深入浅出容器技术

马震 2022-08-26

会议签到二维码

会议时间：2022.08.26 16:15–17:45

地点：B1001

容器不是虚拟机

- 容器的本质就是一个（被隔离和受限的）进程
  - 使用namespaces对进程进行隔离
  - 使用cgroups限制进程使用的资源
  - 使用 capabilities, AppArmor, Seccomp进行安全限制
- 每个虚拟机都有独立的操作系统内核
- 容器共享同一个操作系统内核

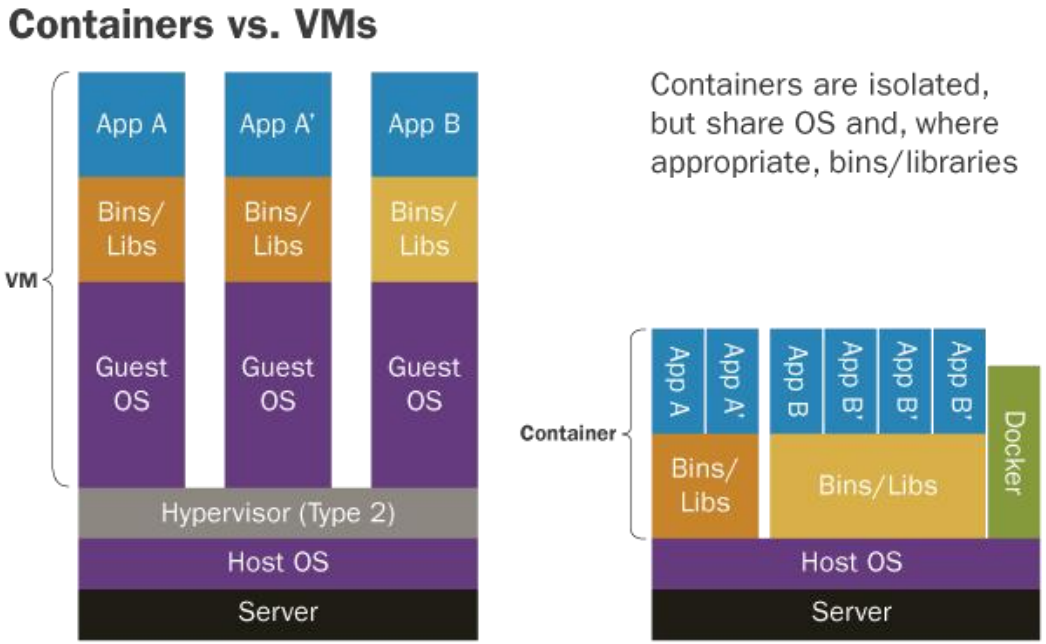

Docker的分层架构

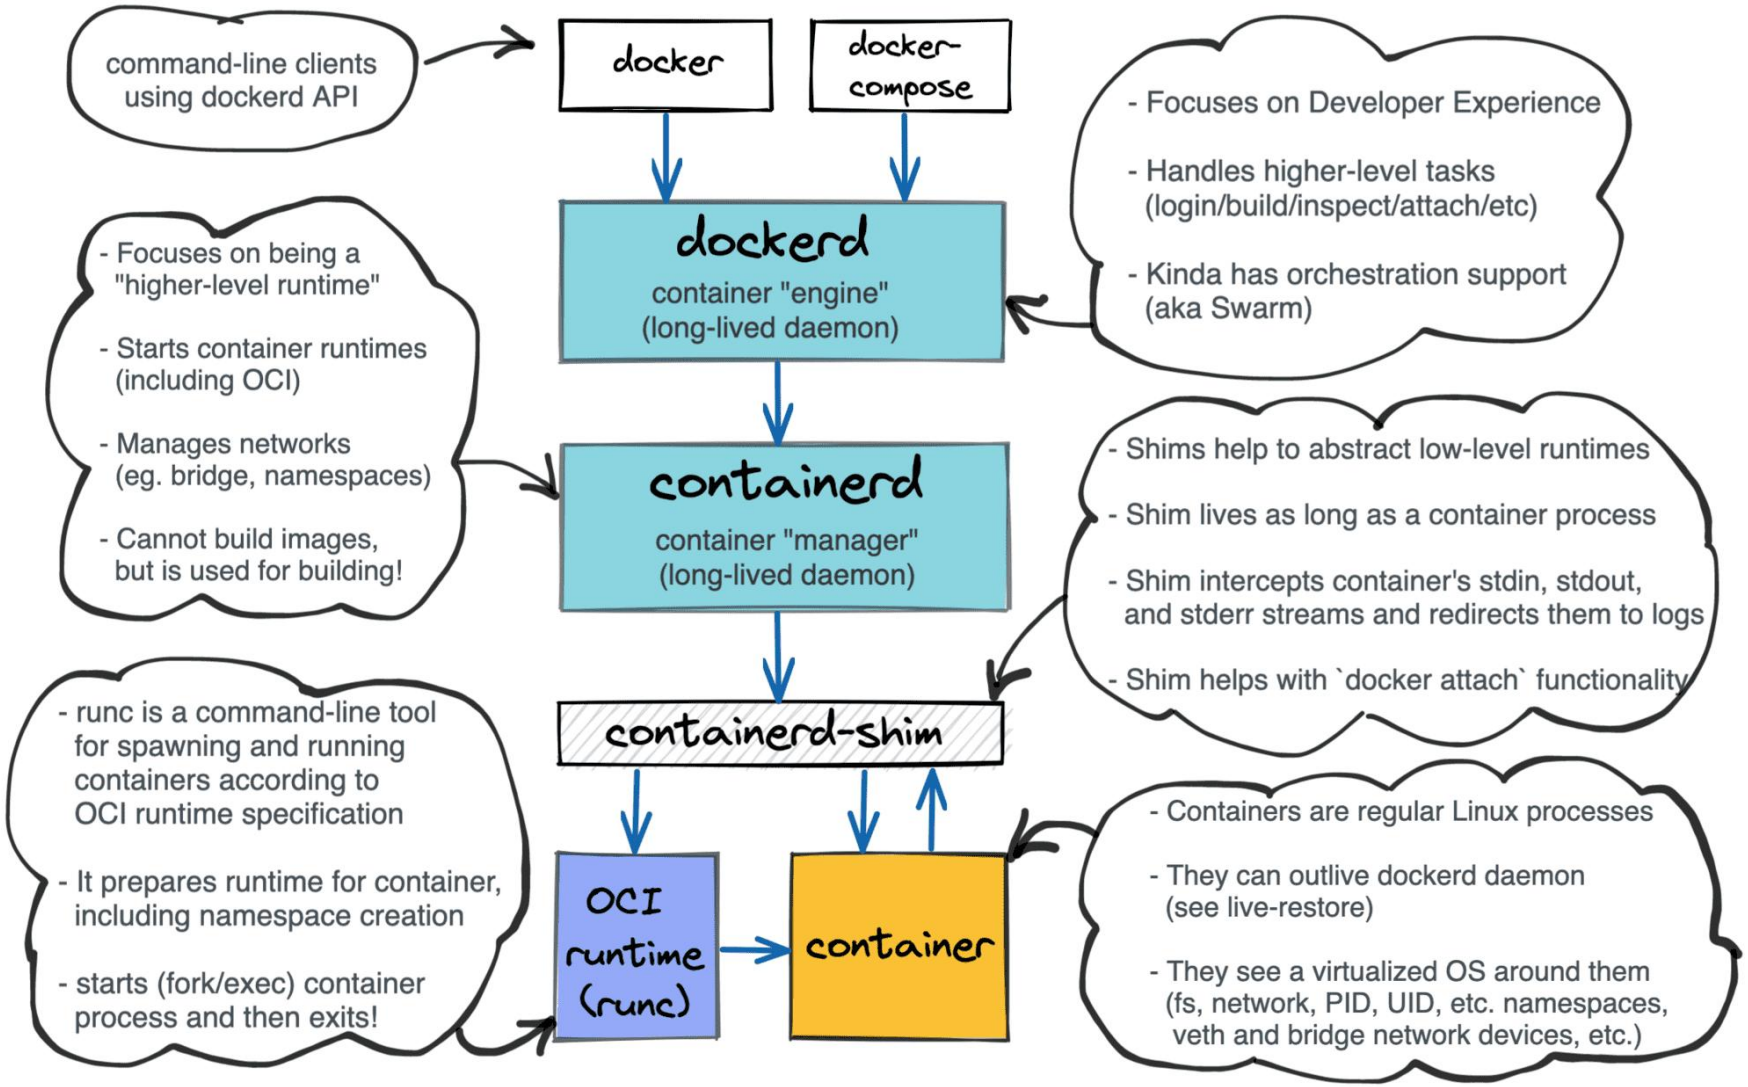

容器运行时

- OCI(Open Container Initiative) 制定了容器运行时规范OCI runtime specification.
- 使用最广泛的容器运行时 runc
  - 最初是Docker的一部分
  - runc是OCI运行时规范的参考实现
- crun
  - C语言编写的OCI容器运行时

runc

- runc是一个命令行工具，启动容器进程
- 需要向runc提供一个bundle
  - Linux root file system
  - OCI运行时规范的配置文件
- runc将准备所有必要的Linux资源，最主要的是namespaces和cgroups，并在容器化环境中启动指定进程

每个容器镜像都必须包含OS吗

- 一般都是基于Ubuntu、centos、alpine等发行版构建镜像
- 容器只是一个Linux进程
- 镜像可以只包含一个可执行文件
  - 基于scratch镜像创建
  - 使用一个静态链接的二进制文件
    - 不依赖系统中的一些共享库
    - 基于Linux内核就可以运行

