

小规模实验室 自动化和计算系统的建设

罗嘉宏

中国科学技术大学化学物理系

luojh@mail.ustc.edu.cn

目录

- 概述——**为什么需要？**

- **系统构成**

- 计算服务器
- 存储系统
- 内部和外部网络
- 与实验硬件连接
- 电源供应、环境监测
- 维护设施

- **业务**


- 计算任务
- 公共服务
- 系统管理

- **展望**


1. 概述

- **自动化高效率**的灵活**计算、数据处理**需求

- 例如，对大量 (10^6 ?) 图像和谱学数据进行特征提取



Peak #	Center	Height	Width
1	2900	1.0	100
2	1450	0.3	20
...			



- 硬件设施
- 配套软件 (计算、管理)
- 业务逻辑

2. 系统构成

- 计算

- 小计算量的任务占主体，大计算量的上超算
- 精细高效地分配好有限的计算资源（精确到 CPU 时间）
- 隔离、一致的运行环境
- 自主设计程序的源代码管理、CI/CD

- 存储

- 大量实验数据从不同的设备上采集
- 远、近，快、慢均有
- 可靠、中心存储，支持自动化程序的数据采集
- 分层级、速度组织存储器

2. 系统构成

- 网络

- 安全可靠的**内部高速互联** ($\geq 1\text{Gbps}$)
- 为特定的（有需求的）线路提高带宽
- 实验中心之间有网络访问


- **计算系统**

- 设备环境监测
- 计算节点在线检查
- 视频监控
- 电力供应
- 系统维护

2. 系统构成

• 计算服务器


- 目前主要是 CPU 服务器
- 均使用 **Debian 12**
- 解决**中等核心数**、**高计算速度**的需求
- **避免个人PC可能导致的问题**（电力供应、硬件管理等）
- 繁重计算任务**不干扰其他办公工作**



2. 系统构成

- 存储系统


- 按速度分层



2. 系统构成

• 存储系统


- 本地&远程（**中心存储服务器**）访问



2. 系统构成

• 网络


- 基础：**1GbE** 校园网
- 基础：**1GbE** 内部互联
- 高速：**10GbE** 内部互联，**大数据量通道 RoCE?** 专用 **RDMA 线路?**



2. 系统构成

• 实验硬件

- 有完善的网络设施
- 设备基本通过**有线网络**连接
- 部分为**特定接口**（RS232等），加网关
- 实验硬件使用 **XNet 协议**（2024年开源软件论坛的报告）




2. 系统构成

• 电源供应

- **220V AC**（大部分服务器/网络设备）：**UPS 电源系统**，确保电网掉电时能正常维持工作
- **直流系统**（板卡供电）：双路自动切换的低压电源，可以用**冗余电源笼**




in



2. 系统构成

• 环境监测

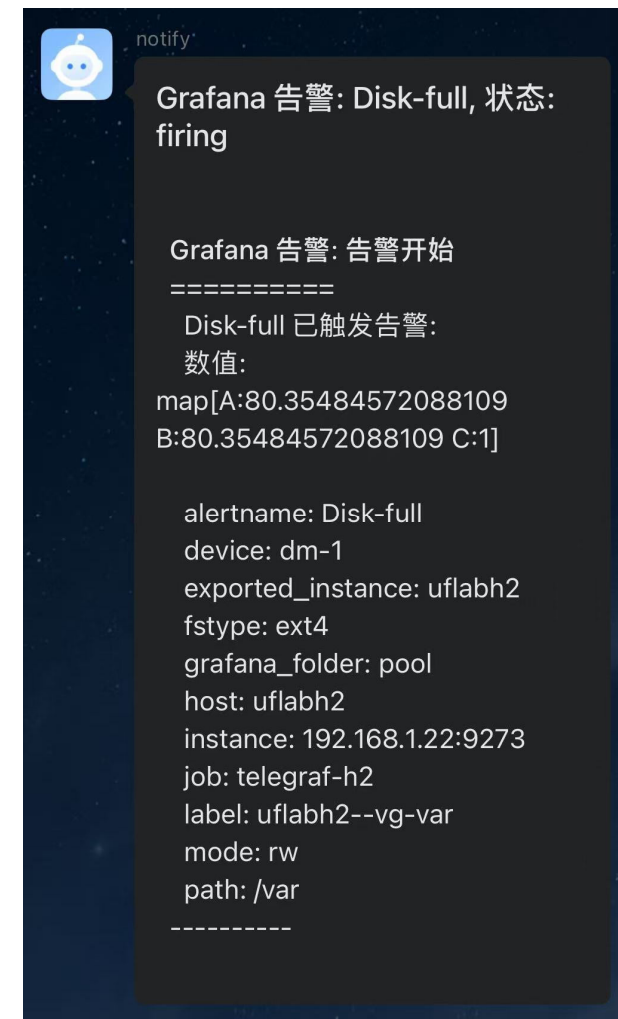
- 自动化/无人值守系统必备！
- 可以及早从监控数据中发现问题。
例如，曾遇到空调故障，就是通过环境检测报警获知。
- （多点）温度，湿度，VOC 等等
- 自行设计的检测设备，同样使用 XNet



