




《编译原理（实验班）》内容回顾

Course Review

编译是什么？

- 编译(Compiling)就是把高级语言程序翻译成与其等价的目标语言程序的过程



- 编译的**科学**: 如何**正确**、**高效**地实现翻译?
- 编译的**艺术**: 如何**设计**过程中所需的各种中间表示?

一坨不成熟的类比




Harness $\approx$ 操作系统

- 回顾：操作系统就是目标程序的运行时环境



- 问：Harness 中有哪些与操作系统神似的概念？



什么东西不见了？




- ◎ 编程语言不见了！编译器不见了！
- ◎ 我们手写 Prompt 类比直接手写汇编？
 - ❖ 由于 LLM 是「生成与执行统一」的，Prompt 可以写得很抽象
- ◎ 强行类比，Prompt 是否有「High Level」和「Low Level」之分？
- ◎ 如果有的话，**编译**代表啥？**编译器**是啥？

在这之前，先来看看汇编

- ◎ 不同的 LLM $\approx$ 不同的 CPU
- ◎ 不同的 Harness $\approx$ 不同的操作系统
- ◎ **但是 Skill 为啥能通用？**
 - ❖ 回忆：Skill 是「以自然语言为汇编直接写的应用程序」
- ◎ **通用不是必然的**
 - ❖ 思想实验：假设 LLM A 只懂英文，LLM B 只懂中文，还能通用吗？
- ◎ 再次类比：Apple Rosetta，把 Intel 应用转译到 Arm 架构上
- ◎ SkVM: Revisiting Language VM for Skills across Heterogenous LLMs and Harnesses

