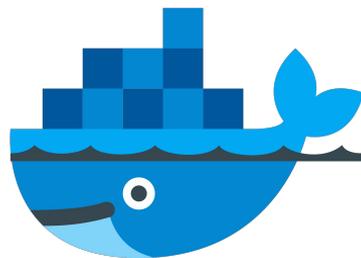


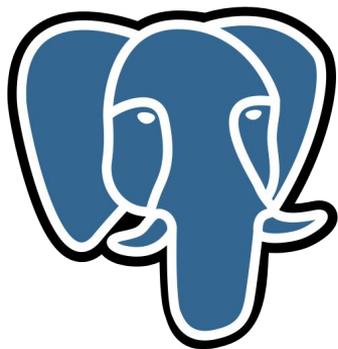
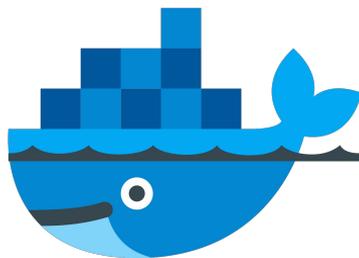
Stateful в k8s, которого мы боимся

Женя Дехтярёв

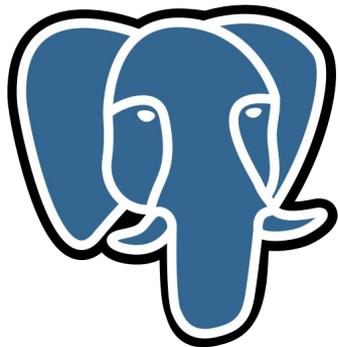
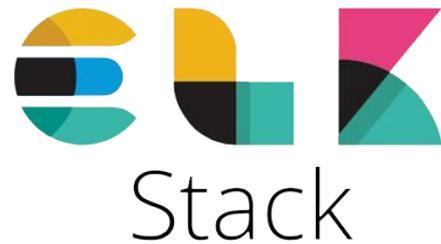
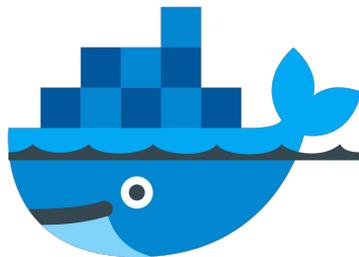




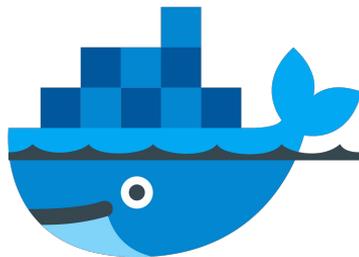
Про команду



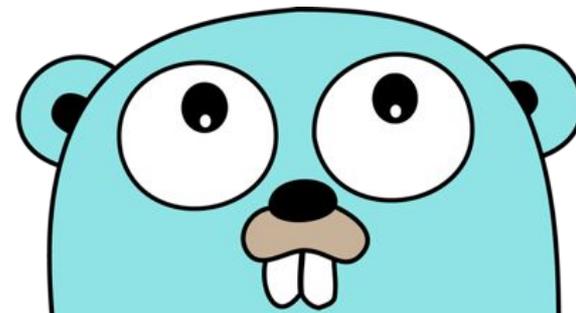
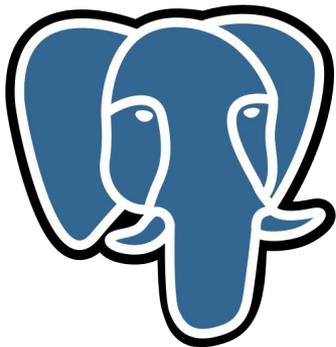
Про команду



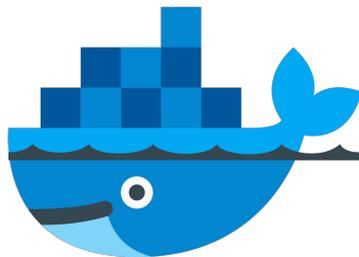
Про команду



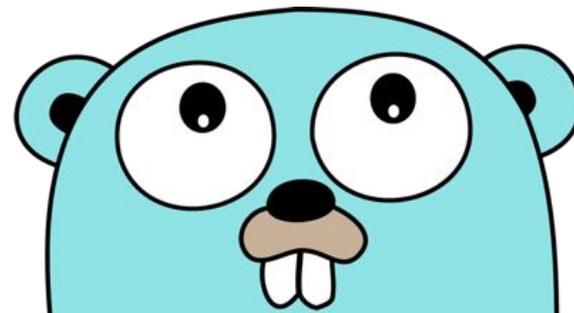
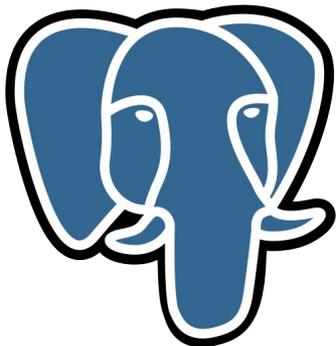
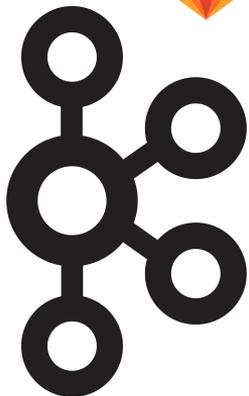
Stack