使用dive查看hello镜像

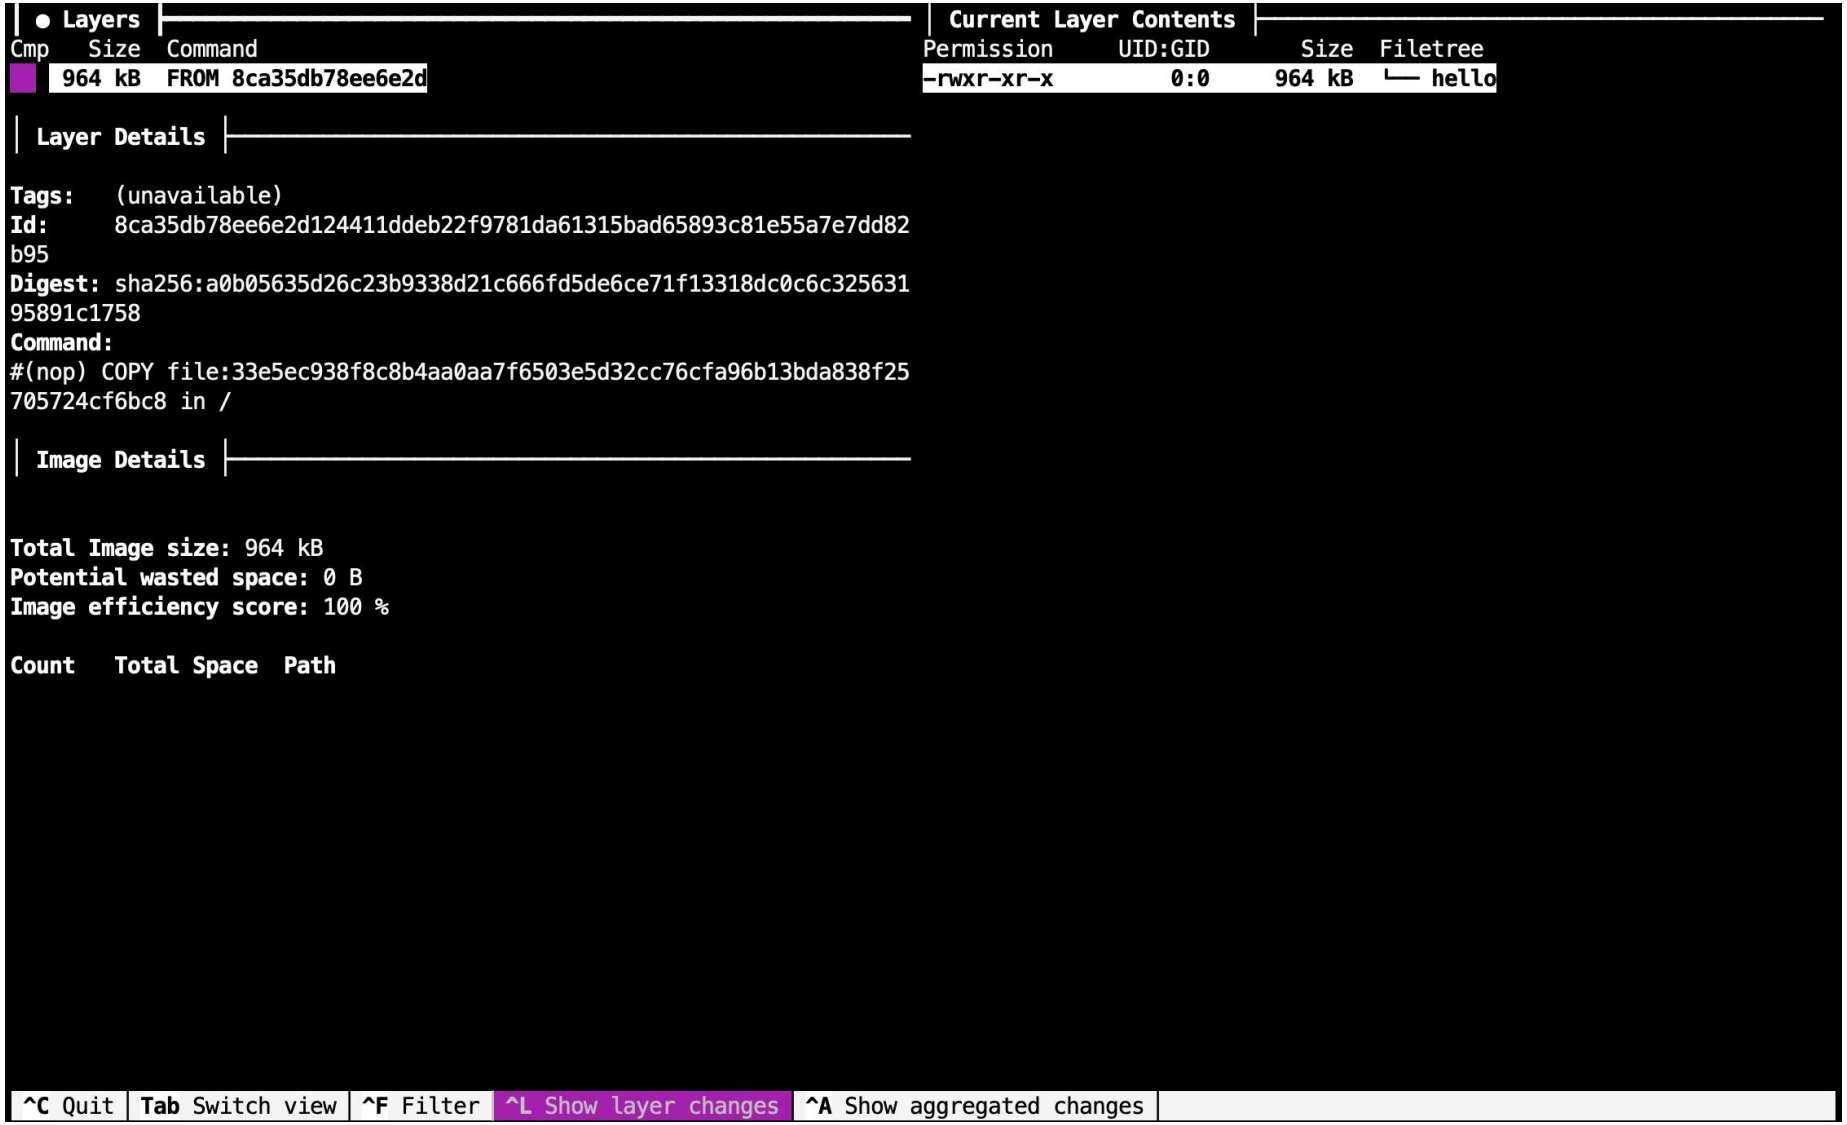

使用dive查看nginx镜像

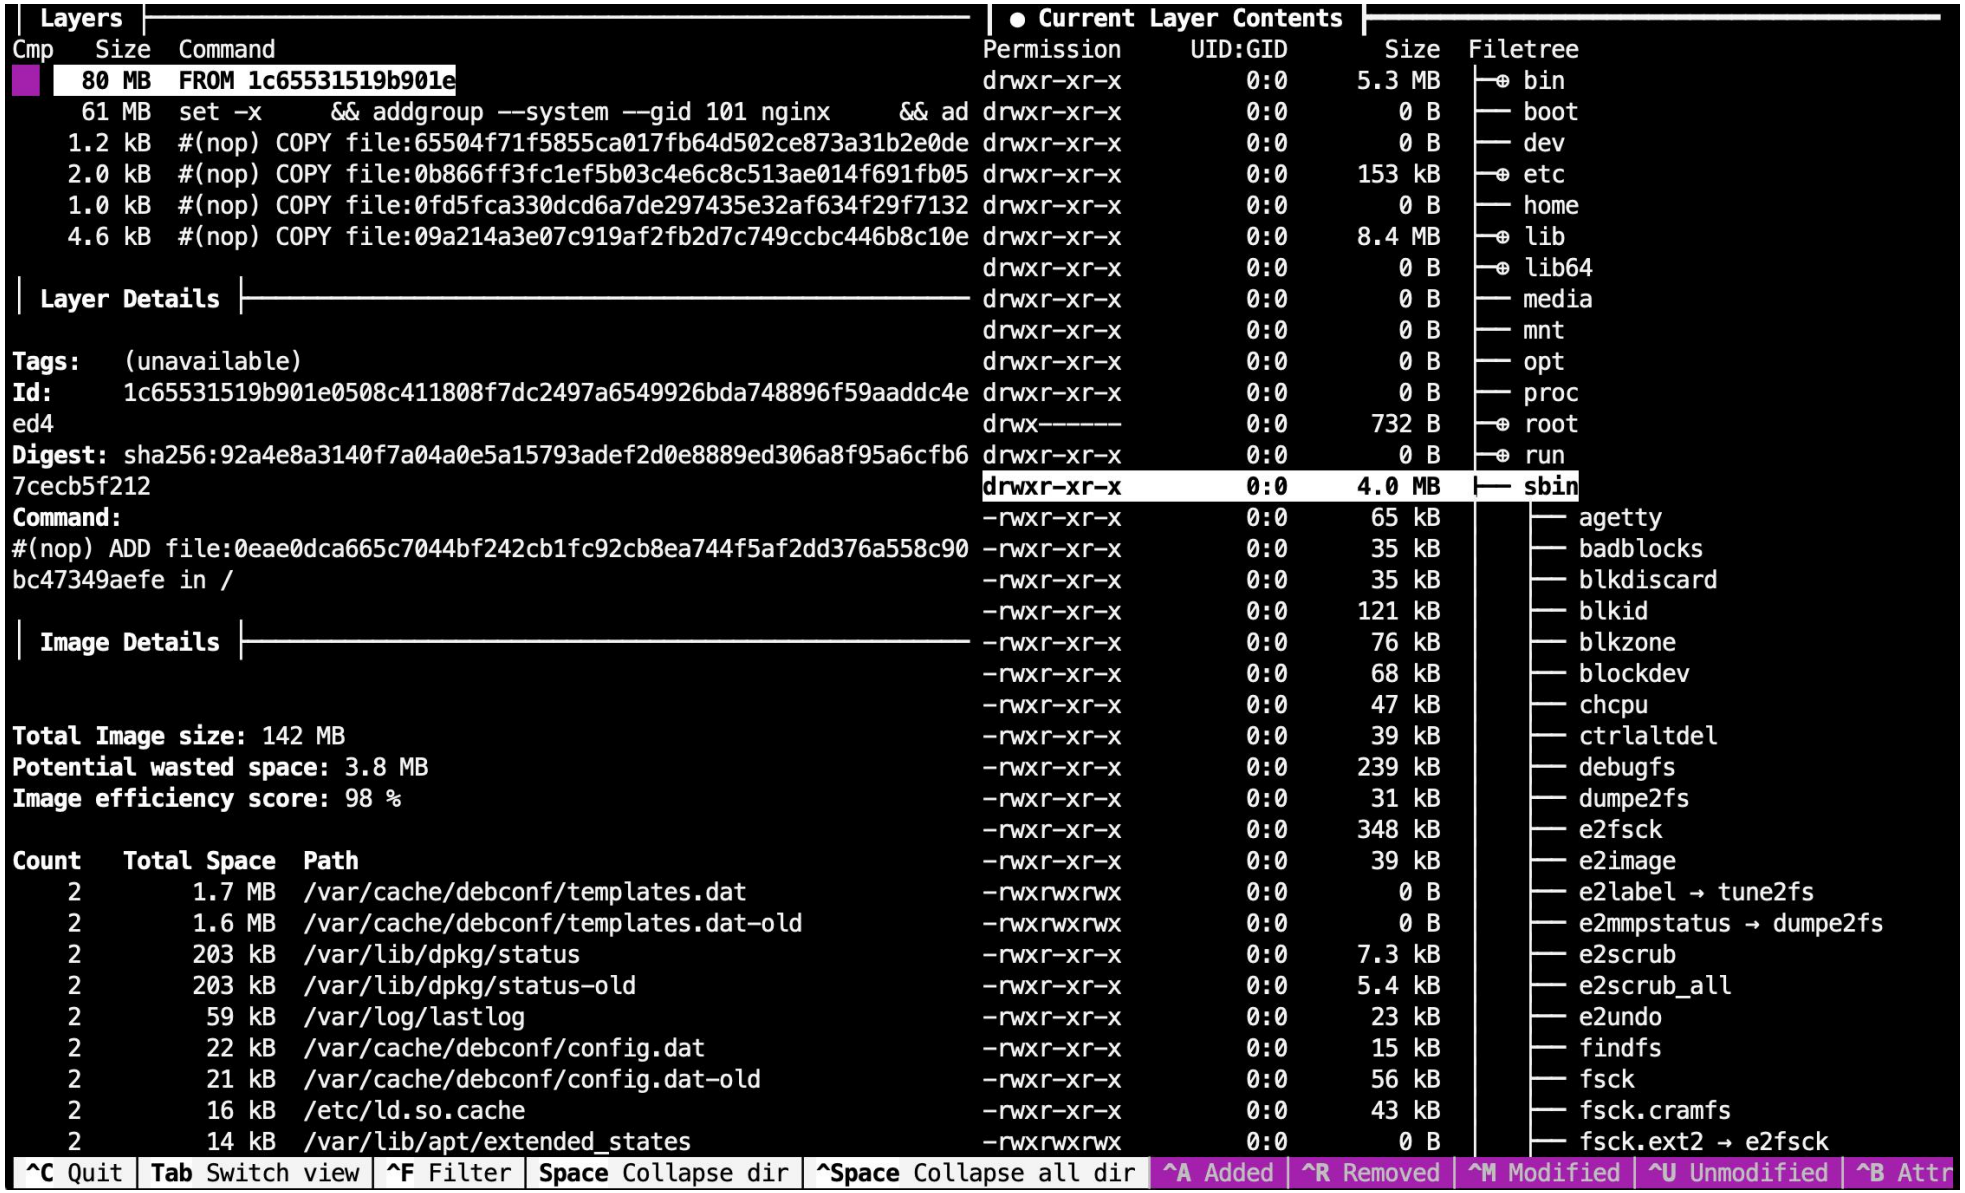

Nginx和debian镜像

- Nginx镜像基于debian:bullseye-slim构建
- debian:bullseye-slim 只是把根文件系统复制到一个空的文件夹
- 将Debian用户空间程序和host的内核相结合，容器表现的像一个完整的操作系统

