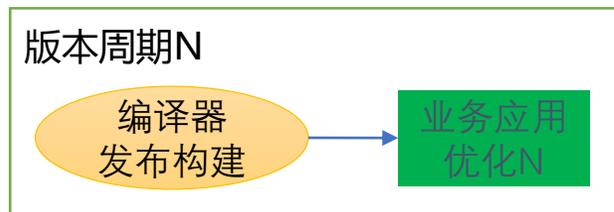
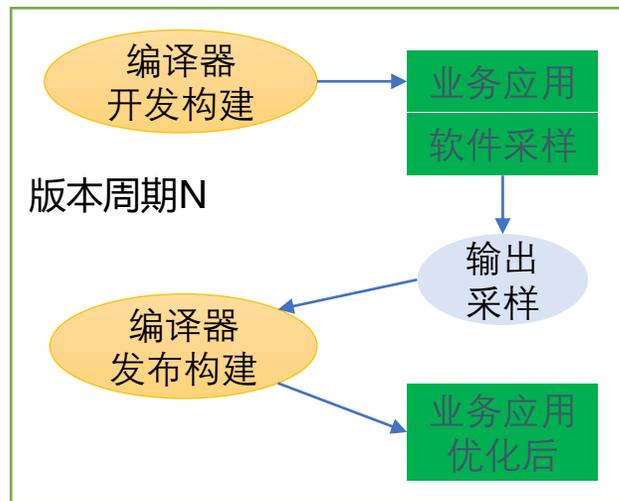
Facebook团队

- [1] Feedback-Directed Optimizations with Estimated Edge Profiles from Hardware Event Sampling, Open64 Workshop at CGO' 08.
- [2] Feedback-Directed Optimizations in GCC with Estimated Edge Profiles from Hardware Event Sampling, Proceedings of the GCC Developers' Summit, 2008.
- [3] Taming hardware event samples for FDO compilation, In CGO' 10.
- [4] Lightweight Feedback-Directed Cross-Module Optimization, In CGO' 10.
- [5] Taming hardware event samples for precise and versatile feedback directed optimizations, TOC, 2013.
- [6] Google-wide profiling: A continuous profiling infrastructure for data centers. MICRO, 2010.
- [7] AutoFDO: Automatic Feedback-Directed Optimization for Warehouse-Scale Applications, CGO' 16.
- [8] Optimizing Function Placement for Large-Scale Data-Center Applications, CGO' 17.
- [9] BOLT: A Practical Binary Optimizer for Data Centers and Beyond, CGO' 19.
- [10] Lightning BOLT: Powerful, Fast, and Scalable Binary Optimization, CC' 21.

反馈优化编译器社区支持情况



不同形式反馈优化的区别



插桩反馈编译:

1. 版本周期内编译器**两次构建**
2. 软件插桩**代码输出采样**, **时间长**, **无硬件事件** (cache miss)

自动反馈编译AutoFDO:

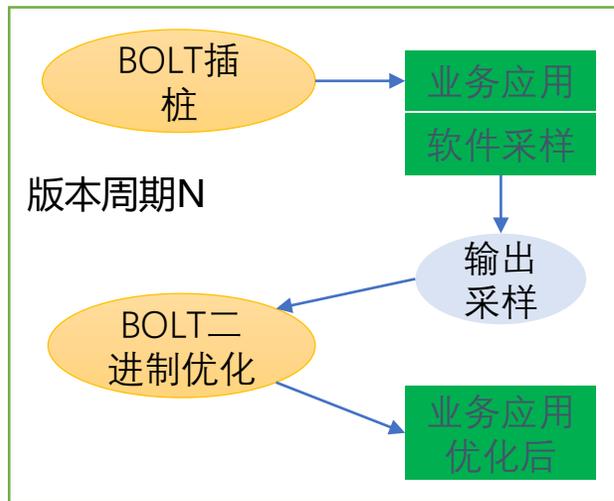
1. 版本周期内编译器**一次发布构建**
2. **硬件输出采样**, **时间短有精度损耗**, **有硬件事件** (cache miss)

智能预取:

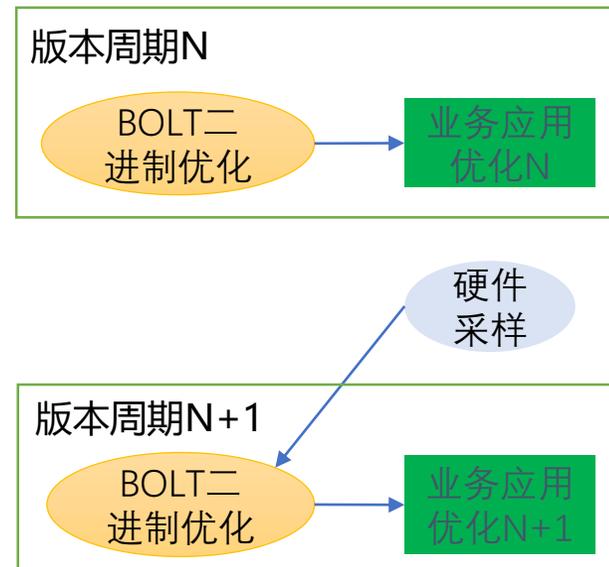
1. 版本周期内**模拟器执行**、**编译器发布构建**、**算法分析采样数据**
2. 软件**模拟输出采样**, **时间非常长**, **有硬件事件** (cache miss)

根本差异: 采样数据收集方式

BOLT二进制反馈优化



插桩反馈优化



硬件采样反馈优化

优势:

- 二进制层面直接优化，不需要对应回源码，精确度高
- 二进制层面的全局优化，优化效果好，与编译器的LTO优化相比应用场景更广泛
- 可以与AutoFDO叠加使用

劣势:

- 二进制级别优化难以感知代码高级语义，丧失了做部分高级优化的机会
- 与AutoFDO合用时需要两次采样

当前AutoFDO及BOLT的短板

多样性算力相关问题:

- 强依赖x86 PMU的LBR采样能力, 对于其他架构的支持并不友好
- 缺少LBR而仅依据BB块采样次数很难准确地推断代码分支的执行概率

技术自身的短板:

- 目前AutoFDO只聚焦于插桩反馈优化的能力, 未充分的利用PMU能够采集的信息
- 目前BOLT与AutoFDO结合使用需要进行一次额外的采样和额外的链接

CFG构造精度问题

指令执行次数

源码行执行次数

BB块执行次数

带分支概率的CFG

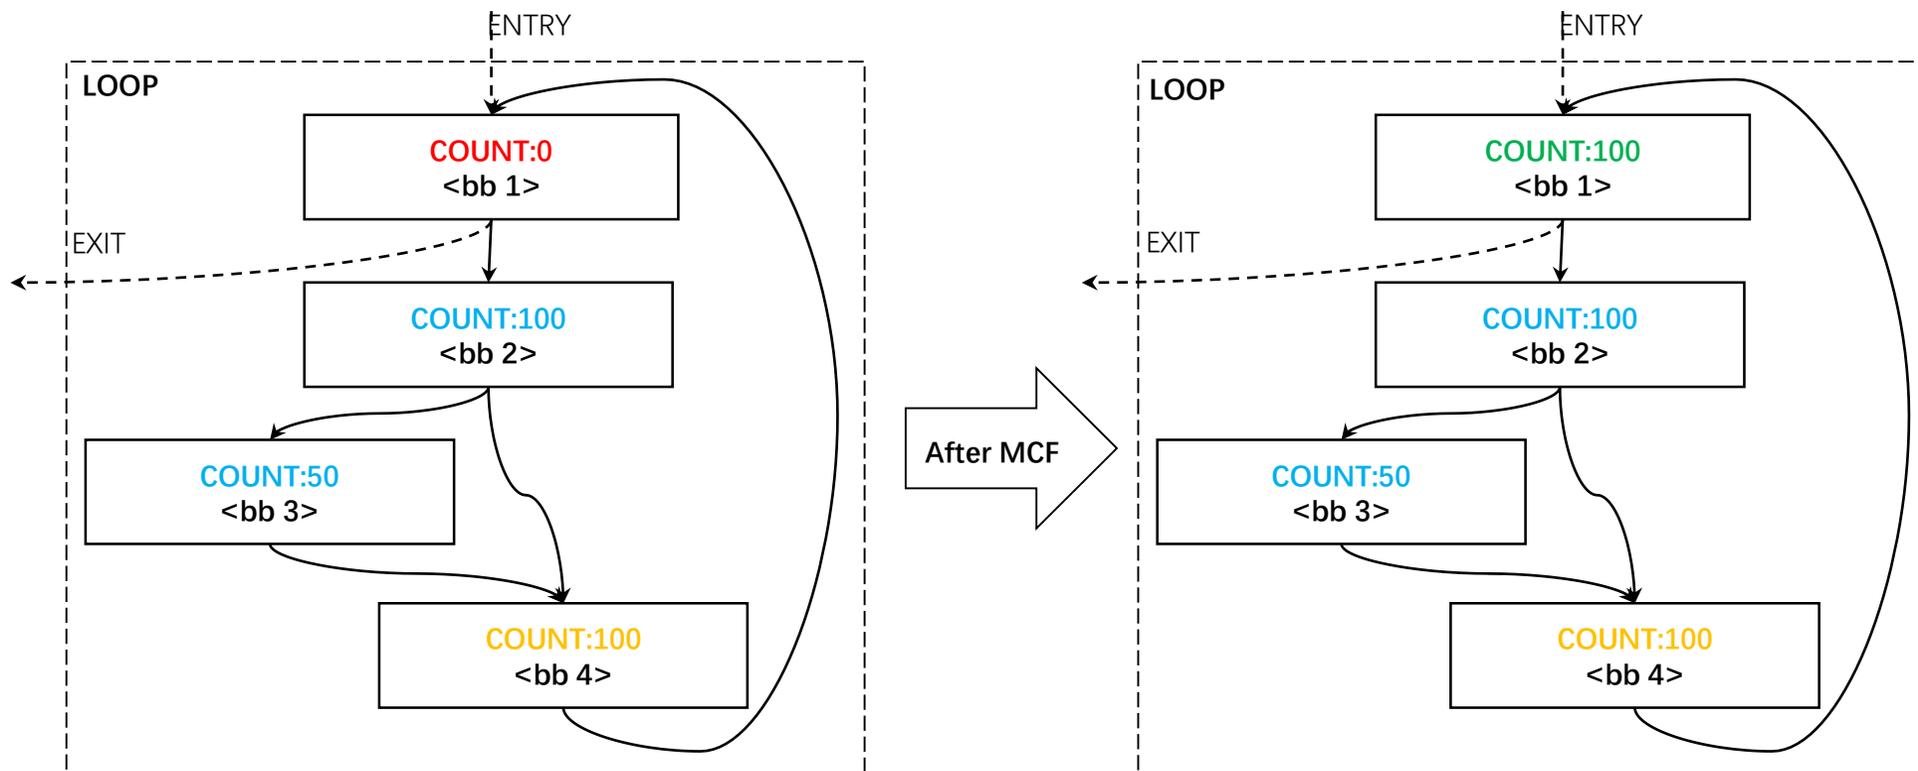
问题：PMU采样数据精度误差
解决方法：采用MCF算法

问题：一行源码可能对应多个BB块
解决方法：使用discriminator

问题：inline函数的语境信息丢失
解决方法：CSSPGO

问题：仅依据BB块采样次数理论上无法求得绝对精确的CFG分支概率
解决方法：使用跳转指令执行次数辅助构造CFG

PMU采样数据准确性提升



通过MCF算法提升采样数据准确性

Discriminator

Source:

```
0: FUNCTION()  
1: for( init_stmt ; test_stmt ; update_stmt ) {  
2: LOOP_BODY  
3: }
```