SkVM $\approx$ JVM

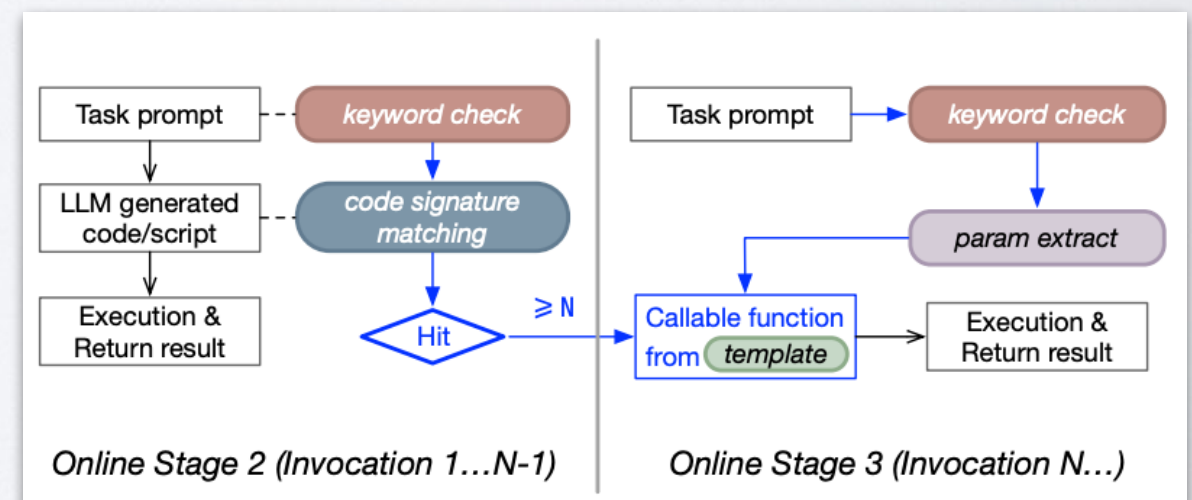
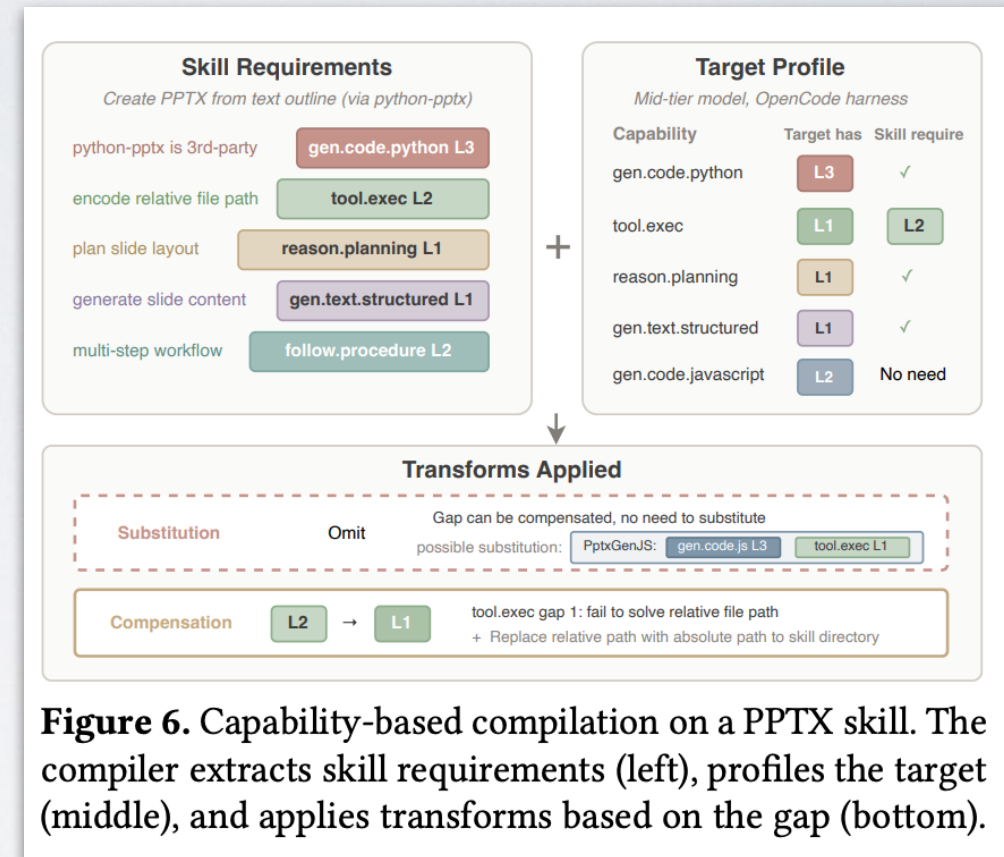