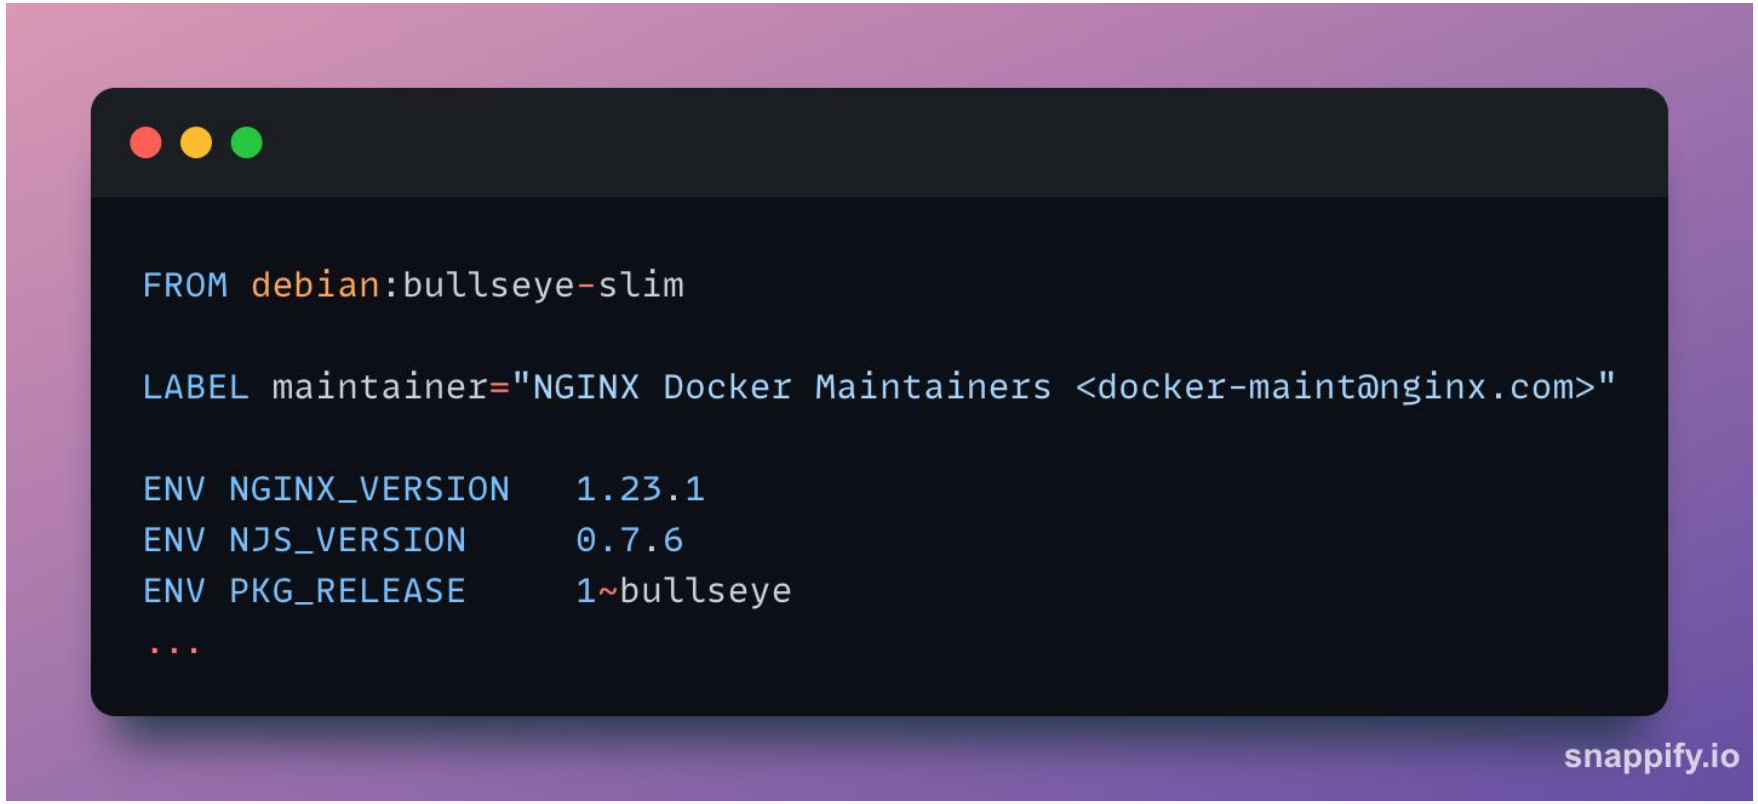

不使用镜像运行容器

- runc只需要一个普通的目录，里面至少有一个可执行文件和一个config.json
- 这个组合被称为bundle

```
# tree
.
├── config.json
└── rootfs
    └── hello
# cat config.json
{
  "ociVersion": "1.0.2-dev",
  "process": {
    "terminal": false,
    "user": {
      "uid": 0,
      "gid": 0
    },
    "args": [
      "/hello"
    ],
    "env": [
      "PATH=/usr/local/sbin:/usr/local/bin:/usr/sbin:/usr/bin:/sbin:/bin",
      "TERM=xterm"
    ],
    "cwd": "/",
    "capabilities": {
  ...
}

# runc create mycontainer
# runc start mycontainer
Hello world!
# runc list
ID           PID         STATUS      BUNDLE                    CREATED                          OWNER
mycontainer  0           stopped     /root/docker/my_container  2022-08-22T06:10:03.102507972Z   root
# runc delete mycontainer
```

为什么需要镜像

- 镜像是Docker的主要创新
  - 分层结构
  - 层的不可变性
- 镜像解决了高效构建和存储的问题
  - 消除文件的重复，缩短构建时间，减少空间需求，
  - 由于层的不可变性，我们只需要解压一次镜像，然后根据需要多次加载
  - 唯一可变的层是最上面的层

容器运行时

- 使用runc可以启动任意多的容器
- 需要一个容器管理器，管理多个容器
  - 跟踪容器的状态
  - 失败时重启容器
  - 容器终止时释放资源
  - 拉取镜像
  - 容器网络配置

容器管理器

- 在单个主机上进行容器生命周期管理的软件
- 常见的容器管理器
  - containerd
  - cri-o
- runc是一个命令行工具，containerd是一个守护进程

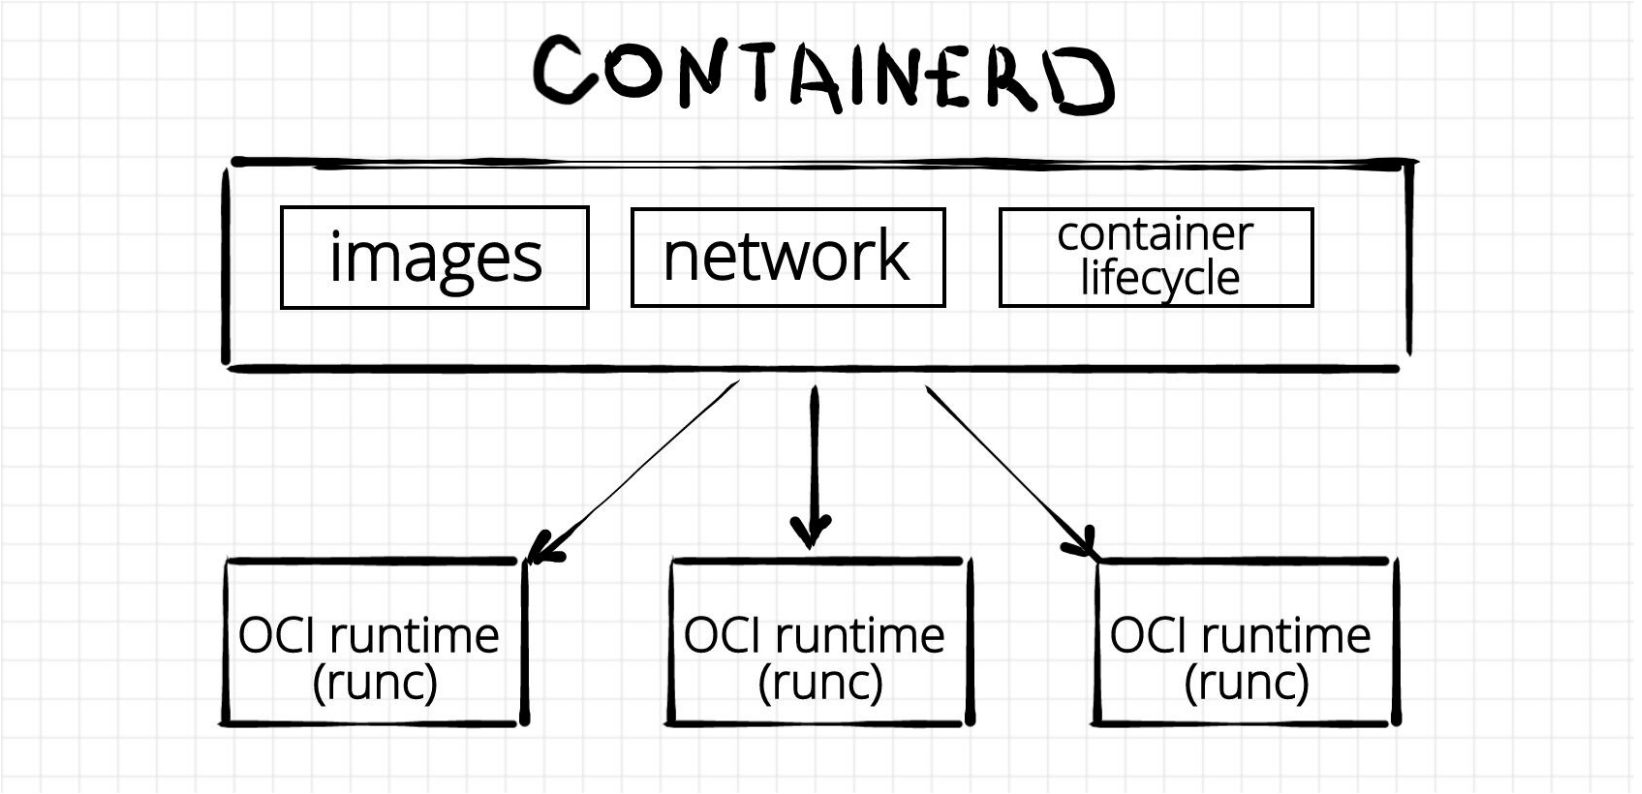

容器管理器

- Container Runtime Interface (CRI) 任何符合CRI的容器管理器都可以无缝接入进Kubernetes
- Kubernetes 通过CRI 使用不同的容器管理器

