WORKSHOP 研讨/分享/感悟

仓颉社区中的灵感碰撞　社区先行者的干货分享

仓颉代码转译工具code_tools

主讲人：杨海龙（博士在读）

- code_tools
- antlr4cj
- code generation
- based on AI

江南大学 JIANGNAN UNIVERSITY
人工智能与计算机学院 School of Artificial Intelligence and Computer Science

WORKSHOP

WORKSHOP 研讨/分享/感悟

目录

- 仓颉转译工具code_tools的介绍
- 基于code_tools的社区实践项目antlr4cj
- 基于人工智能的code_tools学术探索

WORKSHOP

仓颉转译工具code_tools的介绍

仓颉转译工具code_tools是通过源源转译的方式为仓颉生态自动生成代码的工具。
code_tools主要包括如下工具：

- j2cj：java语言代码转译成仓颉代码。
- c2cj：c语言代码转译成仓颉代码。
- g2cj：go语言代码转译成仓颉代码。（设计中）
- 注释：自动为仓颉编程语言添加注释
- 用例：自动为仓颉编程语言生成LLT和UT用例。

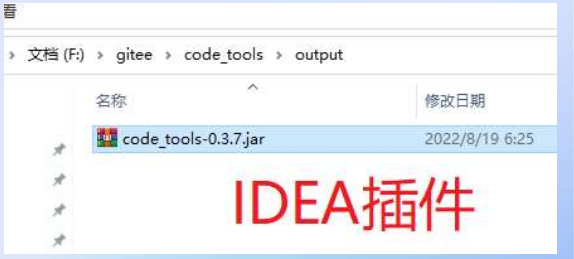

code_tools的意义将其他成熟工业语言（java/c/c++/go…）生态的优秀项目引入到仓颉生态，辅助仓颉生态构筑领域框架和领域库等基础设施。

code_tools相关项目的gitee地址：
https://gitee.com/HW-PLLab/code_tools
https://gitee.com/HW-PLLab/c2cj
https://gitee.com/HW-PLLab/j2cj