Про команду



Stack



2ГИС — это

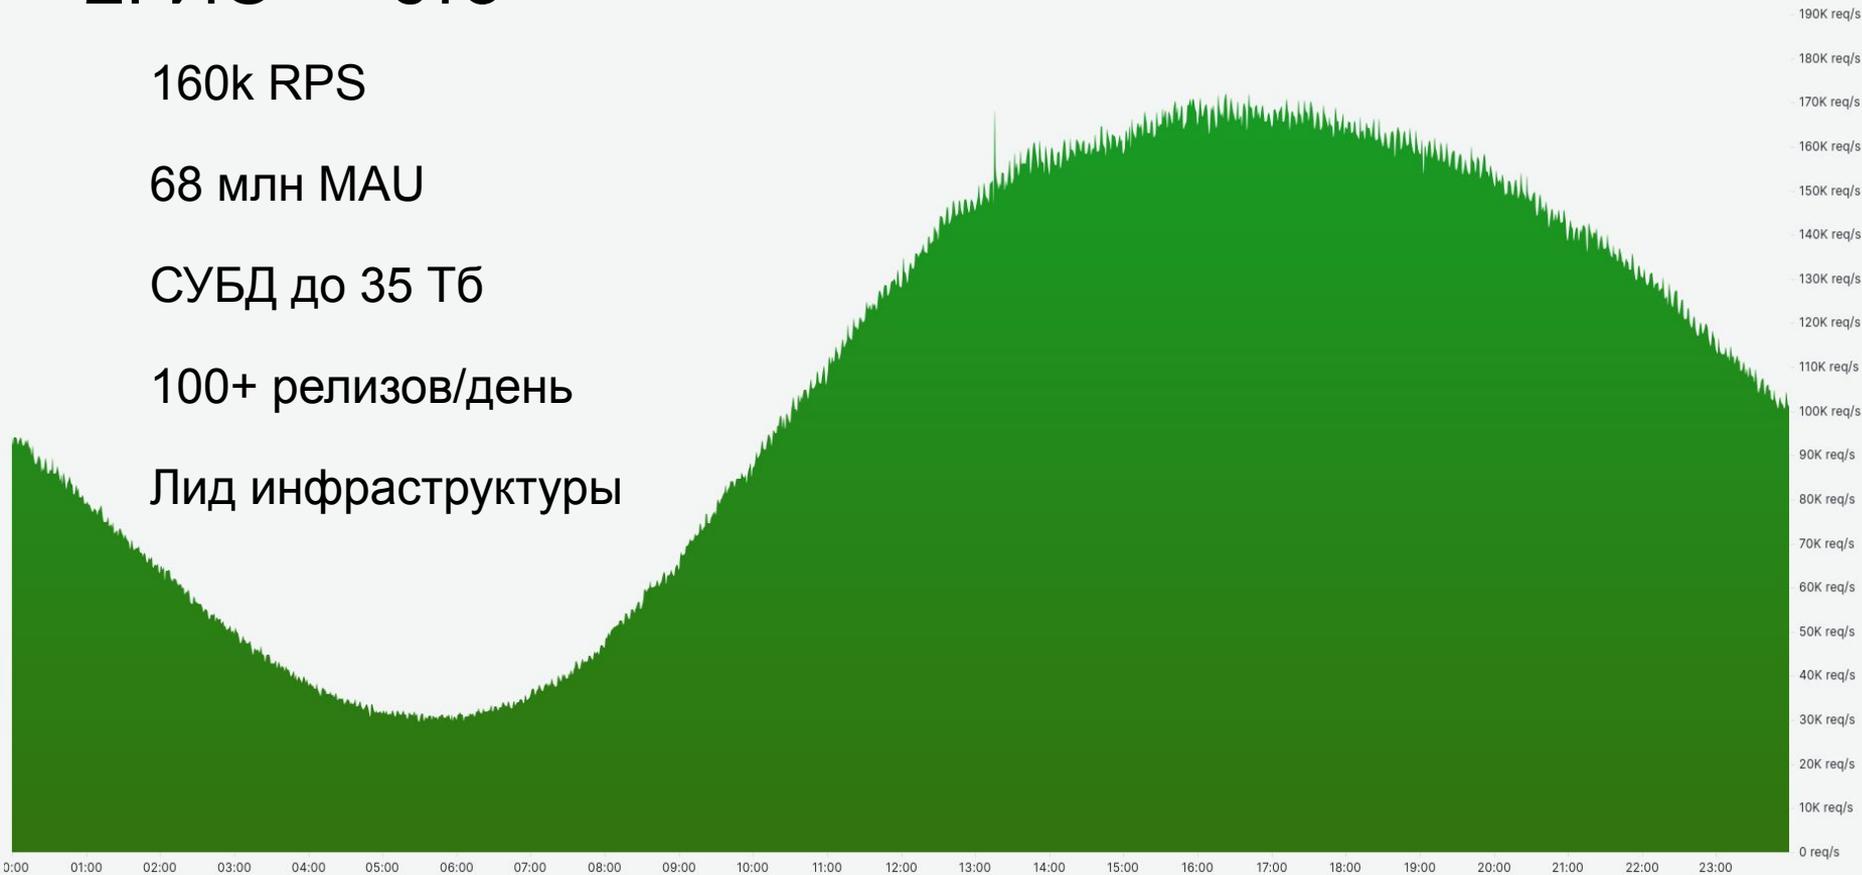
160k RPS

68 млн MAU

СУБД до 35 Тб

100+ релизов/день

Лид инфраструктуры



О чём поговорим

- Почему Stateful в k8s?
- Локальные и сетевые PV в k8s
- Особенности Stateful для PV
- Интересные случаи использования PV