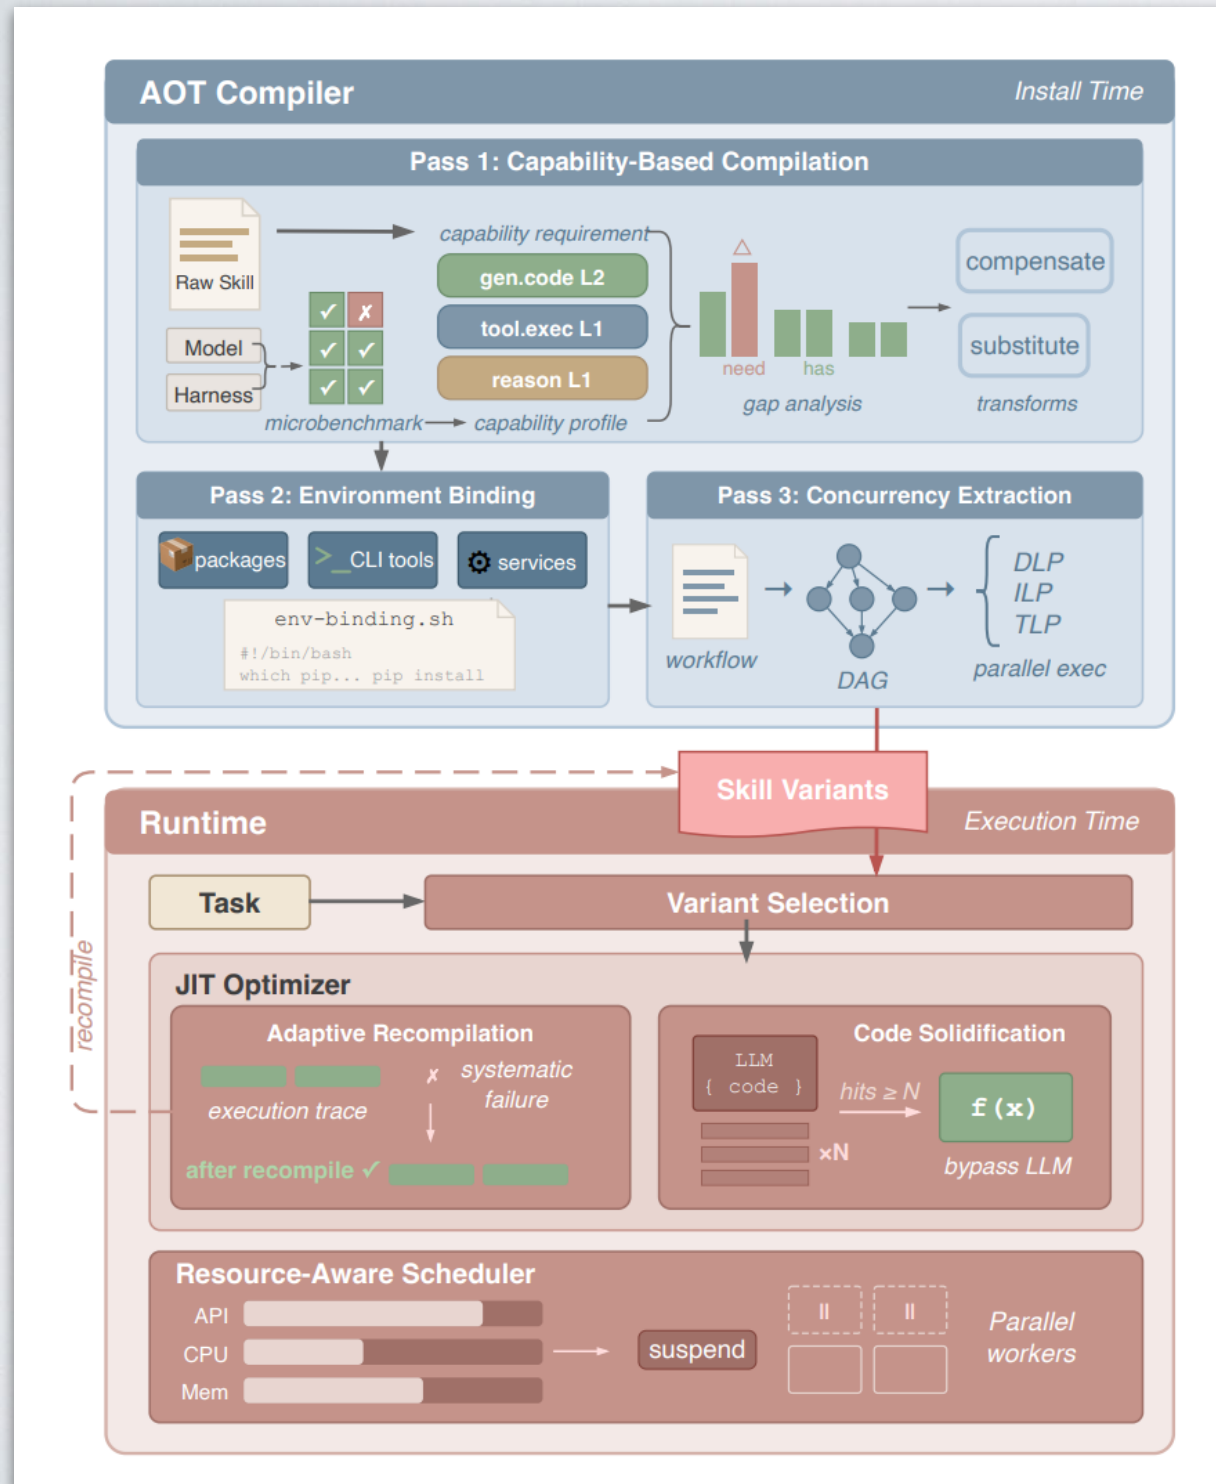
● 虽然 Skill 确实通用，但是效果也确实受 LLM + Harness 影响




