

# 编译原理

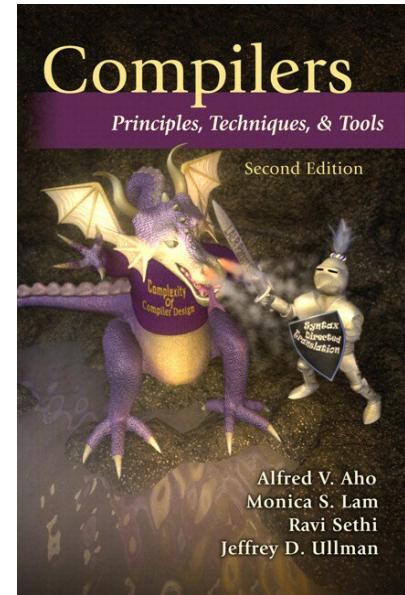
## 1. 导引

谭添

南京大学计算机学院

2025 春季



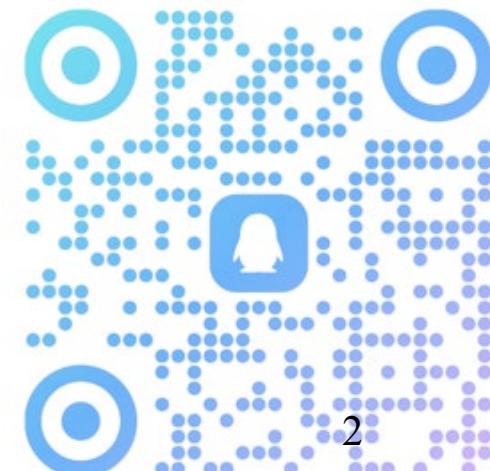


# 课程概要

- 教材
  - 理论: 《编译原理》(龙书), 第二版
  - 实验: 《编译方法、技术与实践》
- 安排
  - 主讲教师: 谭添
  - 网站: <https://cs.nju.edu.cn/tiantan/courses/compiler-2025/index.html>
  - 学时: 16周 (学时64节)
  - 时段: 周二3-4节、周四5-6节
  - 教室: 仙II-212
  - 助教: 钟哲瑀(实验)、湛忠胜(作业)

