QCon 全球软件开发大会
INTERNATIONAL SOFTWARE DEVELOPMENT CONFERENCE

BEIJING 2018

《阿里巴巴百万级容器技术 PouchContainer 揭秘》

演讲者 / 孙宏亮

主办方 Geekbang. 极客邦科技 InfoQ

Agenda

- 阿里巴巴集团容器现状
- PouchContainer 技术优势
  - 富容器
  - 隔离性
  - P2P镜像分发
  - 内核兼容性
  - 原生支持Kubernetes
- PouchContainer 开源发展

阿里巴巴集团容器现状

规模：

- 覆盖集团大部分BU
- 2017年双11百万级容器
- 在线业务100%容器化

覆盖场景：

- 运行模式
- 编程语言
- 技术栈

覆盖业务：

- 蚂蚁&交易&中间件
- B2B/CBU/ICBU/1688/村淘
- 合一集团（优酷）
- 菜鸟&高德&UC（接入中）
- 集团测试环境
- 广告（阿里妈妈）
- 阿里云专有云输出
- ……

阿里巴巴集团容器现状

- 本意育儿袋，隐喻贴身呵护应用
- 始于2011年
- 基于LXC
- 阿里内部容器技术产品，并于当年上线
- 2015年初开始吸收Docker镜像功能
- 容器结合阿里内核，大幅提高隔离性
- 大规模部署于阿里集团内部
- opensource：https://github.com/alibaba/pouch

PouchContainer

PouchContainer 演进之路

容器的要素--阿里内部运维和应用视角

- 有独立IP
- 能够ssh登陆
- 独立的的文件系统
- 资源隔离—使用量和可见性

- 手工Hack实现容器要素
  - **虚拟网卡，网桥**
  - **sshd**
  - **Chroot (pivot_root)**
  - **CGroup，Namespace**

