编译原理
1. 导引

谭添

南京大学计算机学院

2026 春季

课程概要

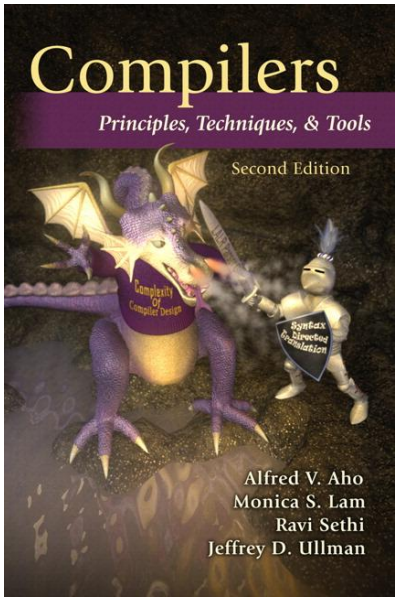

- 教材
  - 理论：《编译原理》(龙书)，第二版
  - 实验：《编译方法、技术与实践》
- 安排
  - 主讲教师：谭添
  - 网站：https://cs.nju.edu.cn/tiantan/courses/compiler-2026/index.html
  - 学时：16周 (学时64节)
  - 时段：周二3-4节、周四3-4节
  - 教室：仙II-301
  - 助教：钟哲瑀 (实验)、郑恒彬 (作业)

