

# **Rootless Kubernetes.**

## **Плюсы и минусы**

# О себе

- 80-е
  - ЕС ЭВМ, перфокарты
  - ОС ДЕМОС (UNIX)
  - Data General, Австрия
  - SCO UNIX - 220ix
- 90-е
  - Узел Relcom, Slackware, Debian, Linux Yes, переход на Linux
  - База Терем, Пермская товарная биржа- распределенная система торгов, АС Пенсия (SCO UNIX), перевод на Linux — распределенная система обмена информацией и создаваемого ПО, 1993-2018
  - Ведение новостей по Linux
- 0-е
  - Интернет провайдер на базе дистрибутива ALTLinux
  - Установка Linux в школах Пермского края, Поносов
- 10-е
  - Большие данные (hadoop, Solr, clickhouse, ...)
- 20-е
  - ALTLinux, Базальт Отдел Виртуализации, защищенные решения kubernetes
  - podsec, ALT-Orchestra/talos

# Поверхность атаки на кластер



- Доступ контейнера к HOST-системе путём монтирование каталогов HOST-системы с получением привилегий root
- Повышение привилегий контейнера
- Прямой доступ к узлу кластера через ssh
- Ошибки в настройках RBAC
- Доступ к токенам приложений
- ...

# Уменьшение поверхности атаки на кластер



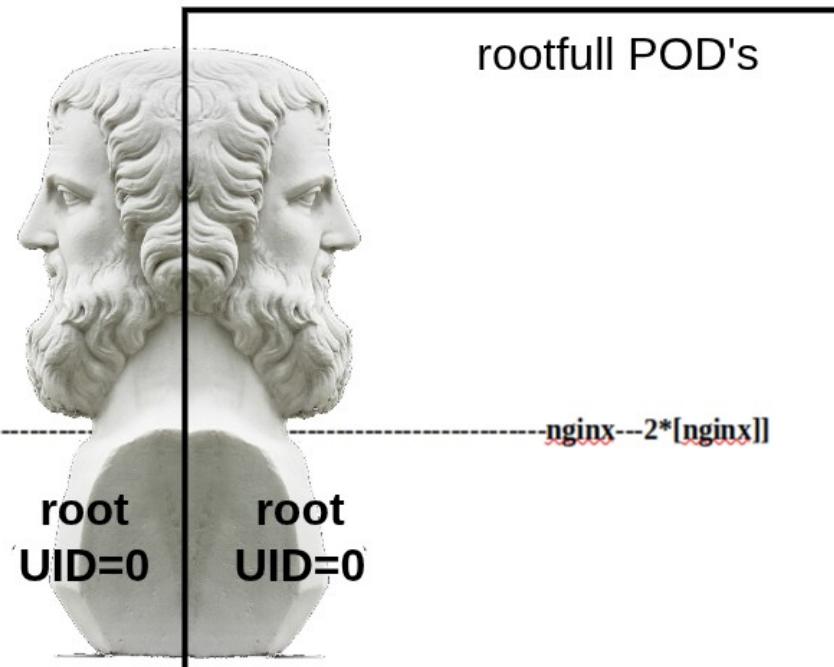
- **rootless kubernetes (usernetes/podsec-k8s):**
  - Доступ контейнера к HOST-системе путем монтирование каталогов HOST-системы с получением привилегий root
  - Повышение привилегий контейнера
- ***исключение доступа по ssh (talos/ALT Orchestra):***
  - Прямой доступ к узлу кластера через ssh
  - ..

# **podsec-k8s (usernetes) — rootless кластер**

# Одноликий янус - rootfull

## HOST система

```
USER=root
|-kubelet---12*[kubelet]
|-common---kube-scheduler---7*[kube-scheduler]
|-common---kube-controller---4*[kube-controller]
|-common---etcd---8*[etcd]
|-common---kube-apiserver---8*[kube-apiserver]
|-common---kube-proxy---5*[kube-proxy]
|-common---flanneld---8*[flanneld]
|-2*[common---coredns---7*[coredns]]
|-crio---10*[crio]
|-2*[common---...
|-...
```



# Опасность rootfull

```

apiVersion: apps/v1
kind: Deployment
spec:
  selector:
    matchLabels:
      app: nginx
  replicas: 1
  template:
    metadata:
      labels:
        app: nginx
    spec:
      containers:
        - name: nginx
          image: nginx:1.14.2
          volumeMounts:
            - mountPath: /hostRoot
              name: host-root
      volumes:
        - name: host-root
          hostPath:
            path: /

```

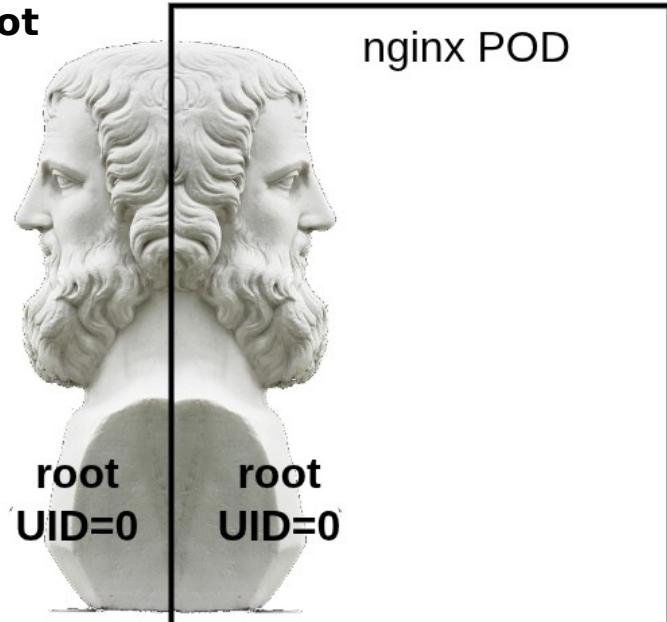
```

# # Запуск HOST-команд под root
# kubectl apply -f deployment.yaml
# kubectl exec -i pod/nginx-... -- \
  rm -rf /hostRoot/...

# # Запуск вредоносного ПО
# # с правами root
# kubectl run -i \
  --image <образ_с_вредоносным_ПО> \
  -- <вредоносное_ПО>