Stateful vs Stateless

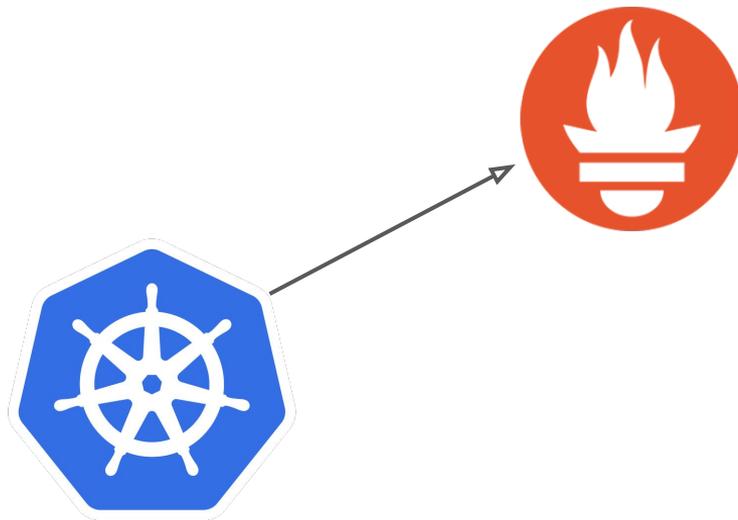
- **Stateless** — не храним данные, всегда чистый лист
 - Пример: REST API

Stateful vs Stateless

- **Stateless** — не храним данные, всегда чистый лист
 - Пример: REST API
- **Stateful** — храним данные, ответ зависит от данных
 - Пример: СУБД

Почему мы хотим stateful в k8s?

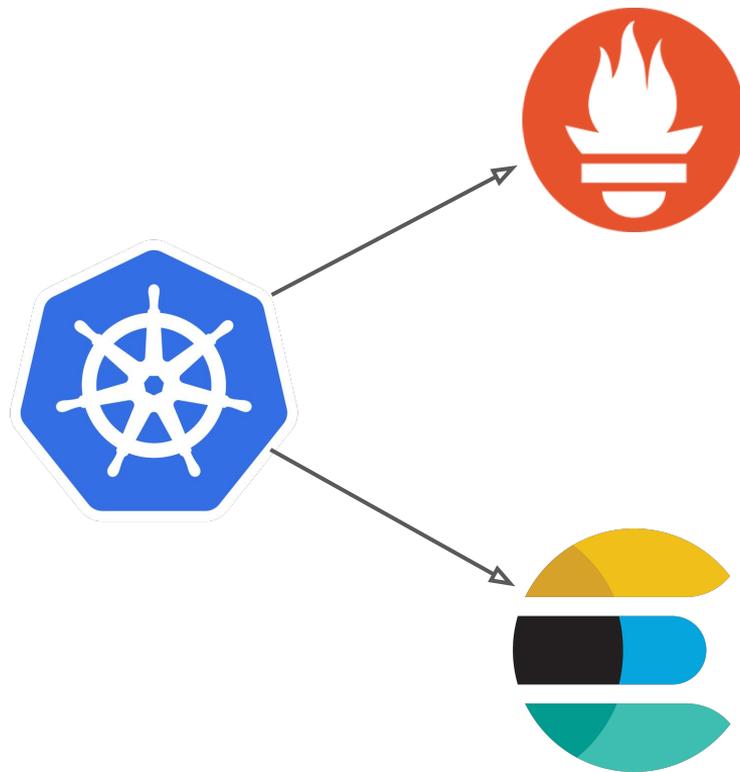
Платформа k8s — это окружение,
которое позволяет экономить
время на операционку