阿里容器技术

- 引入LXC（Linux Container）
- 内核可见性隔离Patch
- 内核磁盘空间配额Patch

引入Docker

PouchContainer 生态架构

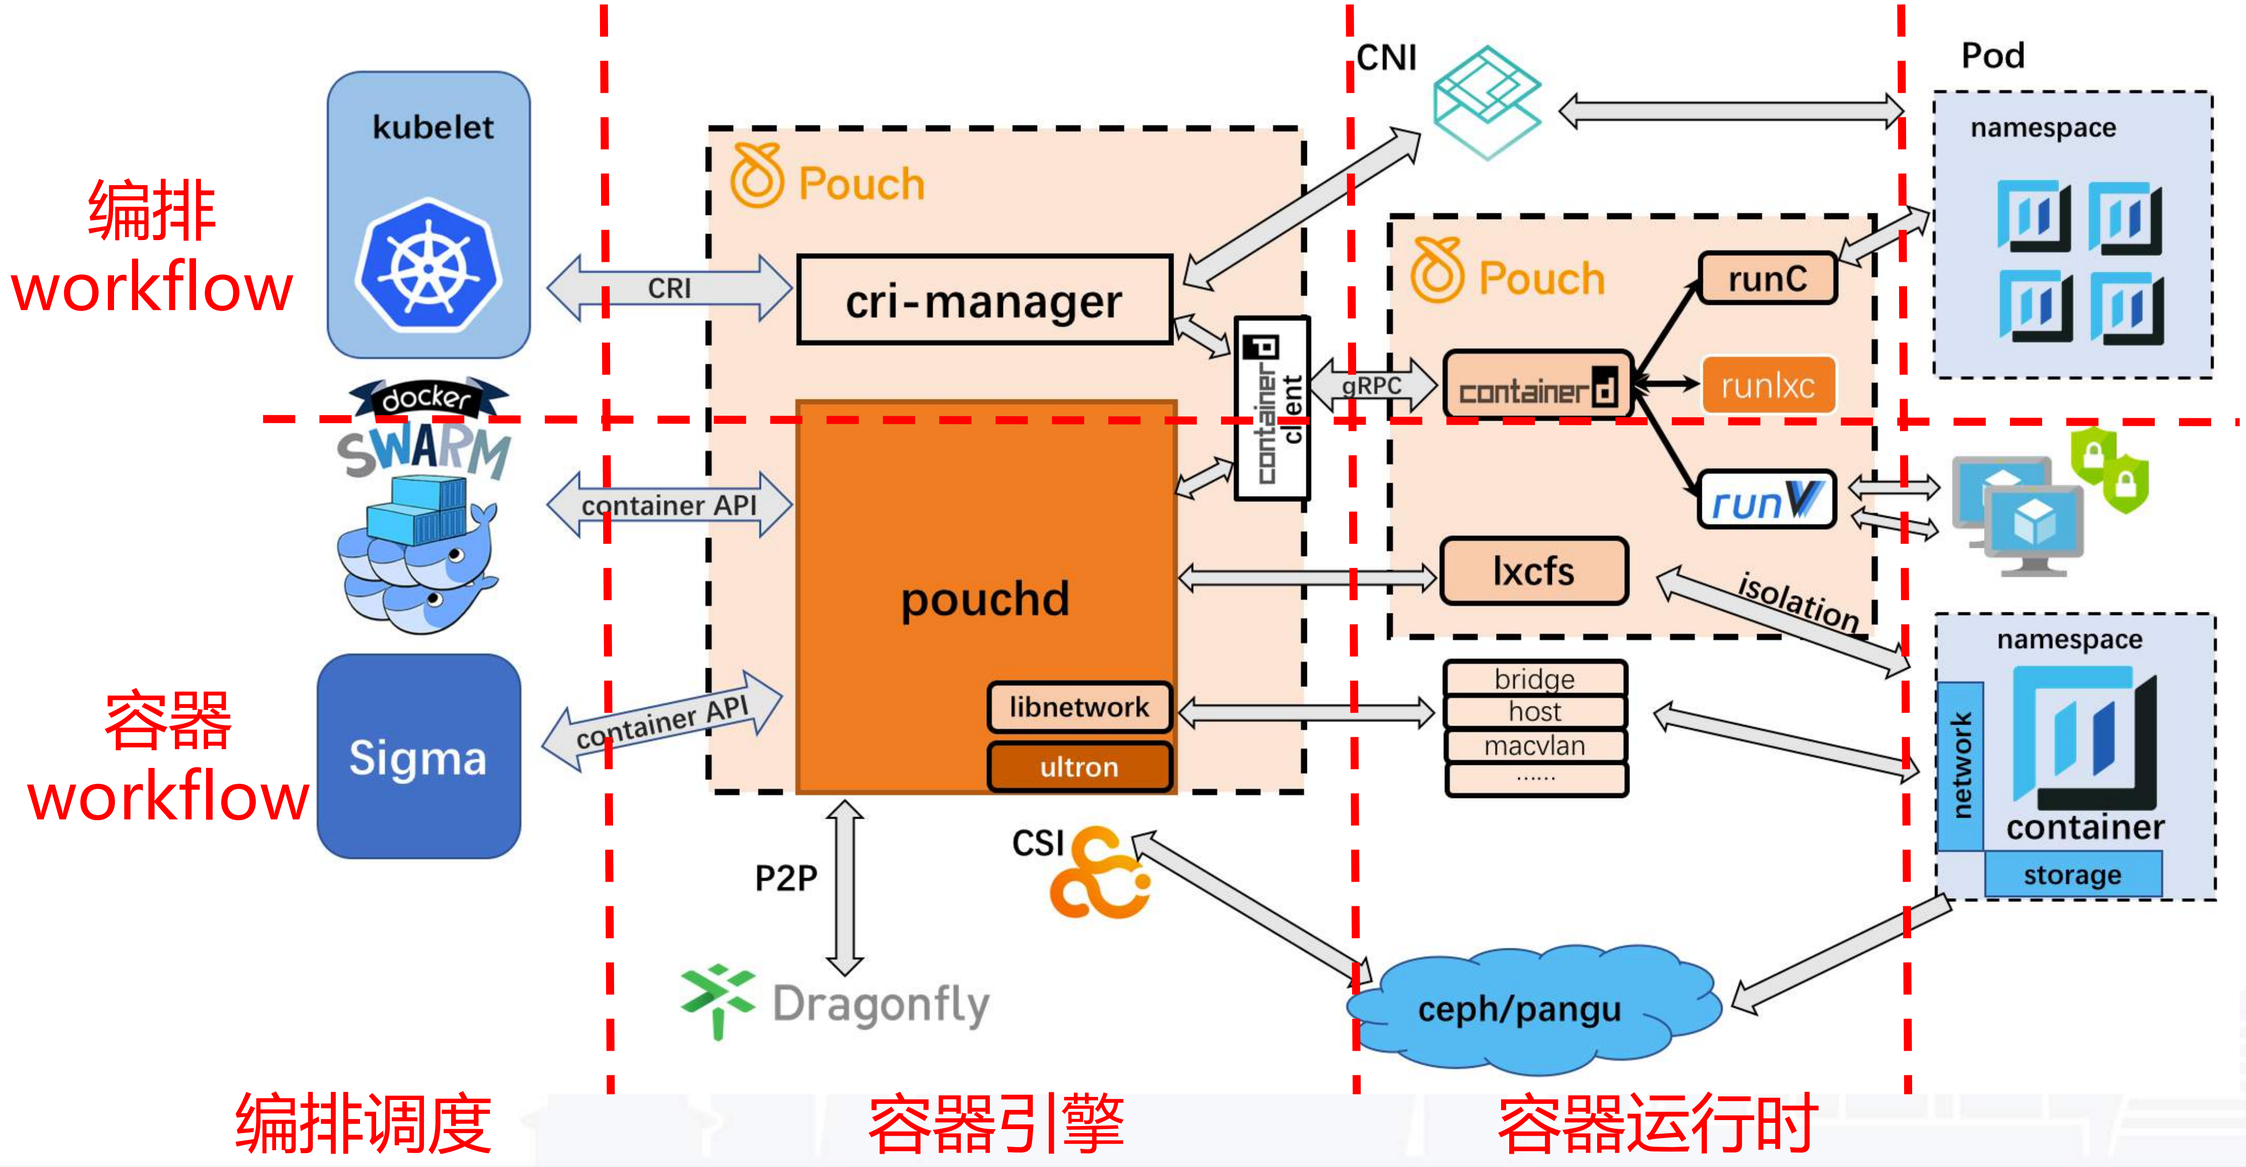

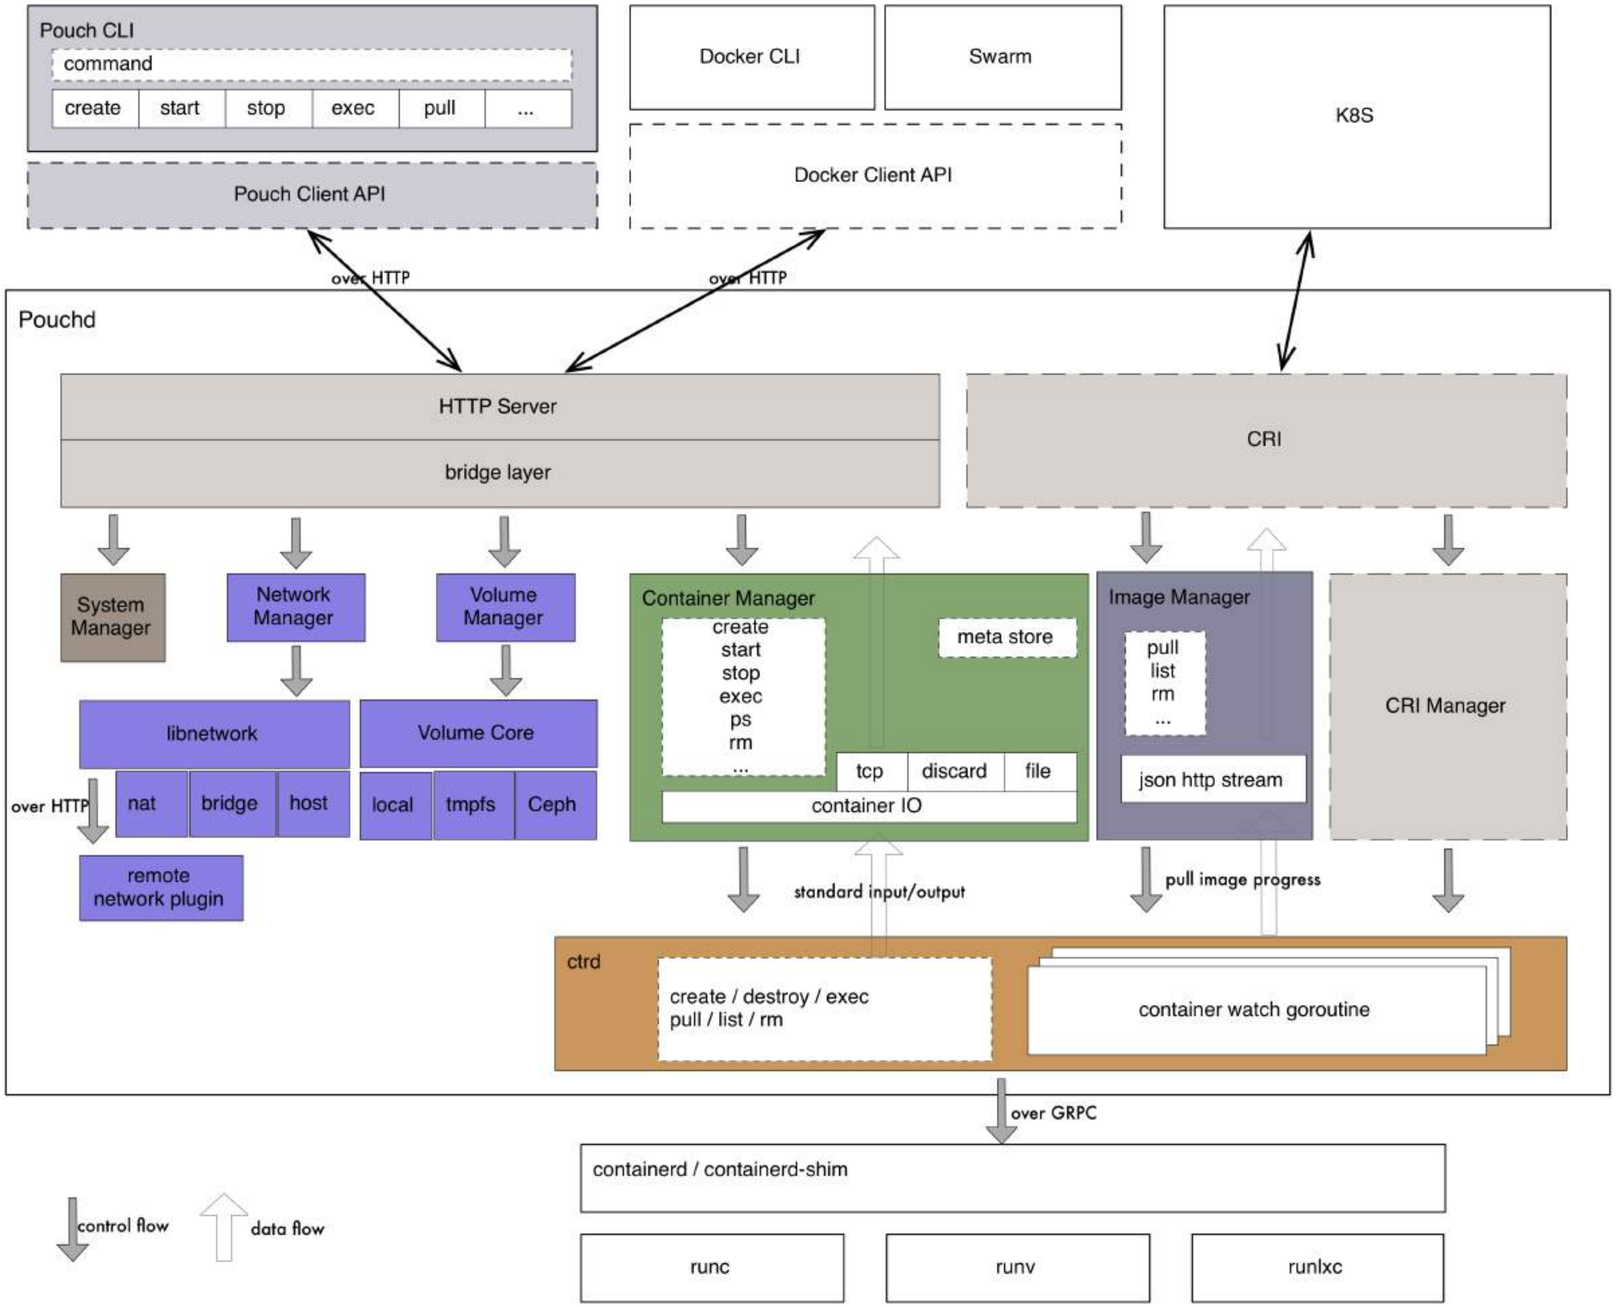
Pouch CLI
command
create
start
stop
exec
pull
...
Pouch Client API
Docker CLI
Swarm
Docker Client API
K8S
over HTTP
over HTTP
Pouchd
HTTP Server
bridge layer
CRI
System Manager
Network Manager
Volume Manager
Container Manager
create
start
stop
exec
ps
rm
...
meta store
tcp
discard
file
container IO
Image Manager
pull
list
rm
...
json http stream
CRI Manager
libnetwork
Volume Core
over HTTP
nat
bridge
host
local
tmpfs
Ceph
remote network plugin
standard input/output
pull image progress
ctrd
create / destroy / exec
pull / list / rm
container watch goroutine
over GRPC
containerd / containerd-shim
runc
runv
runlxc
control flow
data flow