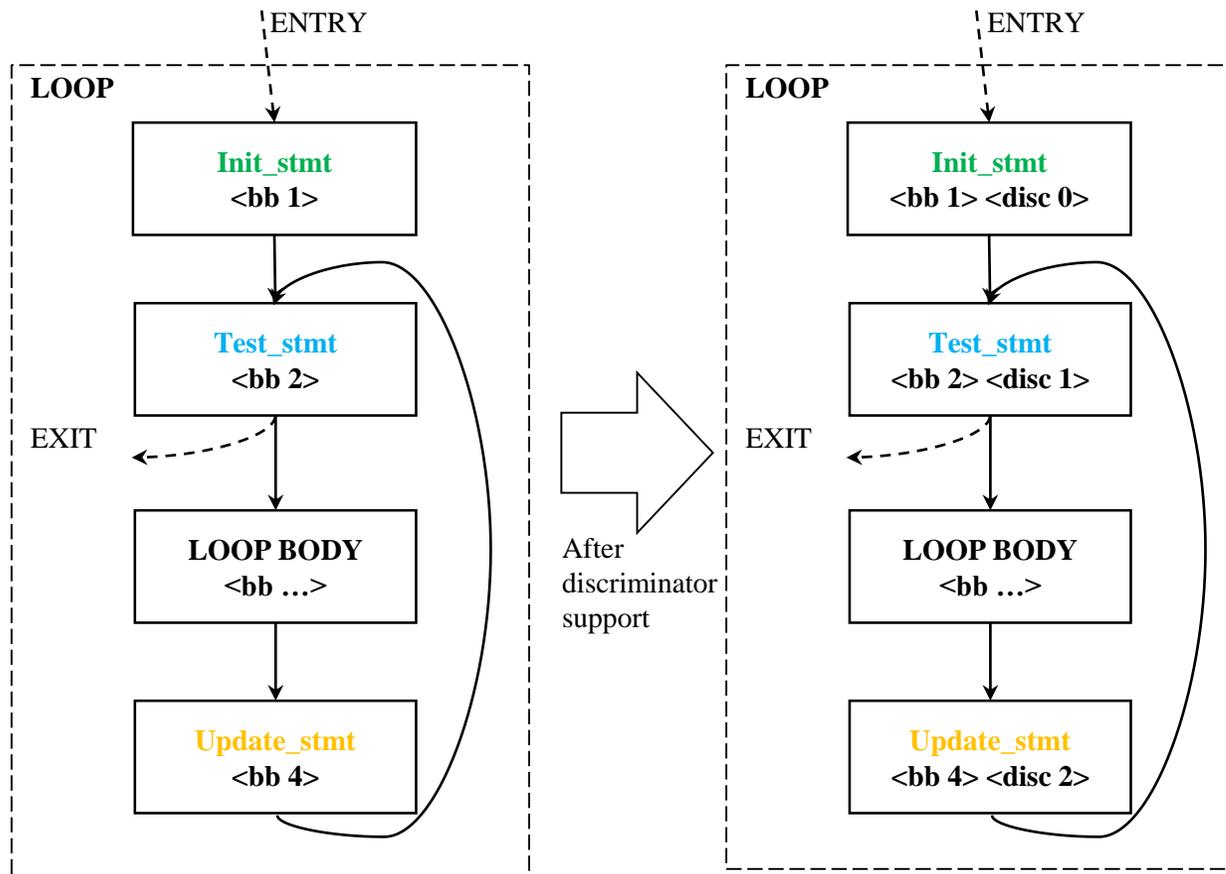
```
FUNCTION() total:X  
head:X  
1: LOOP_COUNTS  
2: LOOP_COUNTS
```

Discriminator支持前:

- 同一行源码对应多个BB块的情况下, 编译器无法区分多个不同分支的BB块计数;

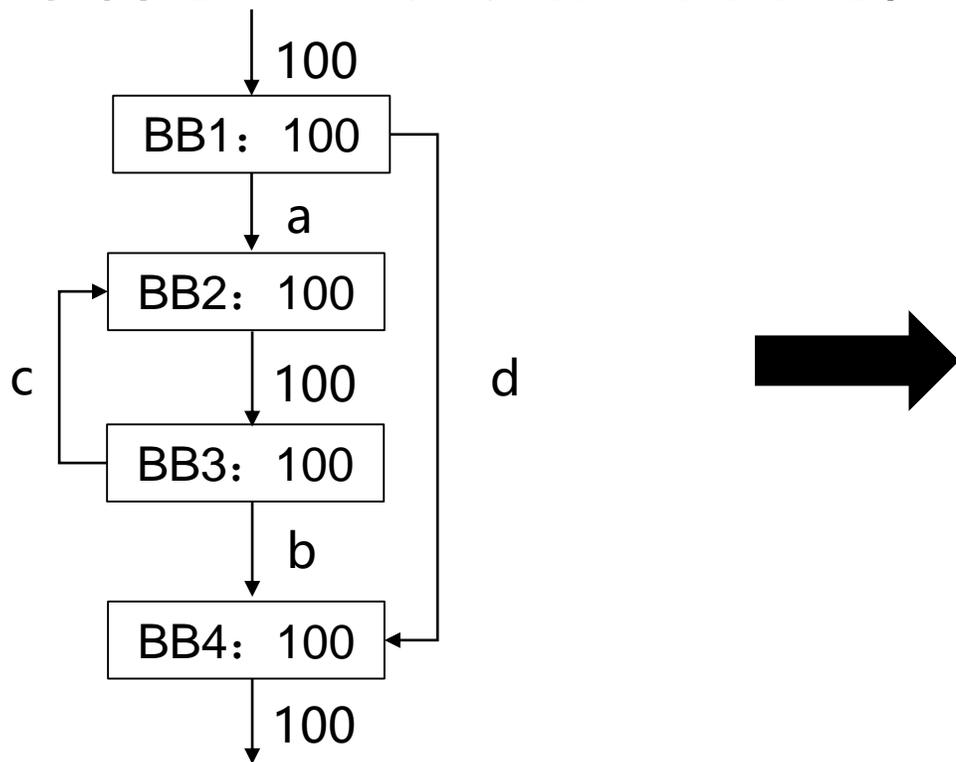
Discriminator支持后:

- 同一行源码的对应的每个BB块计数都能够被正确处理;



BB块采样求CFG分支概率的局限

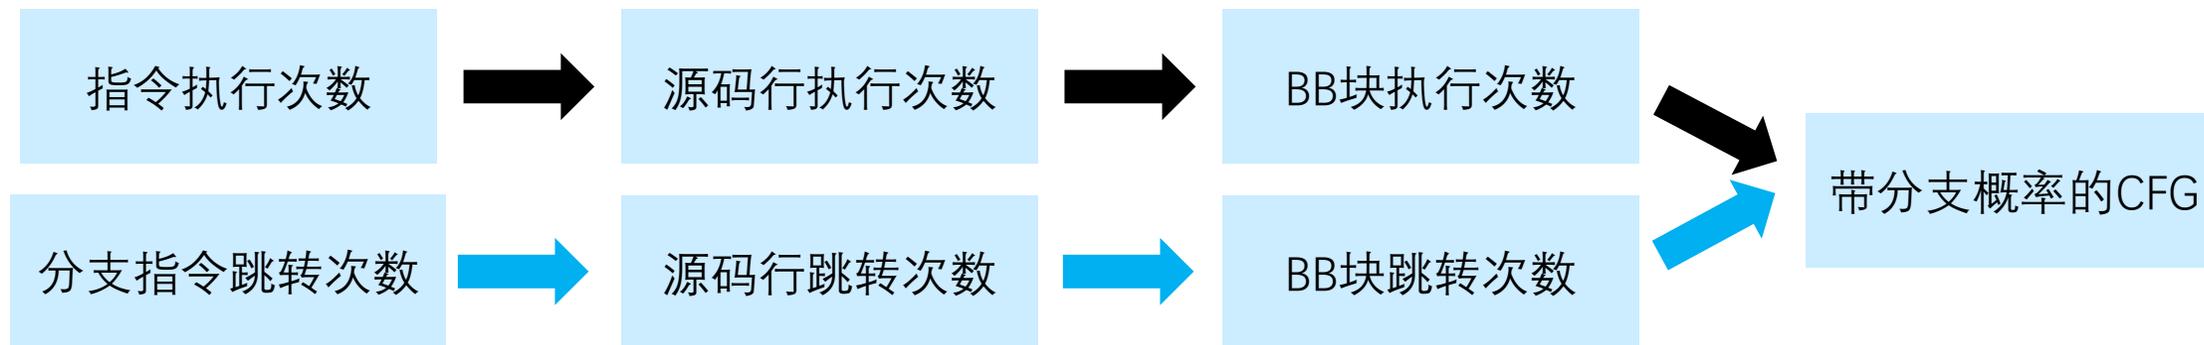
问题:



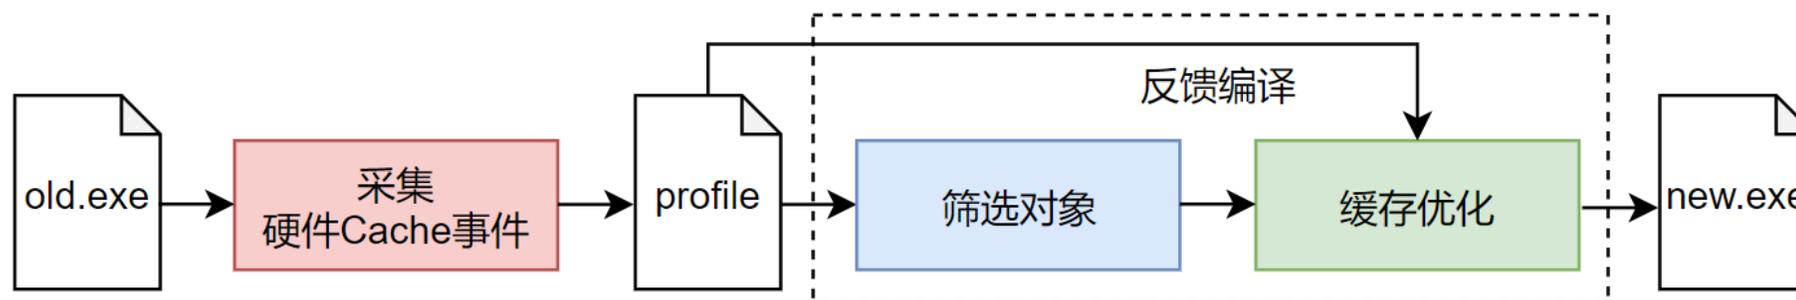
$$\begin{cases} a+c=100 \\ b+c=100 \\ b+d=100 \end{cases}$$