● 问：JVM 做了什么？

- ❖ AOT (Ahead-of-Time): 编译时翻译到平台无关的字节码
- ❖ JIT (Just-in-Time): 运行时为热点代码实时生成机器码
- ❖ 可以怎么类比？

SkVM $\approx$ JVM




什么东西不见了？



- ◎ SkVM 是一套「编译器」技术
 - ❖ 在自然语言 Prompt 层面的「源源编译」
 - ❖ 还有很多潜力：并行化、技能内联、工具固化、死上下文消除……
- ◎ 问：还有可能从「汇编语言」走向「高级语言」吗？
- ◎ 会是自然语言、形式语言，还是两者的混合？

编译器是什么？

- ◎ **编译器(Compiler)**：实现源程序编译到目标程序的**软件**



- ◎ 编译的**工程**：如何**架构**编译器使得开发更加可控？

词法分析：源代码 $\rightarrow$ Token 流

词法分析的工作流程(以 Lex 为例)

❖ 正则表达式 $\Rightarrow$ NFA $\Rightarrow$ DFA $\Rightarrow$ 最小化 DFA

关键技术

❖ 正则表达式的表示

❖ 正则语言

❖ 正则表达式转换为 DFA

❖ 求导法

例题

◎ 下列哪个正则表达式与 $(0^*10^*1)^*0^*10^*$ 表示的语言相同：

(A) $0^*1(0 \mid 10^*1)^*$

(B) $(0 \mid 10^*1)^*$


(C) $1^*0(1 \mid 01^*0)^*$

(D) $(1 \mid 01^*0)^*$

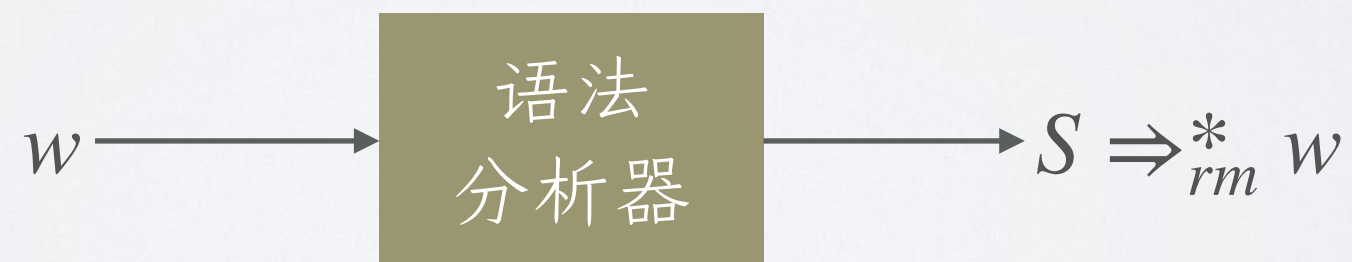
语法分析：Token 流 $\rightarrow$ 分析树

- 上下文无关文法

- 自顶向下分析



- 自底向上分析



自顶向下分析

◎ 自顶向下分析算法的基本思想:

- ❖ 对于文法 $G[S]$: 若 $S \Rightarrow^+ w$ 则 $w \in L(G[S])$, 否则 $w \notin L(G[S])$

◎ 主要问题:

- ❖ 左递归问题
- ❖ 回溯问题

◎ 主要方法:

- ❖ 递归下降分析法
- ❖ LL 分析法
- ❖ PEG 和 Packrat 算法
- ❖ Parser Combinators

自底向上分析

- ◎ 自底向上分析算法的基本思想:

- ❖ 对于文法 $G[S]$: 若 $S \Leftarrow^+ w$ 则 $w \in L(G[S])$, 否则 $w \notin L(G[S])$

- ◎ 主要问题:

- ❖ 分析栈状态的识别问题

- ◎ 主要方法:

- ❖ 移进-归约分析法

- ❖ LR 分析法

语法分析的关键技术

◎ 文法的构造与转换

- ❖ 消除左递归
- ❖ 提取左公因子

◎ 自顶向下的语法分析

- ❖ 递归下降分析
- ❖ LL(1) 分析: FIRST、FOLLOW 集合, LL(1) 分析表

◎ 自底向上的语法分析

- ❖ 移进-归约分析
- ❖ LR 分析: LR(0), SLR(1), LR(1), LALR(1)
- ❖ LR 项和 LR 项集的构造
 - ❖ 识别分析栈的 DFA