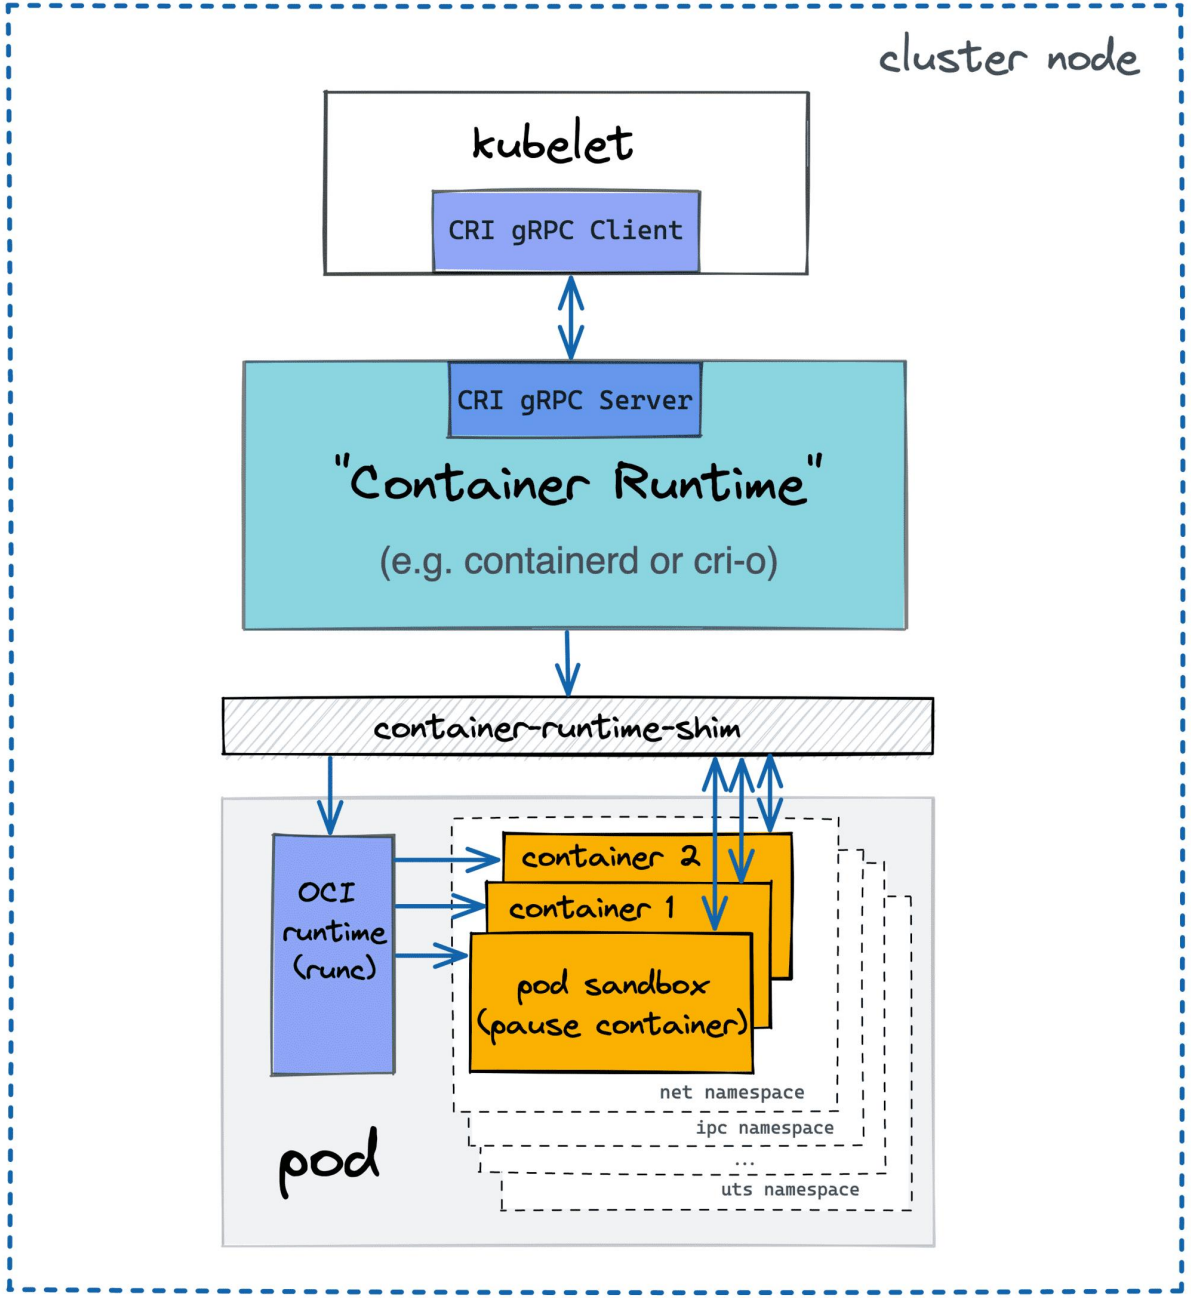

容器管理器

- Kubernetes已去除对docker的依赖

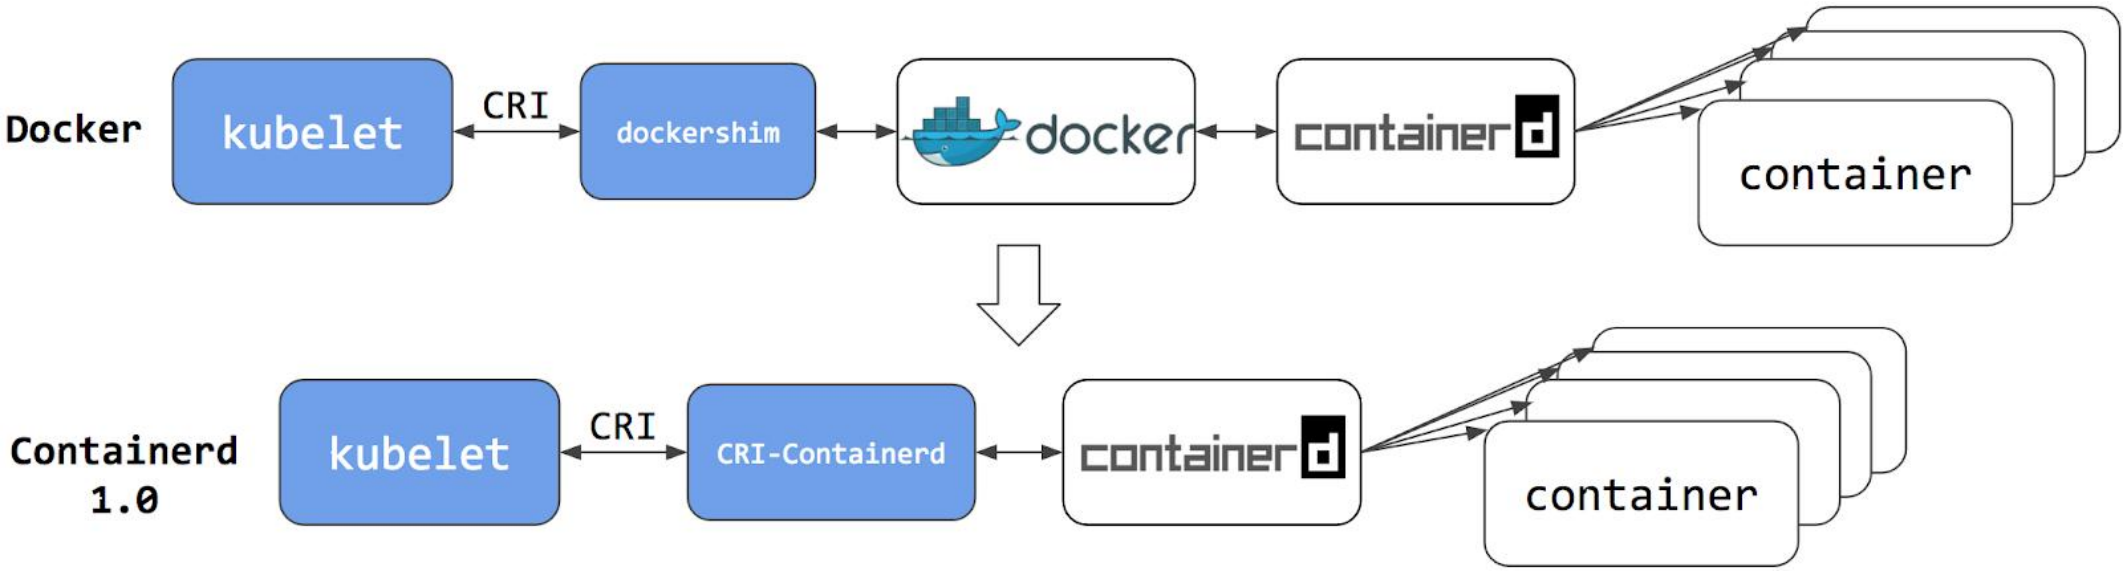

Runtime shim

- 容器管理器可以由于崩溃、更新或其他一些原因而被重新启动，不能直接从容器管理器进程中启动runc
- 需要一个与容器进程一样长时间运行的辅助进程，Runtime shim
- shim是一个轻量级的守护程序，它启动runc并控制容器进程
- shim与容器进程紧密结合，但与管理器的进程完全分离
- 容器和容器管理器之间的所有通信都是通过 shim 进行的

shim的职责

- 启动runc并处理容器创建错误
- 将容器的stdout和stderr定向到日志文件
- 跟踪并报告容器的退出代码。容器进程将被reparent到shim，这样shim可以收到容器进程终止的通知
- 提供attach到运行中容器的服务

进程ID

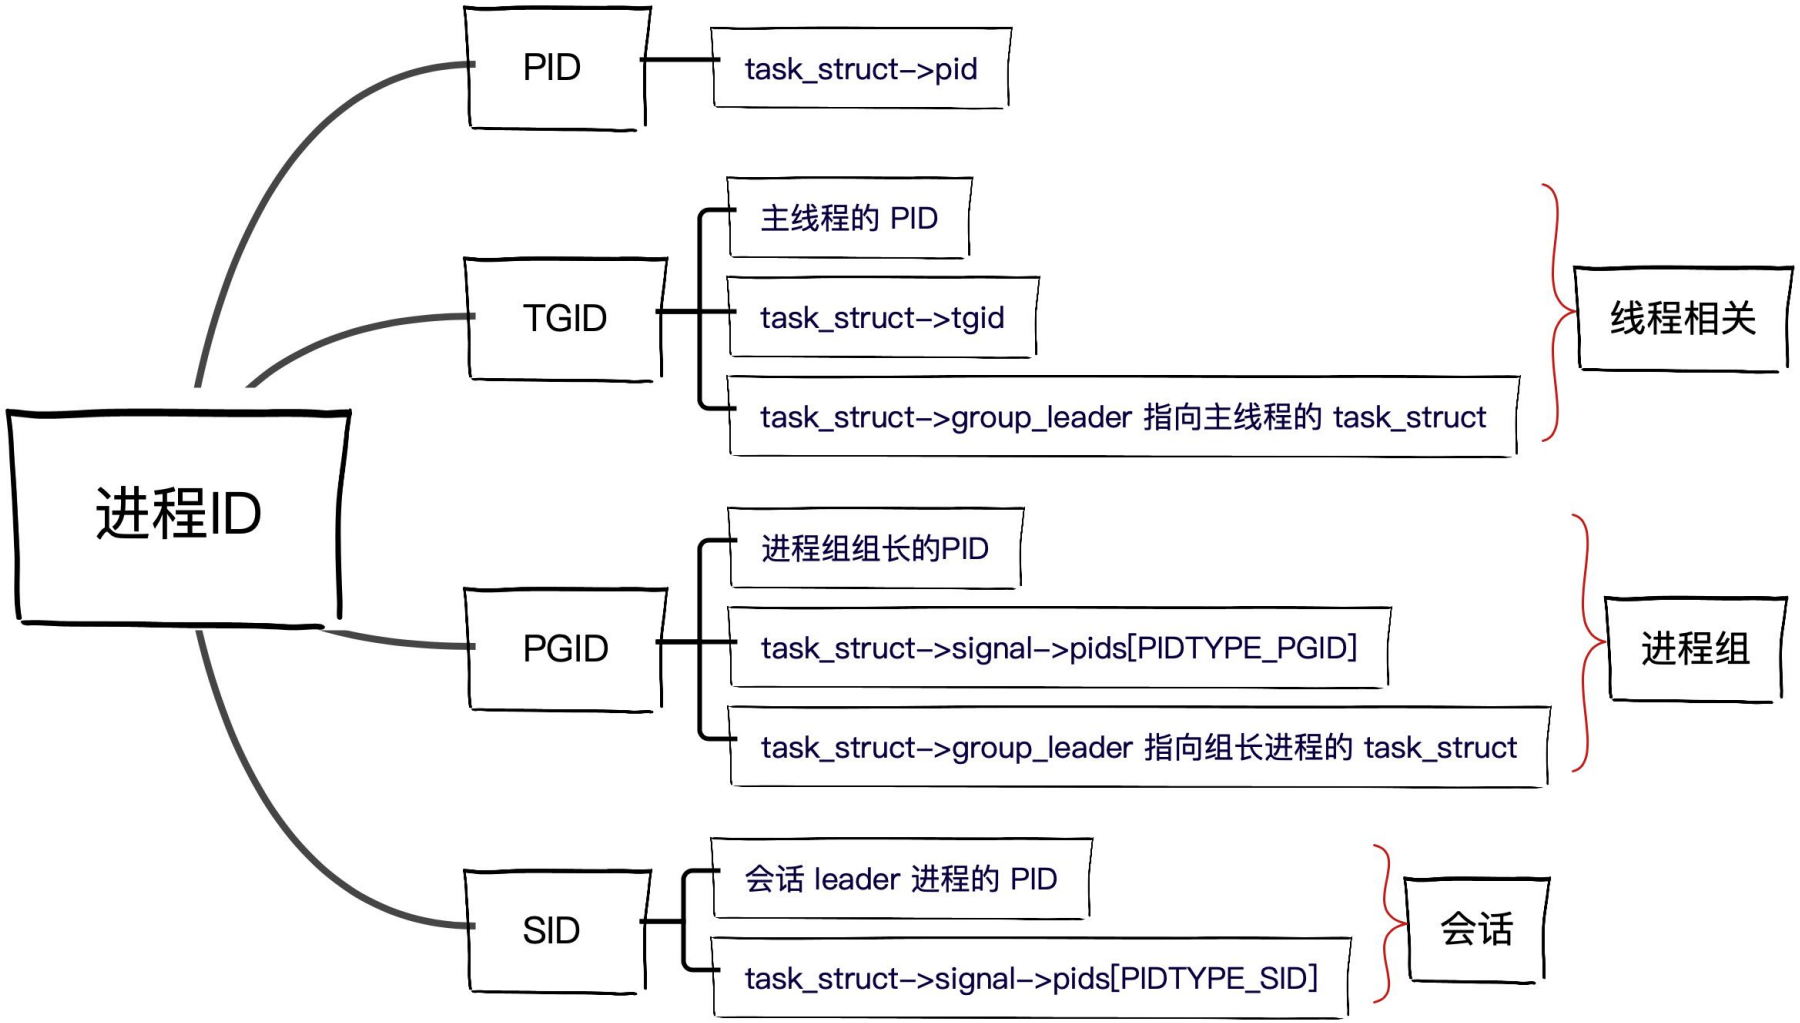
进程ID
PID
task_struct->pid
TGID
主线程的 PID
task_struct->tgid
task_struct->group_leader 指向主线程的 task_struct
线程相关
PGID
进程组组长的PID
task_struct->signal->pids[PIDTYPE_PGID]
task_struct->group_leader 指向组长进程的 task_struct
进程组
SID
会话 leader 进程的 PID
task_struct->signal->pids[PIDTYPE_SID]
会话

进程间关系

- 内核中所有进程的 task_struct 会形成多种组织关系
  - 亲属关系
  - 会话和进程组关系

亲属关系

- 进程通过 fork() 创建出一个子进程，就形成来父子关系，fork出多个子进程，那么这些子进程间属于兄弟关系
- 当一个进程创建了子进程后，它应该通过系统调用 wait() 或者 waitpid() 等待子进程结束，回收子进程的资源。而子进程在结束时，会向它的父进程发送 SIGCHLD 信号。因此父进程还可以注册 SIGCHLD 信号的处理函数，异步回收资源。
- 如果父进程提前结束，那么子进程将把1号进程 init 作为父进程。
- 进程都有父进程，负责进程结束后的资源回收。在子进程退出且父进程完成回收前，子进程变成僵尸进程。僵尸进程持续的时间通常比较短，在父进程回收它的资源后就会消亡。如果父进程没有处理子进程的终止，那么子进程就会一直处于僵尸状态。

亲属关系

- 进程描述符 task_struct 的 parent 指向父进程，children 指向子进程链表的头部，sibling 把当前进程插入到兄弟链表中
- 通常情况下，real_parent 和 parent 是一样的。如果在 bash 上使用 GDB 来 debug 一个进程，这时候进程的 parent 是 GDB，进程的 real_parent 是 bash