```

HOST система

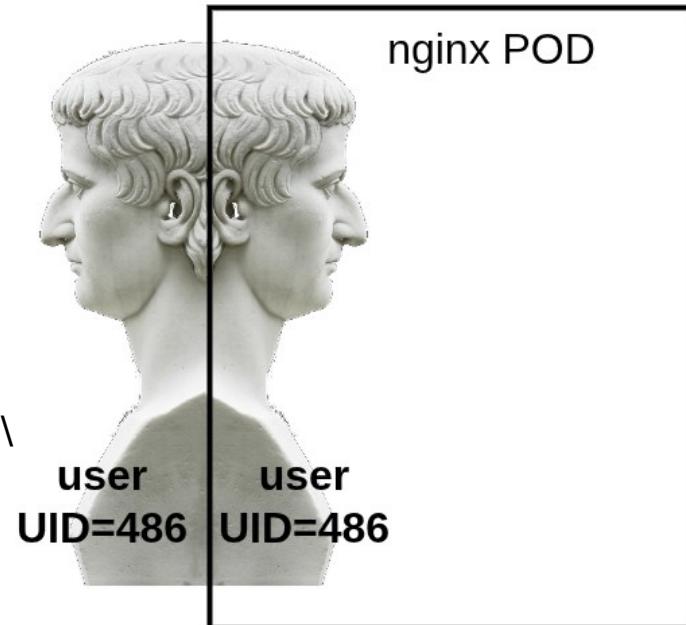


# Использование не-root образов

```

apiVersion: apps/v1      # # Запуск HOST-команд под root HOST системы
kind: Deployment
spec:
  selector:           # # Процесс запускается с правами
    matchLabels:
      app: nginx      # пользователь с ID=486
  replicas: 1           # kubectl apply -f deployment.yaml
  template:
    metadata:
      labels:
        app: nginx    # # Запуск вредоносного ПО
    spec:
      containers:
        - name: nginx  # # с правами пользователя
          image: nginx:1.14.2  UID=486
          volumeMounts:
            - mountPath: /hostRoot
              name: host-root
      volumes:
        - name: host-root
          hostPath:
            path: /

```

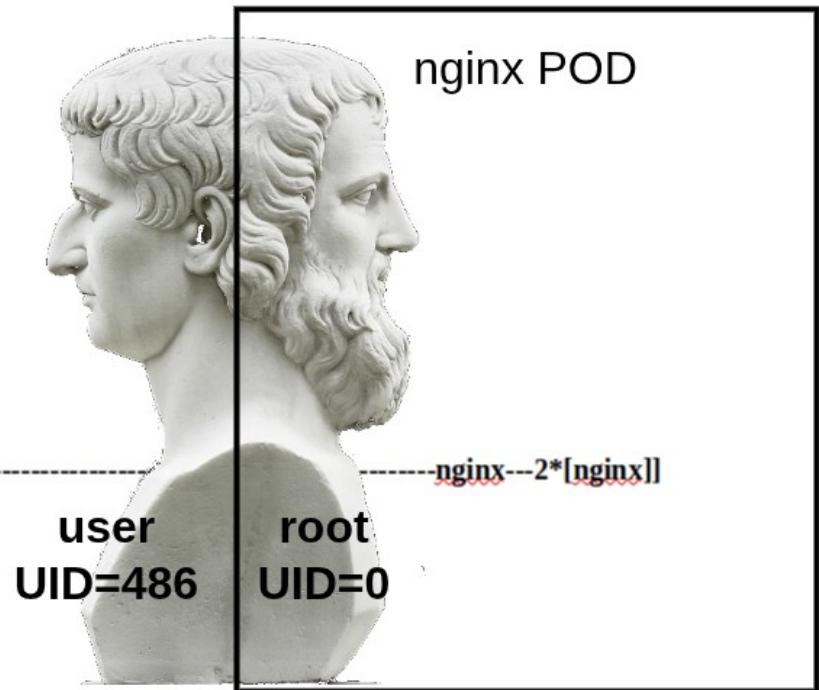


Поддержка rootless  
в нативном kuber >= v1.33

# Запуск POD в rootless-режиме

HOST система

```
USER=root
|-kubelet---12*[kubelet]
|-common---kube-scheduler---7*[kube-scheduler]
|-common---kube-controller---4*[kube-controller]
|-common---etcd---8*[etcd]
|-common---kube-apiserver---8*[kube-apiserver]
|-common---kube-proxy---5*[kube-proxy]
|-common---flanneld---8*[flanneld]
|-2*[common---coredns---7*[coredns]]
|-crio---10*[crio]
|-2*[common---...]
```



# Особенности rootless

```

apiVersion: apps/v1
kind: Deployment
spec:
  selector:
    matchLabels:
      app: nginx
  replicas: 1
  template:
    metadata:
      labels:
        app: nginx
  spec:
    containers:
      - name: nginx
        image: nginx:1.14.2
        volumeMounts:
          - mountPath: /hostRoot
            name: host-root
    volumes:
      - name: host-root
        hostPath:
          path: /

```

**# # Запуск HOST-команд НЕ под root**

```

# kubectl apply -f deployment.yaml
# kubectl exec -i pod/nginx-... -- \
  /hostRoot/...

```

**# # Запуск вредоносного ПО**

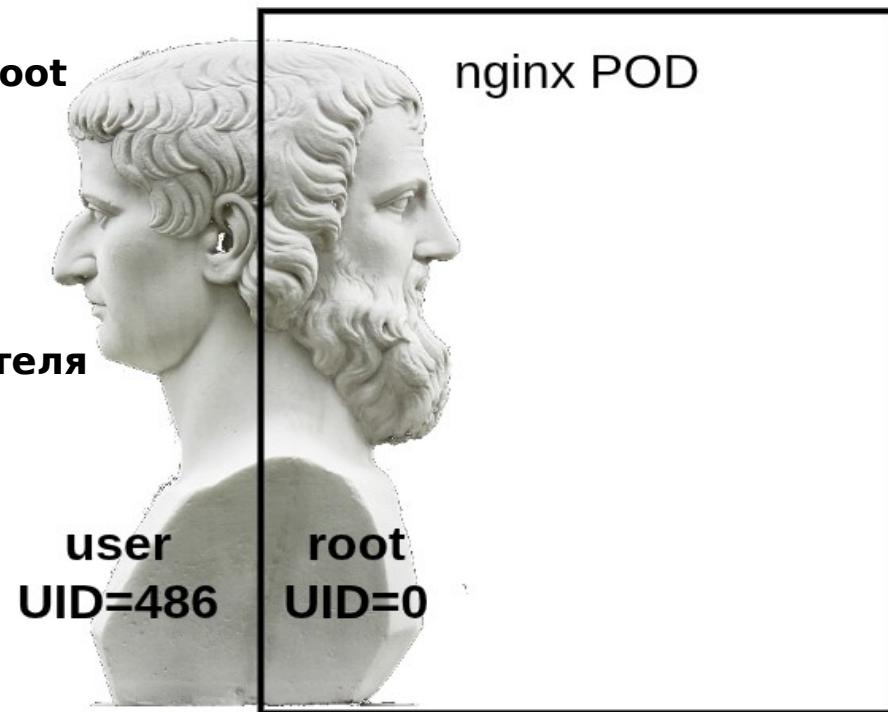
**# # с правами обычного пользователя**

```

# kubectl run -i \
  --image <образ_с_вредоносным_П0> \
  -- <вредоносное_П0>

```

## HOST система



# Дерево процессов rootfull kuber

Контейнеры (POD'ы) основных сервисов kubernetes вызываются с правами root.