课程QQ群

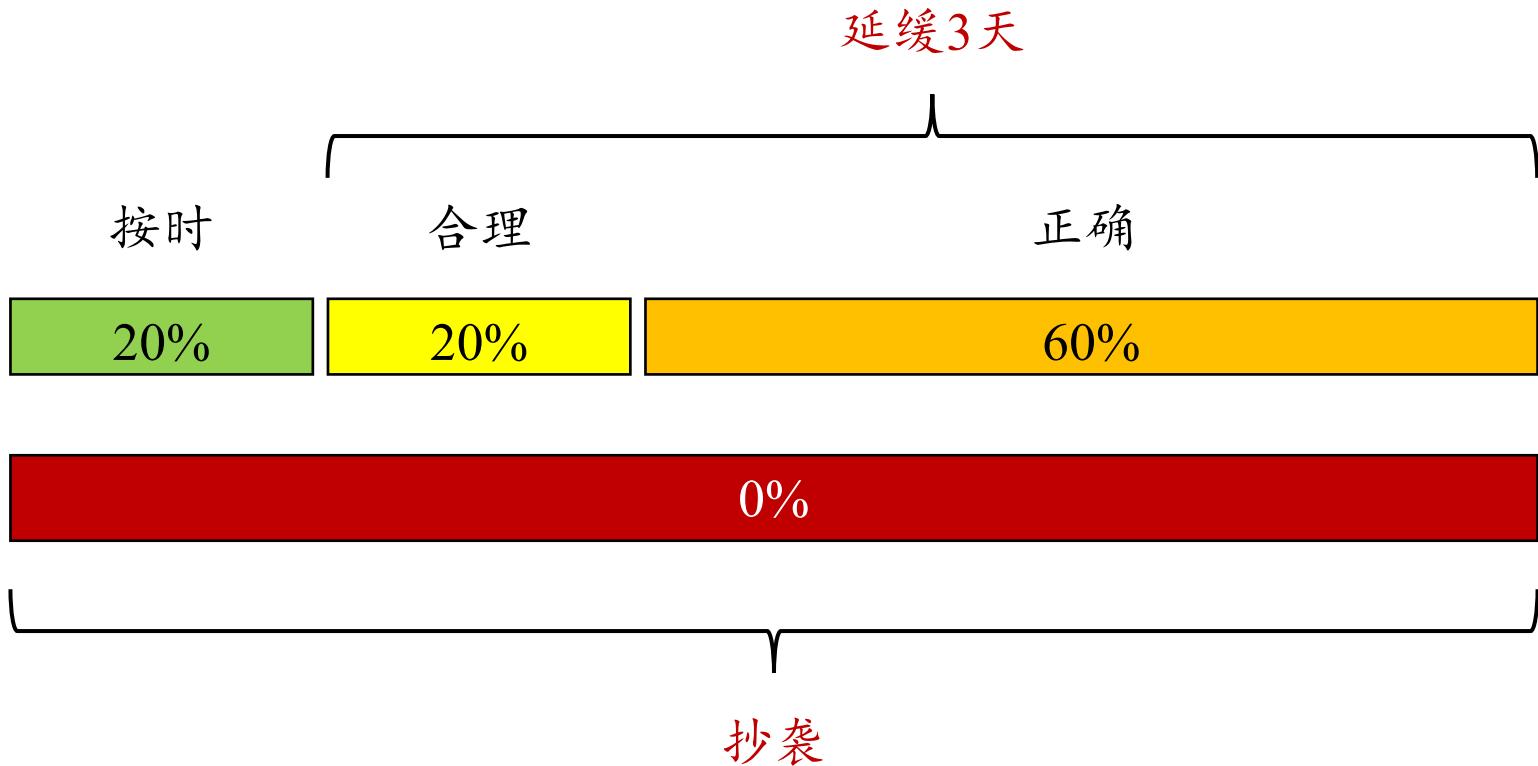
Tian Tan @ Nanjing University



# 课程概要

- 课程结构
  - 理论部分：上课听讲，下课作业，交书面作业
  - 实践部分：实现编译器的几个阶段，交实验作业
- 评分标准
  - 书面作业：10% ( $20\% + 20\% + 60\%$ )
  - 上机实验：30% ( $20\% + 20\% + 60\%$ )
    - 组队调整：110% (1人), 100-105% (2人), 90-95% (3人)
    - 实验内容：五次实验
  - 期末考试：60%
  - 不可控因素：随机签到 (加分)、抄袭检查 (归零) 等

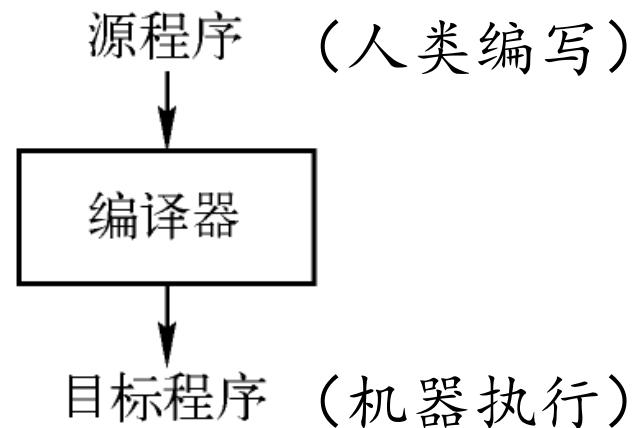
# 实验说明



# 什么是编译器？

- 本质上是一种翻译程序
- 读入以某种语言（源语言）编写的程序
  - C/C++、Java、Rust、Haskell.....
- 输出等价的用另一种语言（目标语言）编写的程序
  - 汇编、WebAssembly.....

通常目标程序是可执行的



# 为什么学习编译原理？

编译原理 = 编译器工作的原理

编译器：最重要、最复杂的基础系统软件之一

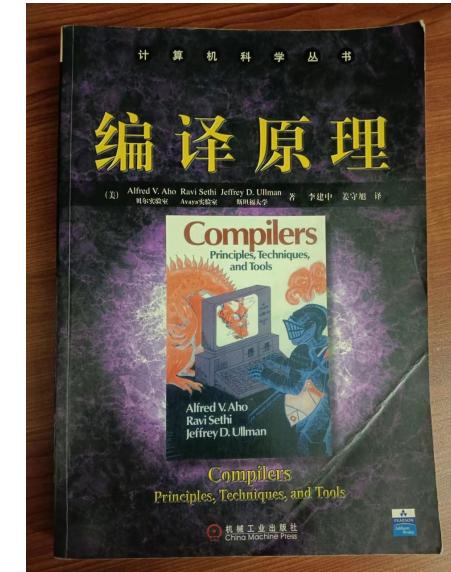
- 现代计算机系统的基石软件
- 为程序设计语言提供支撑
- 提高对程序设计语言的理解

- 现代编译器架构形如长流水线
- 涉及程序设计语言理论、操作系统、体系结构、数据结构与算法等技术
- 提高对复杂系统软件的理解

获得能力：创造属于你的编程语言

# 为什么是我？

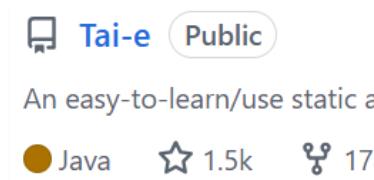
- 20年前，命运的齿轮开始转动.....