课程QQ群

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

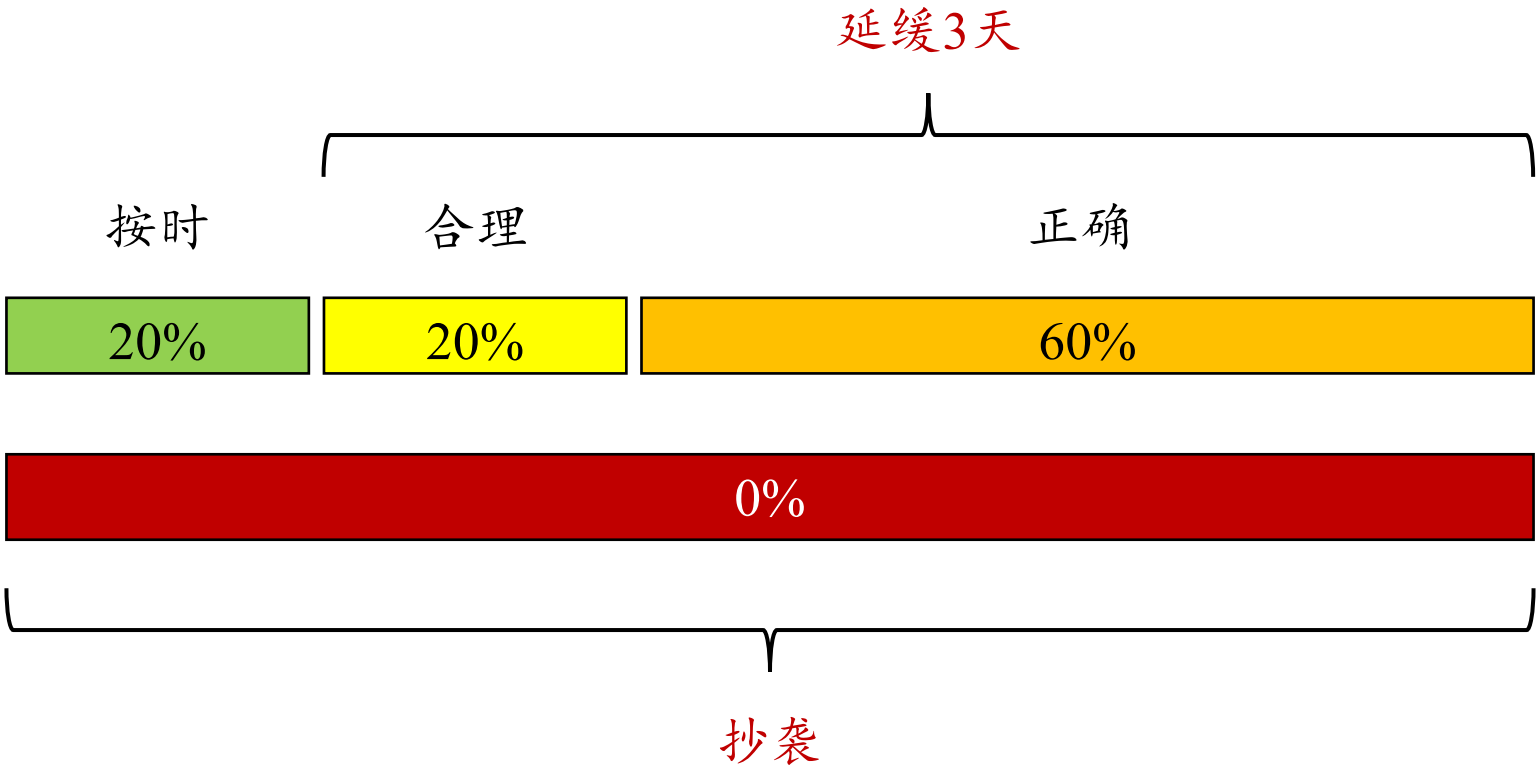

什么是编译器？

- 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

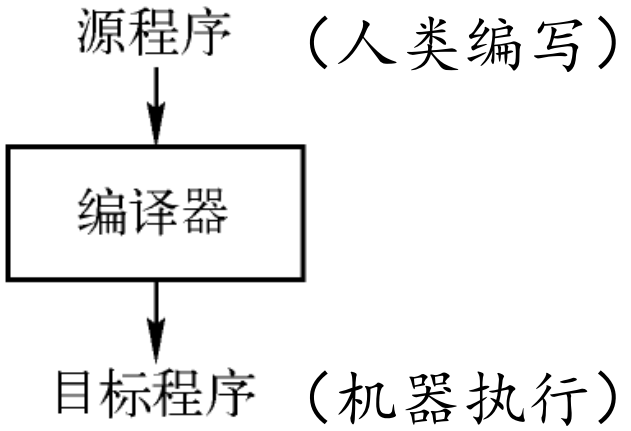

为什么学习编译原理？

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？

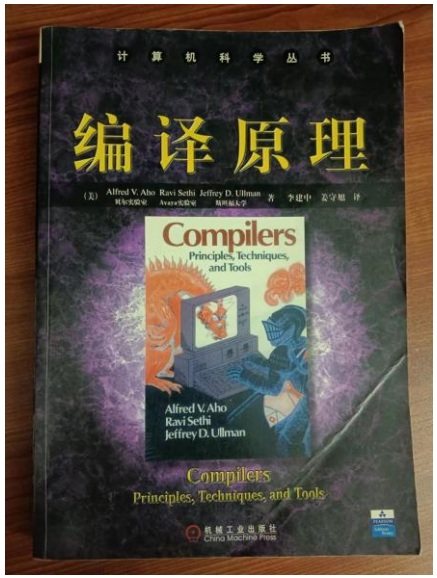

- 20年前，命运的齿轮开始转动……
- “根正苗红”

CORG
COmpiler Research Group@UNSW

- 研究方向：程序设计语言/程序分析
  - PLDI: ACM SIGPLAN Conference on **P**rogramming **L**anguage **D**esign and **I**mplementation
  - TOPLAS: ACM **T**ransactions **o**n **P**rogramming **L**anguages **a**nd **S**ystems
  - 程序分析平台Tai-e主要作者

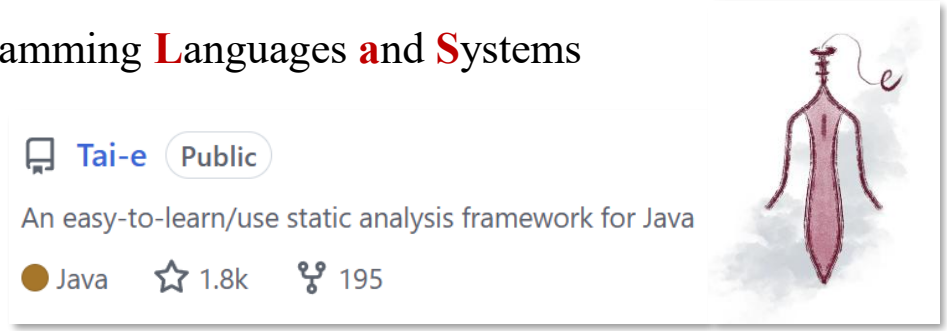

太阿 (Tai-e)