Пользовательские контейнеры (POD'ы) в зависимости от указаниях в манифестах разворачивания могут вызываться с правами root, обычного пользователя или с версии v1.33 под указанным пользователем rootless-окружении.

```
USER=root
|- kubelet---12*[{kubelet}]
|- common---kube-scheduler---7*[{kube-scheduler}]
|- common---kube-controller---4*[{kube-controller}]
|- common---etcd---8*[{etcd}]
|- common---kube-apiserver---8*[{kube-apiserver}]
|- common---kube-proxy---5*[{kube-proxy}]
|- common---flanneld---8*[{flanneld}]
|- 2*[common---coredns---7*[{coredns}]]]
|- crio---10*[{crio}]
|- common---<root_kubernetes_POD>
|- common---<user_kubernetes_POD>
|- common---<rootless_kubernetes_POD>
|- ...
```

# Не зарекайся

- Медицина: «Не бывает абсолютно здоровых людей. Есть недообследованные»
- Программирование: «Не бывает абсолютно защищенных программ. Есть недопроанализированные»

Dockerfile:

```
FROM ubuntu
USER 4611686818427387984
...
```

**Полный rootless  
(usernetes/u7s)  
podsec  
(PODman SECurity)**

# Состояние на март 2023

- реализованы podman, kubernetes сервисы (команды), kubernetes docker-образы 1.26, разворачиваемые стандартно в rootfull режиме
- Требования ФСТЕК к июню 2023:
  - обеспечить запуск podman-контейнеров, разворачивание через kubeadm kubernetes-образов в rootless режиме
  - Три класса пользователей:
    - Администраторы кластера
    - Создатели образов
    - Пользователи образов

- Пользователи docker-образов имеют право использовать только подписанные образы от создателей образов. Любые «левые» схемы получения образов (podman load, podman build, ...) запрещены
- Система должна мониторить
  - попытки изменения прав,
  - несанкционированных изменений в работающих контейнерах,
  - использование «левых» образов, или образов с критическими CVE уязвимостями,
  - ...

# Дilemma

Самая сложная проблема - обеспечить разворачивание через kubeadm kubernetes-образов в rootless режиме по причине отсутствия на тот рабочего момента решения.

Варианты:

- Подождать когда появится решение и перенести его в ALTLinux.
- Реализовать собственное решение.

# Варианты rootless kuber

	kind	minikube	k3s	Usernetes Gen1	Usernetes Gen2
<b>Runtime environment</b>	Docker compose	Docker compose	Docker compose	Docker compose	<b>kubeadm</b>
<b>Containers Policy</b>	Experiment	No	Experiment	<b>Yes</b>	<b>Yes</b>
<b>Podman (CRI-O)</b>	Experiment	No	Experiment	<b>Yes</b>	<b>Yes</b>
<b>Namespace support by</b>	docker podman	docker podman	<b>rootlesskit</b>	<b>nsenter</b> <b>rootlesskit</b>	<b>nsenter</b> <b>rootlesskit</b>
<b>Language</b>	go	go	go	<b>bash</b>	<b>bash</b>
<b>Multihost</b>	No	No	<b>Yes</b>	No	<b>Yes</b>
<b>Docker (containerd)</b>	Yes	Yes	Yes	Yes	Yes

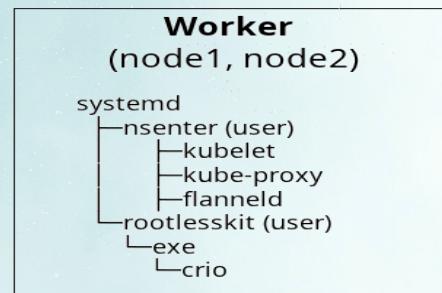
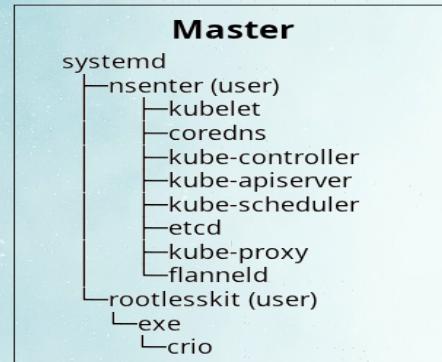
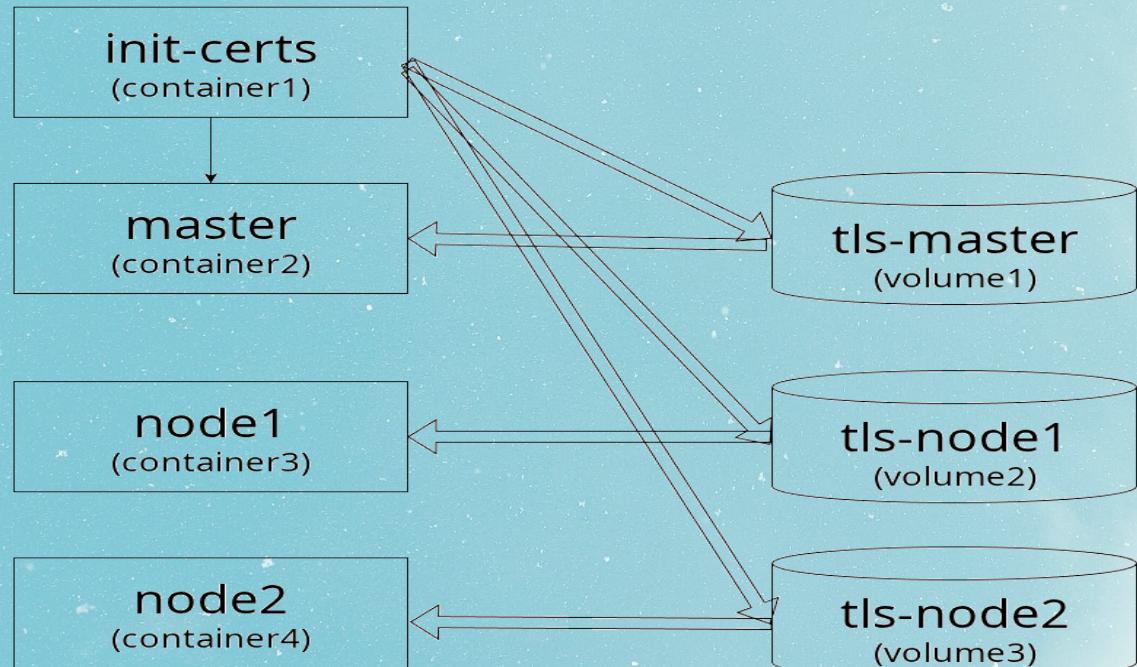
# История

- Имеет две версии — Generation I, Generation 2.
- Generation 1 — разворачивание rootless kuber в docker-стеке в рамках одного узла.
- Generation 2 — разворачивание rootless kuber на множестве узлов.
- podsec-k8s — отталкивался от Gen1, поддерживает нативное разворачивание kuber через kubadm на множестве узлов, был выпущен на 3 месяца ранее (июнь 2023) usernetes Gen2 (сентябрь 2023).