- “根正苗红”

- 研究方向：程序设计语言/程序分析

- PLDI: ACM SIGPLAN Conference on Programming Language Design and Implementation
- TOPLAS: ACM Transactions on Programming Languages and Systems
- 程序分析平台 Tai-e 主要作者



# 太阿 (Tai-e)

Java程序分析平台“太阿”(Tai-e)

- 2020年1月启动
- 2022年8月开(出)源(道)
- 开发时长**两年半**

The screenshot shows the GitHub repository page for 'pascal-lab / Tai-e'. The repository is public and has 178 forks. The 'Code' tab is selected. The repository has 7 issues and 2 pull requests. The commit history shows several contributions from 'zhangt2333' and others. The repository description is: 'An easy-to-learn/use static analysis framework for Java'. It features tags for 'java', 'security', 'static-analysis', 'call-graph', and 'taint-analysis'. License information indicates 'LGPL-3.0, GPL-3.0 licenses found'. The repository URL is [tai-e.pascal-lab.net/docs/index....](https://tai-e.pascal-lab.net/docs/index....).

“太阿”的用户

- 30+高校学者
- 10+企业部门主管
- 200+高校/科研院所
  - 华盛顿大学
  - 宾夕法尼亚大学
  - 普渡大学
  - 东京大学
  - 阿姆斯特丹大学
  - 清华大学
  - 北京大学
  - 香港大学
  - .....

pascal-lab / Tai-e

Type to search

Code Issues 7 Pull requests 2 Actions Wiki Security Insights Settings

Pulse Contributors Give feedback

Period: All Contributions: Commits

Contributors per week to master, excluding merge commits

Commits over time  
Weekly from 2020年1月12日 to 2025年2月9日

silverbullettt

Overview Repositories 13

Tian Tan  
silverbullettt

编写7万+行代码

**silverbullettt**  
1,923 commits 343,577 ++ 265,936 --

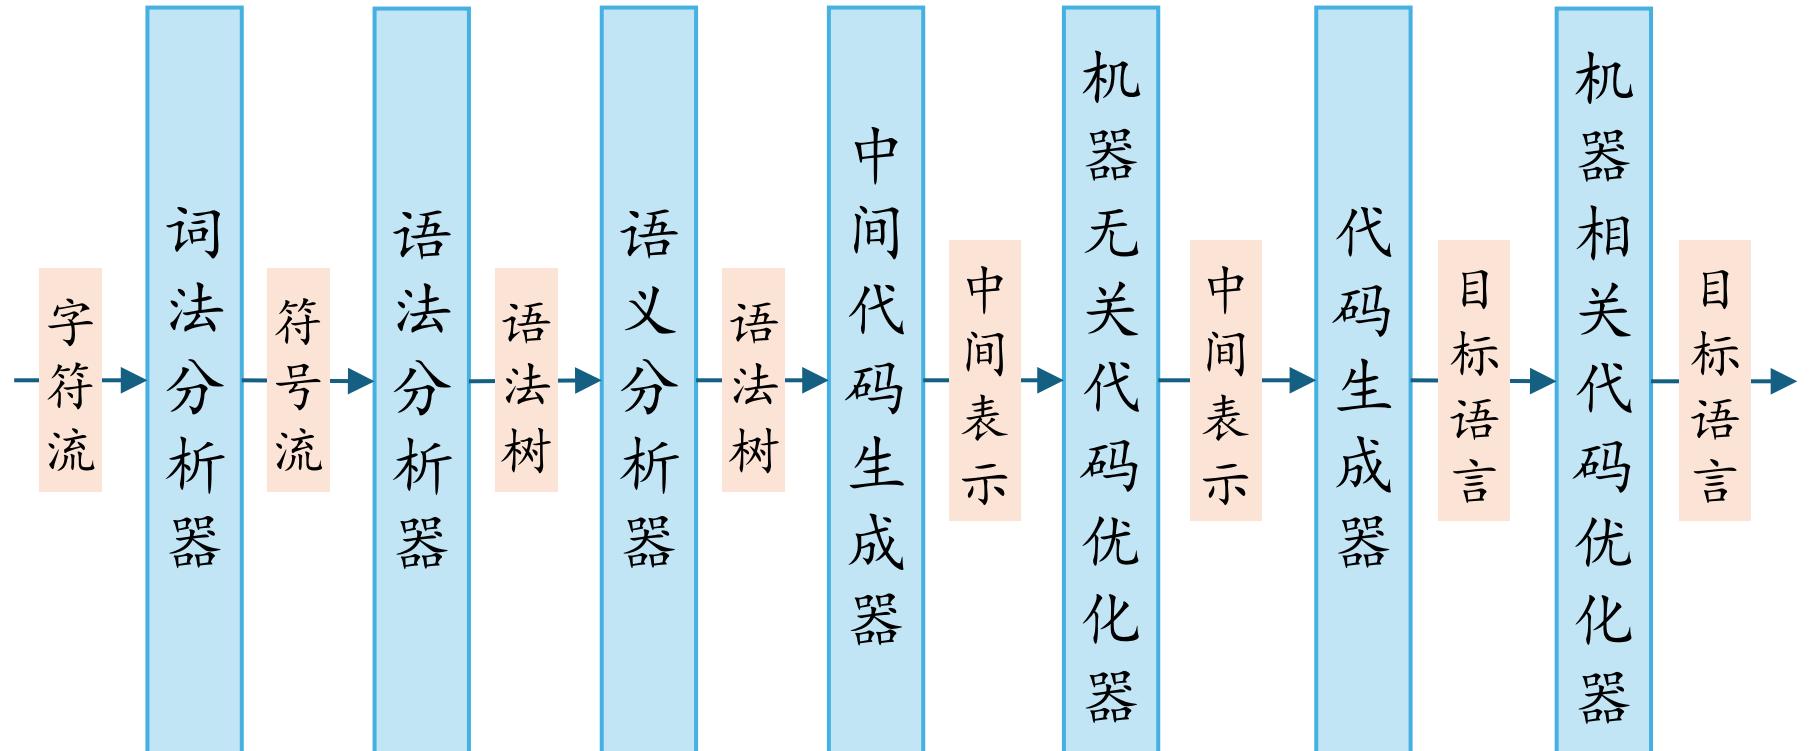
**zhangt2333**  
141 commits 16,362 ++ 5,941 --