富容器

- 容器内运行init进程，PID = 1
- 满足运维域视角（应用运维、基础设施运维）
- 容器内运行系统服务，满足业务需求
- 极强的应用适配性，快速容器化存量业务
- 阿里集团应用100%容器化的重要前提
- 容器内资源多维度隔离（alikernel支持）

https://github.com/alibaba/pouch/blob/master/docs/features/pouch_with_rich_container.md

富容器

兼容容器镜像
-保障交付效率

兼容运维体系
-保障运维能力

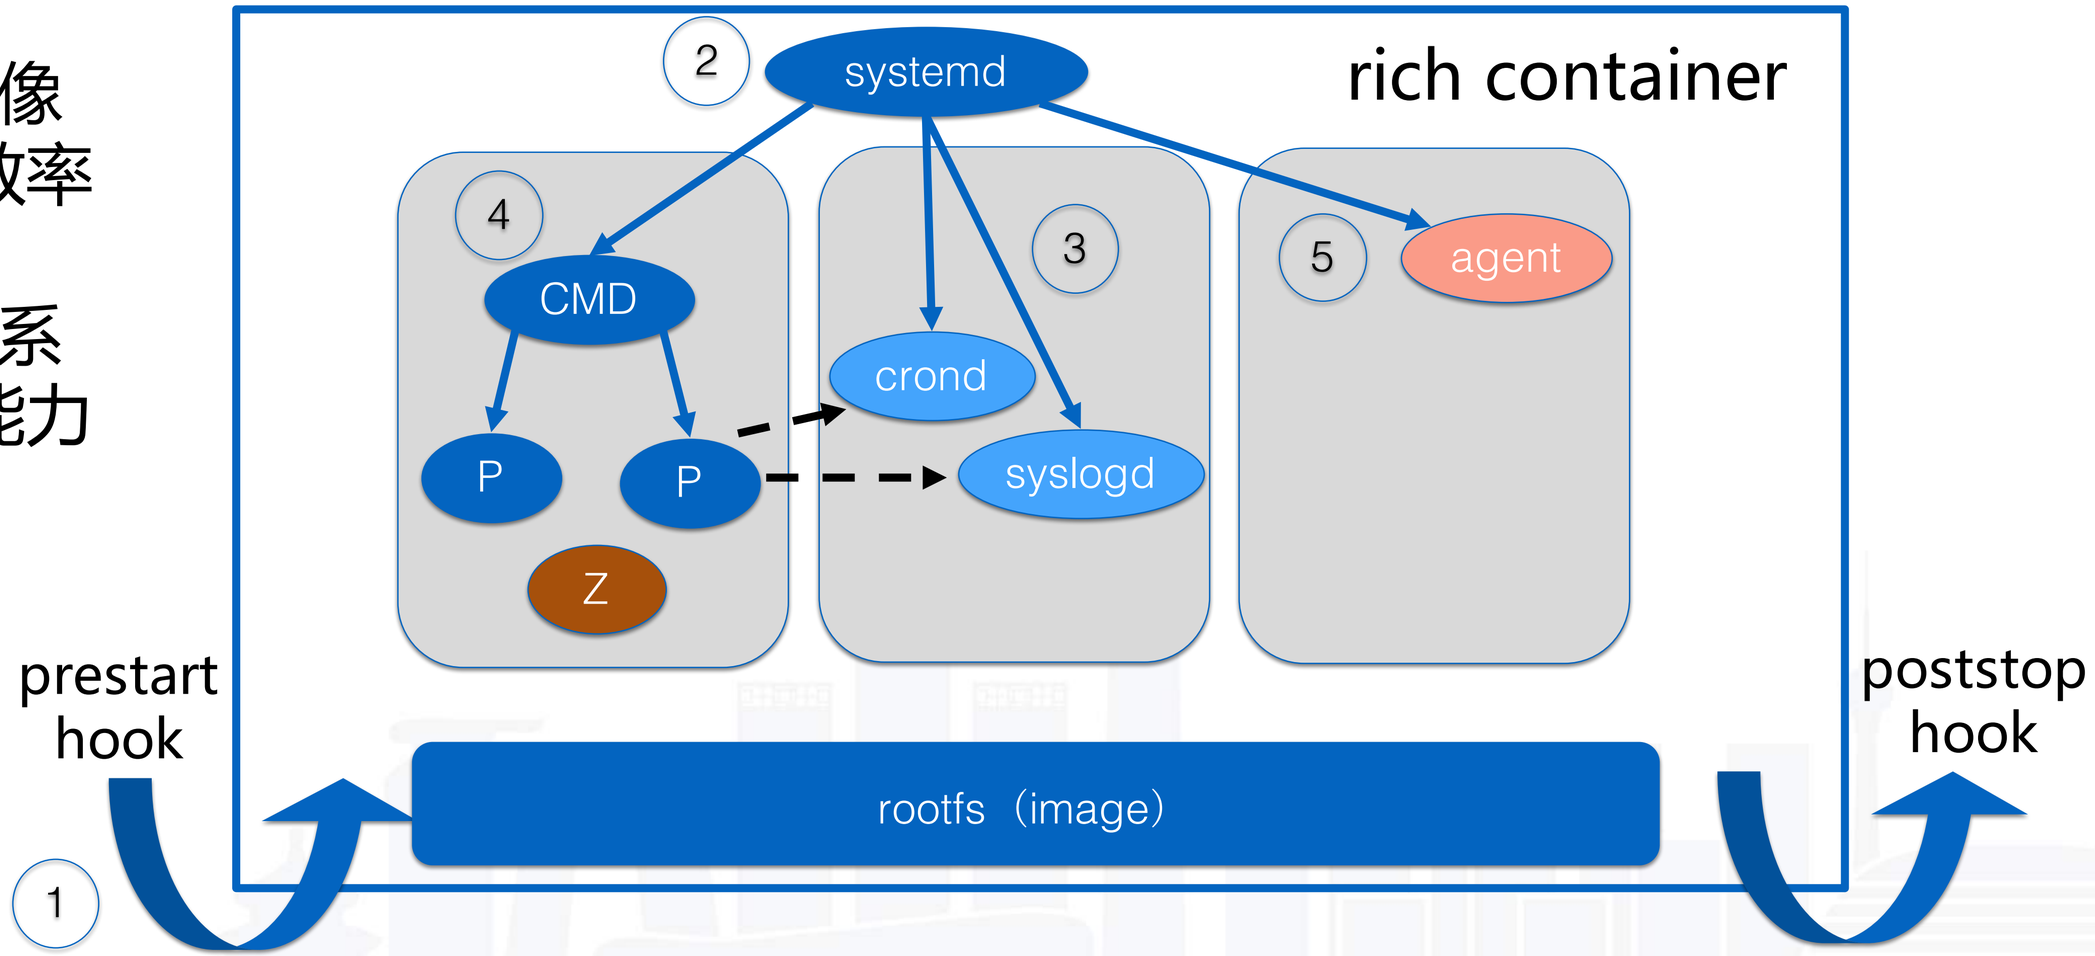

丰富的隔离性

- 传统容器的隔离维度：namesapce，cgroup
- 更优的容器可见性隔离：内核patch，lxcfs
- 额外隔离维度：磁盘，网络等：diskquota
- 基于Hypervisor的强容器隔离
  - runV
  - clear container
  - katacontainer

资源可见性隔离 LXCFS

使用场景：

- Java应用判断内存资源大小动态分配堆栈大小，莫名OOM
- Java中间件通过CPU核来创建线程数
- /proc

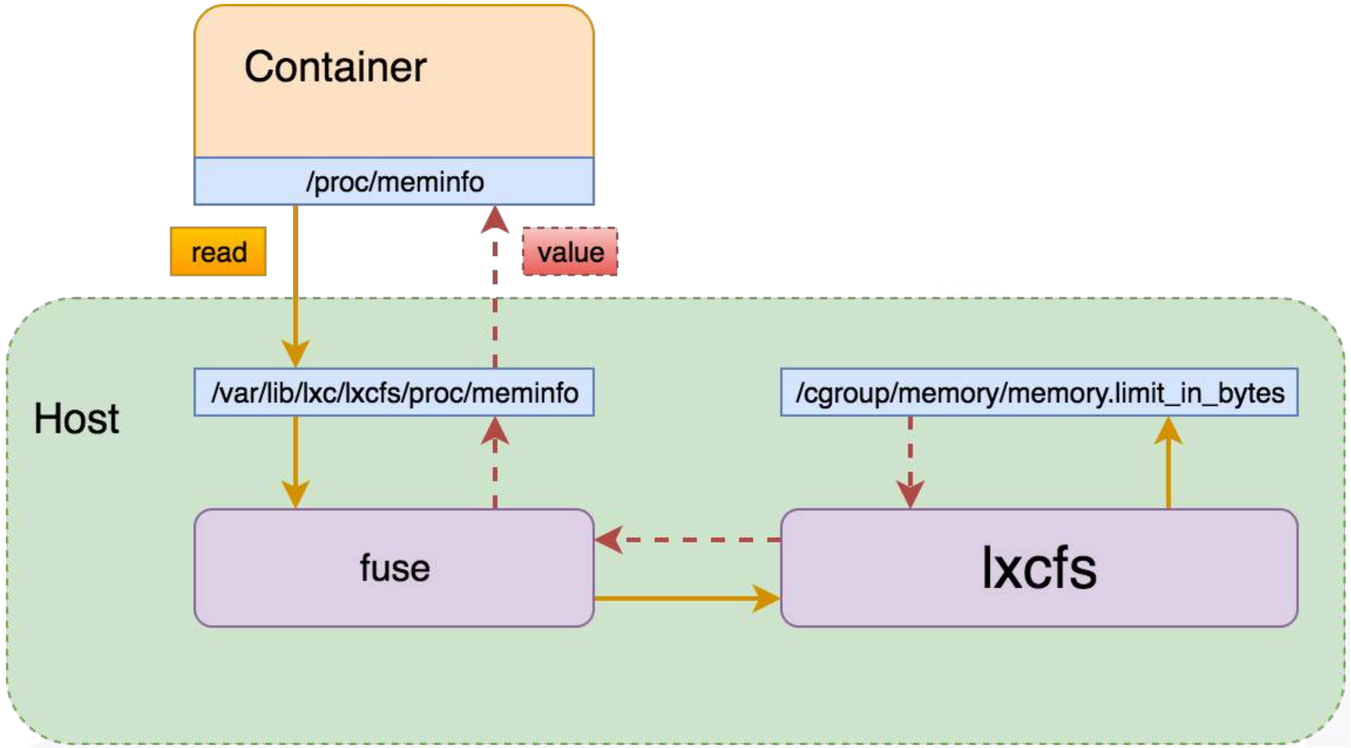

资源可见性隔离 LXCFS

不使用LXCFS

```
$ pouch run -m 200m registry.hub.docker.com/library/ubuntu:16.04 free -h
              total        used        free      shared  buff/cache   available
Mem:           2.0G        103M        1.2G       3.3M        684M        1.7G
Swap:          2.0G          0B        2.0G
```

使用LXCFS

```
$ pouch run -m 200m --enableLxcfs registry.hub.docker.com/library/ubuntu:16.04 free -h
              total        used        free      shared  buff/cache   available
Mem:           200M        876K        199M       3.3M          12K        199M
Swap:          2.0G          0B        2.0G
```

https://github.com/alibaba/pouch/blob/master/docs/features/pouch_with_lxcfs.md

Diskquota容器磁盘限额

DiskQuota是一种限制文件系统磁盘空间使用的技术；

控制磁盘使用量的功能(Volume/容器rootfs)；

基于块设备的方式是可以直接控制磁盘的使用量（size/inode）；

DiskQuota功能在内核支持的版本情况：

	user/group quota	project quota
ext4	> 2.6	> 4.5
xfs	> 2.6	> 3.10

Diskquota容器磁盘限额

1. rootfs设置quota，通过--disk-quota的参数指定

```
# pouch run -ti --disk-quota 10g registry.hub.docker.com/library/busybox:latest df -h
Filesystem                Size      Used Available Use% Mounted on
overlay                  10.0G     24.0K     10.0G   0% /
tmpfs                    64.0M         0     64.0M   0% /dev
shm                      64.0M         0     64.0M   0% /dev/shm
tmpfs                    64.0M         0     64.0M   0% /run
tmpfs                    64.0M         0     64.0M   0% /proc/kcore
tmpfs                    64.0M         0     64.0M   0% /proc/timer_list
tmpfs                    64.0M         0     64.0M   0% /proc/sched_debug
tmpfs                     1.9G         0      1.9G   0% /sys/firmware
tmpfs                     1.9G         0      1.9G   0% /proc/scsi
```