**Лицензия GPL V2.1.**

# Инициализация кластера USERNETES(Gen1)

## Сервер с dockerd



# PODSEC VS USERNETES

	Usernetes Gen1	Usernetes Gen2	podsec
<b>Runtime environment</b>	Docker Compose	<b>kubeadm</b>	<b>kubeadm</b>
<b>Multihost</b>	No	<b>Yes</b>	<b>Yes</b>
<b>Containers Policy</b>	No/Yes	<b>No/Yes</b>	<b>Yes</b>
<b>Engine</b>	Containetd <b>CRI-O</b>	Containetd <b>CRI-O</b>	<b>CRI-O</b>
<b>Start kuber services AS</b>	Systemd services	<b>PODs</b>	<b>PODs</b>
<b>Monitoring</b>	No	No	<b>Yes</b>
<b>Local Registry</b>	No	No	<b>Yes</b>
<b>Image Signing</b>	No	No	<b>Yes</b>

# Инициализация кластера USERNETES(Gen2)

```
# Set ENGINE
export CONTAINER_ENGINE=podman

# Bootstrap a cluster
make up
make kubeadm-init
make install-flannel

# Enable kubectl
make kubeconfig
export KUBECONFIG=$(pwd)/kubeconfig
kubectl get pods -A

# Multi-host
make join-command
scp join-command another-host:~/usernetes
ssh another-host make -C ~/usernetes up kubeadm-join
make sync-external-ip
```

# Преимущества решения podsec/usernetes

- **usernetes/rootless**
  - Все POD'ы включая базовые работают в rootless окружении
  - Даже при наличии уязвимостей в базовых образах и образов пользователей злоумышленник не может нарушить работу компонентов узла и файлов HOST-системы.
- **podsec**
  - Поддержка создания безопасного окружения
    - Строгие политики доступа к образам
    - Создание пользователей различного класса (разработчики образов, пользователи образов, администраторы безопасности)
    - Подъем необходимых сервисов (регистратора, сервера доступа к открытым подписям создателей образов).
    - Мониторинг уязвимостей узлов kubernetes-кластера.

# Команды работы с namespace пользователя

`nsenter` - команда запуска программы в пользовательском namespace:

- `mount` – изолированное монтирование;
- `UTS` – изолированные `hostname` и `domainname`;
- `IPC` – изолированные межпроцессные каналы;
- `network` – изолированные сетевые интерфейсы, `iptables`, ...;
- `PID` – изолированный дерево PID-процессов;
- `user` - изолированные `UID`, `GID`, `capabilities`;
- `cgroup` – изолированный Control Group (ограничение, учет, изоляция ресурсов группы процессов);
- `time` – изолированные `CLOCK_MONOLITIC` и `CLOCK_BOOTTIME`.

# Команды работы с namespace пользователя

**rootlesskit** – реализация fake root (псевдо root) в пользовательском namespace:

- **Mount:**
  - **--copy-up <каталог>**
  - **--propagation [rprivate, rslave]**
- **Network:**
  - **--net [slirp4net, host, pasta, vpnkit, ...]**
  - **--cidr IP/Mask**
  - **--ifname [tap0, ethN]**
- **Port:**
  - **--port-driver [none, builtin, slirp4nets]**
  - **--publish <IP>:portIN:portOUT/[tcp, udp]**
- **Process:**
  - **--pidns, --cgroupns, --utsns, --ipcns**

# Команды работы с namespace пользователя

**rootlessctl** – rootlesskit API клиент:

- **list-ports;**
- **add-ports;**
- **remove-ports;**
- **Info.**

# Особенности реализации podsec-k8s

В переменную PATH добавляется каталог скриптов, замещающих команды kubernetes: `export PATH=/usr/libexec/podsec/u7s/bin/:$PATH`

Содержимое каталога /usr/libexec/podsec/u7s/bin:

```
crio.sh
init-crio.sh
kubeadm -> /usr/bin/podsec-u7s-kubeadm
_kubeadm.sh
kubeadm.sh
_kubelet.sh
kubelet.sh
nsenter_u7s
rootlessctl
rootlesskit.sh
systemctl
u7sinit.sh
u7s-start-stop.sh
```

Команды (скрипты) `kubeadm`, `rootlessctl`, `systemctl` замещают аналогичные системные команды, реализуют собственный интерфейс и вызывают в итоге системные.

Скрипты `_kubeadm.sh`, `_kubelet.sh` вызываются в пользовательском namespace.

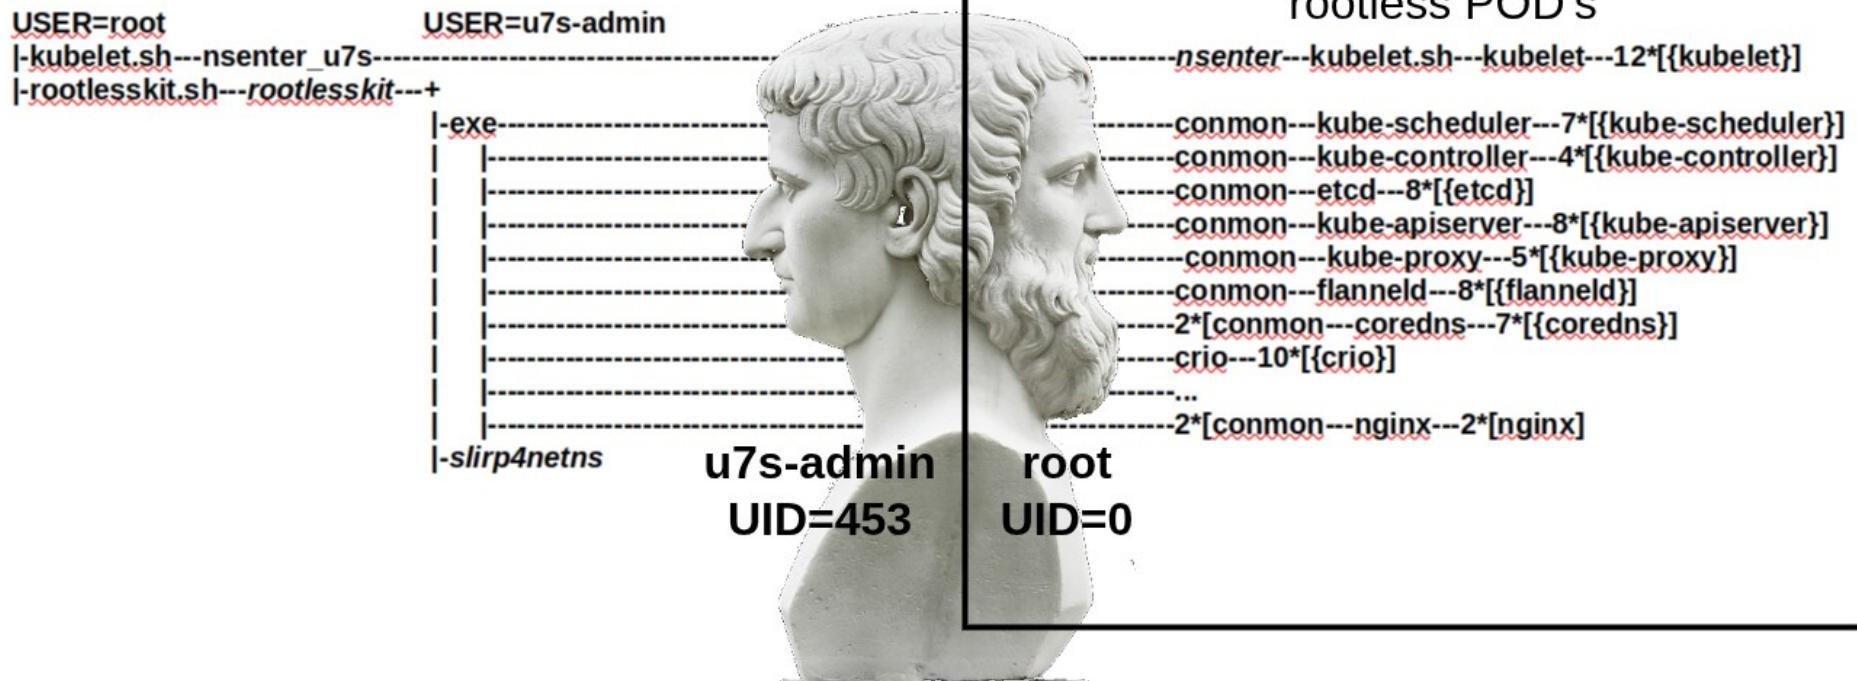
Скрипт `_kubeadm.sh` вызывает нативную команду `/usr/bin/kubeadm` в пользовательском namespace