Commits over time (2020-2025)

Commits over time (2020-2025)

# 编译器的经典架构

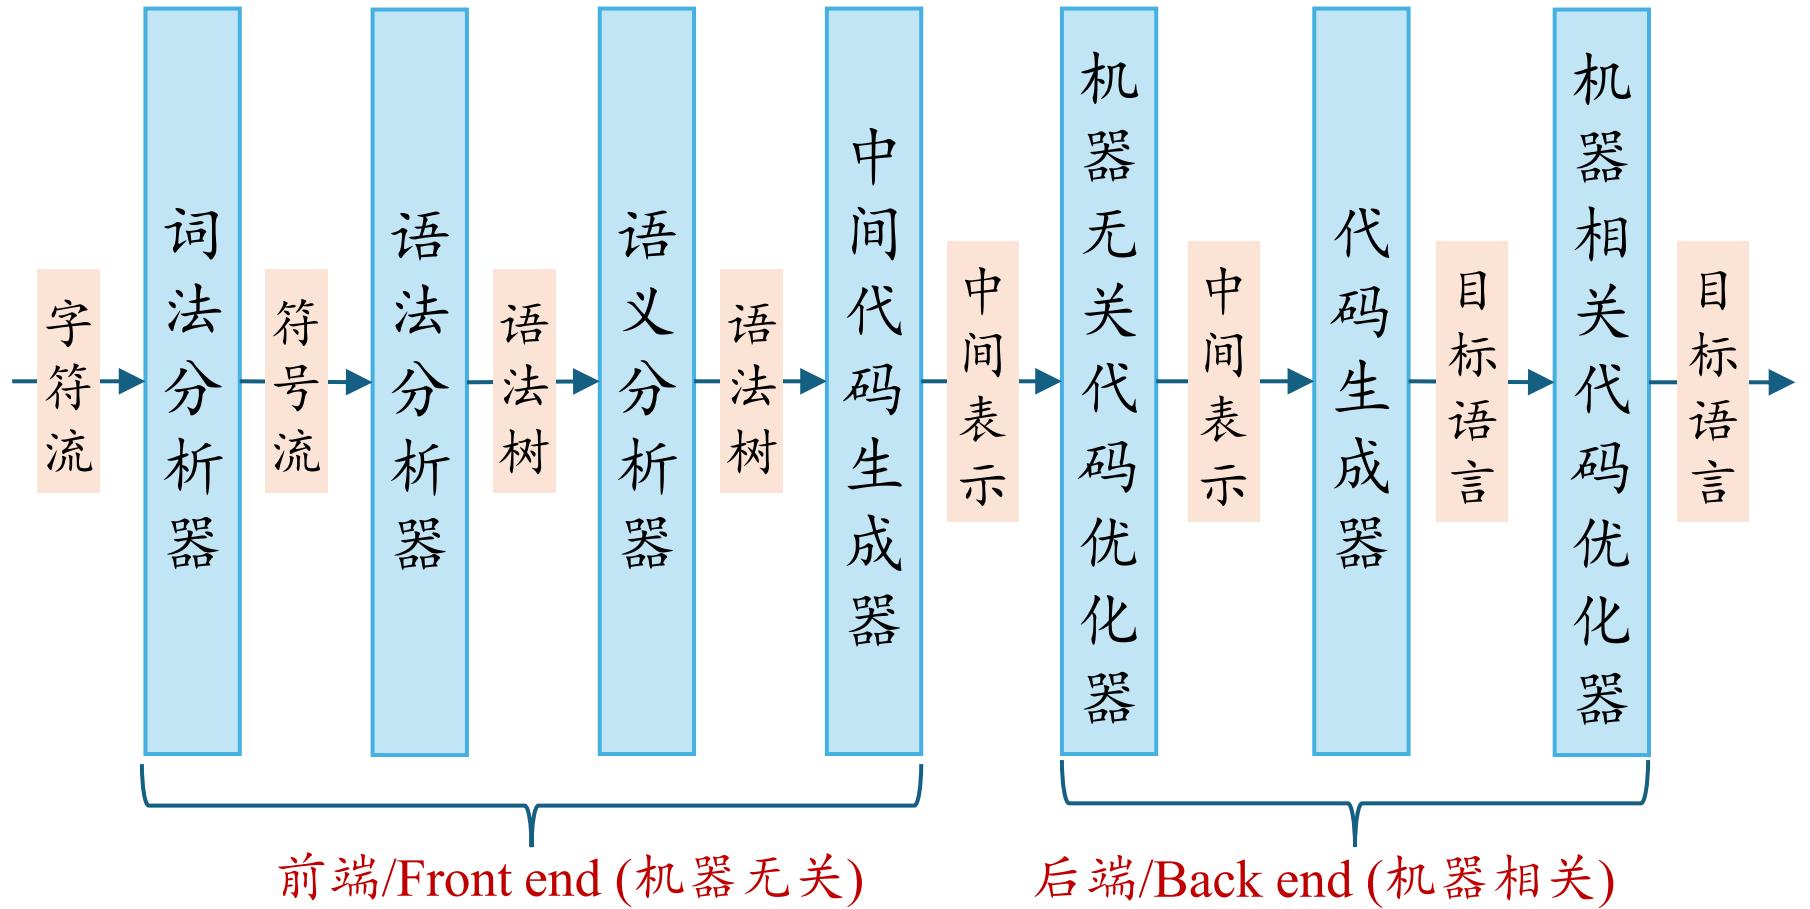
符号表



编译器是一条巨大的流水线

# 编译器的经典架构

符号表



前端/Front end (机器无关)

- 从源程序解析出以及相应的语法结构
- 使用这个结构创建源程序的中间表示
- 同时收集源程序信息，存入符号表

后端/Back end (机器相关)

- 根据中间表示和符号表信息构造目标程序
- 同时对目标程序进行分析、优化

# 课程内容

- |                  |      |
|------------------|------|
| 1. 导引 (易)        | 安排较紧 |
| 2. 词法分析 (难-)     |      |
| 3. 语法分析 (难)      |      |
| 4. 语法制导的翻译技术 (中) | 安排较松 |
| 5. 中间代码生成 (难)    |      |
| 6. 运行时刻环境 (易)    |      |
| 7. 代码生成 (中)      |      |