Diskquota容器磁盘限额

2. volume设置quota，通过设置volume size参数指定

```
# pouch volume create -n volume-quota-test -d local -o mount=/data/volume -o size=10g
Name:         volume-quota-test
Scope:
Status:       map[mount:/data/volume sifter:Default size:10g]
CreatedAt:    2018-3-24 13:35:08
Driver:       local
Labels:       map[]
Mountpoint:   /data/volume/volume-quota-test

# pouch run -ti -v volume-quota-test:/mnt registry.hub.docker.com/library/busybox:latest df -h
Filesystem                Size      Used Available Use% Mounted on
overlay                  20.9G    212.9M     19.6G   1% /
tmpfs                    64.0M         0     64.0M   0% /dev
shm                      64.0M         0     64.0M   0% /dev/shm
tmpfs                    64.0M         0     64.0M   0% /run
/dev/sdb2                10.0G      4.0K     10.0G   0% /mnt
tmpfs                    64.0M         0     64.0M   0% /proc/kcore
tmpfs                    64.0M         0     64.0M   0% /proc/timer_list
tmpfs                    64.0M         0     64.0M   0% /proc/sched_debug
tmpfs                     1.9G         0      1.9G   0% /sys/firmware
tmpfs                     1.9G         0      1.9G   0% /proc/scsi
```

Hypervisor-based Container

runV
QEMU

兼容容器镜像
-保障交付效率

提供隔离的内核
-保障容器安全

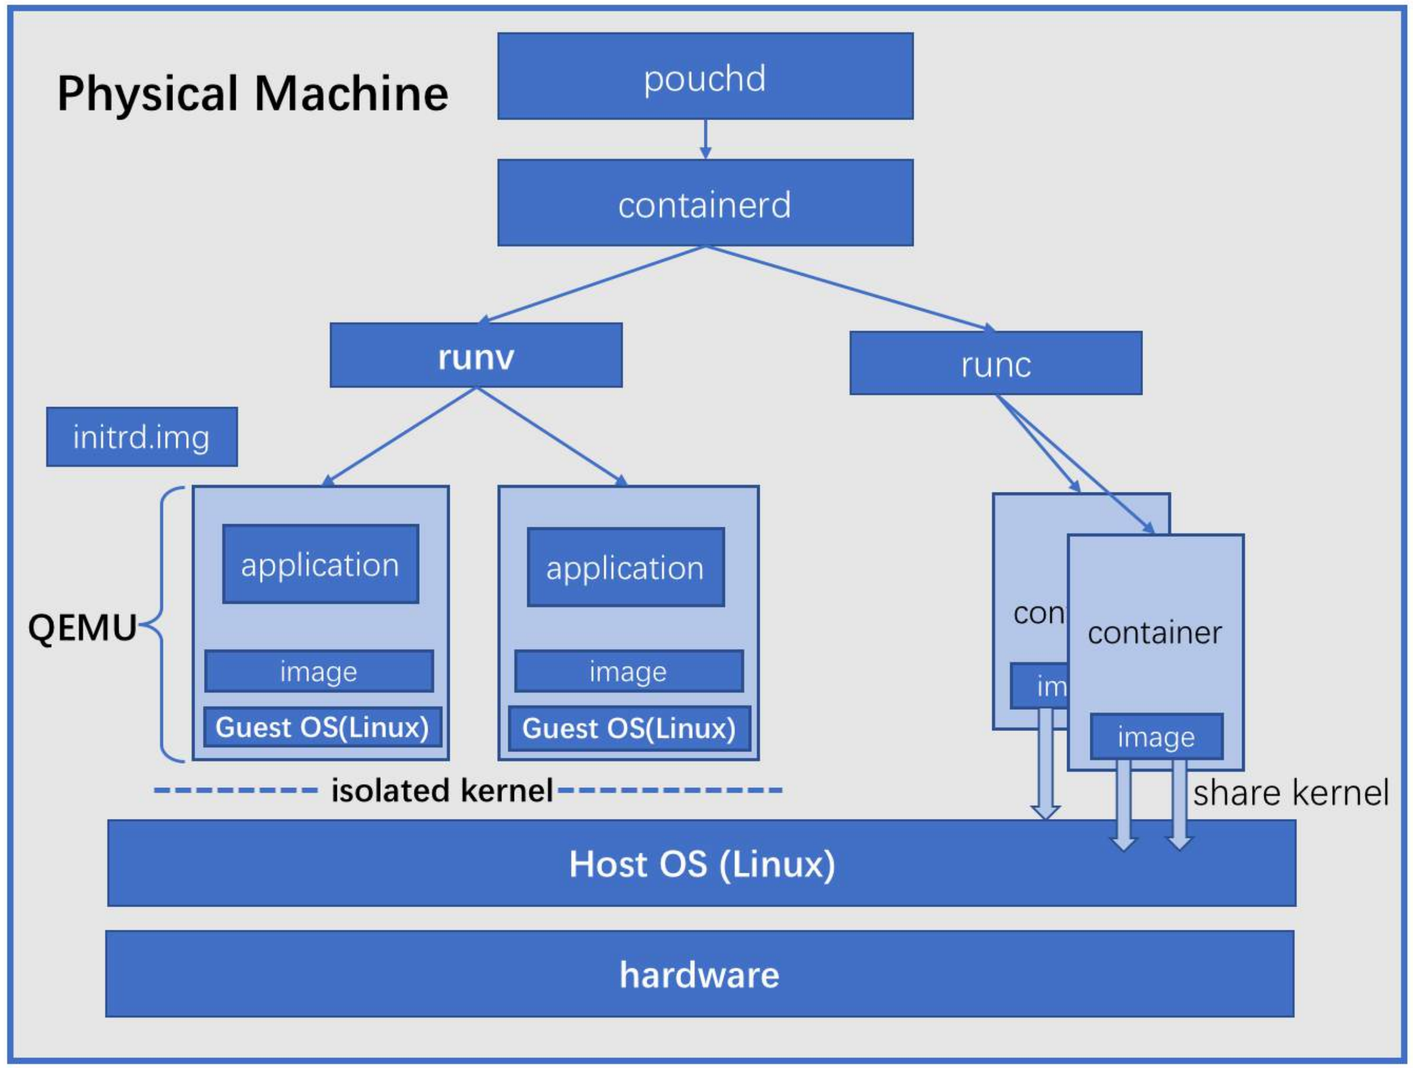

Hypervisor-based Container

多容器运行时统一管理

```
$ pouch create --name hypervisor --runtime runv docker.io/library/busybox:latest
container ID: 95c8d5215451 5e58ab267f3c33ef74ff84c901ad77ab18ee6428a1ffac12400d, name: hypervisor
$
$ pouch ps
Name          ID       Status    Image                                Runtime
hypervisor    95c8d5   created   docker.io/library/busybox:latest     runv
4945c0        4945c0   stopped   docker.io/library/busybox:latest     runc
1dad17        1dad17   stopped   docker.io/library/busybox:latest     runv
fab7ef        fab7ef   created   docker.io/library/busybox:latest     runv
505571        505571   stopped   docker.io/library/busybox:latest     runc
```