无穷多解

解决方案



预取反馈优化



- 使用硬件Cache事件指导预取对象的筛选
- 提出一种分支加权的预取距离算法，基于反馈信息计算分支的执行概率，精准的计算预取距离，提升优化精度

分支加权的预取距离计算方法

利用反馈信息，计算控制流图的主要执行分支，提高预取准确性

- 1、筛选计算集中于循环体内的循环：

$$\begin{aligned} \text{loopRate} &= 1 - \frac{\text{sum}(\text{exit}_{\text{bb}} \times \text{exit}_{\text{edge}})}{\text{header}_{\text{bb}}} \\ &= 1 - \frac{100 \times 1\%}{100} = 99\% \end{aligned}$$

- 2、计算循环体内BB块执行概率：

$$\text{BB1} = 100\%,$$

$$\text{BB2} = \text{pre}_{\text{bb}} \times \text{pre}_{\text{edge}} = 100\% \times 1\% = 1\%$$

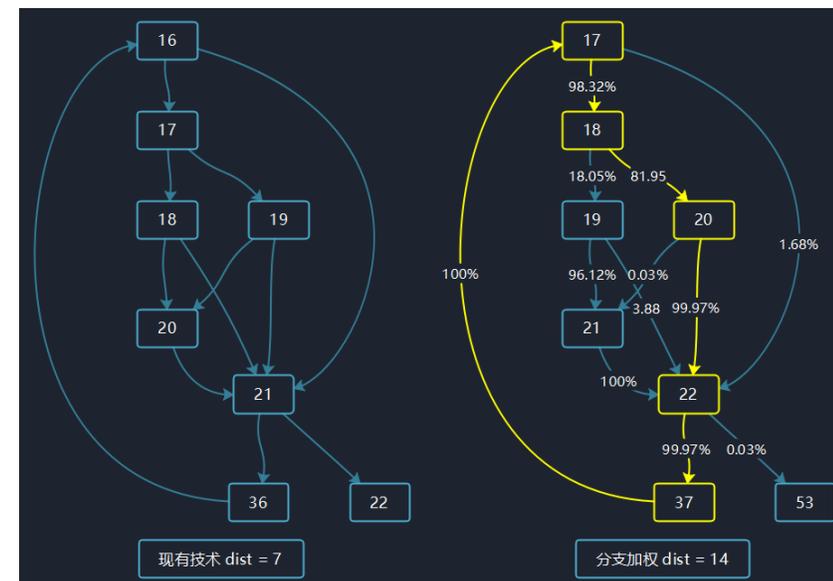
- 3、得到循环体的期望运行时间：

$$\text{loopTime} = \text{sum}(\text{BB}_{\text{prob}} \times \text{sum}(\text{inst}_{\text{time}}))$$