| 8. 机器无关优化 (中)    |      |

# 符号表 (Symbol Table)

- 用于记录源程序中出现的标识符信息的数据结构
  - 标识符的**名字**
    - 变量名、函数名
  - 标识符在源程序中的**位置**
    - 文件名 + 起止行列号
    - 用于精准报错
  - 标识符的**类型**
    - 用于语义分析、代码生成
  - .....

在编译器运行过程中逐步构建

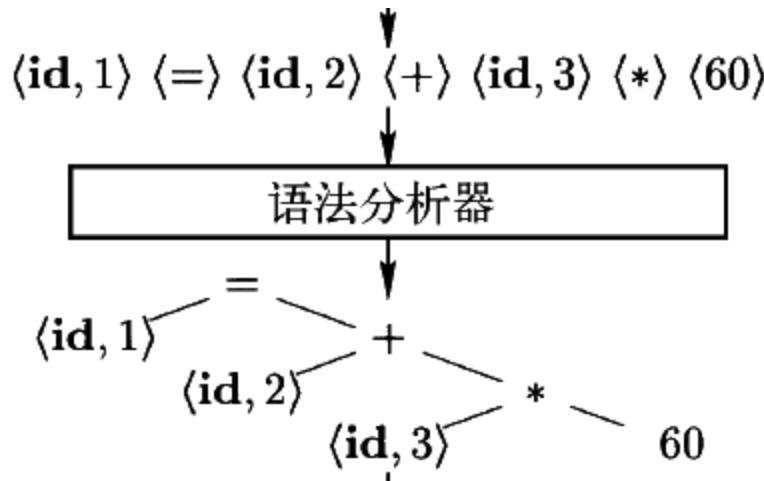
# 词法分析 (Lexical Analysis)

- 读入源程序的字符流，输出为词法单元 (Token)
  - Token kind: 表示词素种类
  - Attribute value: 表示词素附带属性信息
  - Source location: 表示词素在源代码中的位置
- 例子
  - position = initial + rate \* 60
  - <id, 1> <=,> <id, 2> <+,> <id, 3> <\*,> <number, 60>

符号表

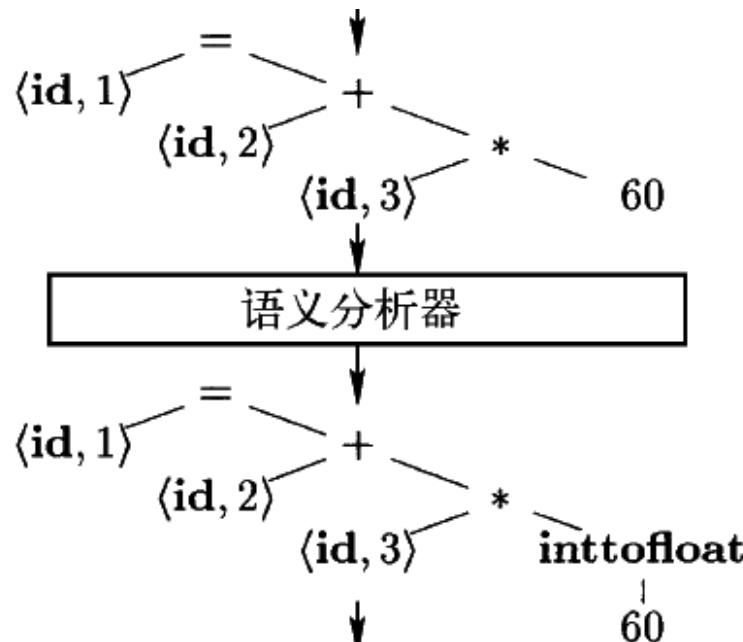
# 语法分析 (Syntax Analysis/Parsing)