# Порядок инициализации узла (kubeadm init, join)



# Двуликий янус - rootless

## HOST система



# Особенности podsec

- Используется только podman, cri-o решения (не containerd), поддерживающее политику доступа к образам.
- Как и в usernetes Gen1/2 контейнеры (POD'ы) основных сервисов kubernetes вызываются в rootless-окружении обычного пользователя (в podsec-k8s – пользователь u7s-admin). Пользовательские контейнеры (с пользователями root и обычными пользователями) также попадают в rootless-окружение.
- Параметризация разворачивания через переменные среды (docker-регистратор, версия kuber, ...).
- На master-сервере кроме kubernetes располагаются:
  - Пользователи группы podman\_dev, имеющие право скачивать любые образы, создавать образы для локального регистратора, подписывать и помещать их в локальный регистратор.
  - Остальные пользователи могут использовать только подписанные образы локального регистратора.
  - WEB-сервер для доступа к открытым ключам пользователи группы podman\_dev.
  - Регистратор подписанных образов.
  - Сервис trivy мониторинга уязвимостей
- Автоматически настраиваются политики доступа к образам
- Обеспечивает мониторинг уязвимостей и функционирования контейнеров кластера.

# Набор RPM-пакетов podsec (PODman SECurity)

- podsec — набор команд создания rootless-окружение (регистратор, политики доступа, создание ролевых пользователей, ...)
- podsec-k8s — набор команд по разворачиванию нативного rootless k8s кластера.
- podsec-k8s-rbac — набор команд по настройке и мониторингу RBAC.
- podsec-inotify — набор команд для мониторинга узлов кластера.
- podsec-k8s-upgrade — обновление версий кластера (в разработке)

# Недостатки решения podsec/usernetes

Из за использования сервиса поддержки rootless-сети slirp4nets для обеспечения оверлейной сети kubernetes пока можно использовать только CNI flannel. Из за трансляции адресов в slirp4nets есть проблемы с применением «продвинутых» CNI.

Возможные пути решения:

- Анализируются возможности использования других сервисов поддержки rootless-сети
- Ведутся работы по использованию в качестве rootless CNI cilium.

# **Инициализация кластера podsec- k8s с доступом в Интернет**

# Инициализация кластера podsec-k8s

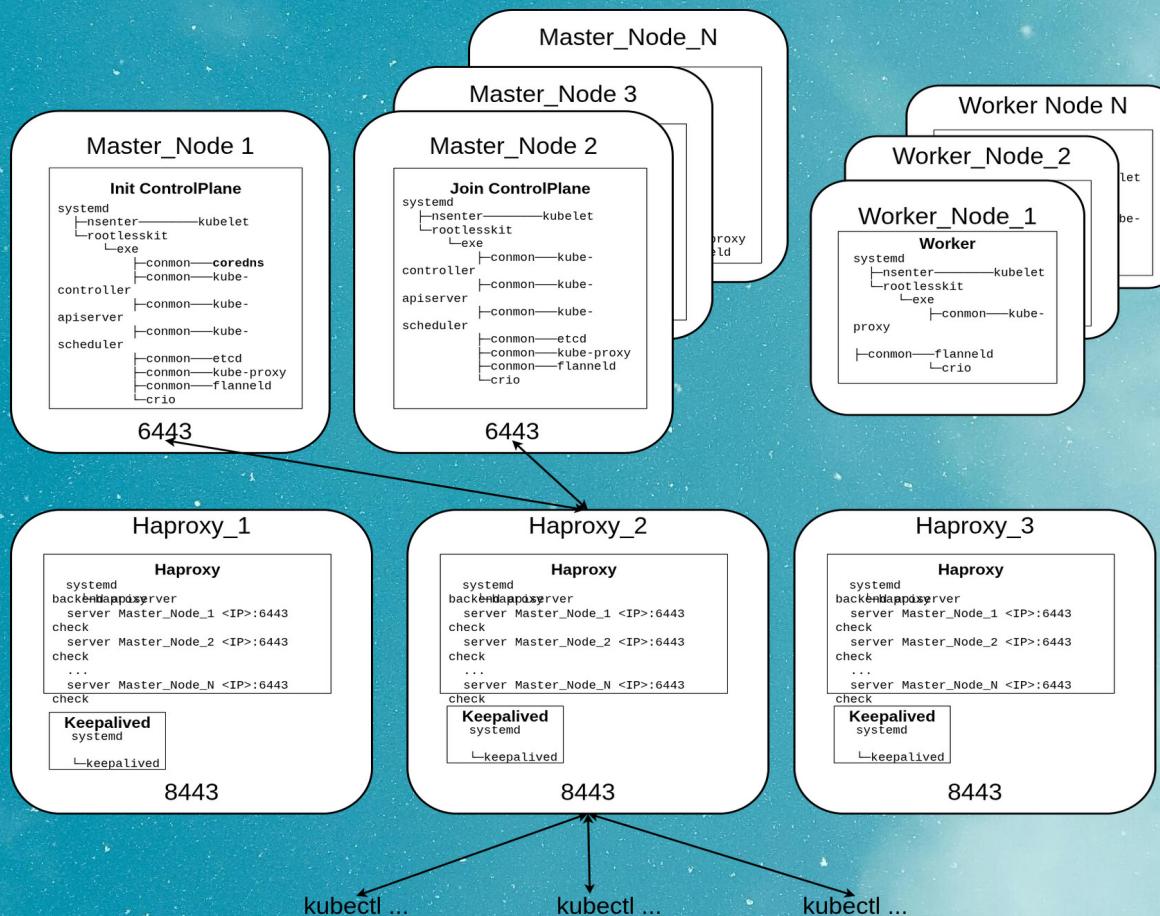
```
# Environment
export U7S_KUBEVERSION= # версия kubernetes (v1.26.9, v1.27.7, ...);
export U7S_REGISTRY= # registry.k8s.io, registry.altlinux.org,
# registry.local
export U7S_PLATFORM= # k8s-c10f2, k8s-c10f1 , k8s-p10, k8s-sisyphus, ...

# Master ControlPlane
export PATH=/usr/libexec/podsec/u7s/bin/:$PATH
kubeadm init -v 9 ...

# ControlPlane
export PATH=/usr/libexec/podsec/u7s/bin/:$PATH
kubeadm join xxx.xxx.xxx.xxx:6443 \
--token ... \
--discovery-token-ca-cert-hash sha256:... \
--control-plane

# Worker
export PATH=/usr/libexec/podsec/u7s/bin/:$PATH
kubeadm join xxx.xxx.xxx.xxx:6443 \
--token ...
```