例题

- ◎ 下列哪些是上下文无关语言：
 - (A) 所有含偶数个 a 和偶数个 b 的由小写字母组成的串
 - (B) 所有形如 $ca^n b^m$ 的串, 其中 $n > 2m$
 - (C) 所有能通过 C 语言编译器编译的串
 - (D) 所有由 1、2、3、4 组成且所表示的十进制数大于 1234 的串

例题

- ◎ 若上下文无关文法 G 定义的语言是一个有限集合, 则下列哪些性质 G 必然满足:
- (A) G 无二义性
 - (B) G 是正则文法
 - (C) 存在无二义性上下文无关文法 G' , 使得 $L(G') = L(G)$
 - (D) 存在正则文法 G' , 使得 $L(G') = L(G)$

例题

◎ 考虑如下文法, 回答下列问题:

$$S \rightarrow AB$$

$$A \rightarrow B + A \mid a$$

$$B \rightarrow C * B \mid b$$

$$C \rightarrow (A) \mid \varepsilon$$

- (A) C 的 FIRST 集合是什么?
- (B) A 的 FOLLOW 集合是什么?
- (C) 这是 LL(1) 文法吗?
- (D) 文法的预测分析表中, 输入符号为 $*$ 时 A 对应的表项是什么?

语义分析：分析树 $\rightarrow$ 「语义」

◎ 语法制导定义(SDD), 也称为属性文法

- ❖ 综合属性
- ❖ 继承属性
- ❖ 属性求值


◎ 语法制导的翻译方案(SDT)

- ❖ 自顶向下翻译
 - ❖ 消除翻译方案中的左递归
- ❖ 自底向上翻译
 - ❖ 消除嵌入在产生式中间的动作

◎ 解释执行、类型检查、中间表示生成

例题

- 考虑上下文无关文法 $T \rightarrow \text{uint} \mid \text{uint} (T) (T)$, 其中 **uint** 是一个表示非负整数的终结符号。该文法可以用来描述二叉树, 且每个结点有一个非负整数作为这个结点的权重。例如, $2(4)(1(5)(3))$ 表示了右下图中的树。定义路径的权重是路径上所有结点的权重之和。
- 设计只包含非负整数属性的 S 型 SDD(只包含综合属性), 计算树上权重最大的路径的值, 并保存在综合属性 *maxlen* 中。**uint** 的数值可以通过 **uint.val** 获得。例如, 右图中根结点的 *maxlen* 值为 12 ($4+2+1+5$)。



例题

- ◎ 以下是上下文无关文法 $G[A]$ 的自底向上的 SDT, 其中 a 、 b 、 c 为终结符, A 、 B 为非终结符:
$$\begin{array}{ll} A \rightarrow a B & \{ \text{print "0"} \} \\ A \rightarrow c & \{ \text{print "1"} \} \\ B \rightarrow A b & \{ \text{print "2"} \} \end{array}$$
- ◎ 若输入串 w 能被 G 识别, 则 SDT 将打印出输出串 w' 。判断所有可能的 w' 构成的语言 L' 是否为正则语言或上下文无关语言, 并对应给出正则表达式或上下文无关文法。

中间代码生成：分析树 $\rightarrow$ 三地址代码

◎ 中间代码的常用形式

- ❖ 抽象语法树、有向无环图、**三地址代码**、静态单赋值、LLVM、MLIR
- ❖ 函数式语言：KNF、ANF、CPS、闭包形式

◎ 通过语法制导翻译实现中间代码生成

- ❖ 为每种语法结构构造中间代码的表示形式
- ❖ 构造生成上述中间代码的 SDD/SDT
 - ❖ 表达式和赋值语句
 - ❖ 类型和声明、数组的处理、类型检查
 - ❖ **布尔表达式和控制流语句**
 - ❖ if, while, do-while, for, switch
 - ❖ 回填

例题

◎ 考虑 Pascal 语言中的 FOR 循环语句：

❖ $S \rightarrow \text{FOR } \mathbf{id} := E_1 \text{ TO } E_2 \text{ DO } S_1$

❖ 其语义为：先计算初始值 E_1 和结束值 E_2 ，再循环执行 S_1 ，循环变量从初始值变化到结束值，每次执行完 S_1 后对循环变量加一

◎ 为如下中间代码形式设计 SDD (继承属性 $S.next$ 记录紧跟在 S 之后的语句标号)