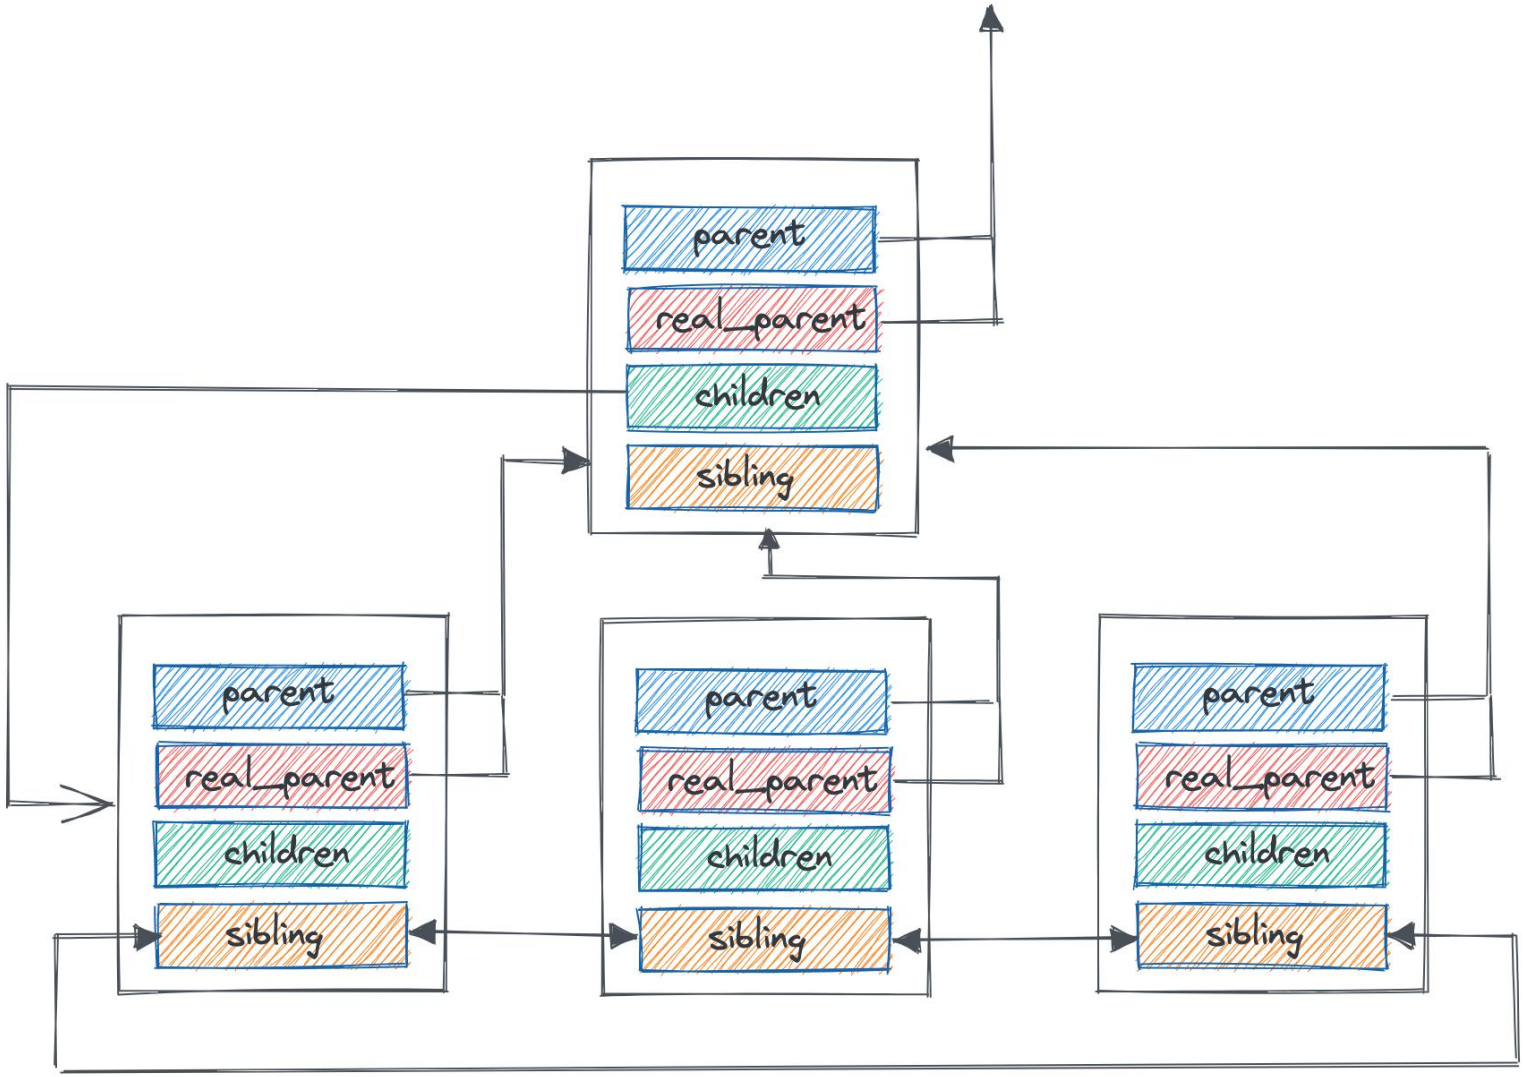

会话、进程组关系

- Linux 系统中可以有多个会话（session），每个会话可以包含多个进程组，每个进程组可以包含多个进程。
- 会话是用户登录系统到退出的所有活动，从登录到结束前创建的所有进程都属于这次会话。登录后第一个被创建的进程（通常是 shell），被称为会话 leader
- 进程组用于作业控制。一个终端上可以启动多个进程组。
- 会话有一个前台进程组，还可以有一个或多个后台进程组。只有前台进程可以从终端接收输入，也只有前台进程才被允许向终端输出。

会话、进程组关系

- 通过 cat | head 创建了第一个进程组，包含 cat 和 head 两个进程。
- 按下 Ctrl + z，会发送信号 SIGTSTP 给前台进程组的所有进程，该信号的缺省行为是暂停作业执行。暂停的作业会让出终端，并且进程不会再被调度，直到它们收到 SIGCONT 信号恢复执行。
- 通过 ps j | more 创建了另一个进程组，包含 ps 和 more 两个进程。

会话、进程组关系

```
# ps 的参数 j 表示用任务格式显示进程。输出中的 STAT 列是进程的状态码
D    uninterruptible sleep (usually IO)
I    Idle kernel thread
R    running or runnable (on run queue)
S    interruptible sleep (waiting for an event to complete)
T    stopped by job control signal
t    stopped by debugger during the tracing
W    paging (not valid since the 2.6.xx kernel)
X    dead (should never be seen)
Z    defunct ("zombie") process, terminated but not reaped by its parent

# 进程除了大写字母代表的进程状态，还跟着一个附加符号
s ：进程是会话 leader 进程
+ ：进程位于前台进程组中
```

会话、进程组关系

- bash 是这个会话的 leader 进程，它的 PID、PGID 和 SID 相同，都是1532。这个会话其他所有进程的 SID 也都是1532。
- cat | head 进程组的 PGID 是 1760
- ps j | more 进程组的 PGID 是 1762
- 用管道连接的进程包含在同一个进程组中，每个进程组内第一个进程成为 Group Leader，并以 Group Leader 的 PID 作为组内进程的 PGID。
- 会话有一个前台进程组，还可以有一个或多个后台进程组，只有前台作业可以从终端读写数据。

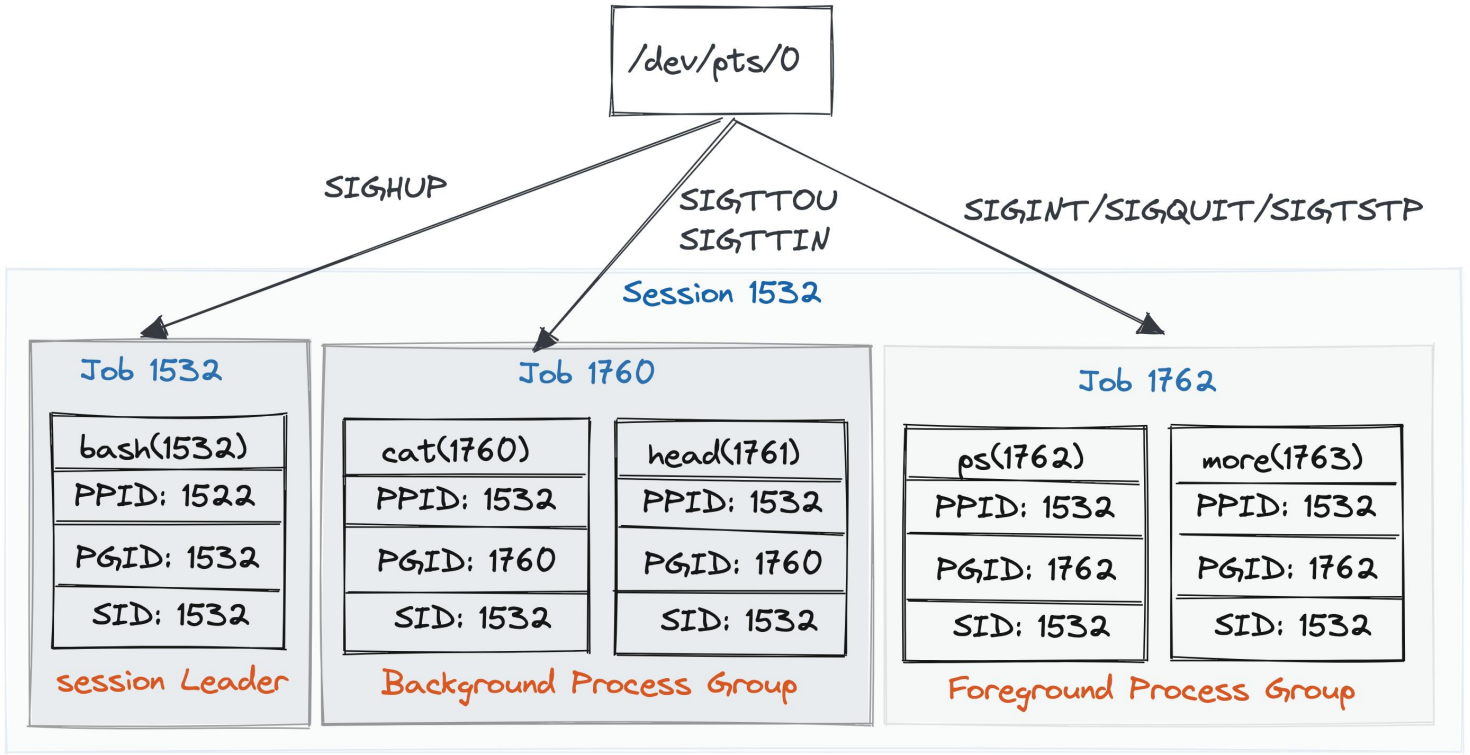

如何创建一个守护进程

- 普通进程的stdin、stdout和stderr被连接到会话的控制终端
- 启动守护进程一般使用 double fork technique
  - fork -> setsid -> fork
  - 主要目的是将守护进程与会话的控制终端分离

shim的demo实现

- 前台进程fork出shim守护进程，然后立即退出
- shim守护进程通过创建一个新的session，并将stdio重定向到/dev/null，使stdio从父进程中分离出来
- 创建 pipe，用来将shim与容器的输出连接起来
- 守护进程再fork出一个子进程，即容器进程的前身。这个进程用提供的参数（bundle目录、config.json等）执行runc create 创建容器进程
- 将pipe设置为容器进程前身的stdio，在容器创建成功后，也设置为容器进程的stdio
- 守护进程等待容器进程前身终止，然后将该操作的状态报告给容器管理器。
- 守护进程开始为容器的stdio提供服务，同时也在等待容器的终止

```
int main() {
    if (int shim_pid = fork()) {
        // write shim_pid to file
        exit(0)
    }
    // redirect shim stdio to /dev/null
    dup2("/dev/null", STDIN_FILENO)
    dup2("/dev/null", STDOUT_FILENO)
    dup2("/dev/null", STDERR_FILENO)
    // create a new session
    setsid()
    // prepare pipe_out and pipe_err
    pipe_out = pipe()
    pipe_err = pipe()

    int runtime_pid = fork()
    if (runtime_pid == 0) {
        // redirect runc stdion to pipes
        dup2("/dev/null", STDIN_FILENO)
        dup2(pipe_out, STDOUT_FILENO)
        dup2(pipe_err, STDERR_FILENO)

        exec("runc create --bundle <...>")
    }
    // wait for the runtime process termination:
    waitpid(runtime_pid)
    // ... start serving container process ...
}
```