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**

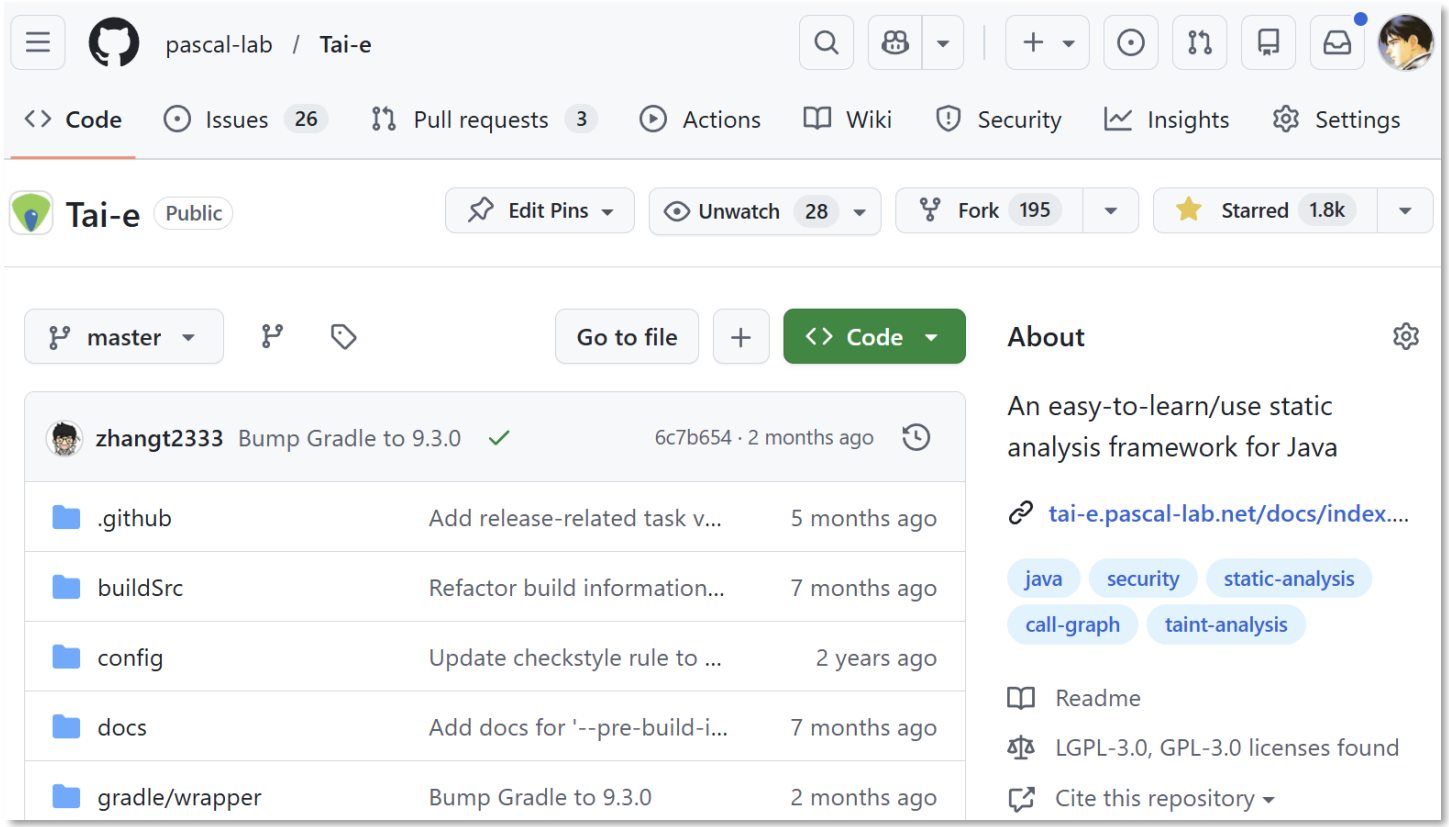

“太阿”的用户

- 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

Contributors

Contributions per week to master, excluding merge commits

Period: All | Contributions: Commits

Commits over time

Weekly from 2020年1月12日 to 2026年3月1日