- 根据各个词法单元的第一个分量来创建树型的中间表示形式，通常是语法树 (Syntax tree)
- 中间表示形式指出了词法单元流的语法结构



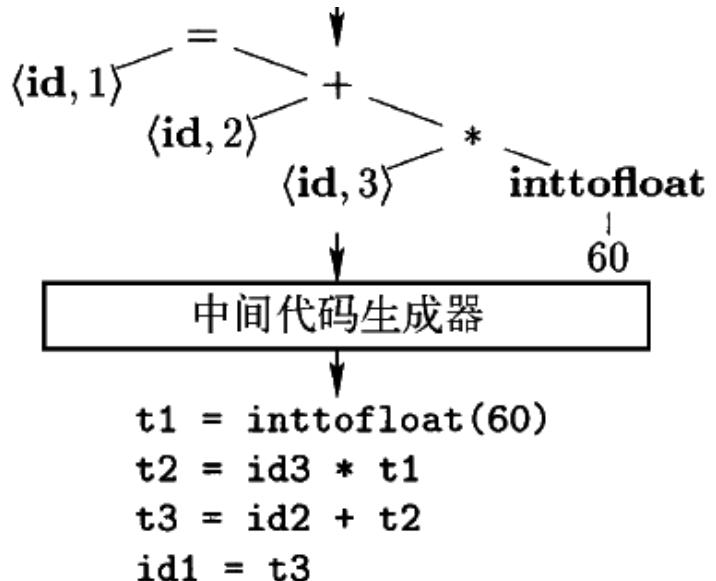
# 语义分析 (Semantic analysis)

- 使用语法树和符号表中的信息，检查源程序是否满足语言定义的语义约束
- 同时收集类型信息，用于代码生成、类型检查、类型转换



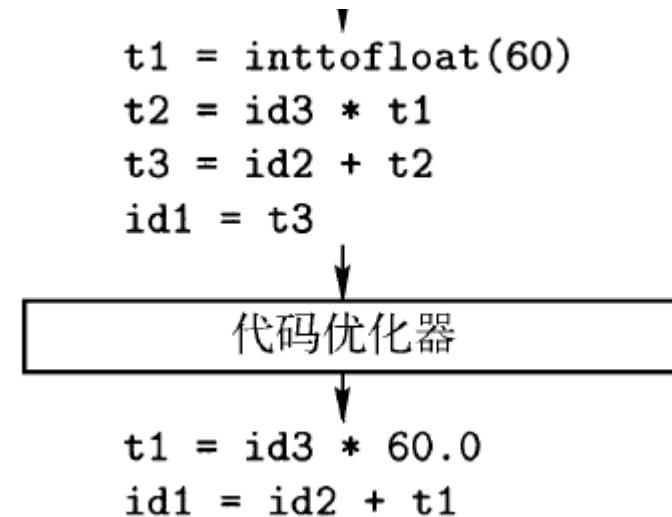
# 中间表示生成 (IR Generation)

- 根据语义分析输出，生成类机器语言的中间表示
- 三地址代码
  - 每个指令最多包含三个运算分量
  - $t1 = \text{inttofloat}(60); t2 = id3 * t1; t3 = id2 + t2; \dots$
  - 很容易生成机器语言指令



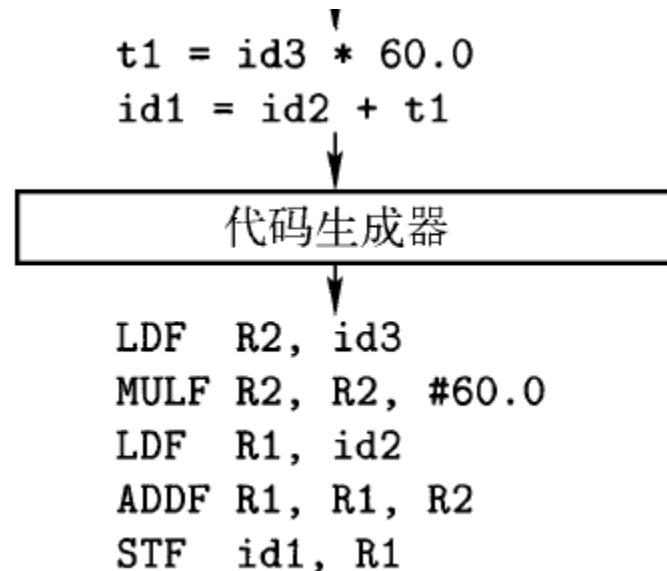
# 中间代码优化 (Optimization)