shim的demo实现

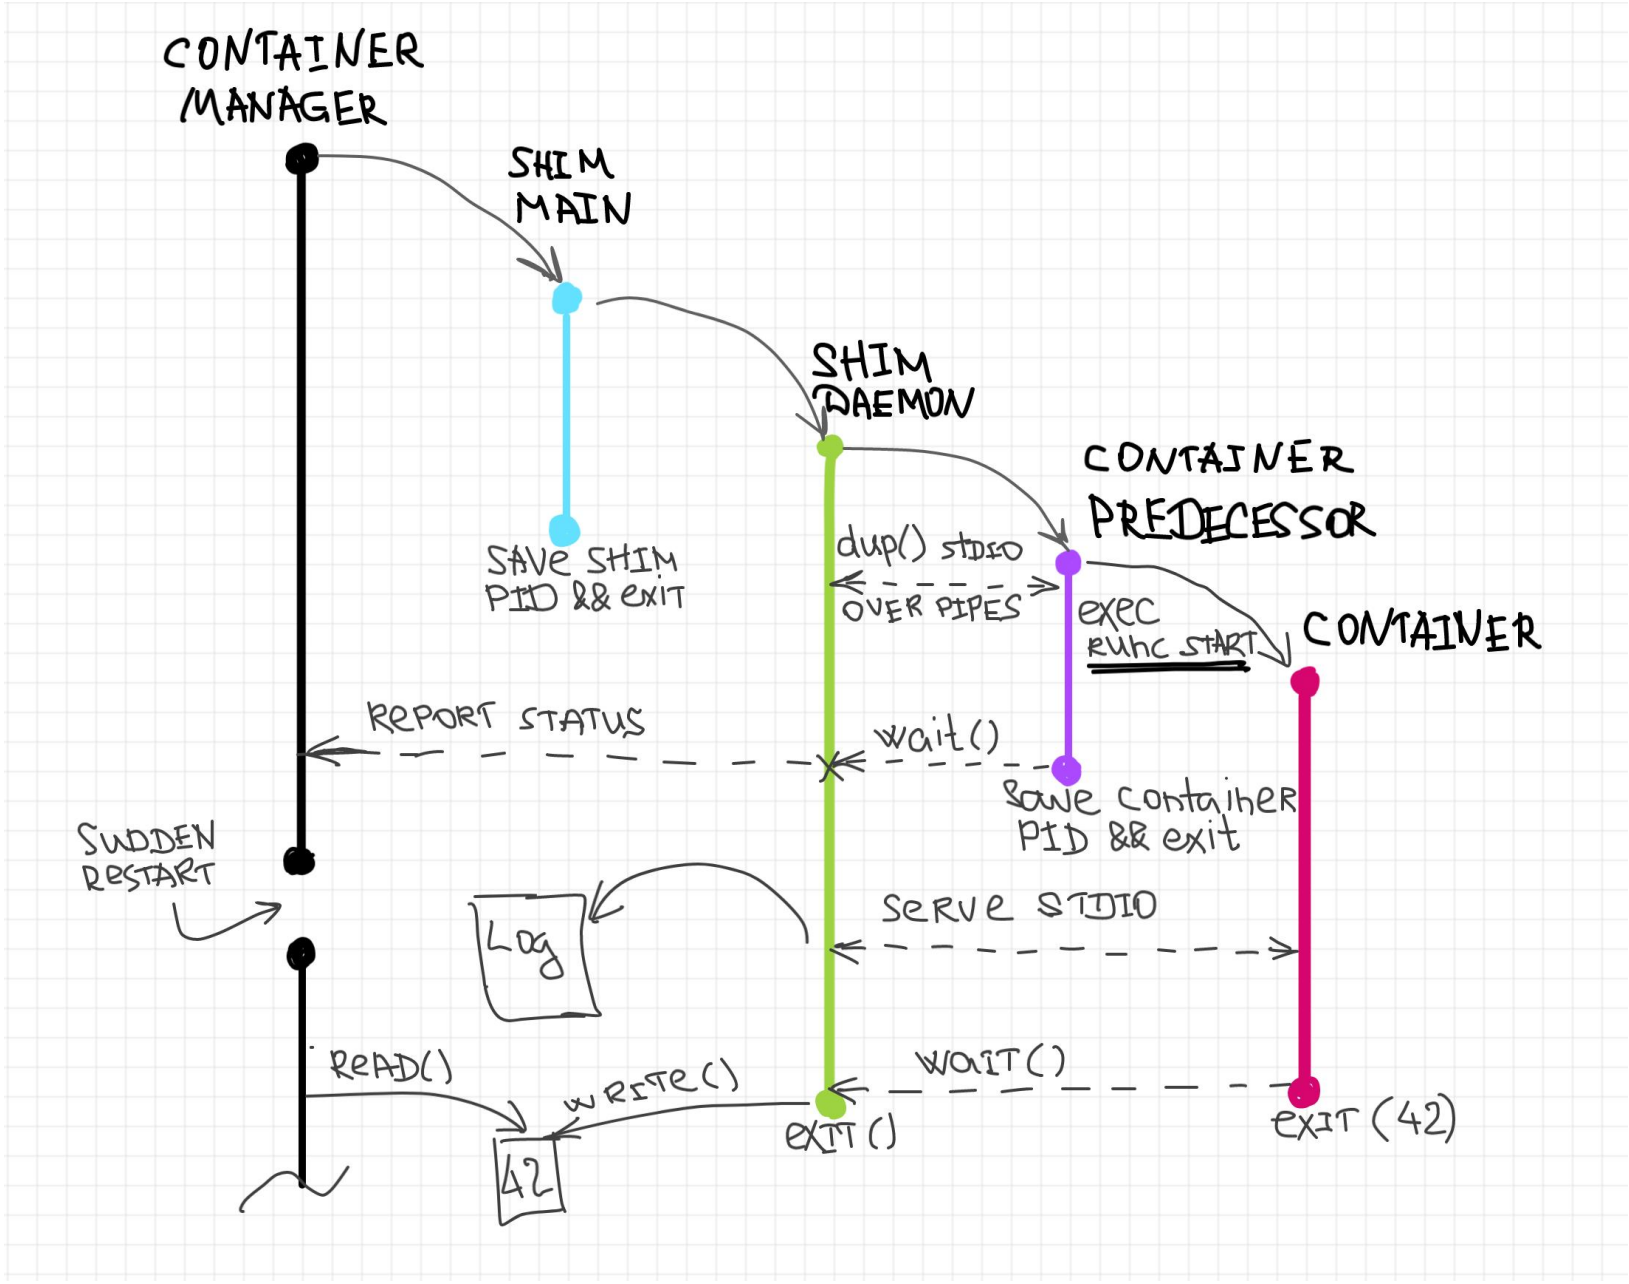

shim 演示

- docker run -d nginx
- ps axfo pid,ppid,command

```
2850634       1 /usr/bin/containerd-shim-runc-v2 -namespace moby -id ee0069f40fe9ee2df211e5176a631
2850655 2850634  \_ nginx: master process nginx -g daemon off;
2850714 2850655      \_ nginx: worker process
2850715 2850655      \_ nginx: worker process
```

- shim成为守护进程，parent PID被重新指定为PID 1

shim演示

- shim进程从容器的stdout和stder中读取内容，将它们存储到日志
- 默认情况下，shim会关闭容器的stdin，但如果在docker run命令中设置了-i 参数， stdin会保持开放
- shim充当了服务器的角色，可以通过shim暴露的端口使用RPC访问
- 当你连接到shim时，它会将容器的stdout和stderr内容回传给你
- 如果一个容器是以交互式模式（-i）创建的，那么当你attach到容器后，你在终端中输入的所有内容都将被发送到容器的stdin中

attach的实现

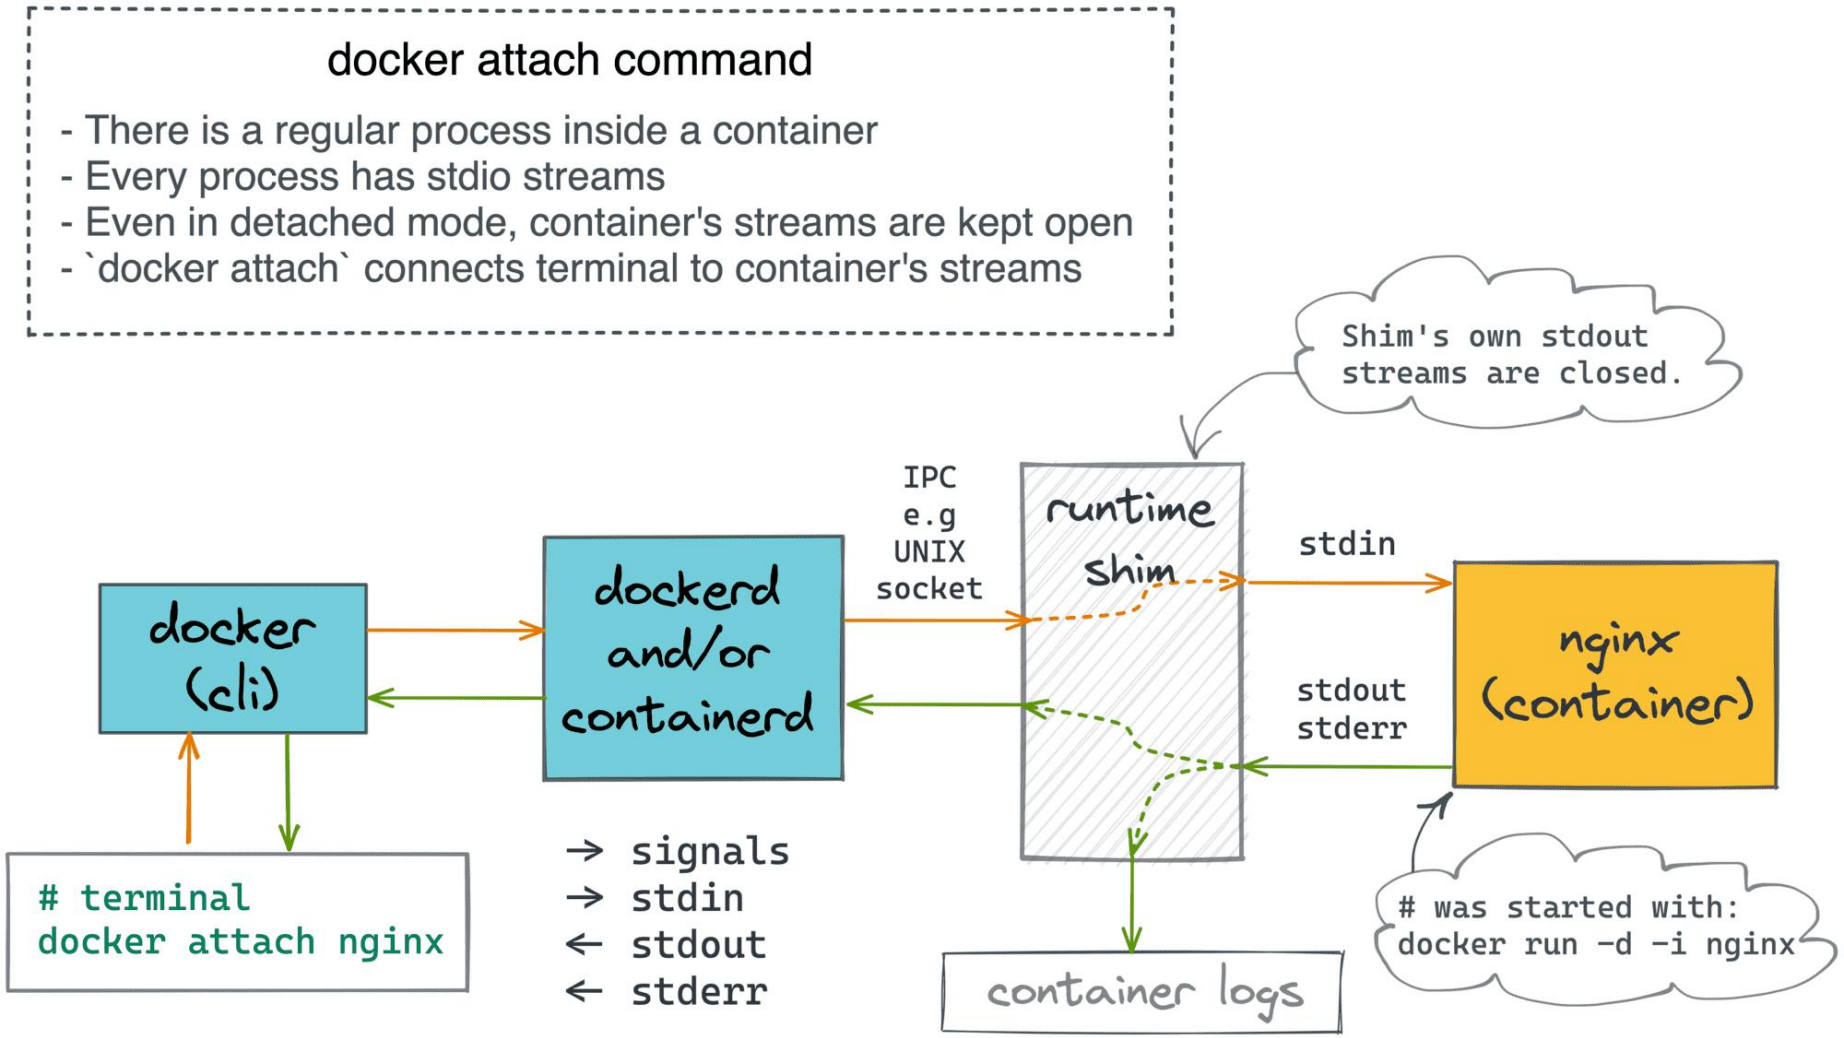
docker attach command
- There is a regular process inside a container
- Every process has stdio streams
- Even in detached mode, container's streams are kept open
- `docker attach` connects terminal to container's streams
Shim's own stdout streams are closed.
IPC e.g UNIX socket
runtime shim
stdin
stdout stderr
docker (cli)
dockerd and/or containerd
nginx (container)
terminal
docker attach nginx
→ signals
→ stdin
← stdout
← stderr
container logs
was started with:
docker run -d -i nginx

exec的实现

- exec命令启动的是一个全新的容器
- 新容器和目标容器共享同样的namespaces和同样的cgroups层次结构
- 从外面看，感觉就像在一个现有的容器内运行一个命令