# Инициализация кластера podsec-k8s с haproxy и keepalived



# Политики доступа к docker-образам (podman, CRI-O)

# Использование политик доступа

/etc/containers/policy.json:

```
{  
  "default": [  
    {  
      "type": "reject"  
    }  
  ],  
  "transports": {  
    "docker": {  
      "registry.local": [  
        {  
          "type": "signedBy",  
          "keyType": "GPGKeys",  
          "keyPath": "/var/sigstore/keys/imagemaker.pgp"  
        }  
      ]  
    }  
  }  
}
```

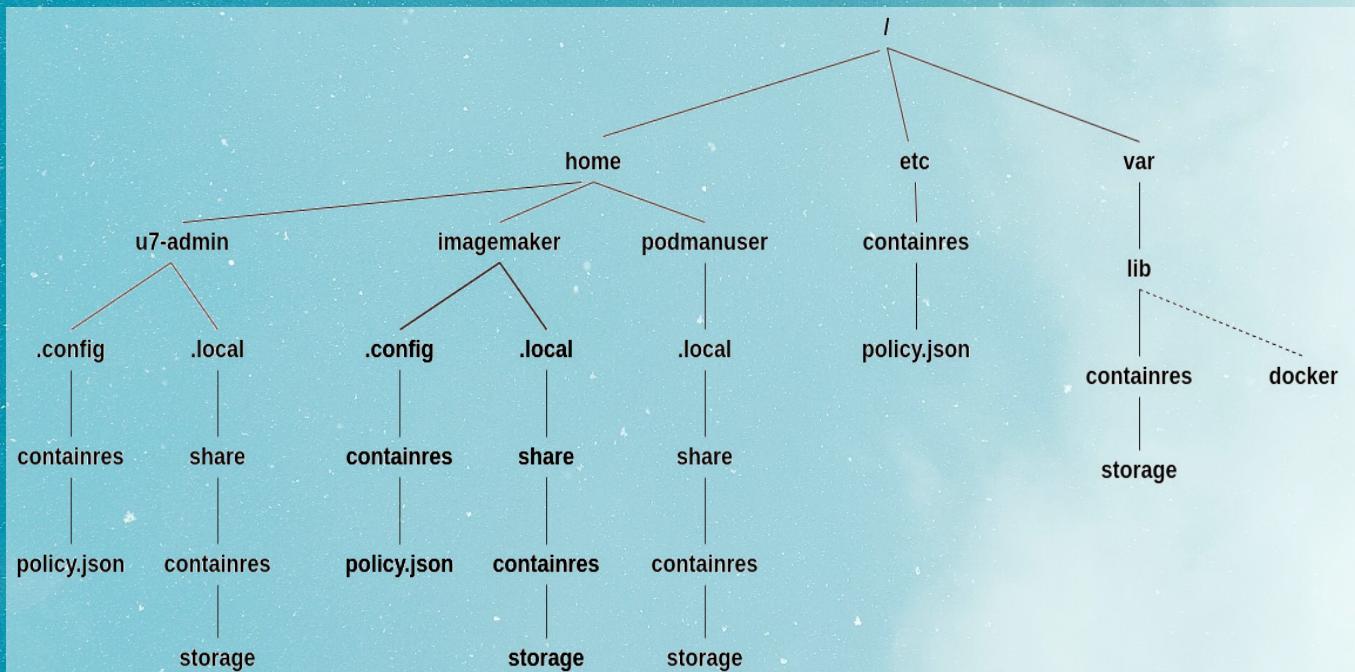
/etc/containers/registries.d/default.yaml

```
default-docker:  
  sigstore: http://registry.local:81/sigstore/
```

# 3 Ограничение прав для доступа образам

По умолчанию всем пользователям назначаются политики из `/etc/containers/policy.json`.

Для пользователей с повышенными правами принадлежащим группе `podman_dev` права описываются в файле `~/.config/containers/policy.json`

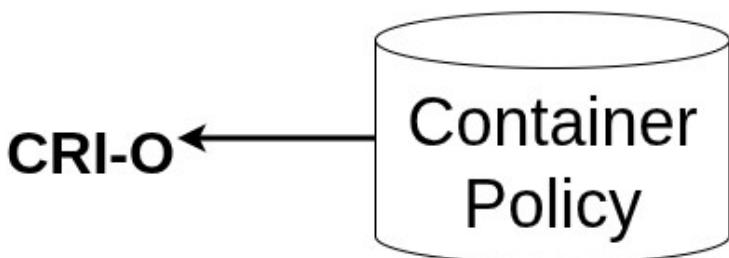


# **Инициализация кластера podsec- k8s в защищенным режиме**

# Master ControlPlane: Настройка политик доступа

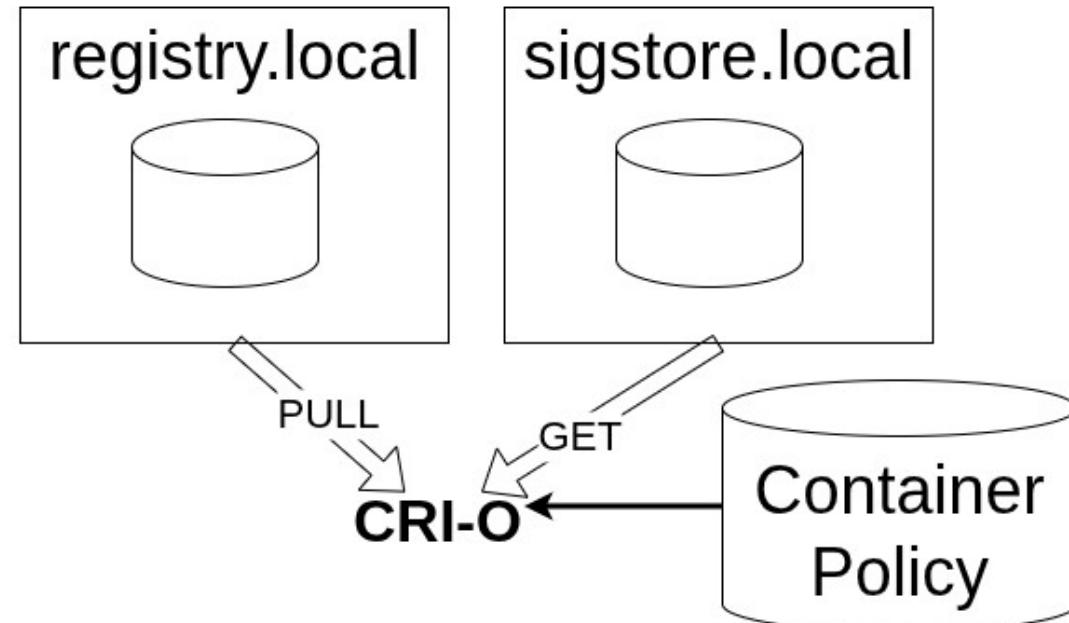
```
# podsec-create-policy
```

Master ControlPlane



# Master ControlPlane: Создание и настройка локального регистратора и WEB-сервера

```
# podsec-create-policy  
# podsec-create-services
```

