

第二届“全国大学生大数据技能竞赛”选拔赛：大数据集群搭建+爬取

序号	名称	分值占比	考核内容	考核技能	建议学习内容
1	基础环境	20%	完成任务书要求的 Linux 基本环境配置。主要考试选手对于 Linux 操作系统的使用及配置方法。	<ol style="list-style-type: none"> 1. 配置 hostname; 2. 安装 net-tools; 3. 配置 firewall; 4. 配置 ntp 服务; 5. 配置 java 环境; 6. 配置 ssh 登陆; 	Linux 基础命令(文本操作/目录操作/等); centos7 防火墙命令; JDK 安装; 环境变量配置; 时间同步/私钥公钥;
2	Hadoop 集群环境搭建	50%	按照任务书要求完成集群搭建,按照正常的大数据集群搭建顺序构建环境,涉及到 Hadoop 的配置情况、配置文件的存在意义以及集群开启方式;	<ol style="list-style-type: none"> 1. 安装 zookeeper; 2. 安装 Hadoop; 3. 安装 Hbase; 4. 安装 MySQL; 5. 安装 Hive; 	大数据搭建顺序; 文件的解压安装; vim 操作/文件配置修改; 大数据服务启动顺序; 根据日志查找报错原因;
3	数据爬取	20%	完成相关爬虫环境搭建,按照要求进行对应数据的获取,并保存至指定位置。	<ol style="list-style-type: none"> 1. 编写爬虫代码; 2. 获取数据保存至 	Python3.6 的使用; Python 库的使用;

				指定位置;	熟悉网页结构; 能够独立完成代码编写;
4	Spark 环境搭建	10%	完成任书要求的 Spark 环境安装配置。主要考察选手对于 Spark 组件工具的使用。	1. 安装 Scala 环境; 2. 配置 Spark 组件; 3. 启动 Spark 环境;	软件的安装与配置; 环境变量配置; 根据要求进行 spark 内存等其他配置; 开启服务 (了解对应进程);

其中 maser 主机提供 Python3.6 环境。

支持的库为:

库名	版本号
beautifulsoup4	4.8.0
bs4	0.0.1
certifi	2019.6.16
chardet	3.0.4
html5lib	1.0.1
idna	2.8
lxml	4.4.1
pip	18.1
requests	2.22.0
setuptools	40.6.2
six	1.12.0
soupsieve	1.9.3

urllib3	1.25.3
webencodings	0.5.1

特别提醒：要学会使用日志手段纠错，人为眼检基本找不出错误所在。