$E_1.code$

$\mathbf{id}.addr = E_1.addr$

$E_2.code$

(loop) if $\mathbf{id}.addr > E_2.addr$ goto (next)

$S_1.code$

$\mathbf{id}.addr = \mathbf{id}.addr + 1$

goto (loop)

(next)

例题

- 考虑 Pascal 语言中的 FOR 循环语句：
 - ❖ $S \rightarrow \text{FOR } \mathbf{id} := E_1 \text{ TO } E_2 \text{ DO } S_1$
 - ❖ 其语义为：先计算初始值 E_1 和结束值 E_2 ，再循环执行 S_1 ，循环变量从初始值变化到结束值，每次执行完 S_1 是对循环变量加一
- 为上一页的 SDD 设计自顶向下的 SDT
- 把上面的 SDT 改造成边扫描边生成代码
- 继续改造，使用回填技术生成代码
 - ❖ 综合属性 $S.nextlist$ 中的跳转语句的目标是紧接着 S 的位置
 - ❖ 变量 $nextinstr$ 保存了生成过程中紧跟着的下一条语句的标号
- 继续改造成自底向上的 SDT
 - ❖ 如果要求显式操作语法分析栈呢？

机器无关优化：在三地址代码上进行

- 了解编译优化的基本概念

- 局部优化

- ❖ 基本块的划分、流图的构造、循环的识别
- ❖ 基本块内的活跃变量分析
- ❖ 基本块内的优化

- 全局优化

- ❖ 常用方法：常量折叠、公共子表达式消除、复写传播、死代码消除、循环优化(代码外提、归纳变量消除、强度消减)
- ❖ 简单的数据流分析
 - ❖ 活跃变量、可达定值、可用表达式


例题

- ◎ 代码优化(不局限于编译优化)的目的包括以下哪些内容:
 - (A) 提高运行速度
 - (B) 优化能耗
 - (C) 减少资源消耗
 - (D) 提高开发速度
 - (E) 提高代码质量和可维护性
 - (F) 更改代码的功能

例题

◎ 下列代码变换中所用的优化技术是什么？

❖ 可选项：强度消减、复写传播、常量折叠/传播、死代码消除、公共子表达式消除



例题

- 考虑右边的三地址代码序列, 其中 `ret s` 语句表示从函数中返回变量 `s`
- 把这段代码序列划分为基本块
- 为这段代码构造流图, 并额外添加入口结点 ENTRY 和出口结点 EXIT
- 找出流图中的所有循环
- 在流图上进行可达定值分析和活跃变量分析
- 给出流图中可以进行的优化
 - ❖ 在进行一些优化后, 是否会产生新的优化机会?

```
1)  s = 0
2)  i = 0
3)  t1 = s % 19
4)  if t1 == 1 goto (19)
5)  j = 0
6)  if i < 50 goto (8)
7)  ret s
8)  if j >= 100 goto (17)
9)  if i == j goto (15)
10) t2 = 100 * i
11) t3 = t2 + j
12) t4 = 4 * t3
13) t5 = a[t4]
14) s = s + t5
15) j = j + 1
16) goto (8)
17) i = i + 1
18) goto (3)
19) ret s
```

运行时环境：为生成目标代码做准备

◎ 存储分配策略

- ❖ 静态分配
- ❖ 栈式分配
- ❖ 堆式分配

◎ 栈式存储管理

- ❖ 活动记录、控制链、访问链、显示表

◎ 堆存储管理

- ❖ 垃圾回收的基本原理和方法
 - ❖ 引用计数、标记-清扫

例题

● 考虑右下图中两个函数 f、g 在运行过程中的栈空间的内容片段，判断下列说法是否正确：

- (A) (4)(6) 由 f 写入值
- (B) (1)(2)(3)(4)(5) 属于 f 的活动记录
- (C) (7)(8) 由 g 写入值
- (D) (5) 由 g 在函数返回时由 g 写入值


```
void f() { int f1, f2; ... g(5); ... }
int g(int g1) { int g2; float g3; ... }
```

.....
(1) f 返回地址
(2) int f1
(3) int f2
(4) int g1
(5) g 返回值
(6) g 返回地址
(7) int g2
(8) float g3
.....