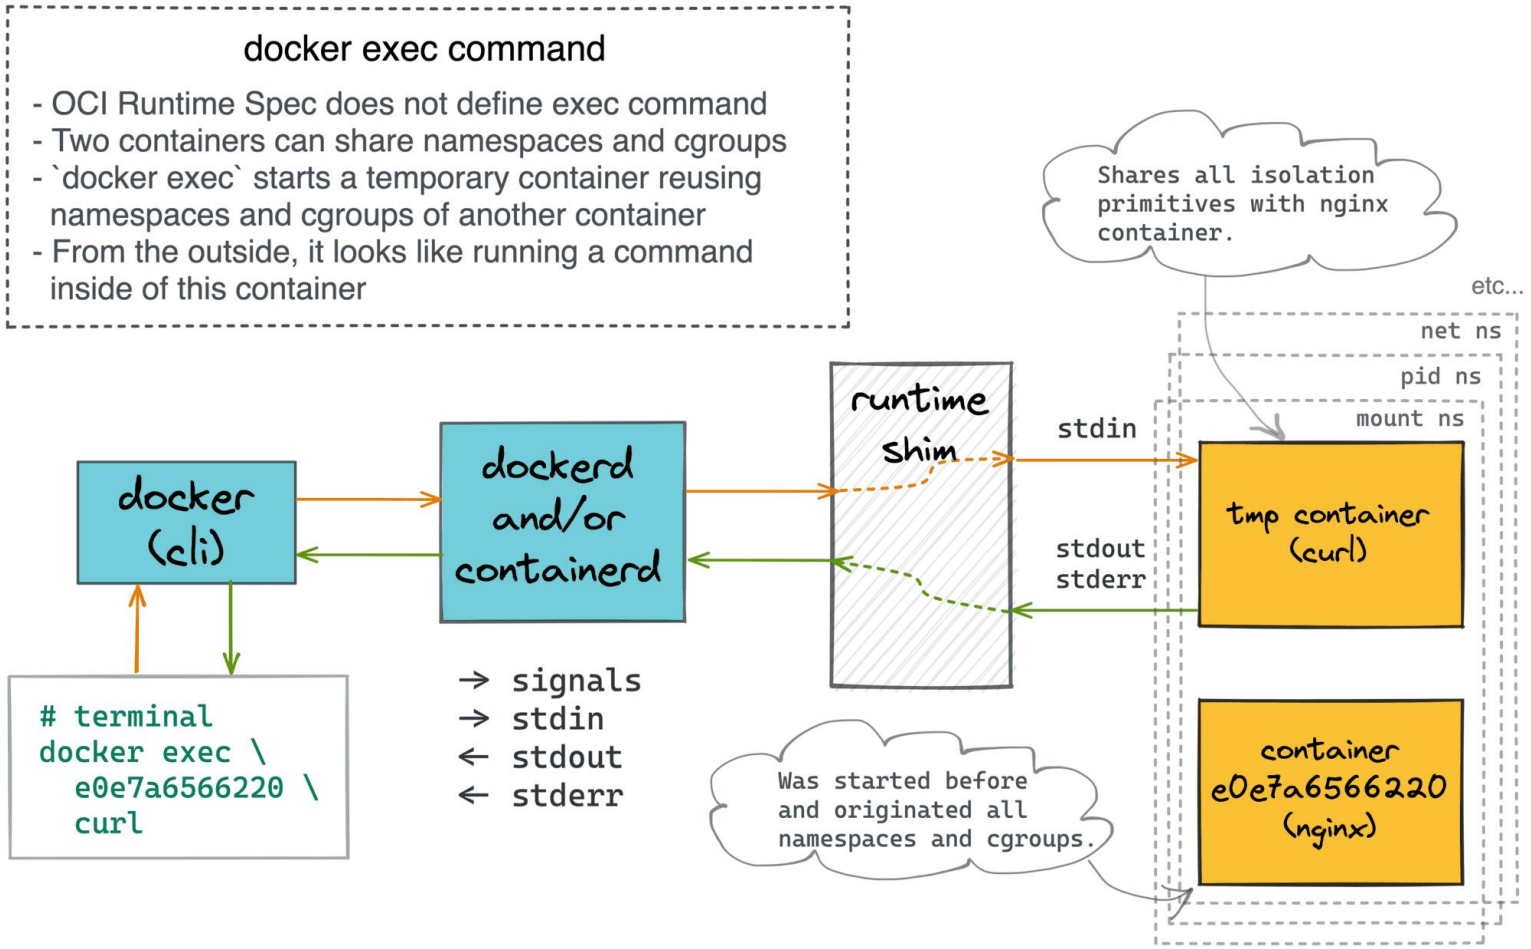

-t 参数的作用是什么

- --tty , -t Allocate a pseudo-TTY

Linux终端

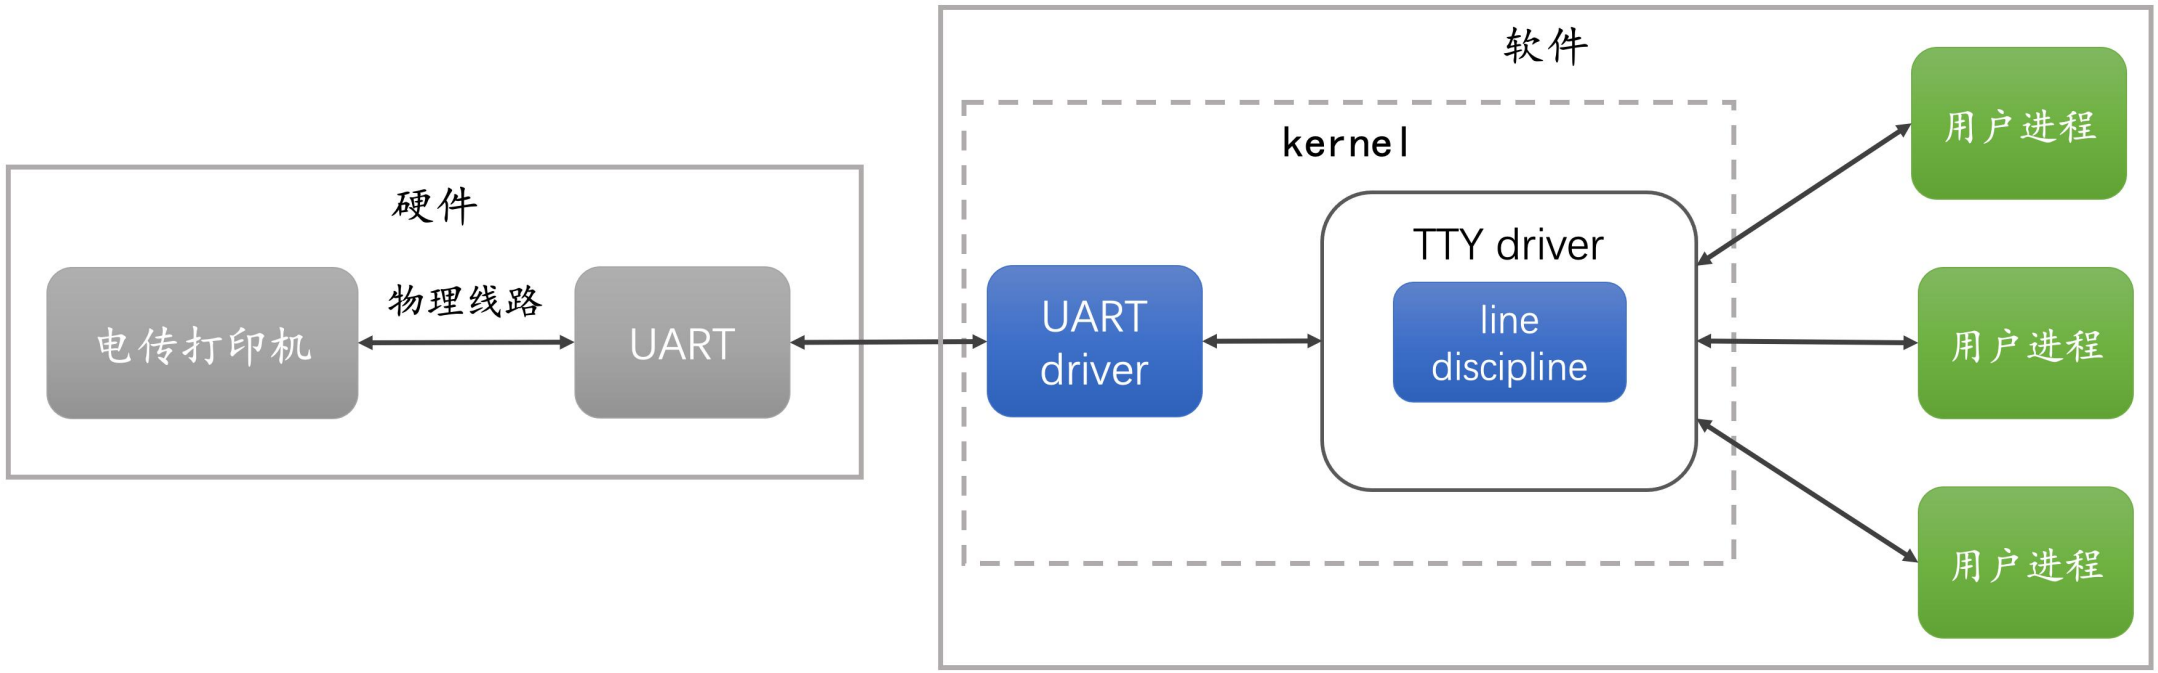
硬件
电传打印机
物理线路
UART
软件
kernel
UART driver
TTY driver
line discipline
用户进程
用户进程
用户进程

终端模拟器(terminal emulator)

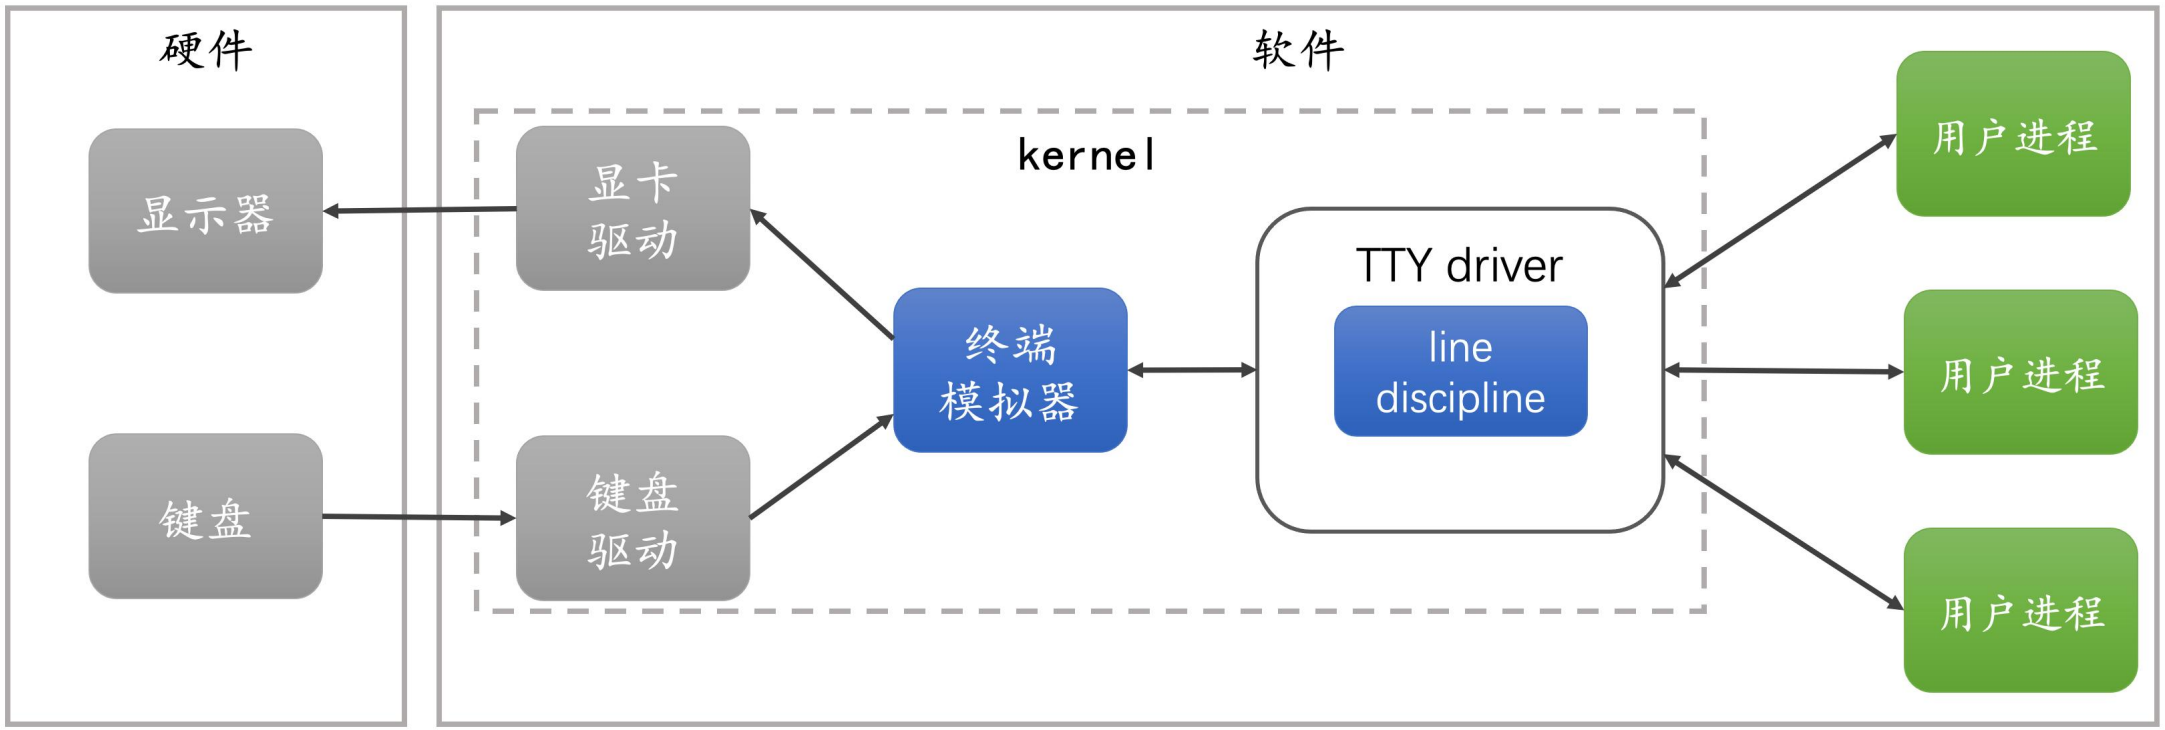

伪终端（pseudo terminal, PTY）

- PTY 是通过打开特殊的设备文件 /dev/ptmx 创建，由一对双向的字符设备构成，称为 PTY master 和 PTY slave
- terminal 持有 PTY master，通过 PTY master接收或发送字符到 PTY slave
- terminal 会 fork 一个 shell 子进程，并让 shell 持有 PTY slave
- shell 通过 PTY slave 接收字符，解释执行，并输出处理结果