Экономия

Мониторинг

Метрики и алерты сразу из коробки

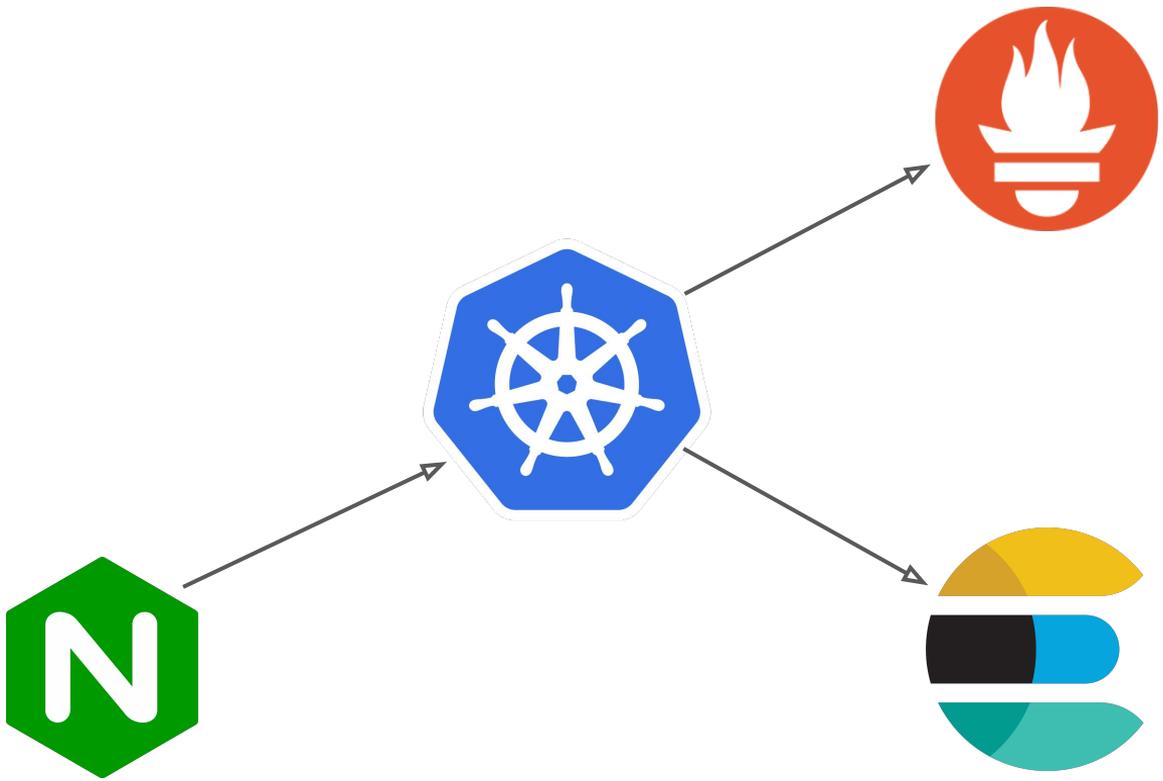


Экономия

Мониторинг

Логирование

Просто отправь в `/dev/stdout`




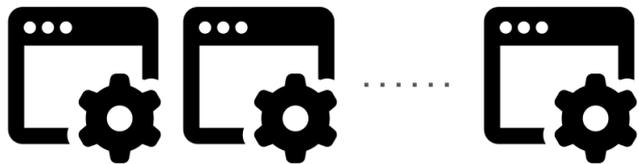
Экономия

Мониторинг

Логирование

Маршрутизация

Только настрой ingress



Экономия

Мониторинг

Логирование

Маршрутизация

Масштабирование

Масштабирование в 1 команду

Stateful-приложения

Локальные диски

- Cassandra
 - 5 Тб
- Kafka
 - 15 Тб
- Elasticsearch
 - 35 Тб
- PGSQL
 - Prod
- Clickhouse
- Mongo

Сетевые диски

- PGSQL
 - Dev-окружения (Spilo)
- Redis

Stateful-приложения

Локальные диски

- **Cassandra**
 - 5 Тб
- Kafka
 - 15 Тб
- **Elasticsearch**
 - 35 Тб
- PGSQL
 - Prod
- Clickhouse
- Mongo

Сетевые диски

- **PGSQL**
 - Dev-окружения (Spilo)
- Redis

Локальные Volume

Локальные Volume. Когда применять?