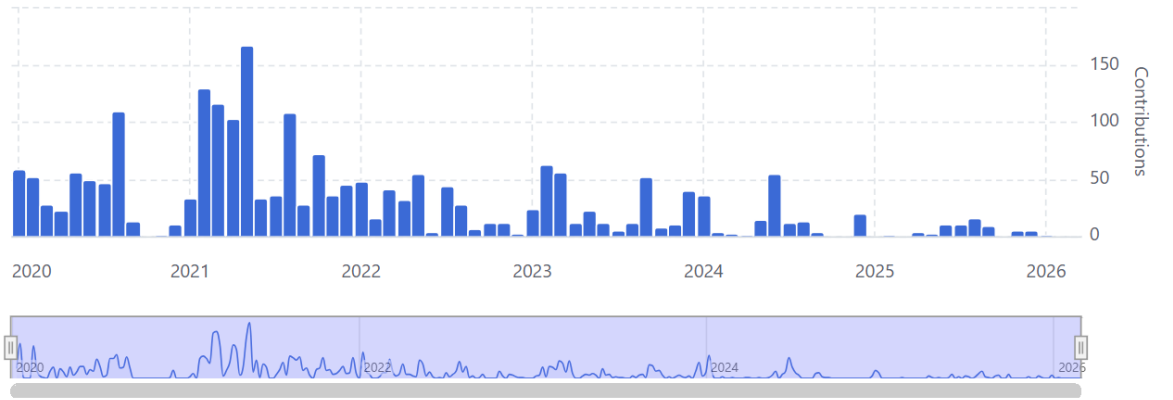

silverbullettt

Overview | Repositories 13

Tian Tan

silverbullettt

编写7万+行代码

silverbullettt #1

1,924 commits 343,608 ++ 265,937 --

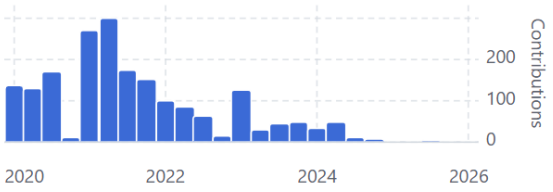

zhangt2333 #2

172 commits 17,744 ++ 6,422 --

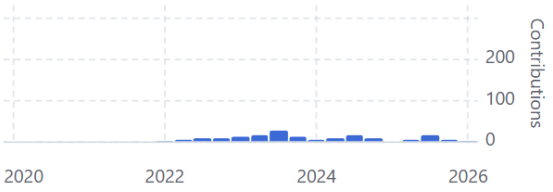

编译器的经典架构