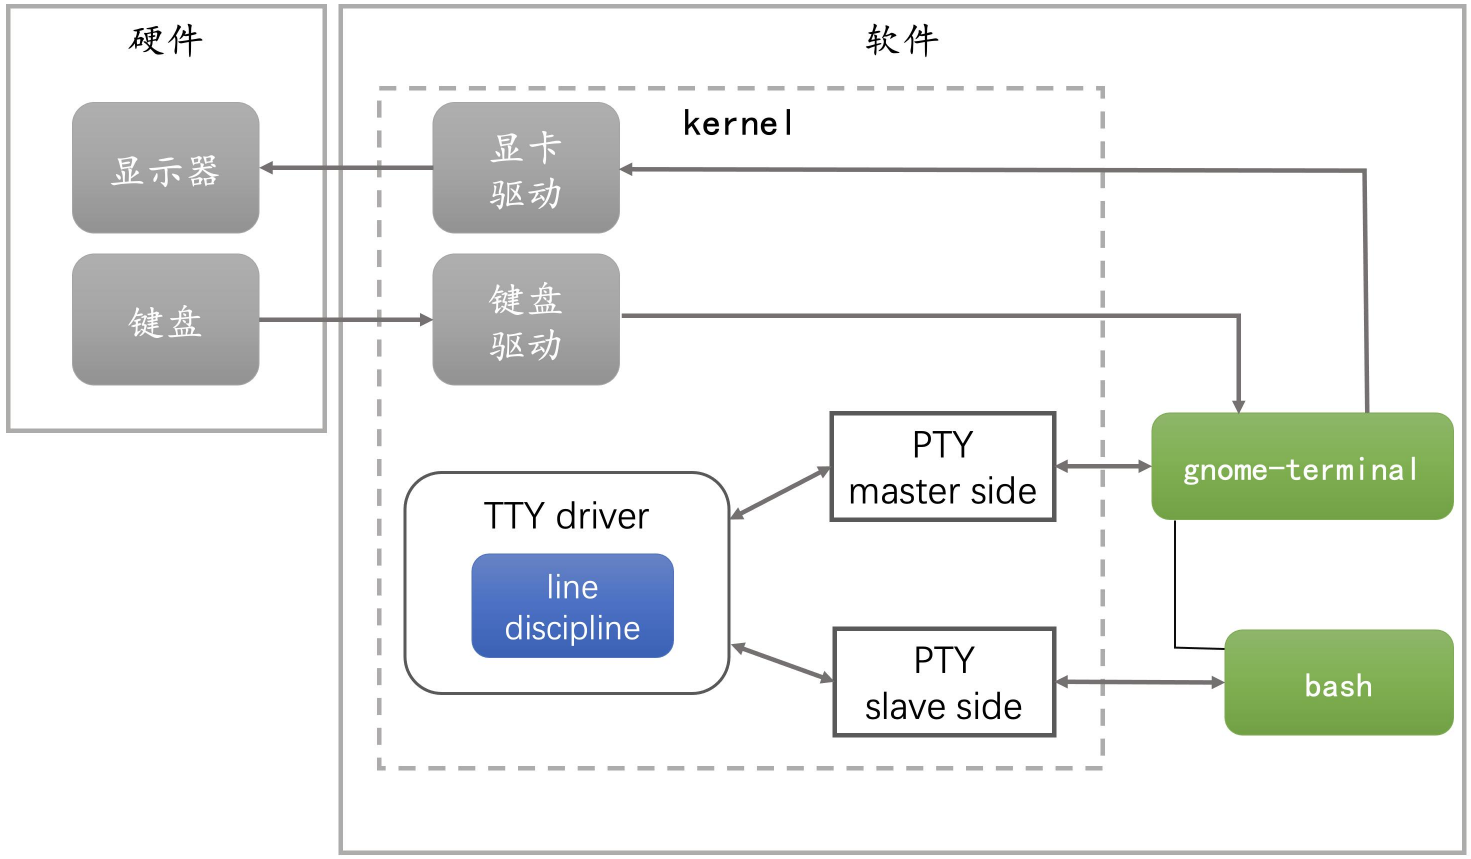

为什么需要PTY

- 实际上我们需要的是TTY driver
- 当用户启动一个普通程序时，它的stdio将被连接到PTY
  - 用户在PTY输入的所有内容都会进入程序的标准输入
  - 程序打印的所有内容都会返回到PTY
- PTY负责信号处理
  - 当用户在键盘上按下Ctrl-C时，通过TTY driver转换为SIGINT信号，发给前台进程
- PTY负责转换特殊字符（如退格、擦除字、清空行）
- PTY负责对字符进行缓冲
  - 按下回车键时，缓冲的数据才会传递给前台进程

-t 参数的作用

- -t 参数让容器进程持有PTY slave，shim持有PTY master
- 当执行attach的时候
  - stdin的路径：PTY master -> TTY driver-> PTY slave ->容器进程
  - stdout/stderr则是相反方向

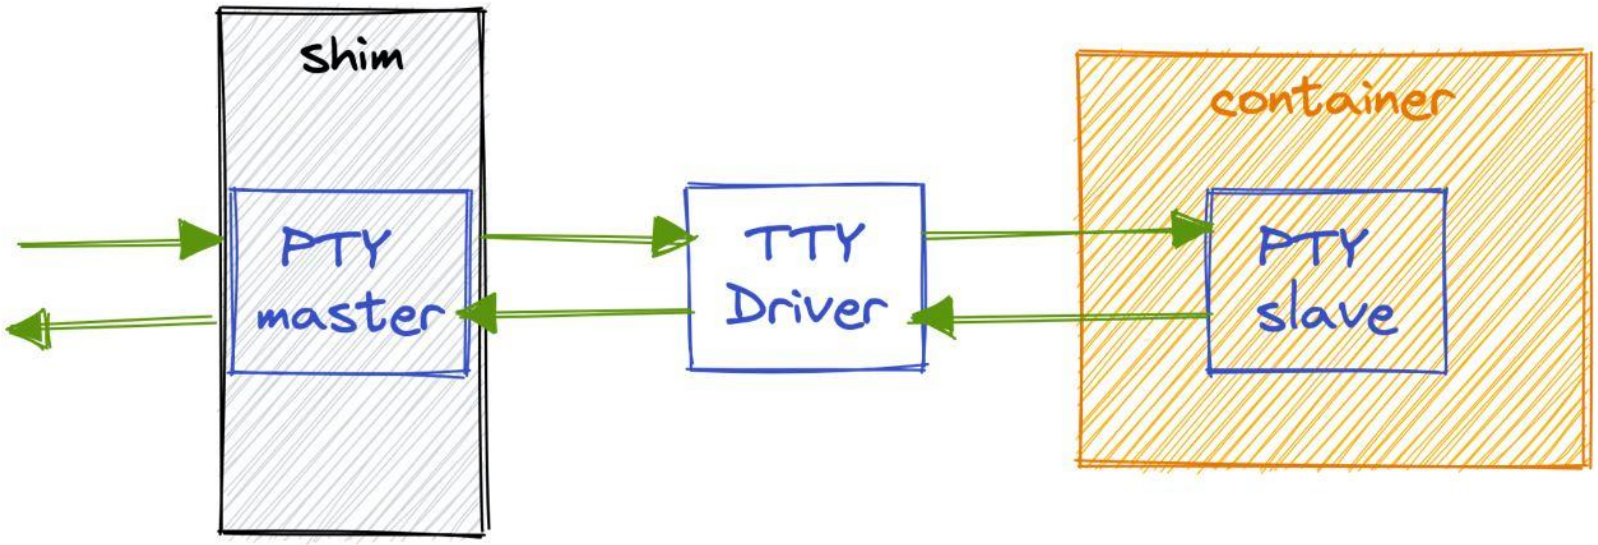

不加-t 参数会怎么样?

- 没有终端提示符
- 仍然能接收输入(-i 打开了stdin)
- 仍然能执行命令并输出
- 没有TTY driver，不能将Ctrl-C转换为信号

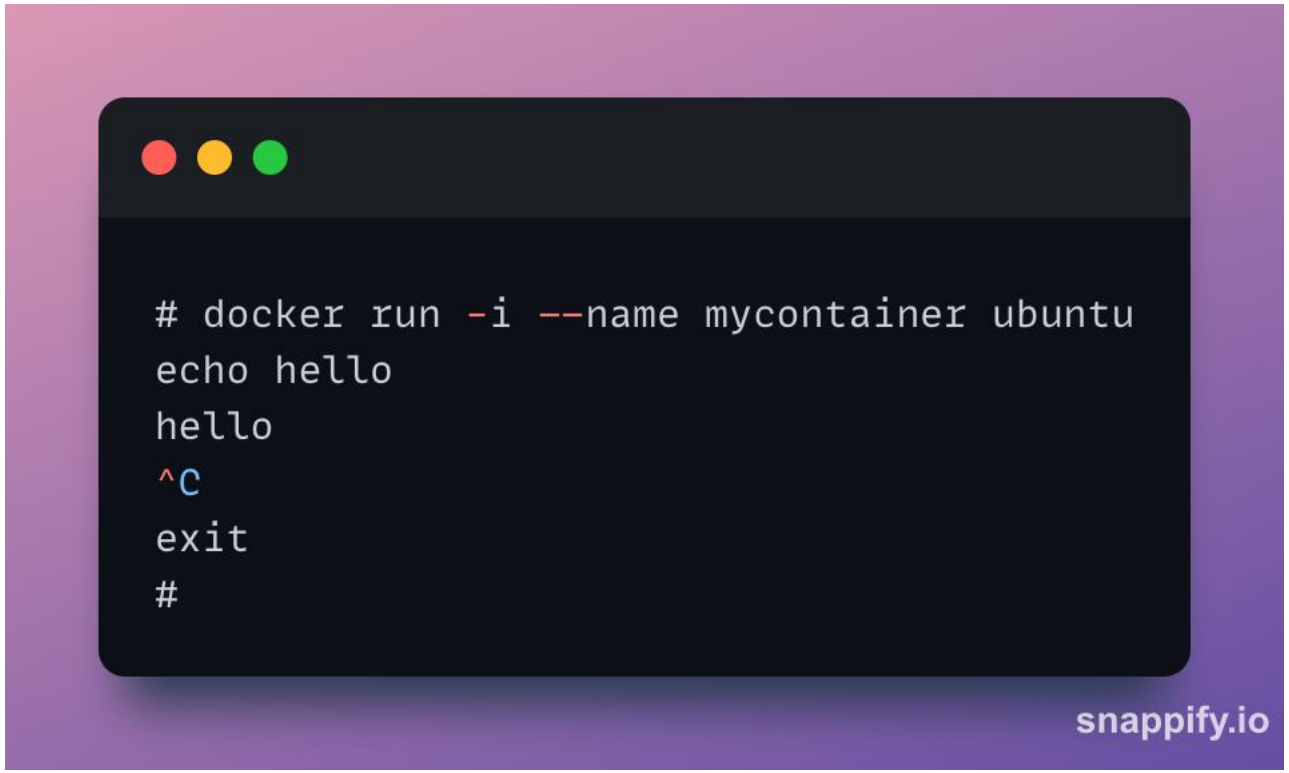

To Be Continued

- 容器网络
- Containers unplugged
  - Containers unplugged：Linux namespaces
  - Containers unplugged：understanding user namespaces
  - Containers unplugged：An introduction to control groups
  - Containers unplugged：Using seccomp to limit the kernel attack surface
  - Containers unplugged：The Linux capabilities model
  - Containers unplugged：Privileged programs

感谢您的参与!