- Нужна максимальная производительность(600 нс ответ)

Локальные Volume. Когда применять?

- Нужна максимальная производительность(600 нс ответ)
- Нужны большие объёмы(4-8 Тб SSD — это ОК)

Локальные Volume. Когда применять?

- Нужна максимальная производительность(600 нс ответ)
- Нужны большие объёмы(4-8 Тб SSD — это ОК)
- Приложение умеет в самостоятельное восстановление
 - Потерять 1 LocalPV — это норма!

Локальные Volume. Пример

Elasticsearch, Cassandra

- Минимальные задержки диска

Локальные Volume. Пример

Elasticsearch, Cassandra

- Минимальные задержки диска
- Недоступность POD в несколько часов не приведёт ни к чему

Локальные Volume. Пример

Elasticsearch, Cassandra

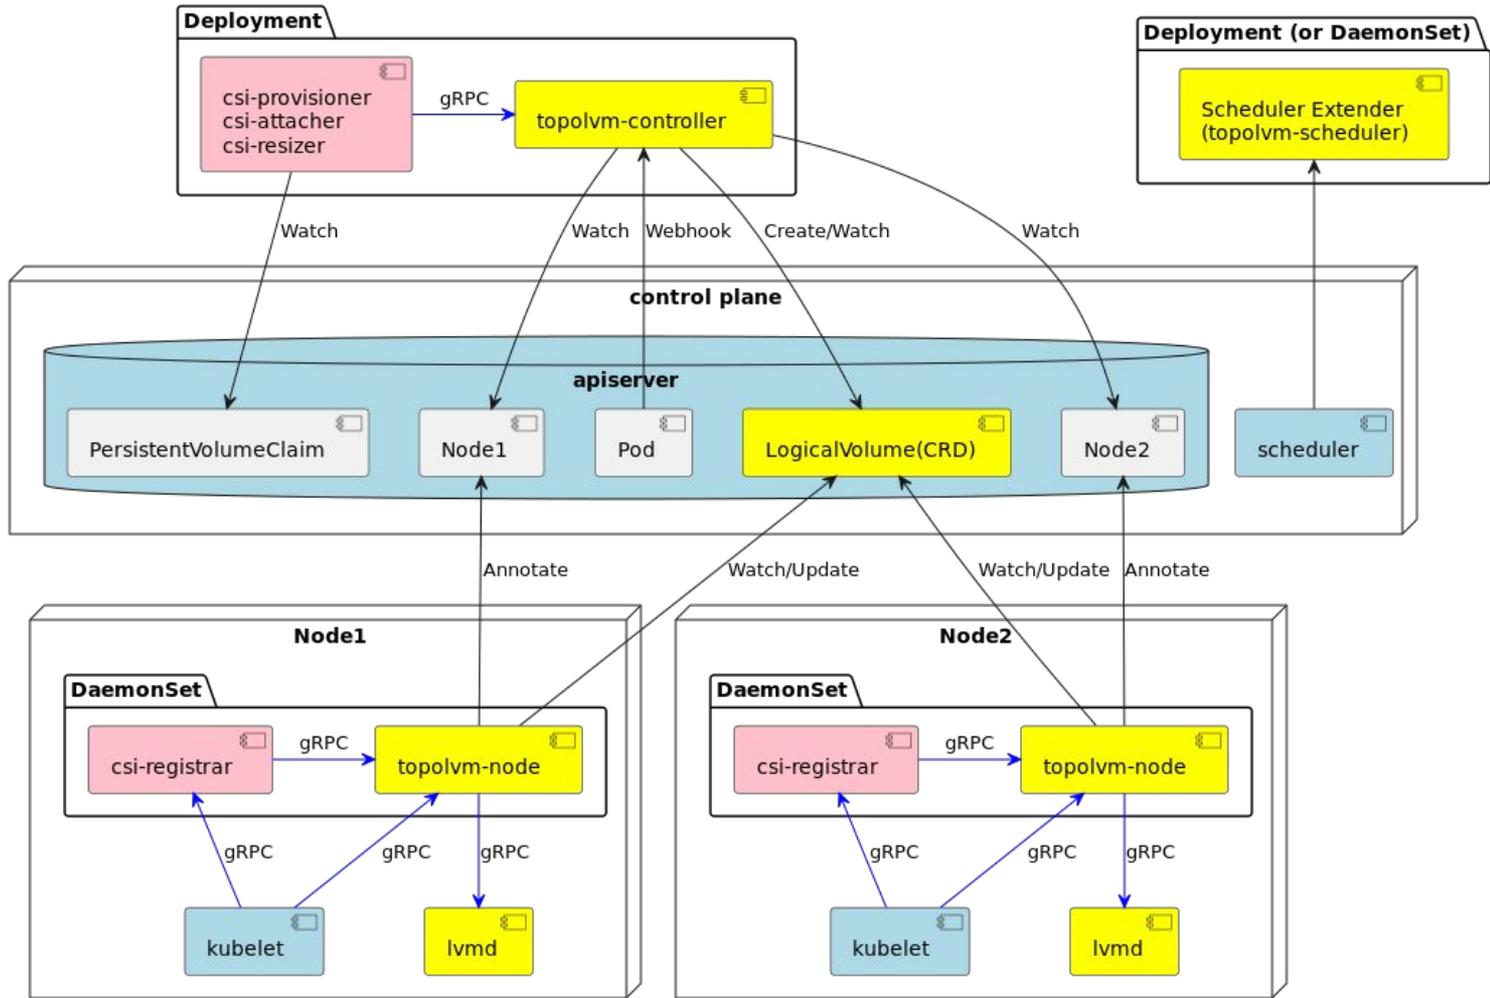
- Минимальные задержки диска
- Недоступность POD в несколько часов не приведёт ни к чему
- Самостоятельное восстановление реплик