WORKSHOP

仓颉转译工具code_tools的j2cj

j2cj

Java to cangjie

代码骨架的转译 1

函数body里逻辑代码的转译 2

Java的base库映射到仓颉标准库：

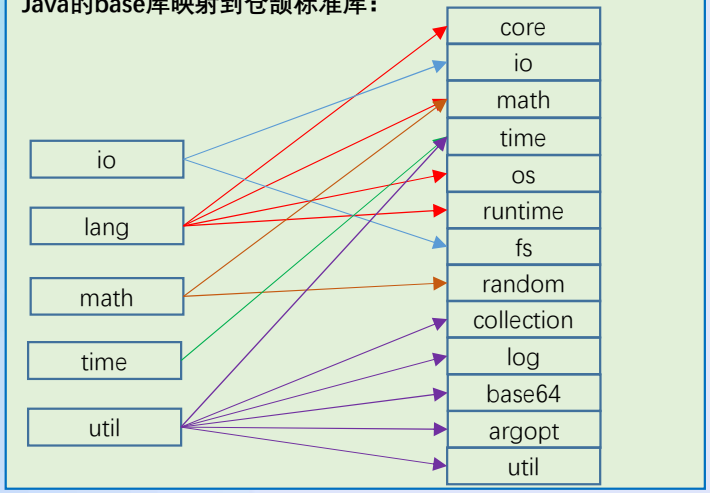

java语法映射到仓颉语法:变量声明和赋值、基本数据类型、操作符、流程控制、数组、函数、枚举、类、接口、lambda…

Java源码

仓颉源码

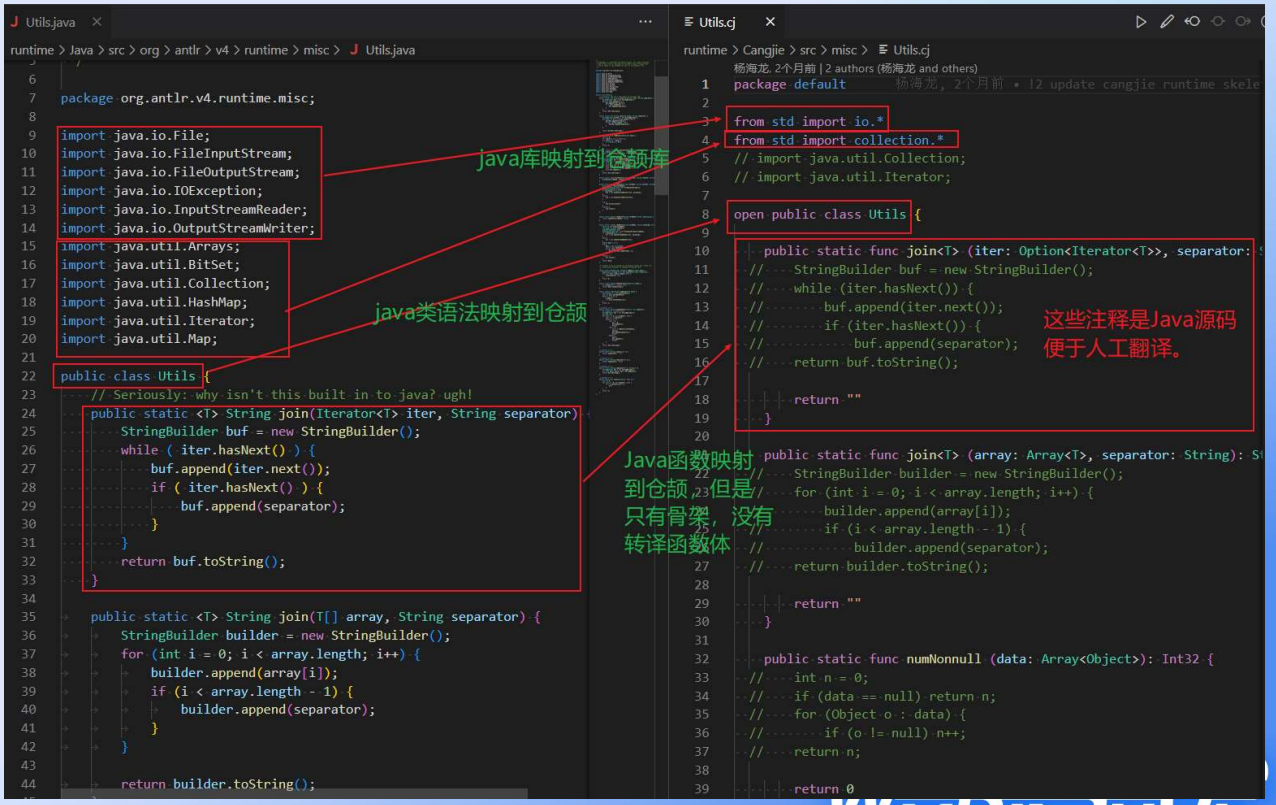

Java与仓颉语法比较：https://gitee.com/HW-PLLab/j2cj/blob/develop/doc/compare_Java9_CangJie.md#%E6%9D%A1%E4%BB%B6%E8%AF%AD%E5%8F%A5

Java与仓颉核心库比较：https://gitee.com/HW-PLLab/j2cj/tree/develop/doc/libs_compare

仓颉转译工具code_tools的c2cj

c2cj是生成对c语言库封装一个仓颉实现的native层。在C语言包括C++的生态语言库可以这个native层间接被仓颉调用。

C语言转仓颉 https://gitee.com/HW-PLLab/c2cj
https://gitee.com/HW-PLLab/cangjie-example/tree/master/NativeInvoke