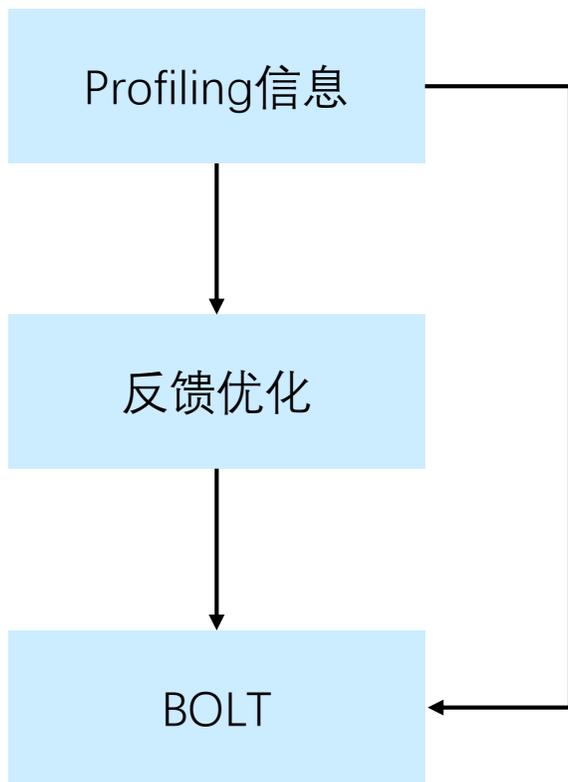
- 4、根据循环体的期望运行时间求取预取距离：

$$\text{prefetch}_{\text{dis}} = \frac{\text{latency}}{\text{loopTime}}$$

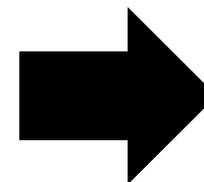
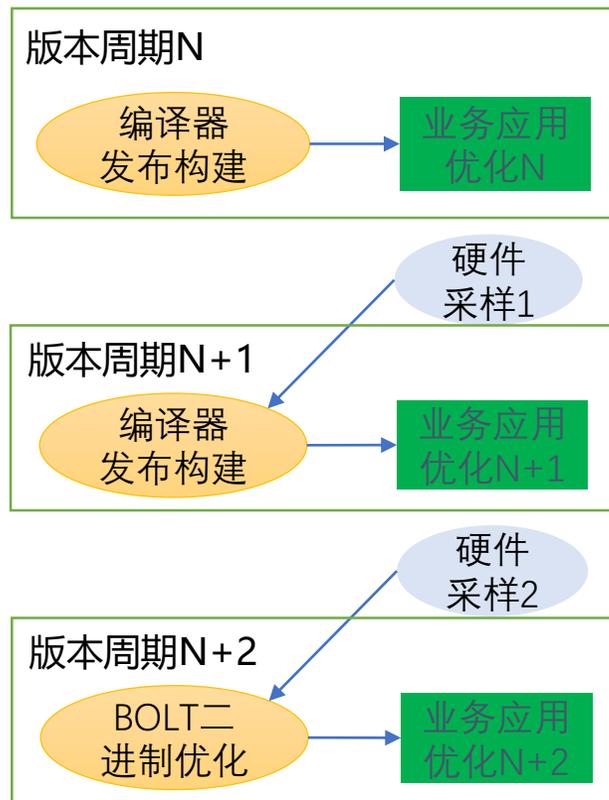
```
for ( ; arc < *end_arc; arc += num_threads) {
  if( arc->ident > BASIC)
  {
    /* red_cost = bea_compute_red_cost( arc ); */
    static long long cnt = 0;
    cnt++;
    red_cost = arc->cost - arc->tail->potential + arc->head->potential;
    if( bea_is_dual_infeasible( arc, red_cost ) )
    {
      basket_sizes[thread]++;
      perm[basket_sizes[thread]]->a = arc;
      perm[basket_sizes[thread]]->cost = red_cost;
      perm[basket_sizes[thread]]->abs_cost = ABS(red_cost);
      perm[basket_sizes[thread]]->number = 0;
    }
  }
}
```