- 通过对中间代码的分析，改进中间代码的质量
  - 更快、更短、能耗更低



# 目标代码生成 (Code Generation)

- 把中间表示形式映射到目标语言
  - 指令选择
  - 寄存器的分配

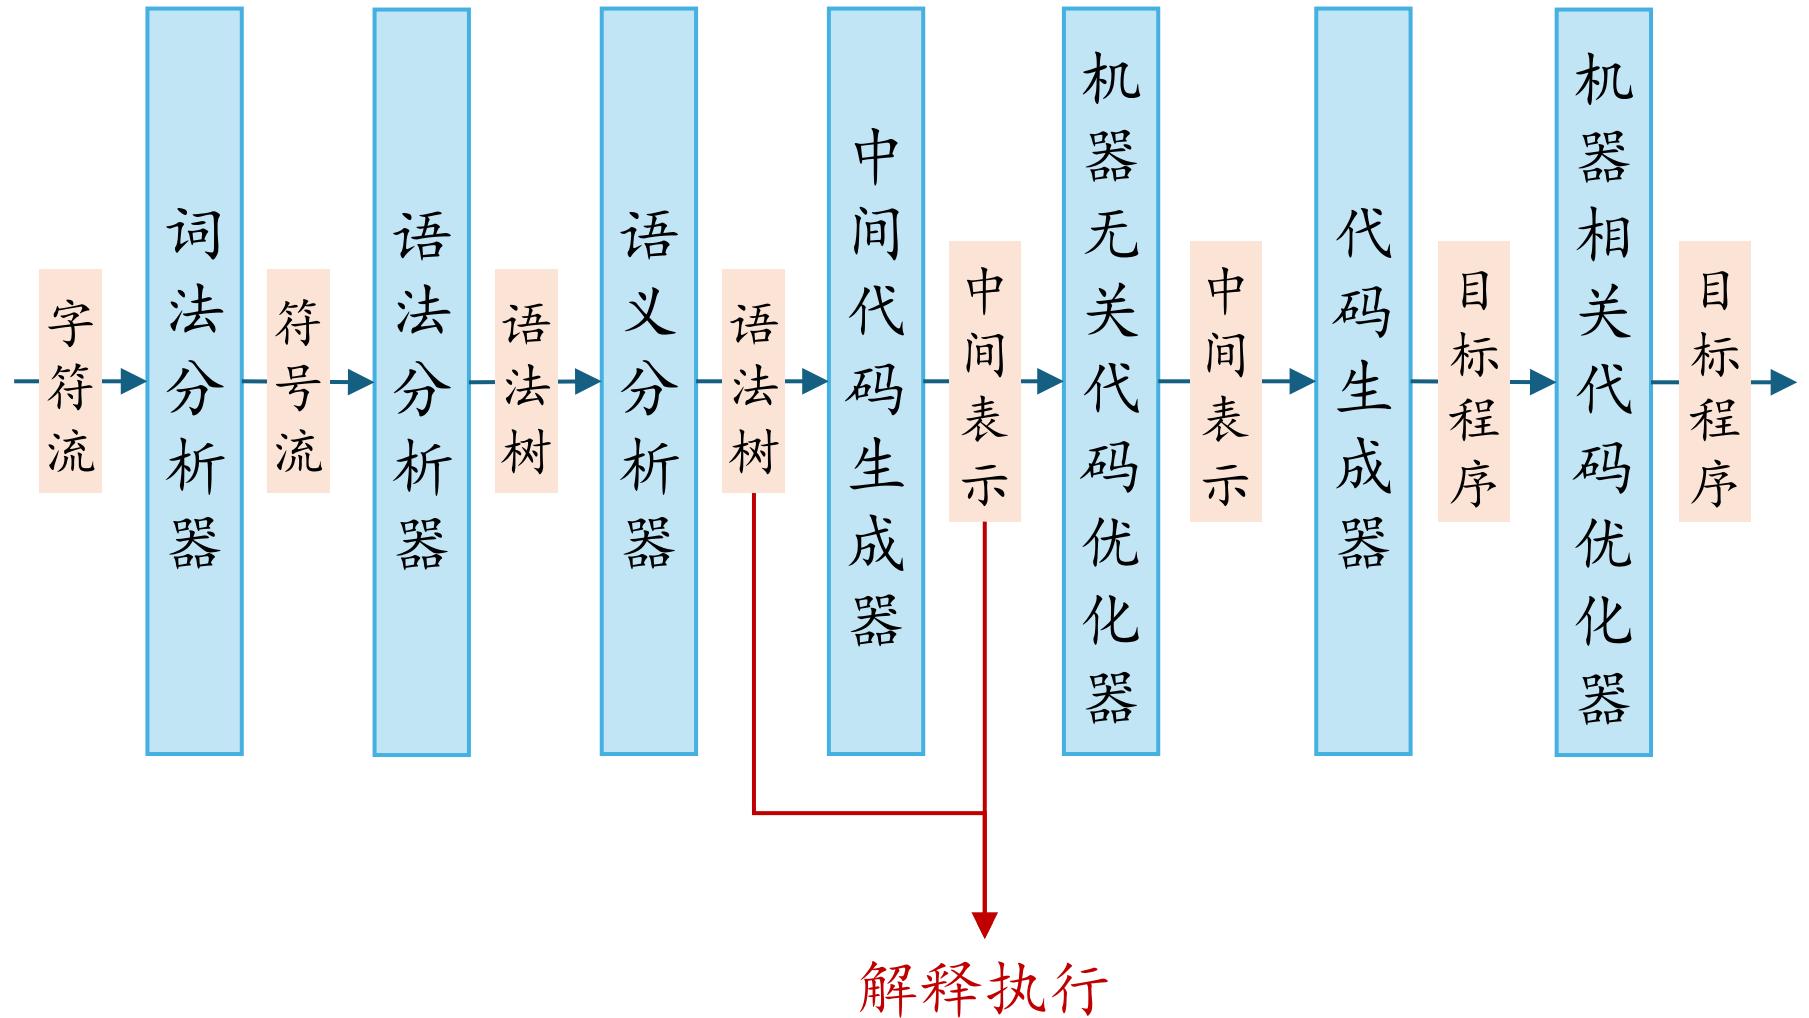


# 编译器与解释器

- 编译器
  - 读入以某种语言 (源语言) 编写的程序
  - **输出等价的用另一种语言** (目标语言) 编写的程序，通常目标程序是可执行的
  - C/C++、Rust、Go.....
- 解释器
  - 直接利用用户提供的输入，执行源程序中指定的操作
  - **不生成目标程序**，而是根据源程序的语义直接运行
  - Python、Ruby、JavaScript  .....

# 编译器与解释器

符号表



# 编译器与解释器

- 二者界限并非明确，许多语言结合了编译和解释
  - 同时包含编译与解释
    - 例如Java, Scala, Kotlin等JVM-based语言，先编译成字节码(bytecode)，然后解释执行
  - 解释执行的过程中加入编译 (Just-in-time, JIT)
    - 例如Java (Hotspot, GraalVM), JavaScript (V8)
  - 在你解释之前，我已经编译了 (Ahead-of-time, AOT)
    - 例如.....没错还是Java

# 编译器架构演化

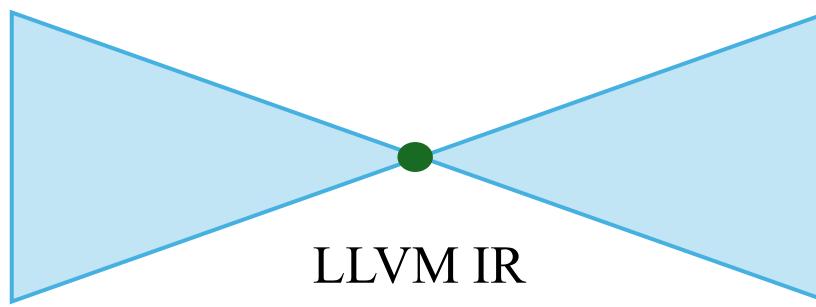
- 经典架构：直线型



- 现代架构：沙漏型