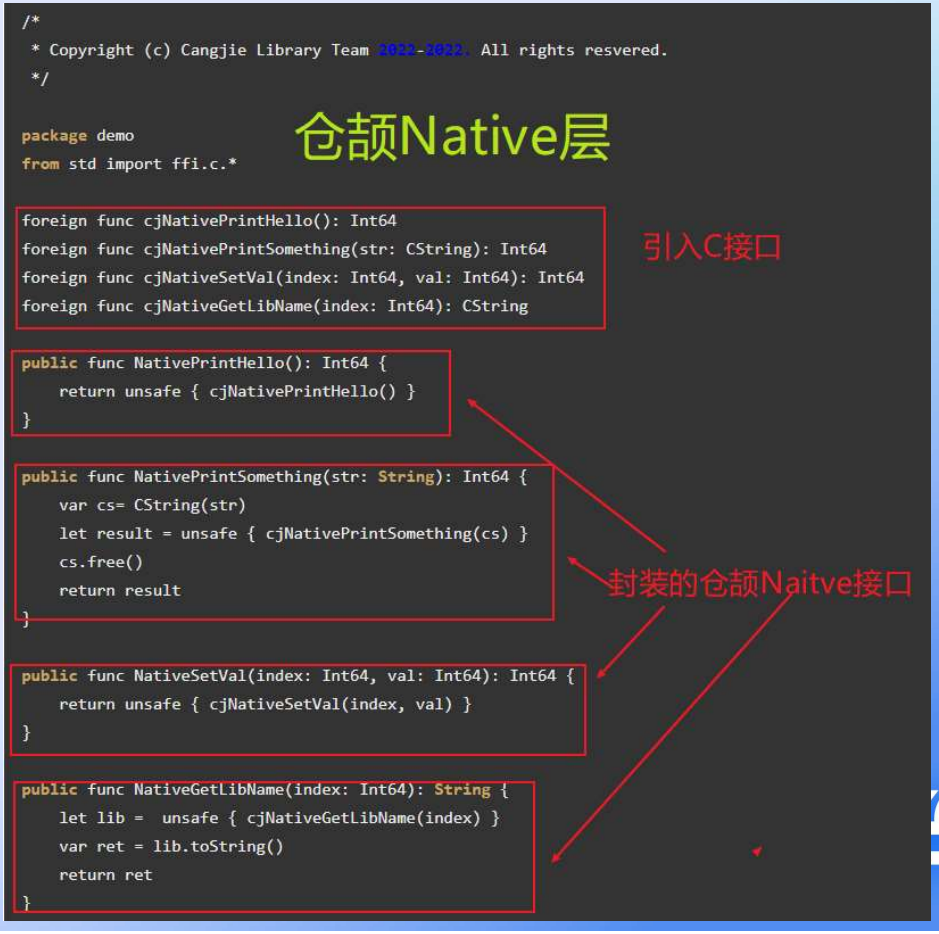

仓颉转译工具code_tools的注释和用例自动生成

code_tools提供针对仓颉源码的注释和用例的自动生成。
注释主要是包括文件头、类注释、函数注释。
Code_tools可以一键生成仓颉源码的LLT和UT用例。

```
/*
 * The Function is compare
 *
 * @param aval of Array<Byte>
 * @param fromIndex of Int64
 * @param bval of Array<Byte>
 *
 * @return Type of Bool
 */
func compare(aval: Array<Byte>, fromIndex: Int64, bval: Array<Byte>): Bool{
    let asize: Int64 = aval.size()
    let bsize: Int64 = bval.size()
    if(asize - fromIndex < bsize) {
        return false
    }
    for(i in 0..asize) {
        if(aval[i + fromIndex] != bval[i]) {
            return false
        }
```