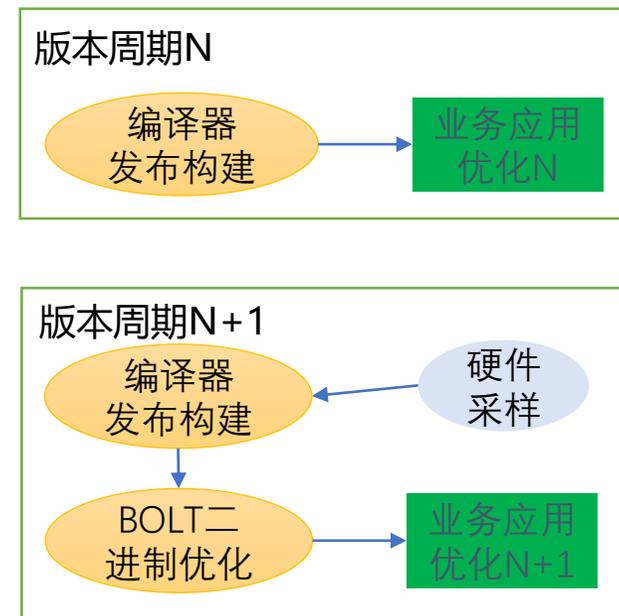
反馈优化与BOLT的集成



集成后的反馈优化流程



一次采样，两者共用



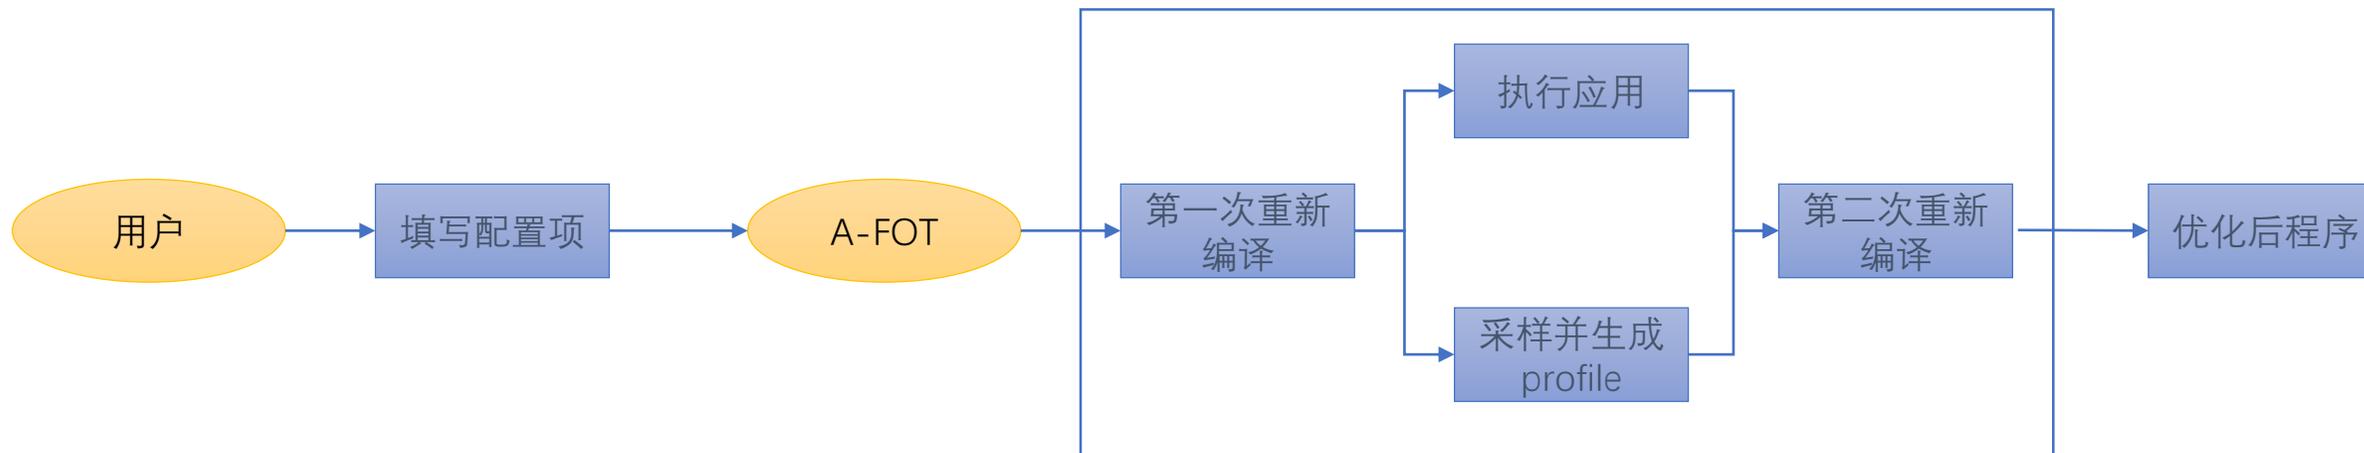
A-FOT

A-FOT(automatic feedback-directed optimization tool):

- 是一款用于提升编译器openEuler GCC自动反馈优化特性易用性的工具
- 用户通过较少的配置即可自动完成反馈优化的相关步骤（包括编译、采样、分析、优化等）

技术细节:

- 支持AutoFDO、AutoPrefetch、AutoBOLT模式，应用模板设计模式，易于增减优化模块
- 使用wrapper自动添加所需编译选项
- 支持自动检测优化结果
- 目前仅支持单实例应用优化
- 未来计划集成分析能力，自动确定采用何种优化模式





OpenEuler | Compiler SIG