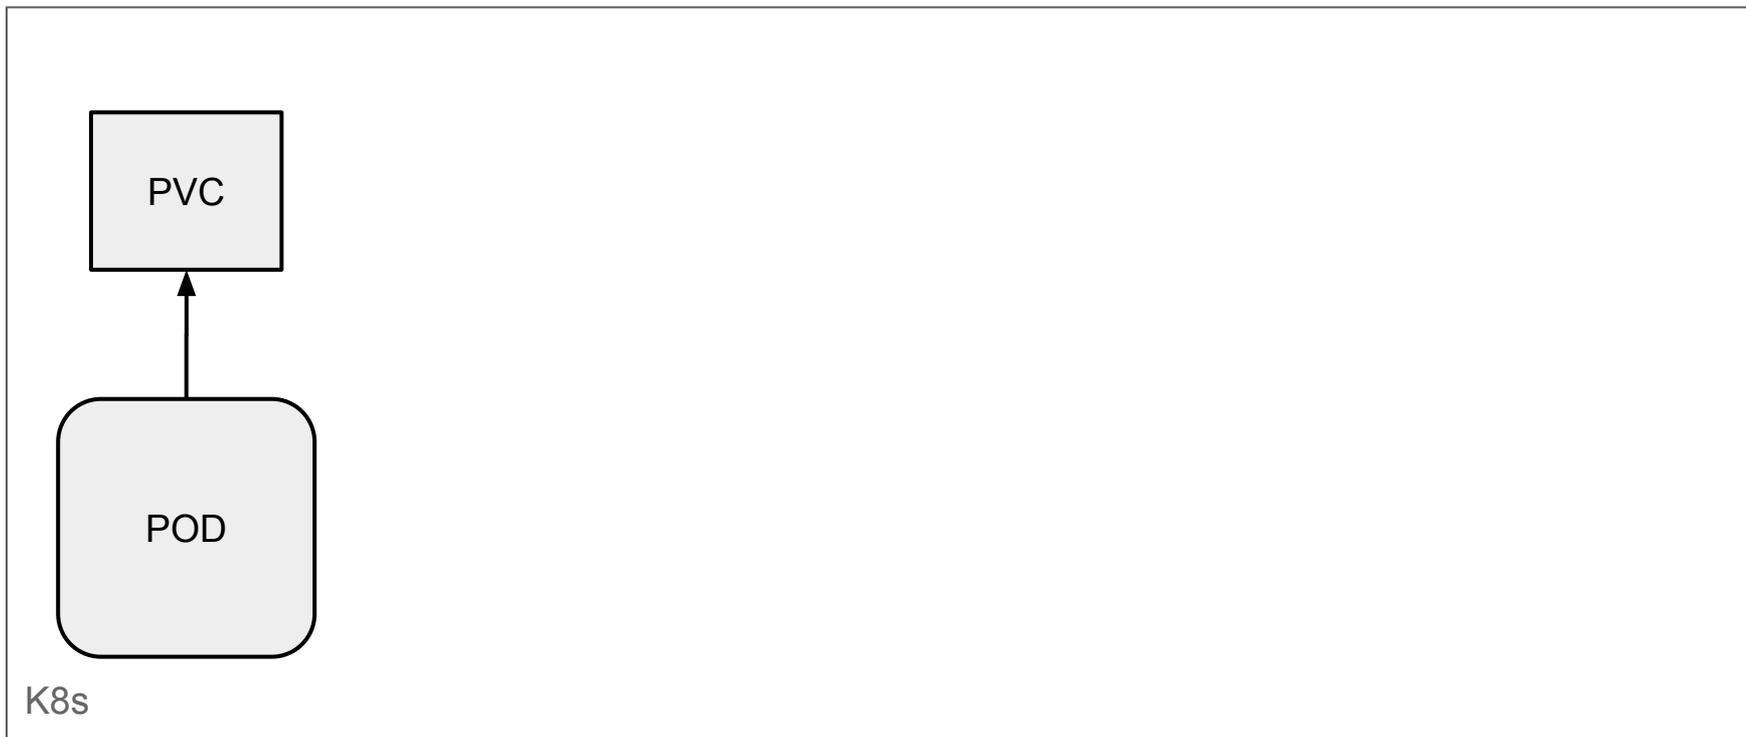
Локальные Volume. Пример

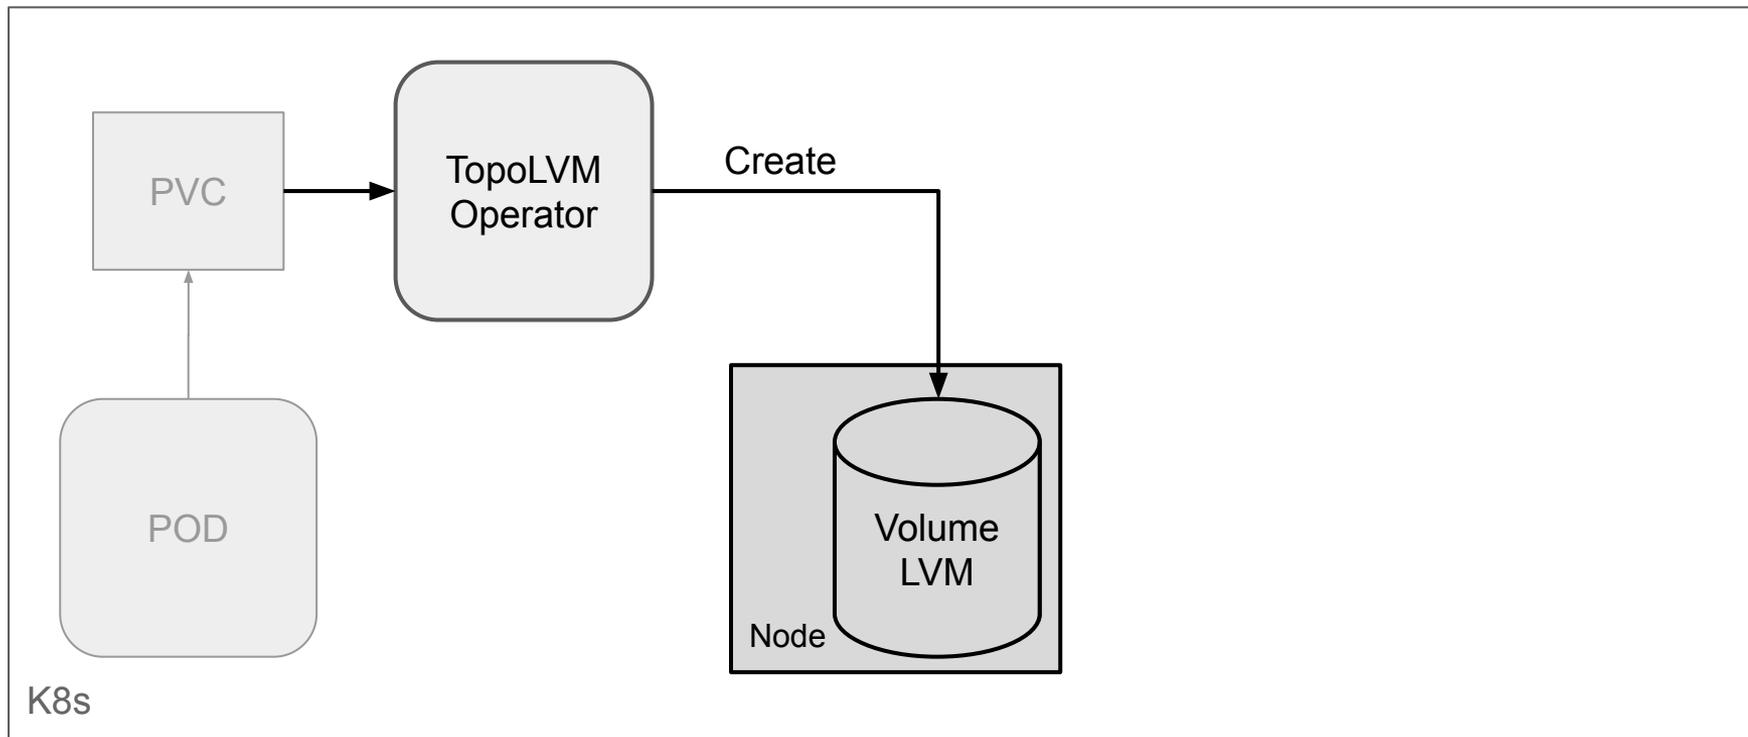
Elasticsearch, Cassandra

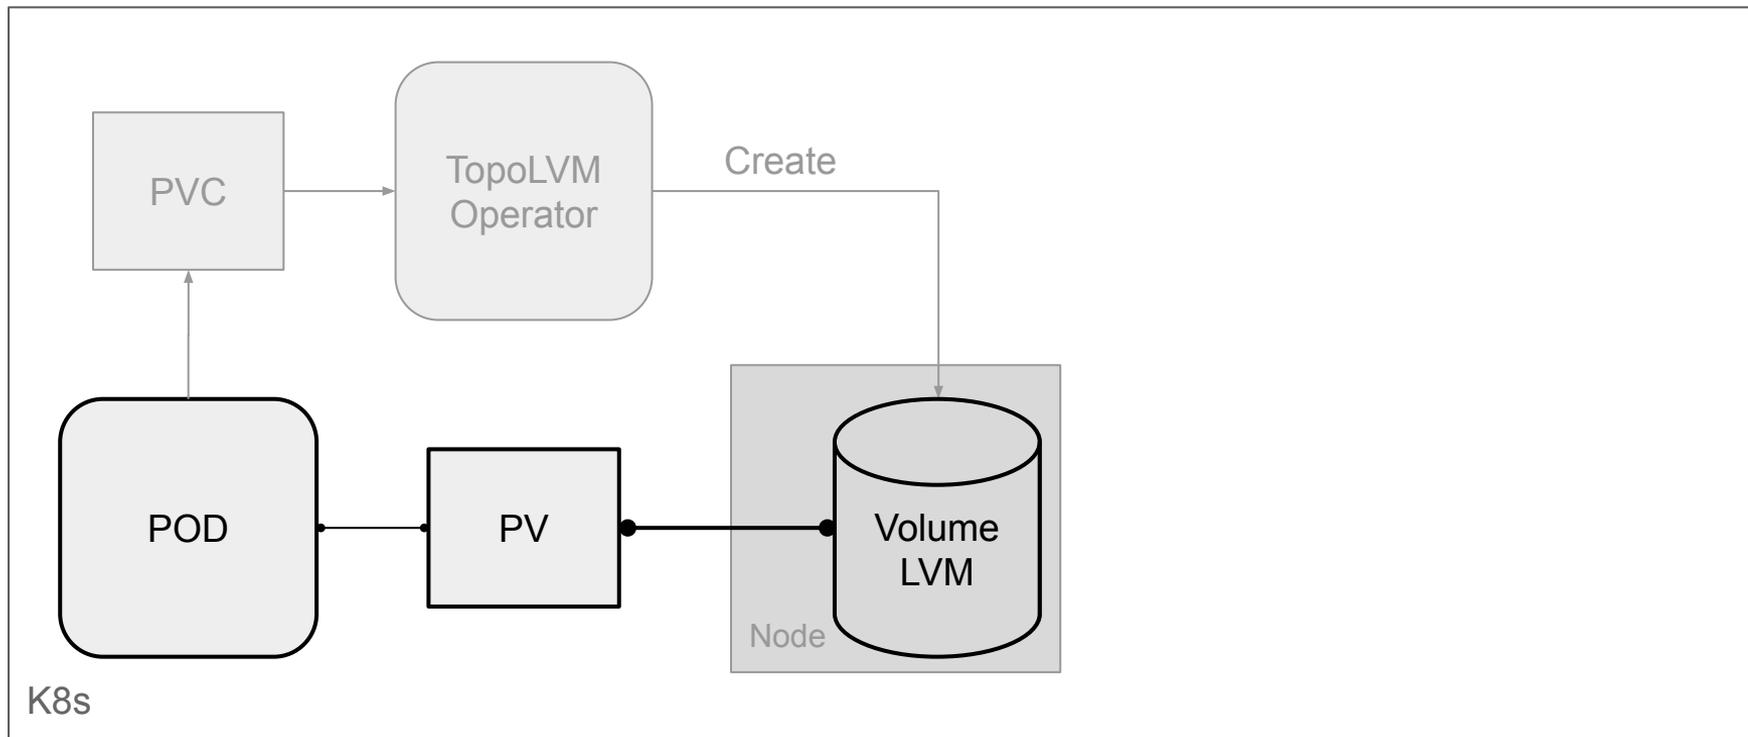
- Минимальные задержки диска
- Недоступность POD в несколько часов не приведёт ни к чему
- Самостоятельное восстановление реплик
- Самостоятельное шардирование