例题

● 使用引用计数进行带垃圾回收的堆存储管理, 对于右下的指向关系图, 删除哪些边, 会导致对象 G 被回收:

- (A) $D \rightarrow G, B \rightarrow E$
- (B) $C \rightarrow B, C \rightarrow D$
- (C) $D \rightarrow G, C \rightarrow B$
- (D) $E \rightarrow F, A \rightarrow D$



例题

- 考虑如下嵌套定义的过程：

```
procedure f;  
  procedure f1;  
    procedure f11;  
      procedure f111;  
        procedure f12;  
          procedure f2;
```

- f 可以调用 f111 吗？反过来，f111 可以调用 f 吗？
- 考虑过程调用序列 $f \rightarrow f2 \rightarrow f \rightarrow f1 \rightarrow f12 \rightarrow f11 \rightarrow f111 \rightarrow f2$ ，画出栈中的过程活动记录，只需要标明过程名和访问链

目标代码生成：三地址代码 $\rightarrow$ 目标代码

◎ 目标代码生成的基本任务

- ❖ 指令选择

- ❖ 寄存器分配和指派

 - ❖ 局部寄存器分配：寄存器描述符、地址描述符

 - ❖ 全局寄存器分配：冲突图构造、图着色算法、溢出

◎ 简单优化

- ❖ 窥孔优化

例题

- 考虑右边的三地址代码，为其生成目标代码，可用的指令为 $LD\ R, x$ 、 $LD\ R_1, R_2$ 、 $ST\ x, R$ 、 $ADD\ R_1, R_2, R_3$ 、 $SUB\ R_1, R_2, R_3$
- 假设可以使用任意多个寄存器，基本块入口处所有寄存器都没有存储有效值，而生成代码要保证出口处所有变量的内存位置都有它们的最新值
- 给出出口处的寄存器描述符和地址描述符
- 不额外生成指令的前提下，至少需要几个寄存器？


$a = b + c$
$d = d - b$
$e = a + f$
$f = a - d$
$b = d + c$

R1	R2	R3	R4	R5	R6

a	b	c	d	e	f

例题

- 考虑右边的流图 (ENTRY 和 EXIT 画不下了)
- 给出各寄存器的活跃范围, 用数字表示指令标号, l 表示在第 l 条指令后活跃
- 画出寄存器冲突图
- 假设有 4 个物理寄存器, 采用图着色法进行寄存器分配
- 假设有 3 个物理寄存器, 给出分配和溢出方案, 并尽可能减少溢出代价 (假设 load 和 store 的开销相同, 循环执行 10 次)



期末考试形式

◎ 以大题为形式, 分为必答题和选答题

◎ 必答题:

- ❖ 自底向上语法分析: LR、SLR、LALR 分析(参考作业的形式)
- ❖ 语法制导的翻译方案: 三地址代码生成(回填思想?)
- ❖ 运行时环境: 非局部数据访问、垃圾回收
- ❖ 代码优化: 公共子表达式提取、死代码消除……
- ❖ ???

◎ 选答题:

- ❖ 静态单赋值(Koopa IR)的生成、优化
- ❖ 函数式语言的编译
- ❖ 类型系统和类型检查
- ❖ ???

去年的期末考试结构

◎ 【必答】语法分析(20分)

- ❖ 计算 FOLLOW 集合
- ❖ 补全 LR(0) 自动机
- ❖ 补全 SLR(1) 的 ACTION 和 GOTO 表

◎ 【必答】中间代码生成(20分)

- ❖ 补全 SDT

◎ 【必答】简答题(20分)

- ❖ 嵌套函数、静态作用域
- ❖ 自举
- ❖ 对编译课的建议

去年的期末考试结构

◎ 【选做】静态单赋值(20分)

- ❖ 描述 SSA
- ❖ 转换 CFG、转换 SSA
- ❖ 转换为非 SSA 形式的三地址代码

◎ 【选做】运行时环境(20分)

- ❖ 尾递归优化
- ❖ 改写函数为尾递归版本
- ❖ 说明尾递归和循环的关系

◎ 【选做】函数式语言(20分, 作业中做过了)

◎ 【选做】类型系统(20分, 作业中做过了)