- 为多前端、多后端的需求提供一套公共接口（中间表示）
- 例如LLVM

- C/C++
- Rust
- Go
- .....



- X64
- ARM
- RISC-V
- .....

# 编译器架构演化

- 经典架构：批量处理型
  - 一个阶段全部运行完毕后再进入下一阶段
- 现代架构：请求驱动型
  - 既能编译完整程序，也能响应分散的IDE请求
  - 例如Roslyn

# 程序设计语言的发展历程

- 历程
  - 机器语言
  - 汇编语言 (宏命令)
  - 高级语言
    - 通用语言: Fortran、Cobol、Lisp、C、C++、...
    - 特定应用语言: SQL、Postscript、NOMAD、...
    - 基于逻辑和约束的语言: Prolog、OPS5、...
- 演化出不同的语言范式
  - 命令式语言
  - 函数式语言
  - 逻辑式语言

许多语言借鉴其它语言特性  
各种范式呈现融合趋势

# 编程语言和编译器之间的关系

- 程序设计语言的发展向编译器设计者提出新要求
  - 设计相应的算法和表示方法来翻译和支持新的语言特征，如多态、动态绑定、类、类属（模板）、…
- 通过降低高级语言的执行开销，推动这些高级语言的使用
- 编译器设计者还需要更好地利用新硬件的能力
  - RISC技术、多核技术、大规模并行技术

# 编译技术的应用

- 文本处理与程序翻译
  - 二进制翻译/硬件合成/数据查询解释器/编译后模拟
- 软件开发工具
  - 智能提示/代码补全/错误提示
- 软件质量工具
  - 程序分析/软件测试/内存管理