自动生成函数注释

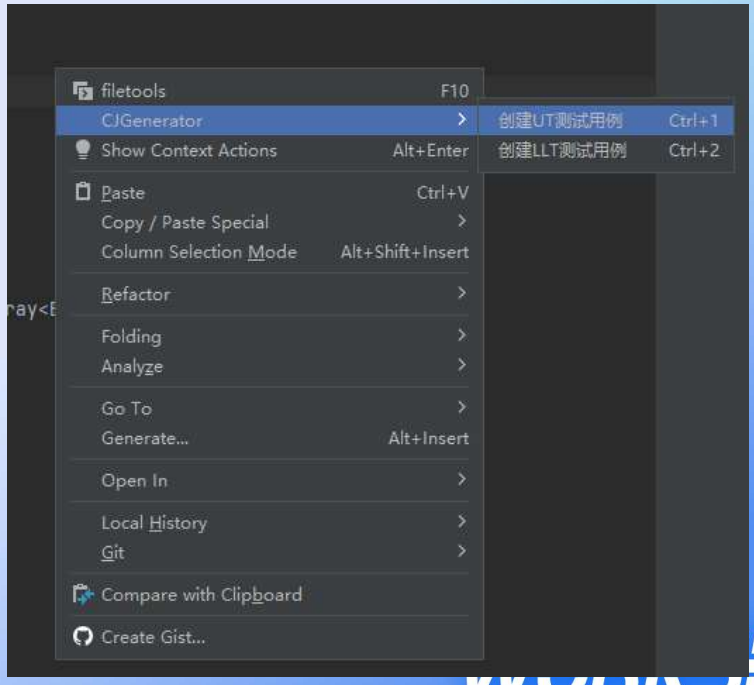

基于code_tools的社区实践项目antlr4cj

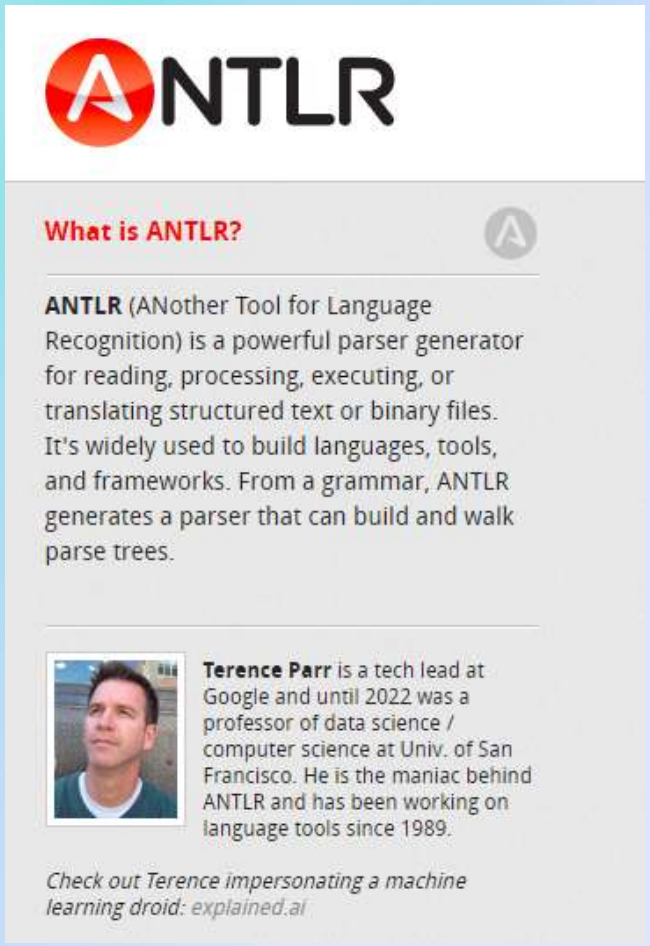

ANTLR（全名：ANother Tool for Language Recognition）是基于LL(*)算法实现的语法解析器生成器（parser generator），用Java语言编写，使用自上而下（top-down）的递归下降LL剖析器方法。由旧金山大学的Terence Parr博士等人于1989年开始发展。

ANTLR有什么用？

- **定制特定领域语言(DSL)**。类似hibernate中的HQL，用DSL来定义要执行操作的高层语法，这种语法接近人可理解的语言，由DSL到计算机语言的翻译则通过ANTLR来做，可在ANTLR的结构语言中定义DSL命令具体要执行何种操作；
- **文本解析**。可利用ANTLR解析JSON，HTML，XML，EDIFACT，或自定义的报文格式。解析出来的信息需要做什么处理也可以在结构文件中定义；
- **数学计算**。加减乘除，线性方程，几何运算，微积分等等；
- **IDE语法检查。**
- **……**

基于code_tools的社区实践项目antlr4cj

ANTLR支持的语言包括C#、c++、Dart、go、java、js、python、swift。Cangjie正在适配中。
antlr4cj项目是code_tools在仓颉社区第一个也是最大的实践项目，一共生成了174个.cj文件，合计1万6千多行代码。
antlr4cj项目中的仓颉代码大部分是code_tools生成的代码，需要大量人力来翻译code_tools暂时没法生成的代码。