https://github.com/alibaba/pouch/blob/master/docs/features/pouch_with_runV.md

P2P镜像分发能力

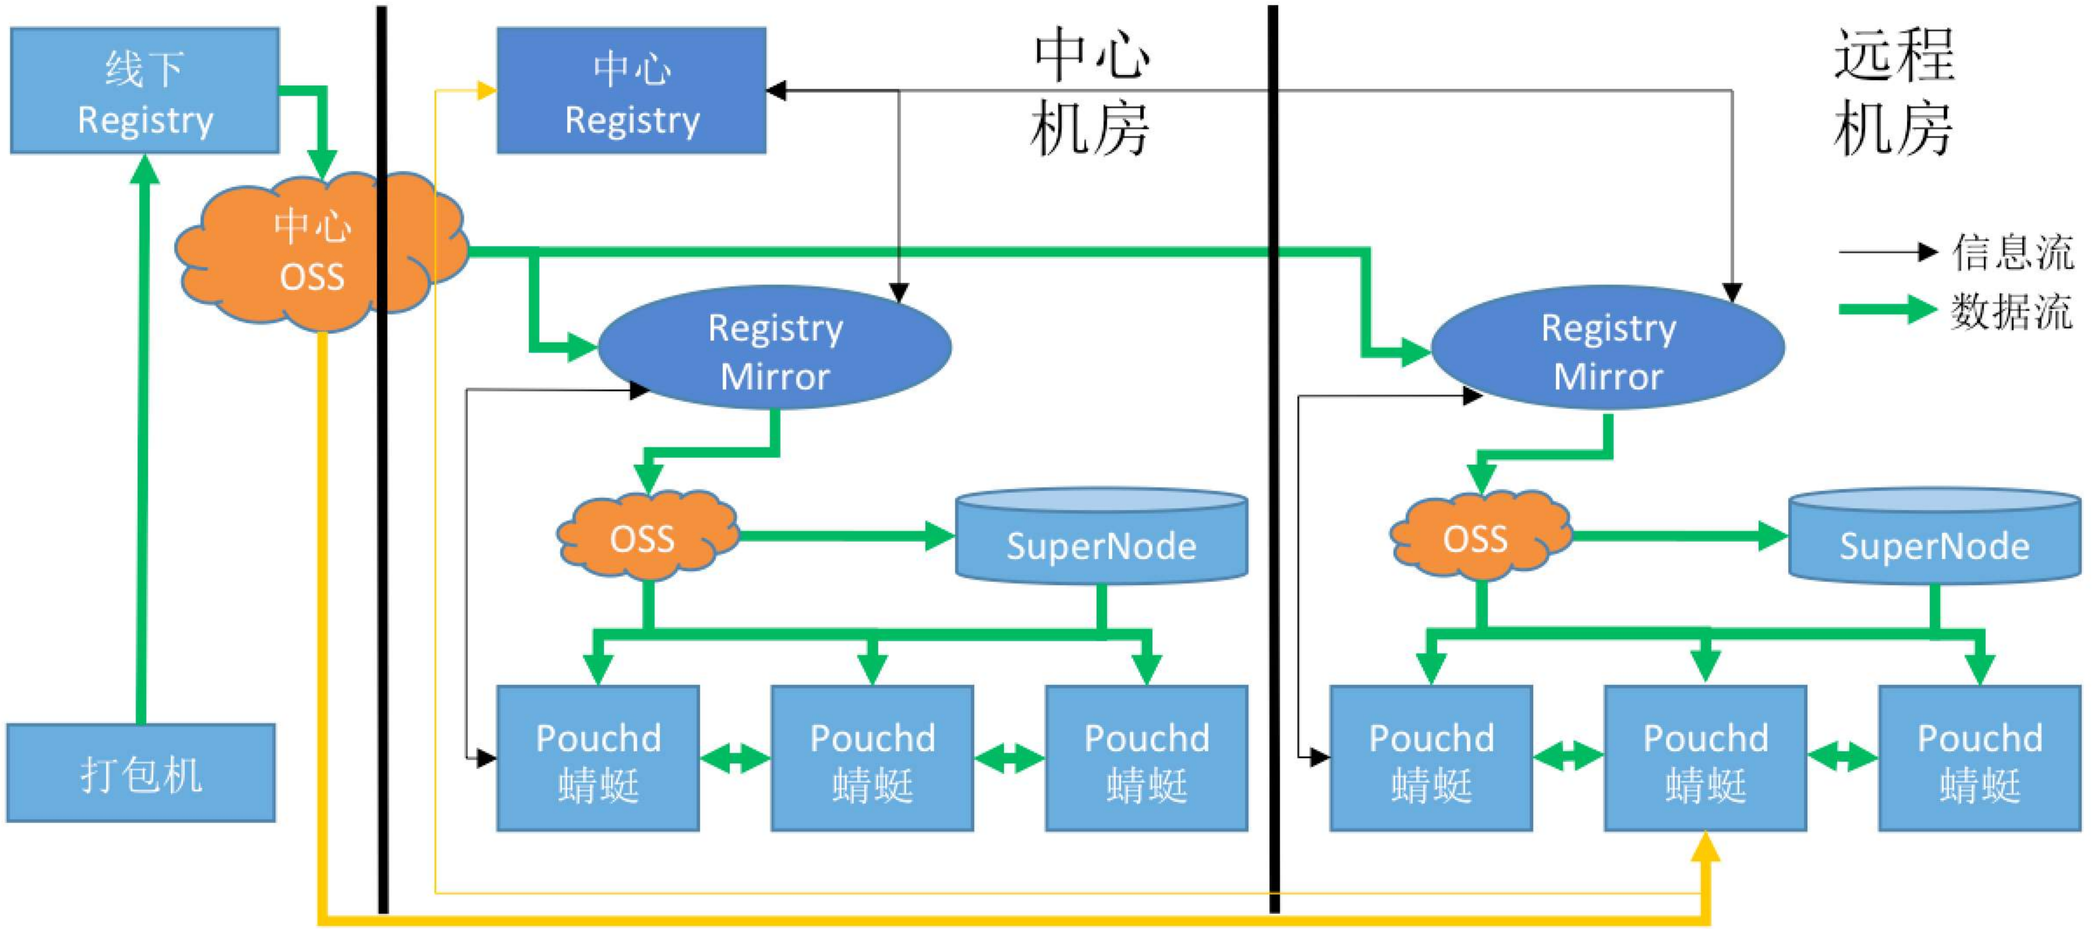
线下
Registry
中心
Registry
中心
机房
远程
机房
中心
OSS
信息流
数据流
Registry
Mirror
Registry
Mirror
OSS
SuperNode
OSS
SuperNode
Pouchd
蜻蜓
Pouchd
蜻蜓
Pouchd
蜻蜓
Pouchd
蜻蜓
Pouchd
蜻蜓
Pouchd
蜻蜓
打包机

内核兼容性

- 阿里仍存有相当规模的 Linux 2.6.x 内核机器
- PouchContainer 支持内部所有 Linux 2.6.x 的内核
- 部分支持来源指定系统调用的回避
- 部分支持来源内核补丁
- runV虚拟机中GuestOS支持 2.6.x内核（TODO）
- 自研OCI runtime runlxc（开源 TODO）