2. 系统构成

• 维护


- **关键任务上的日志&遥测**：任务产生的数据和运行状态都需要记录
- **数据收集**：XNet(硬件) 或 Telegraf(服务器) – Prometheus – Grafana
- **告警**：Grafana Alerting – 各类平台（邮件，企业微信等）
- **备用或测试用的硬件**：硬盘，交换机，内存，温度探头，网线，等等



3. 业务


- 计算任务**统一化，流程规范** (scripting)
- 如何做到？
 - 借鉴 CI/CD，以脚本的方式**定义一个任务的过程**
 - 通过 Docker 容器或者 VM，**规范任务的运行环境**，确保可复现
 - 步骤间隔离，但有中心 NFS 进行**数据的集中存放和共享**，实现步骤之间的传递

3. 业务



3. 业务

- 例如：编译并测试一个 C 程序，类似 OnlineJudge 的流程



3. 业务

- 例如：编译并测试一个 C 程序，Taskfile 写法

compile-and-test:

```
task compile param arch=amd64
parallel (index, 10) {
    task run-program param id=index,arch=amd64
    task compare-output param id=index
}
```

3. 业务

- 例如：编译并测试一个 C 程序，Taskfile 写法

run-program: param *id*, *arch*


require arch:{*arch*} - 依赖 arch:amd64

in linux - 在 linux 容器运行

run ./hello < hello{*id*}.in > hello{*id*}.out


- Taskfile: 结合了 Makefile 和 Dockerfile
- 任务步骤，需要运行的命令，串/并行关系，依赖等等

3. 业务



3. 业务


- 如何运行 Taskfile? 中心服务器上运行。
- 最大程度利用**现有的协议**（**SSH**，**NFS**等），同时进行任务调度。



任务从头到尾都在同一个目录（/work）下运行，这个目录的内容由NFS共享，所有各步骤的容器都能看到。因此——不需要担心运行位置问题。

3. 业务

- 运行环境： **Docker 打包**，或者在需要更好的隔离时用 VM
 - 有效避免了 **环境构建的麻烦**
 - 放在中心服务器的 Docker Registry 上
 - 计算节点在需要时（Taskfile 中指出）自动拉取
 - 目前已经做过的：编译环境，常见的计算软件，Verilator 等等
 - 容器环境定期更新，确保环境内程序的版本正确
 - 较独立的大型软件（/opt 那些）可以考虑做 readonly 挂载到容器



3. 业务

• 公共服务

- 为实验室内成员和计算设备提供服务
- **APT 镜像**: RISC-V 软件镜像源(Nginx), 为 RISC-V 节点提供软件更新
- **内部网页**: 各类通知, 手册等(Apache2 + MkDocs, Gitee CI/CD)
- **代码管理**: Gitea
- **文件存储**: FileZilla FTP, 仪器设备的手册资料/SDK/软件等等
- **环境监控**: 遍布实验室范围的传感器终端, Grafana 可视化
- **OpenVPN**: 内网访问, 方便远程调试
- 等等

3. 业务

• 系统管理

- 全面实现公钥认证
- 多层次日志记录
- 数据收集和可视化
- 故障/异常告警
- 访问控制

物理层面；软件层面



4. 展望

- **新架构计算**

- 在计算任务中更大范围地使用 RISC-V 等新型架构，利用好现有的 RISC-V 硬件设备(4*Lpi 4A, 4*Lpi 3A = 48 cores, 128GB DDR4)

- **更好的身份认证**

- LDAP 等更适合集群的方案

- **GPU 计算节点**

- 除了 CPU 计算节点外，可以使用 GPU 对部分计算进行加速

- **任务调度**

- 精细化的任务调度策略，也许可以引入机器学习？

4. 展望

• 远程计算

- 原理上看，目前的集群设计已经可以支持远程计算，可能需要加网关
- 充分利用本地边缘计算系统的优势，降低跨实验室的数据流量
- 自动将大型计算任务 offload 到公共计算平台

• 共享集群


- 网络中类似结构的集群实现计算资源共享
- 更加广泛且均衡地利用好计算资源

• 节点自动注册

- 节点运行 daemon，向中心服务器自动报告自身的配置状况，实现即插即用

5. 一些经验

- 避免大而全的结构：用一个协议做好一个事情
- 利用现有协议：SSH, NFS, FTP, HTTP, rsync, WebDAV
- 本地服务：特殊情况单独对待（RISC-V 本地镜像站等）
- 降低部署负担：目标主机（节点）上只需要有ssh就能部署
 - 更重要的是因为 RISC-V 架构不完整的支持
- Make it → Make it work → Make it right → Make it fast



Thanks