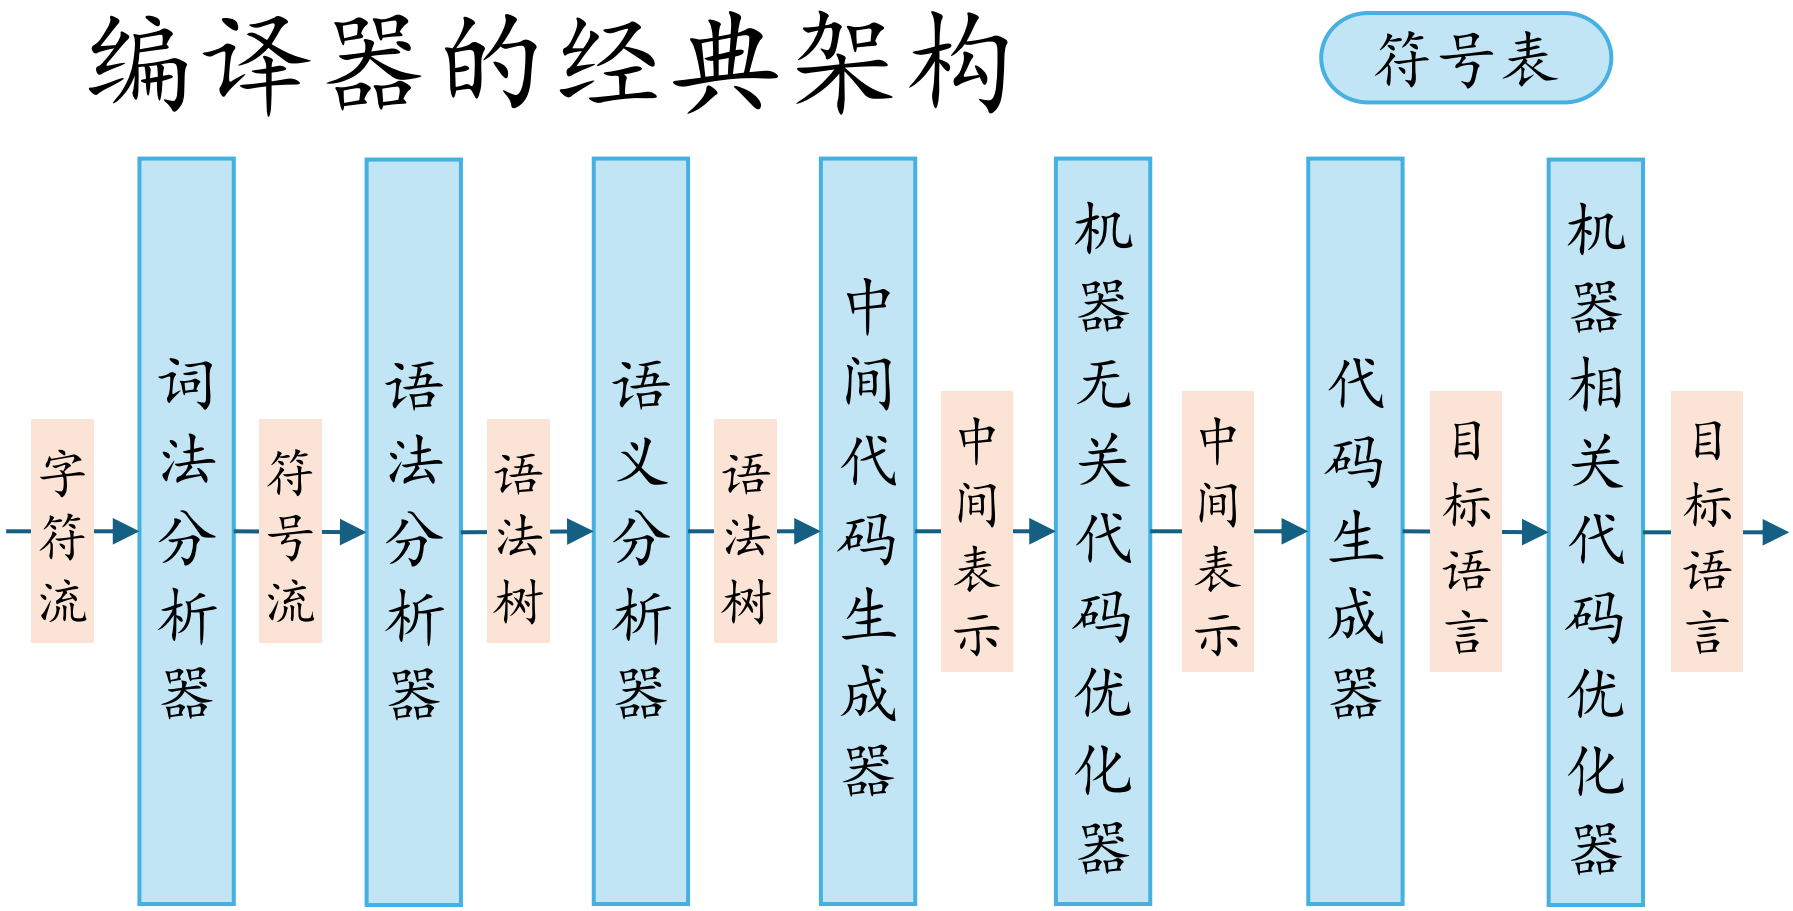

编译器是一条巨大的流水线

编译器的经典架构

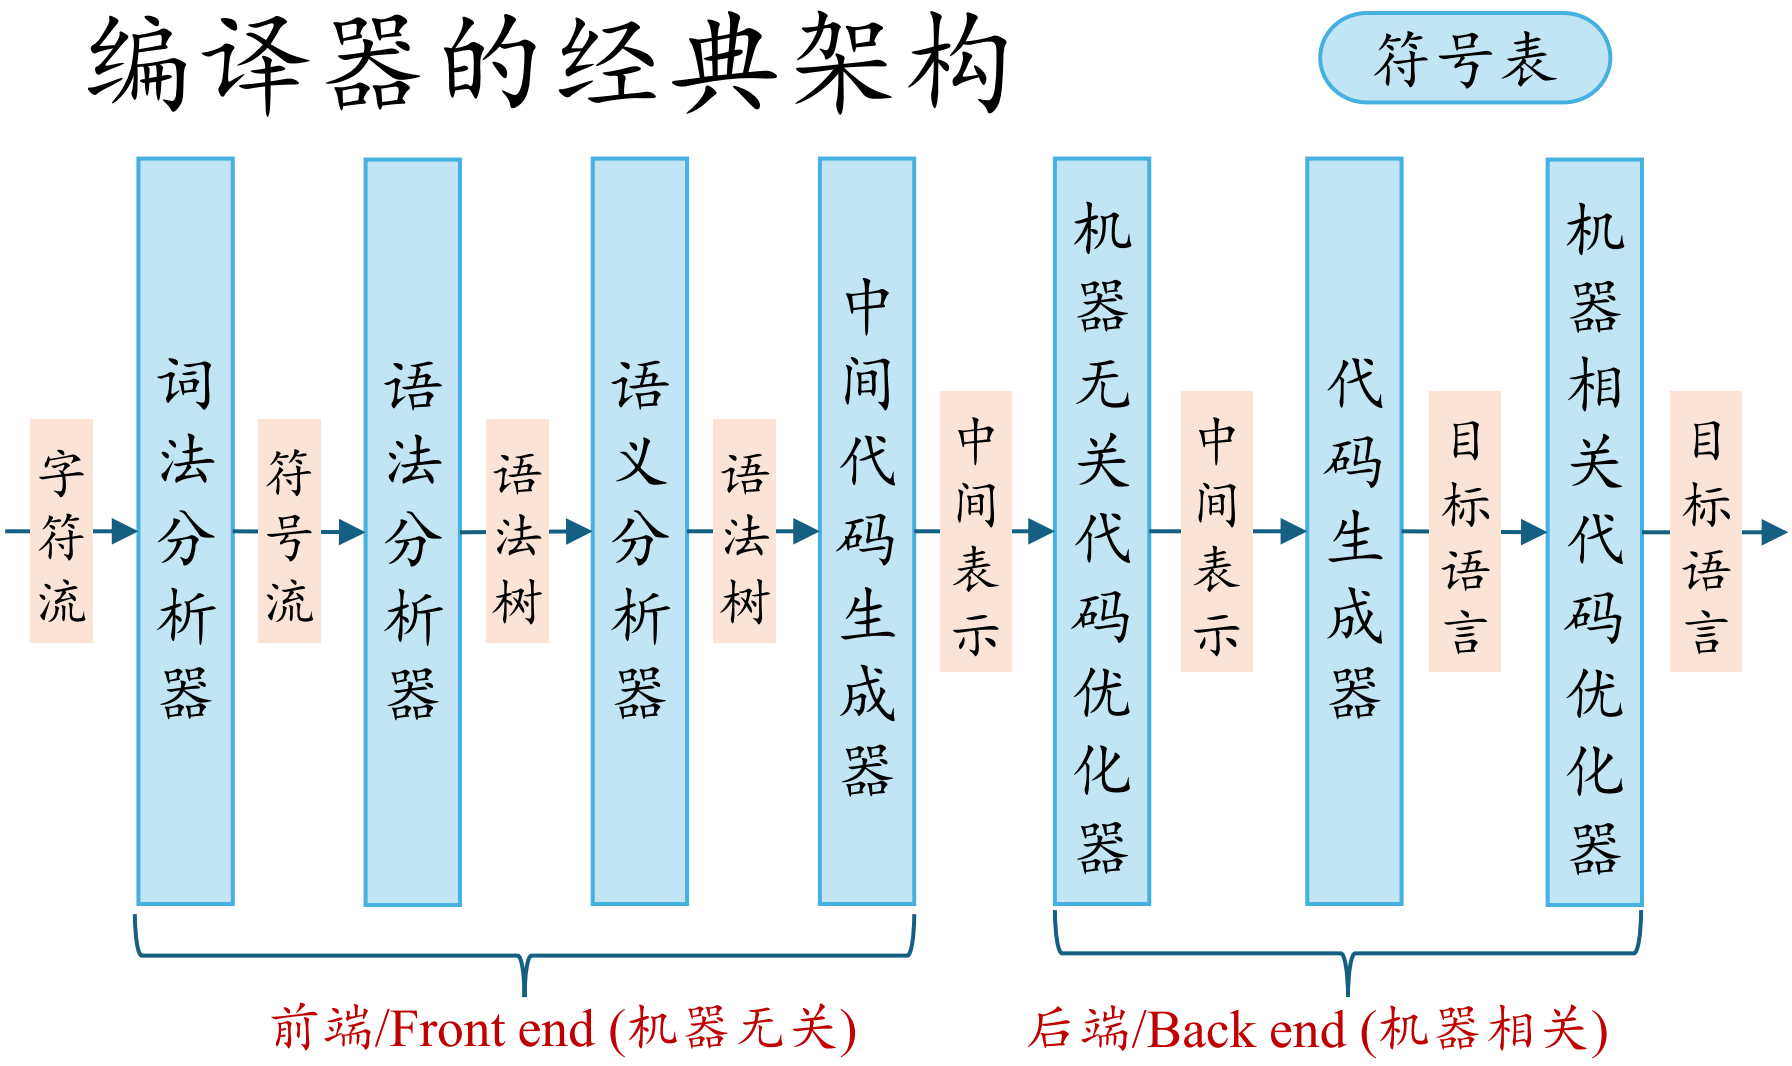

- 从源程序解析出以及相应的语法结构
- 使用这个结构创建源程序的中间表示
- 同时收集源程序信息，存入**符号表**

- 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)
2. 词法分析 (难-)
3. 语法分析 (难)
4. 语法制导的翻译技术 (中)
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)