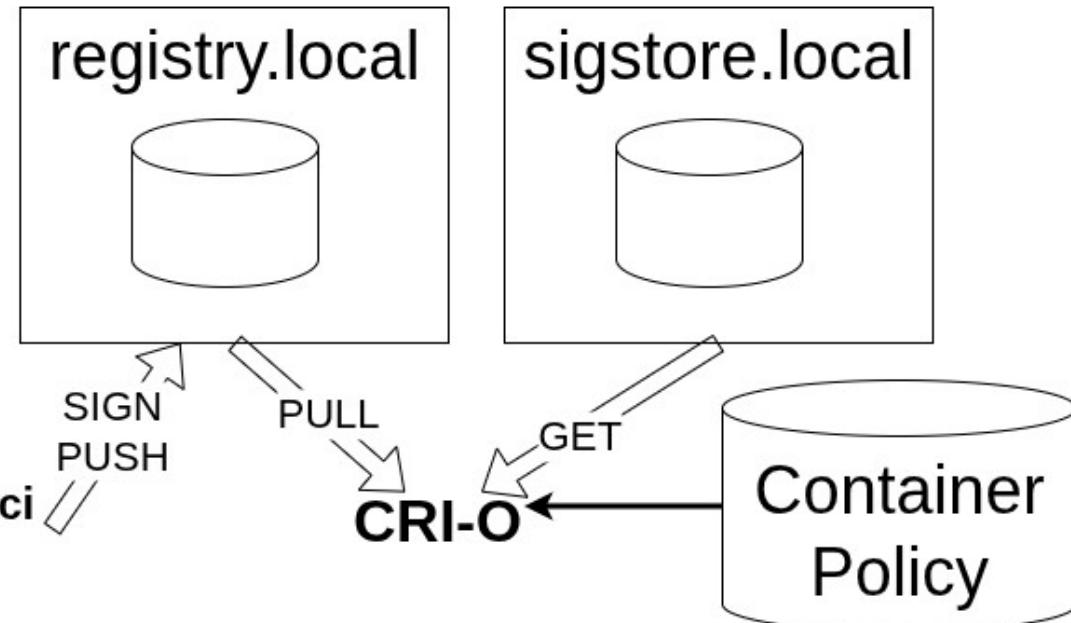


**Master ControlPlane**

# Master ControlPlane: Создание пользователя(ей) для создания образов

```
# podsec-create-policy  
# podsec-create-services  
# podsec-create-imagemakeruser
```

```
imagemaker$ podsec-load-sign-oci  
imagemaker$ podman ...
```



**Master ControlPlane**

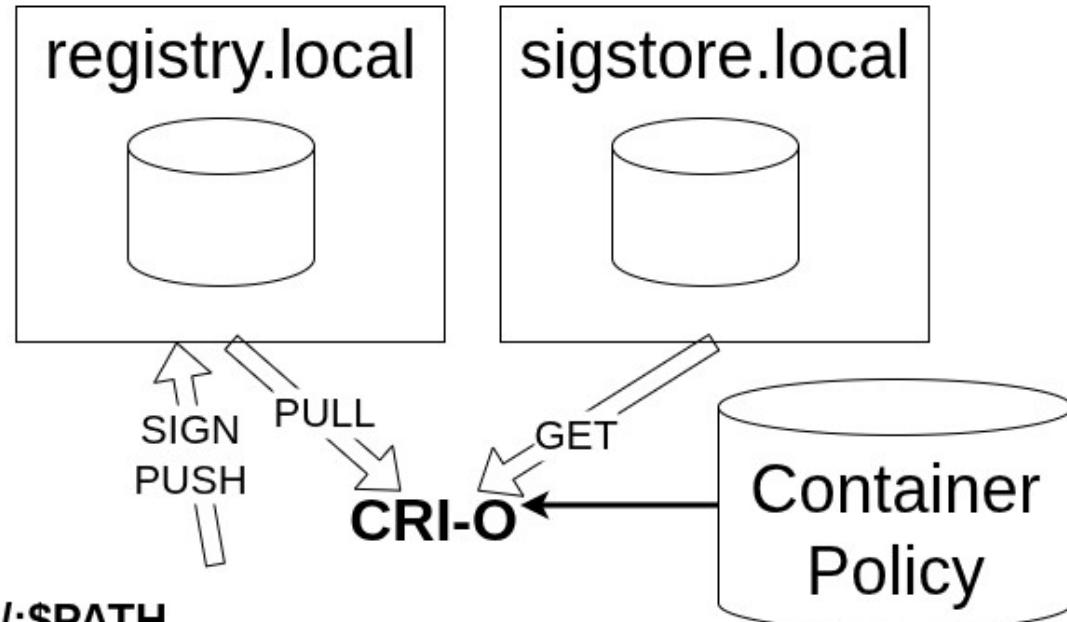
# Master ControlPlane: Разворачивание Master-узла kubernetes

```
# podsec-create-policy  
# podsec-create-services  
# podsec-create-imagemakeruser
```

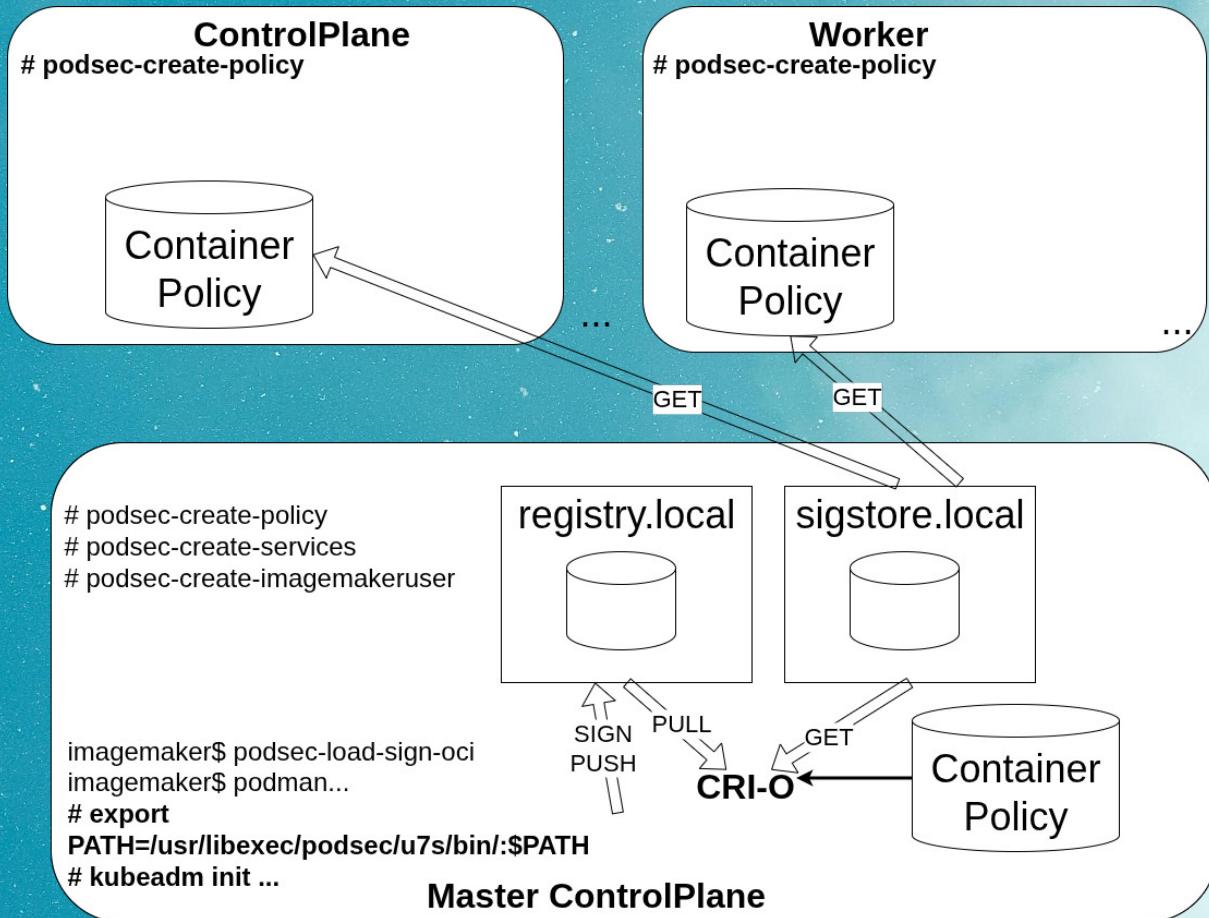
```
imagemaker$ podsec-load-sign-oci  
imagemaker$ podman...
```

```
# export  
PATH=/usr/libexec/podsec/u7s/bin/:$PATH  
# kubeadm init ...
```

