设计文档

小队成员：

031602121 乐忠豪

031602102 蔡子阳

1. 背景

小樱是一名大三的学生，一直痴迷于吃鸡类游戏，某日听闻同宿舍的小狼刚和导师去参加了 CVPR 会议，内心羡慕不已，便下定决心痛改前非、努力钻研，希望能在毕业前完成一篇站在时代前沿的优秀论文。但令人苦恼的是，他不知道近几年顶会的热门领域和研究方向，根据论文 list 去一篇一篇查找总结效率又着实太低，于是求助于“软工实践互助爱心组织”，希望我们能帮助他设计一个平台解决现阶段的需求。

2.设计目标

1.1 需求分析

一、用户给定一个论文列表

1.要求实现通过论文列表爬取论文的题目、摘要以及原文链接。

2.可实现对论文列表的增删改操作（今年、近两年、近三年）。

二、对爬取的信息进行结构化处理，分析 top10 个热门领域或热门研究方向

1. 可对论文属性（oral、spotlight、poster）进行筛选及分析。
2. 形成如热词图谱之类直观的查看方式。

三、可进行论文检索，当用户输入论文编号、题目、作者等基本信息，分析返回相关的 paper、source code、homepage 等信息。

四、可对多年间、不同顶会的热词呈现热度走势对比（这里将范畴限定在计算机视觉的三大顶会 CVPR、ICCV、ECCV 内）。

五、可进行数据统计，例如每个国家录用文章的分析、每个学校录用文章的分析、哪个学校哪方面的研究方向比较强等。

用户附加需求：

在不改变设计理念、符合用户使用习惯的前提下，在上述需求的基础上进行扩充升级，或发挥想象能力为原型添加自己的 idea。

1.2 性能指标

从需求来看，最主要的时间耗费在爬去论文信息以及存储论文结构体上，用户的目标体量在 9000 篇论文左右（3 年的论文*3 大顶会*每大顶会 1000 篇）。论文题目不超过 200 个

字符，总体量为 200W 字符。

1. 完成全部论文标题遍历及存储需 5s 的响应时间。
2. （爬取时间未知）
3. 检索论文题目及相应信息、形成热词图谱的时间各在 1s 内。
4. 添加功能可以通过论文编号、论文关键词查找相关论文。

3.模块设计

3.1 模块流程图及说明

设计实现流程如下：

通过用户给定的论文列表从网页上爬去论文信息（论文编号、作者、原文链接等）-> 使用 C++数据结构以及 map<string,class>容器存储爬去到的论文信息-> 通过 map 容器实现数据检索，热词统计（添加通过文章关键词检索相关文章的功能）以及数据分析-> 将统计结果以图像的形式展现出来

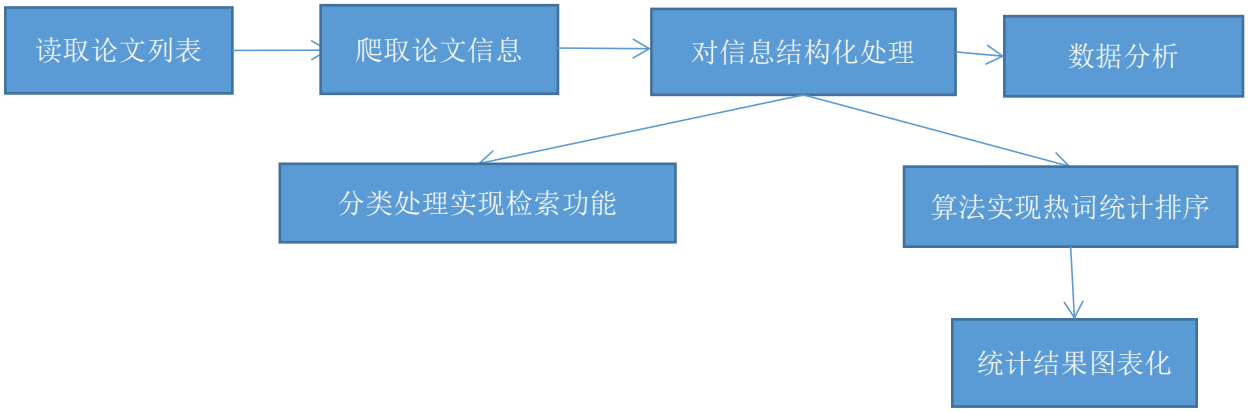

3.2 数据结构说明

论文类：

{

属性：

论文 ID；论文题目；论文摘要；论文年份；论文作者；论文属性（oral、spotlight、poster）；关键词（用作词频统计）；type（表明属于哪一个会议）

成员函数：

获取类属性的各个值；

}

3.3 算法描述

首先使用 python 编写爬虫内嵌至 C++中，将得到的数据存储于文件中，对文件遍历存储于 map 容器中（基于 key,value 值存储功能），通过 map 容器的红黑二叉树进行数据查询

访问，作出词频统计分析，以及检索筛选算法。

3.4 与其它模块的接口

1.爬虫接口
2.类接口

3.5 异常处理

1. 读取论文列表失败。
2. 爬取论文信息失败。
3. 读入爬取数据失败。
4. 论文列表中无用户输入的论文标题。

3.6 测试考虑

单元测试：爬虫测试，类读取信息测试，词频统计排序测试
集成测试：测试能否得到预期需求的效果
测试工具：Visual Studio 2017

4.系统集成包装

将系统包装成一个拥有界面的 windows 窗体软件

5.设计评审意见

No.	问题描述	提出人	处理方式/说明	状态
				Open
				Closed