安排较紧

安排较松

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

符号表

- 例子
  - position = initial + rate * 60
  - <id, 1> <=, > <id, 2> <+, > <id, 3> <*, > <number, 60>

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

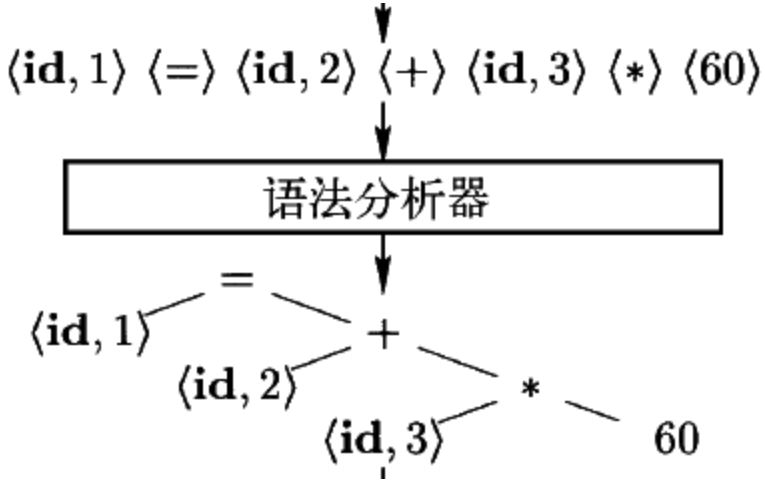

语义分析 (Semantic analysis)

- 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

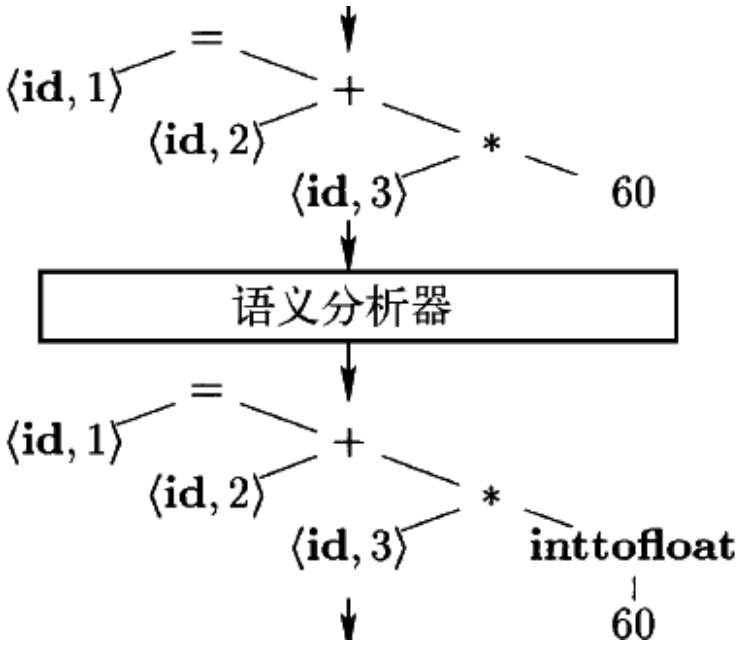

中间表示生成 (IR Generation)

- 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 = inttofloat(60); t2 = id3 * t1; t3 = id2 + t2; …
  - 很容易生成机器语言指令

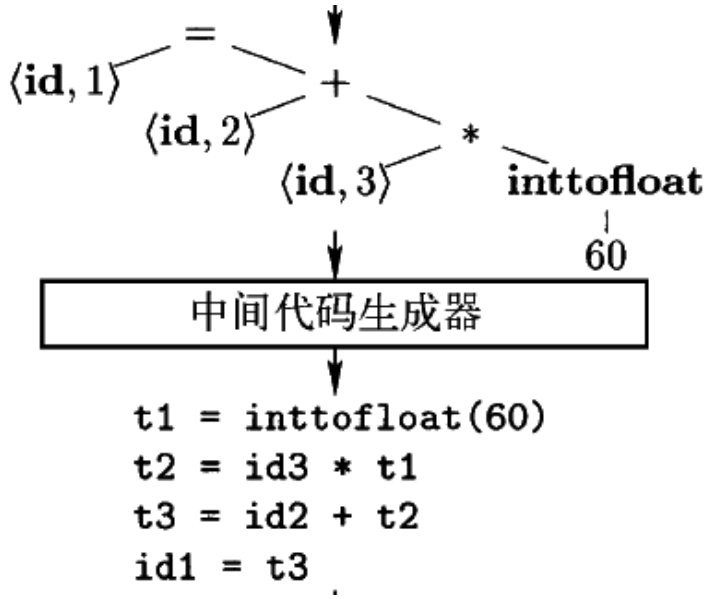

中间代码优化 (Optimization)