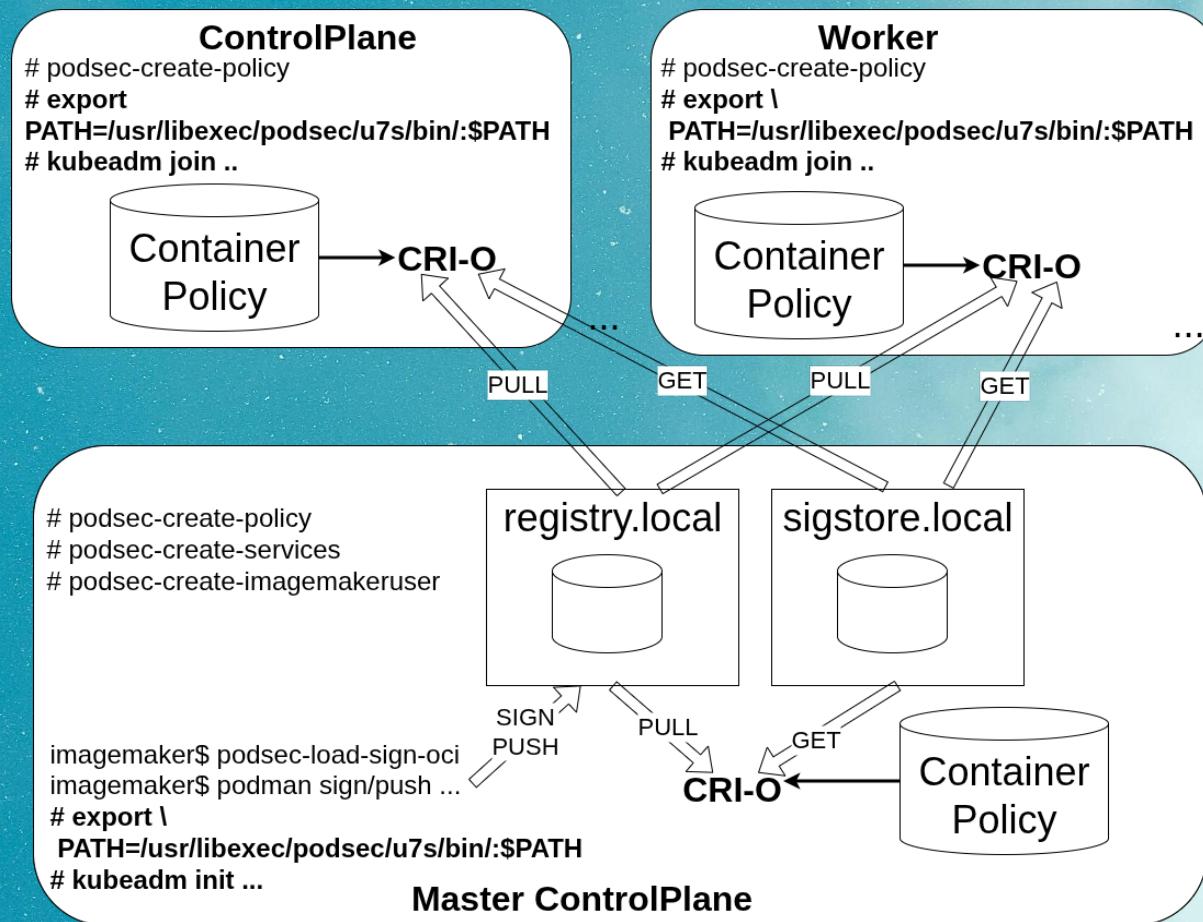
**Master ControlPlane**



# ControlPlane, Worker: Копирование политик доступа, настройка registry, sigstore



# ControlPlane, Worker: Разворачивание узлов командами kubeadm join ...



# Мониторинг безопасности

# Мониторинг безопасности

- **build-invulnerable-image** - команда сборки образов с анализом уязвимостей.
- **check-containers** - мониторинг изменения содержимого rootfull, rootless контейнеров (POD'ов).
- **check-images** - мониторинг образов на предмет их соответствия настройки политикам контейнеризации на узле.
- **check-kubeapi** - мониторинг аудита API-интерфейса сервиса kube-apiserver.
- **check-policy** - мониторинг изменения файлов конфигурации политик доступа к образам.
- **check-vuln** - мониторинг docker-образов узла сканером безопасности trivy.

**ALT-Orchestra/  
talos -  
sshless  
kubernetes  
кластер**

# Особенности ALT Orchestra

- ALT Orchestra (Альт Оркестрация) клон OS Talos.
- Все ISO и docker-образы полностью собираются на основе пакетной базы ALTLinux-Sisyphus.
- Поддерживается собственный стек extensions на основе пакетной базы ALTLinux-Sisyphus.
- Русифицирован и принят в upstream интерфейс image-factory.
- Создан собственный сервис image-factory <https://factory.altlinux.space/>.
- Зарегистрировано в реестре российского программного обеспечения - <https://reestr.digital.gov.ru/reestr/3607624/>

# Особенности решения Talos

- Отсутствие доступа к узлам по ssh
- Работа с кластером только через команды
  - `talosctl`
  - `kubectl`
- Минимальная файловая система размещаемая в оперативной памяти и монтируемая в режиме только на чтение.
- Богатый набор встроенный сервисов: CNI, HA, Service Discovery, VIP, ...

# Сотрудничество – welcome

**Оба описываемых продукта –  
OpenSource, GPL V2**

**Приглашаем разработчиков,  
тестеров, гуру, ... для совместного  
развития продуктов.**

**Костарев А.Ф.**  
**Базальт СПО**  
**[kaf@basealt.ru](mailto:kaf@basealt.ru)**



# Презентация Ссылки