原生支持 Kubernetes

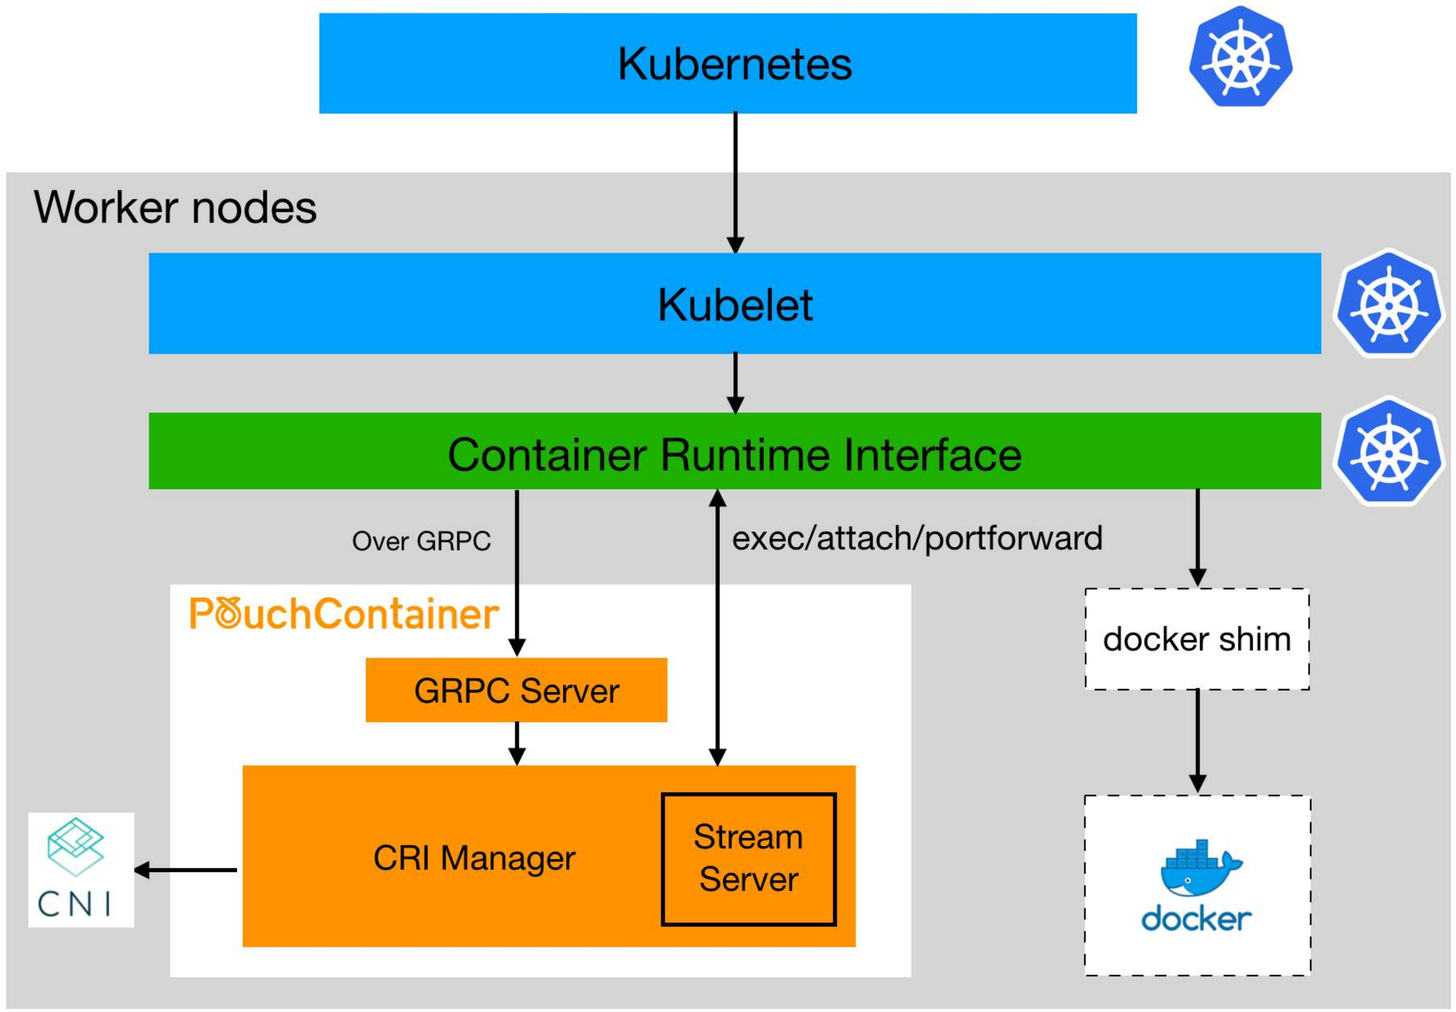

原生支持 Kubernetes

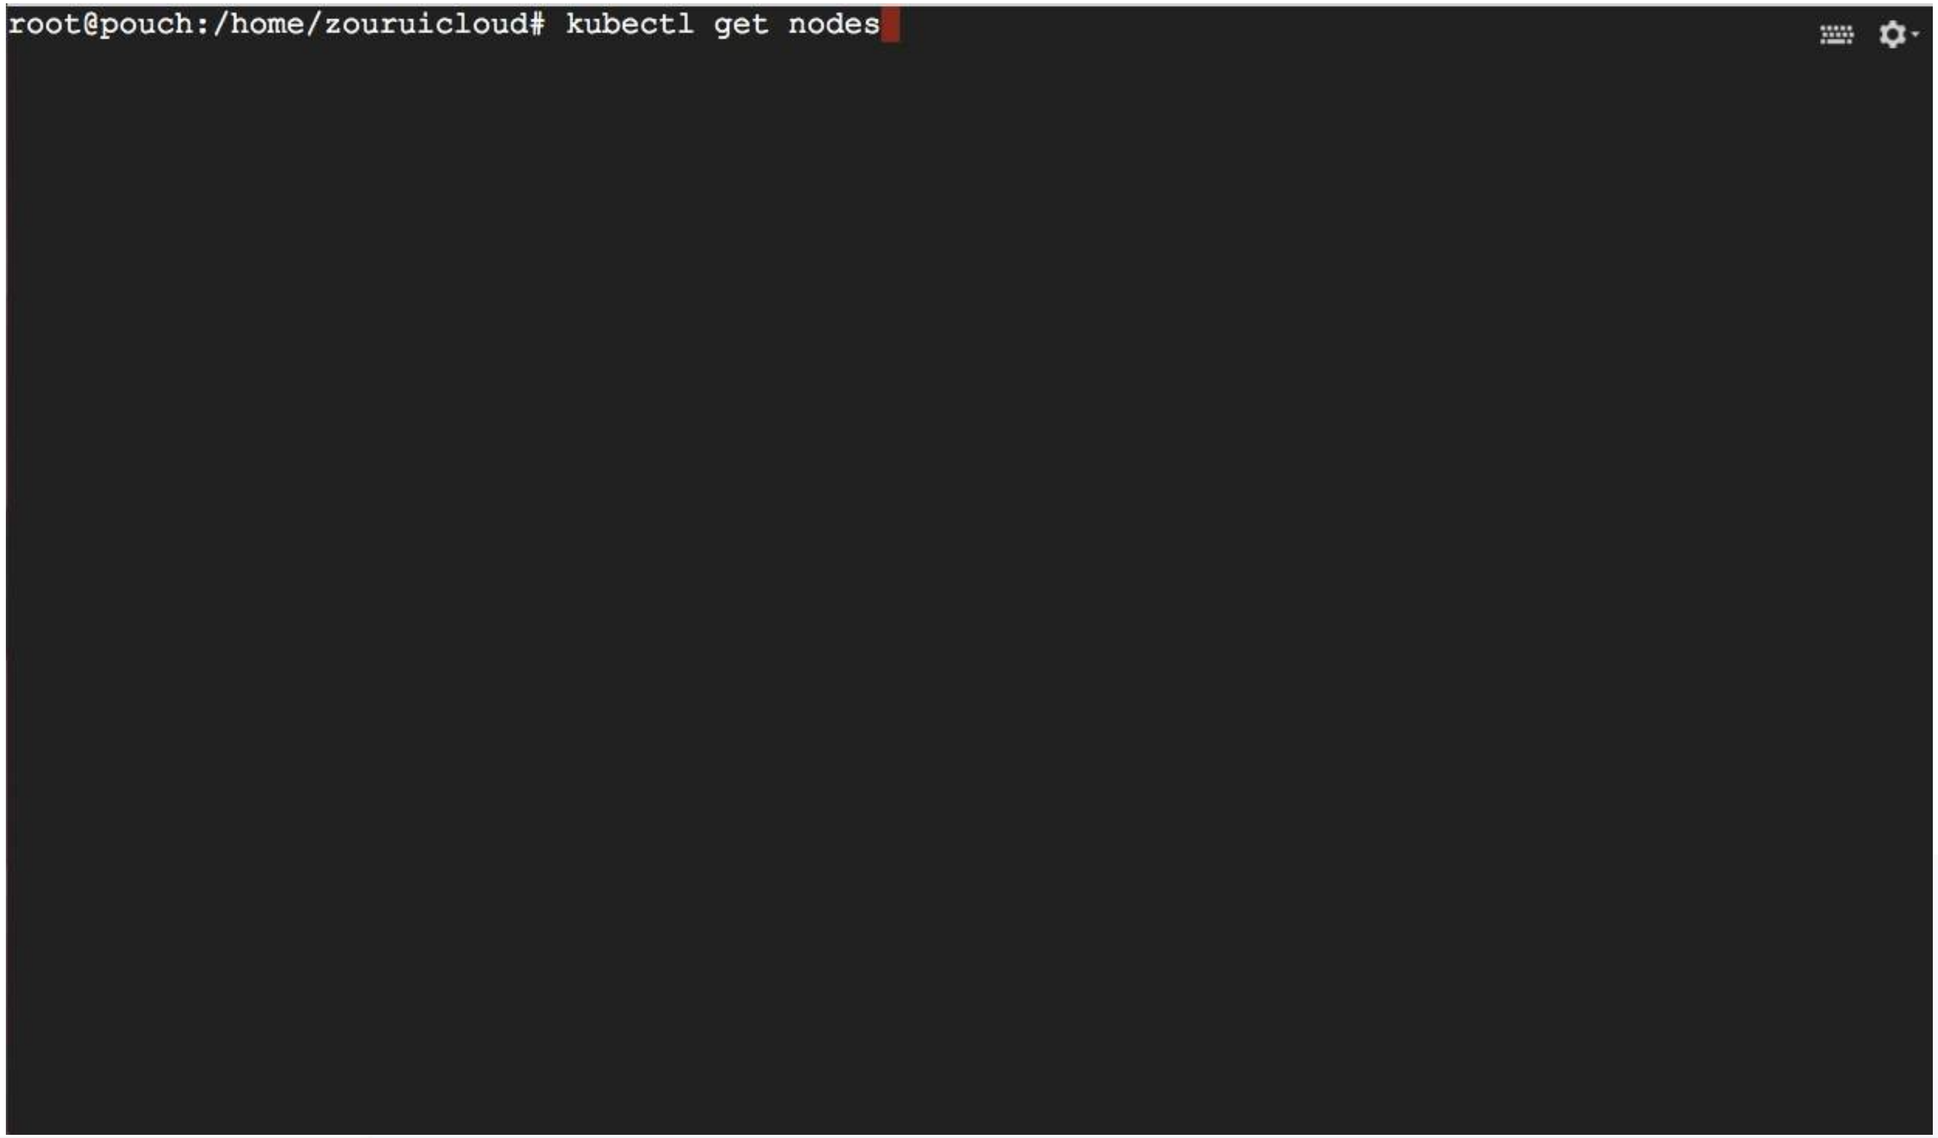

PouchContainer开源现状