- 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

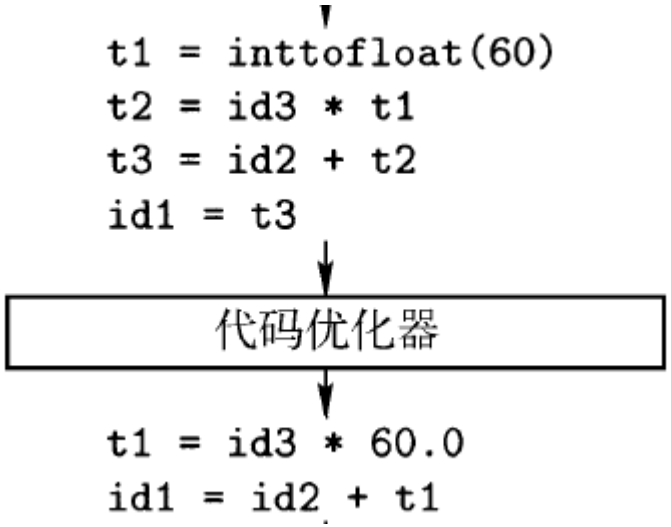

目标代码生成 (Code Generation)

- 把中间表示形式映射到目标语言
  - 指令选择
  - 寄存器的分配

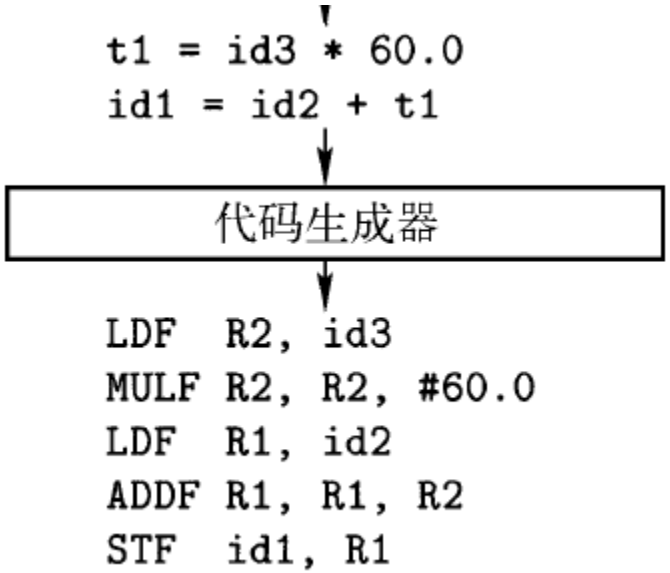

编译器与解释器

- 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

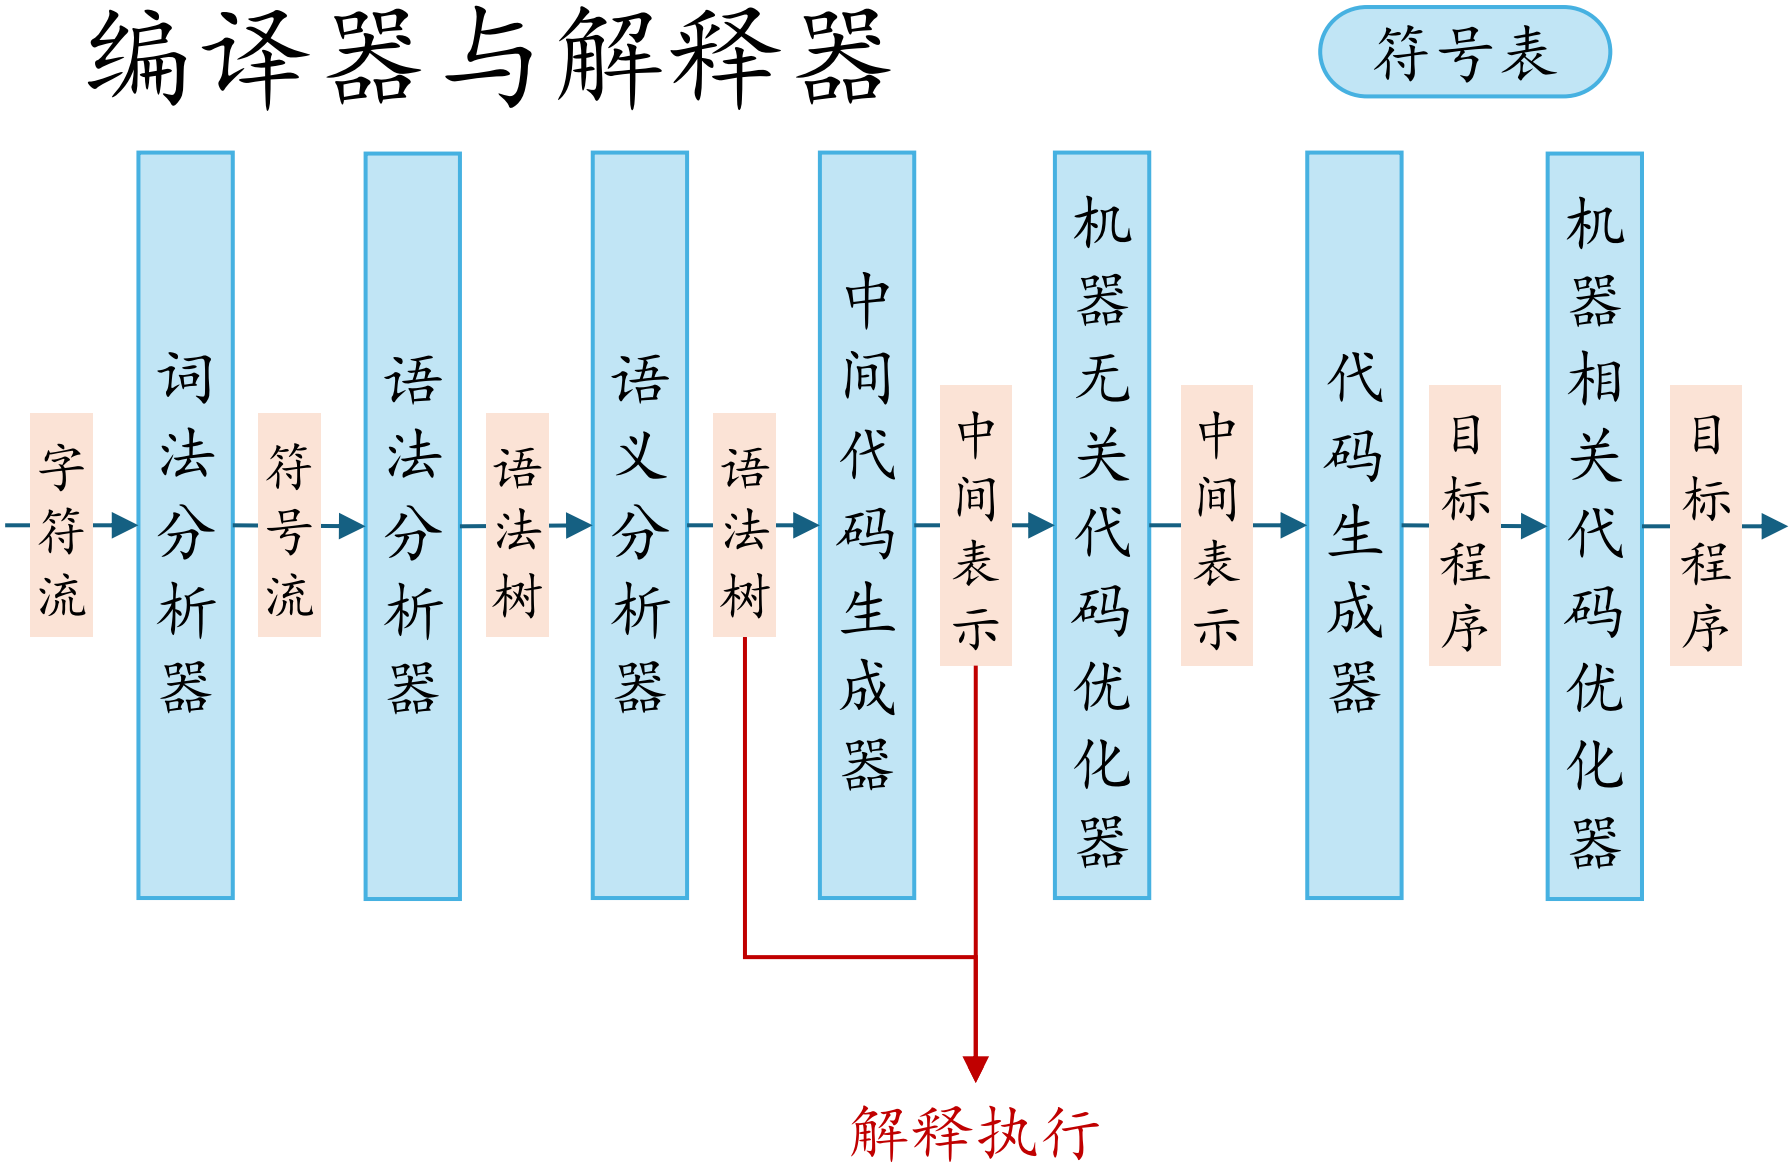
符号表
字符流
词法分析器
符号流
语法分析器
语法树
语义分析器
语法树
中间代码生成器
中间表示
机器无关代码优化器
中间表示
代码生成器
目标程序
机器相关代码优化器
目标程序
解释执行