目前antlr研究小组主要是我和汪鹏程在主导antlr4cj项目，有兴趣的同学可以加入我们。

相关项目的gitee地址：
https://gitee.com/HW-PLLab/antlr4cj

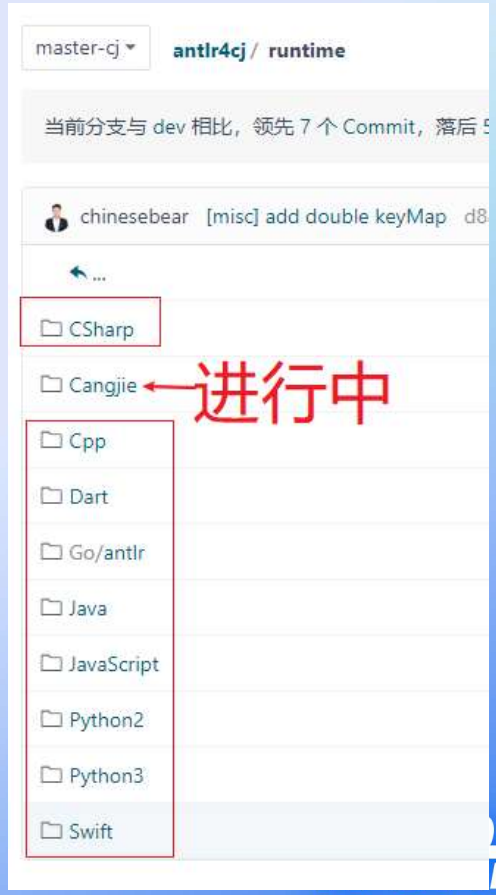

基于人工智能的code_tools学术探索

code_tools的核心任务是将其他语言的程序转译到仓颉编程语言。 → 也就是输入为其他语言的代码生成问题 → **代码生成模型**的设计问题

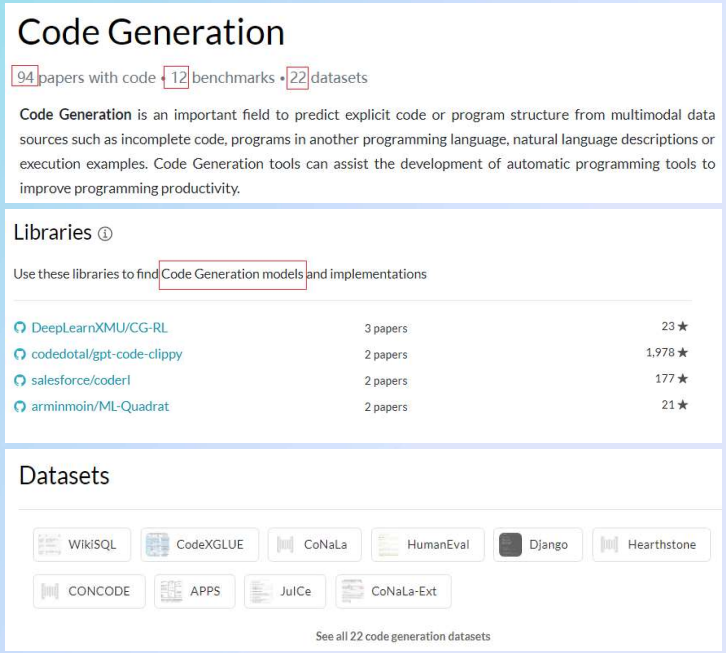

idea1：通过社区代码设计仓颉语言的数据集（dataset），经过训练后，允许多模态（multi-modal）数据作为输入（而不是仅是其他高级语言代码），生成仓颉代码。

idea2：其他语言的编程知识（knowledge）迁移到仓颉代码生成模型中，特别是领域编程知识，这样让仓颉代码生成模型也有了其他领域代码生成能力。

idea3：如何基于对抗学习，将仓颉编译器作为判决器，加上仓颉代码度量，来提升生成仓颉代码的质量。

WORKSHOP

code_tools的规划

基于IDEA插件版本会继续向前演进

- j2cj尝试函数体的转译以提高转译率；
- c2cj现存问题的解决以达到合入主干的要求；
- g2cj的设计方案完成以及实现；

基于人工智能版本的探索

- 尝试基于transformer以及ASN（抽象语法网络）设计仓颉语言的代码生成模型。

WORKSHOP 研讨/分享/感悟

仓颉社区中的灵感碰撞　社区先行者的干货分享

Thanks!

杨海龙(Eric)

江苏 无锡

扫一扫上面的二维码图案，加我为朋友。

邮箱：yanghailong@stu.jiangnan.edu.cn

江南大学 JIANGNAN UNIVERSITY

人工智能与计算机学院 School of Artificial Intelligence and Computer Science

WORKSHOP

仓颉生态之代码觉醒

下次workshop讲吧

WORKSHOP