2445 star

48位贡献者

1位协作机器人

文档

测试

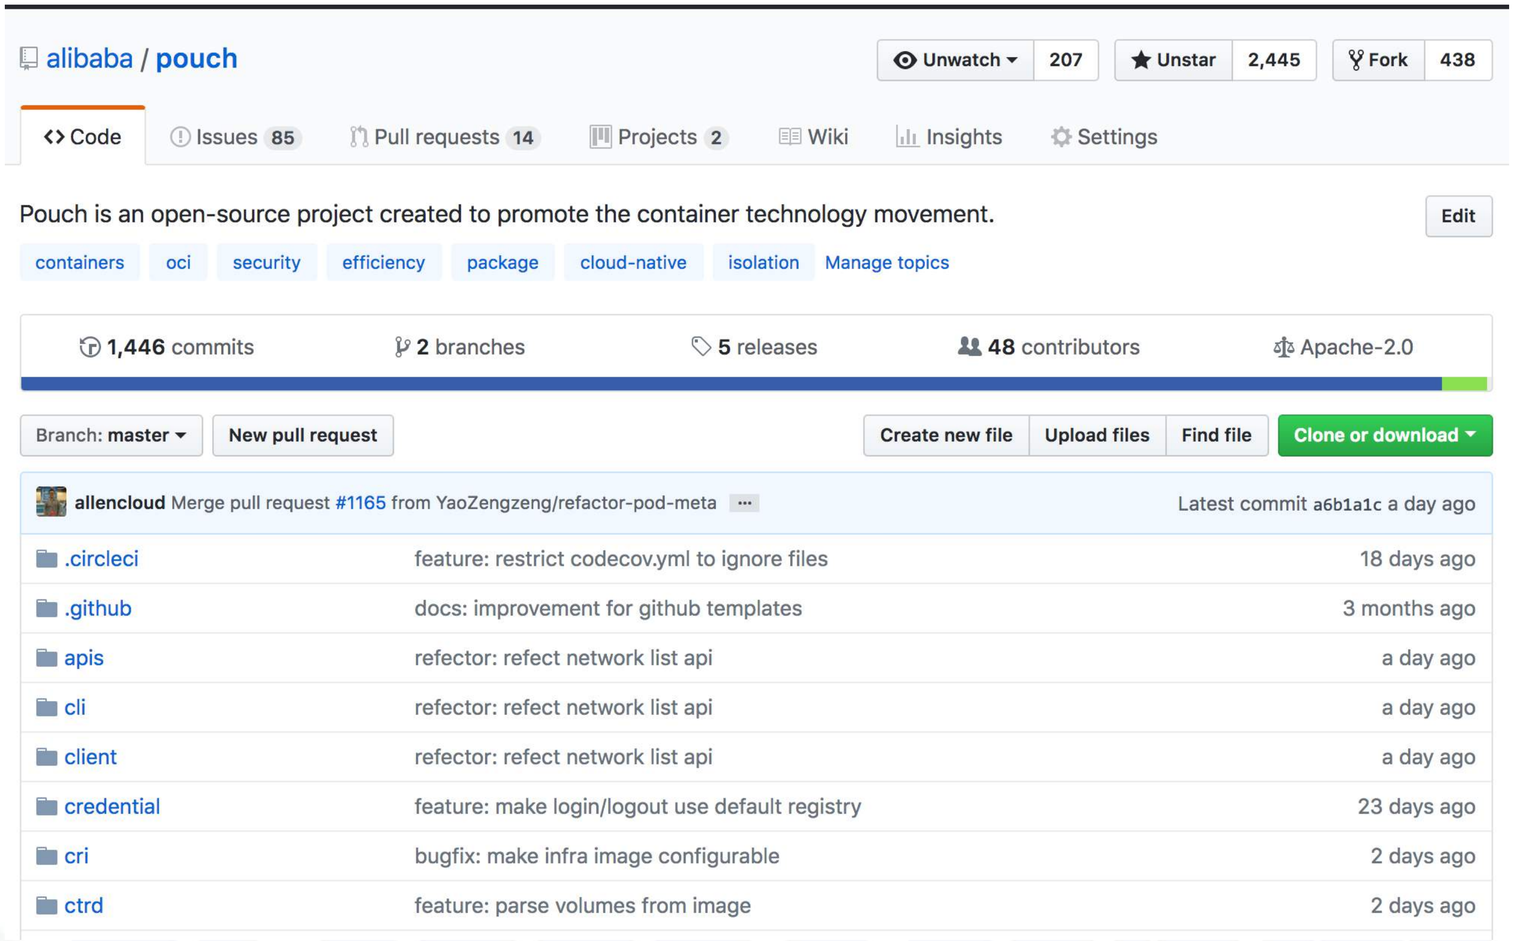

安装指南： https://github.com/alibaba/pouch/blob/master/INSTALLATION.md