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(Java 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
    - ……

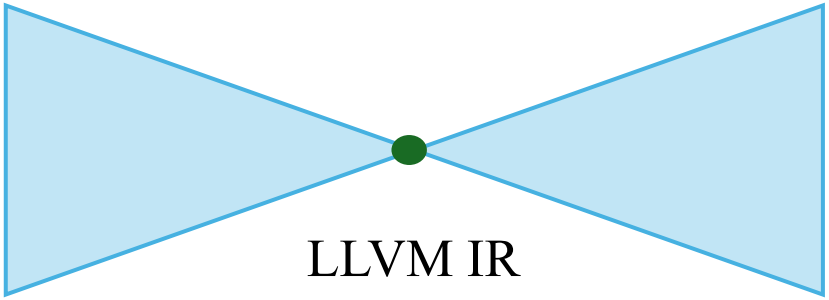

    - X64
    - ARM
    - RISC-V
    - ……

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

编译技术在AI中的应用

- 深度学习编译器
  - TVM/XLA/MLIR计算图优化、算子融合、硬件映射
- 领域特定语言（DSL）
  - AI框架中的DSL设计、词法/语法/语义分析
- 异构硬件适配
  - GPU/TPU/NPU映射、指令选择与寄存器分配

编译技术在编程中的应用

- 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
- LLM辅助编程
  - 为非确定性的AGI提供确定性的代码验证