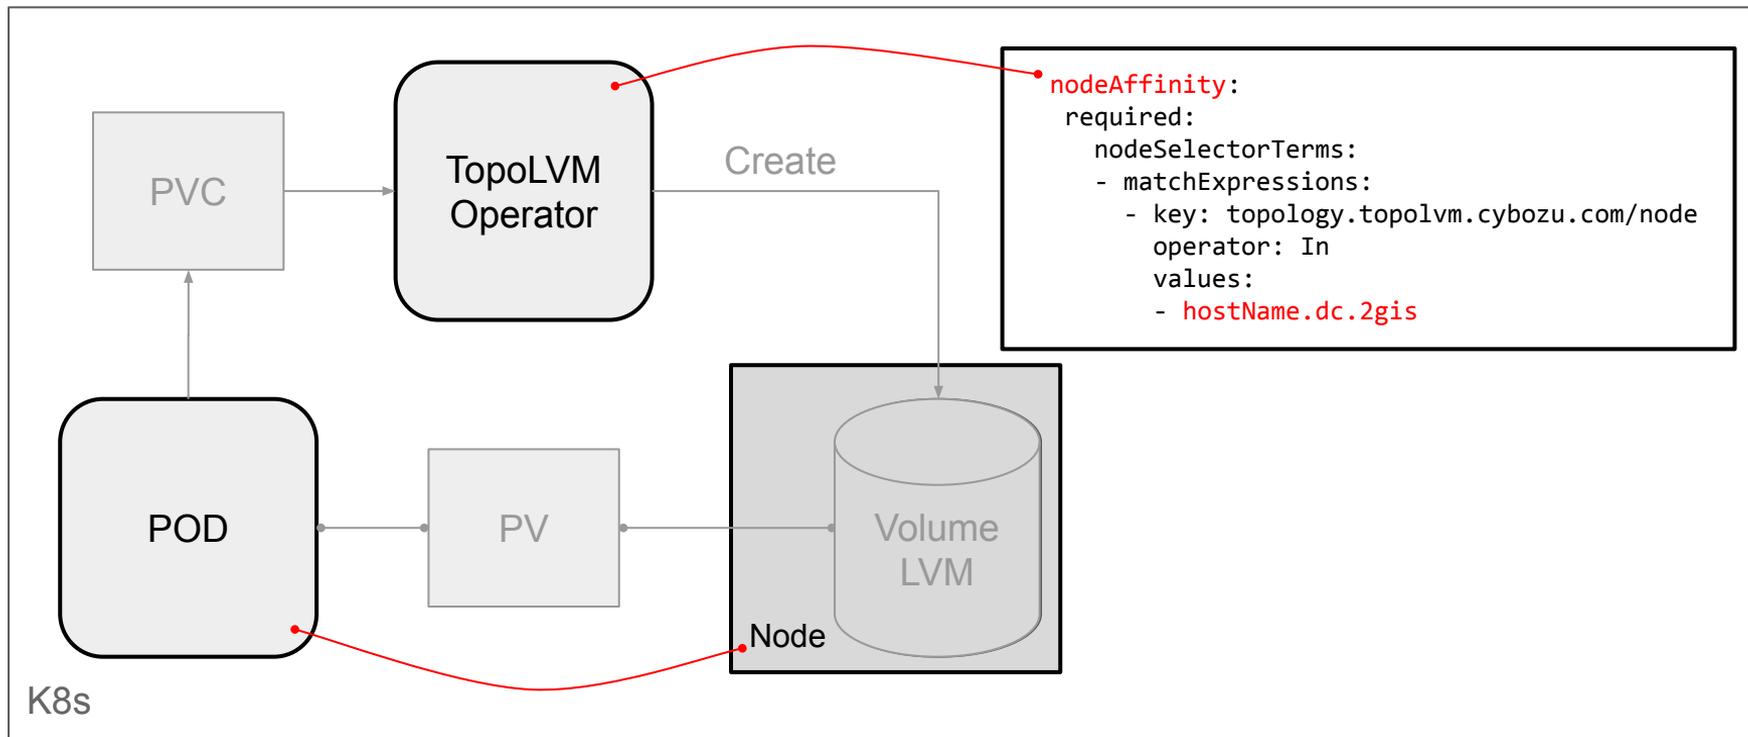
T O P O L V M











- Плюсы
 - Динамический провижининг
 - *в пределах сервера
 - Легкое расширение
 - Метрики
 - Быстрый

github.com/topolvm/topolvm

- Плюсы

- Динамический провижининг
 - *в пределах сервера
- Легкое расширение
- Метрики
- Быстрый

- Минусы

- Нужен оператор
- LVM на нодах k8s

Сетевые Volume

Сетевые Volume. Когда применять?

- Dev/Stage, небольшие объёмы

Сетевые Volume. Когда применять?

- Dev/Stage, небольшие объёмы
- Нужна максимальная надёжность данных(Prod)

Сетевые Volume. Когда применять?

- Dev/Stage, небольшие объёмы
- Нужна максимальная надёжность данных(Prod)
- Не важно где запускаться, главное запускаться
 - Например CronJob с диском

Сетевые Volume. Пример

PGSQL

- 2 реплики (Master-Slave)

Сетевые Volume. Пример

PGSQL

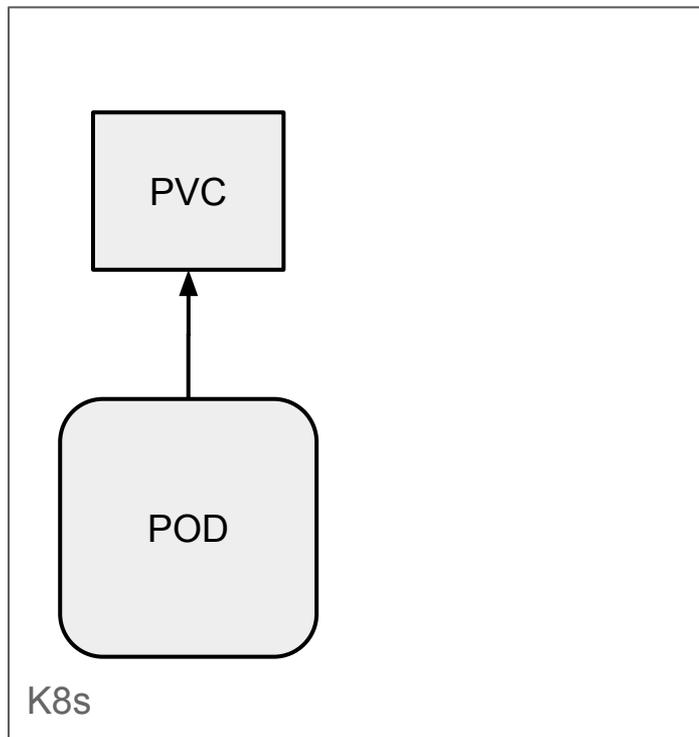
- 2 реплики (Master-Slave)
- Перезапуск POD = минимальный простой Slave

Сетевые Volume. Пример

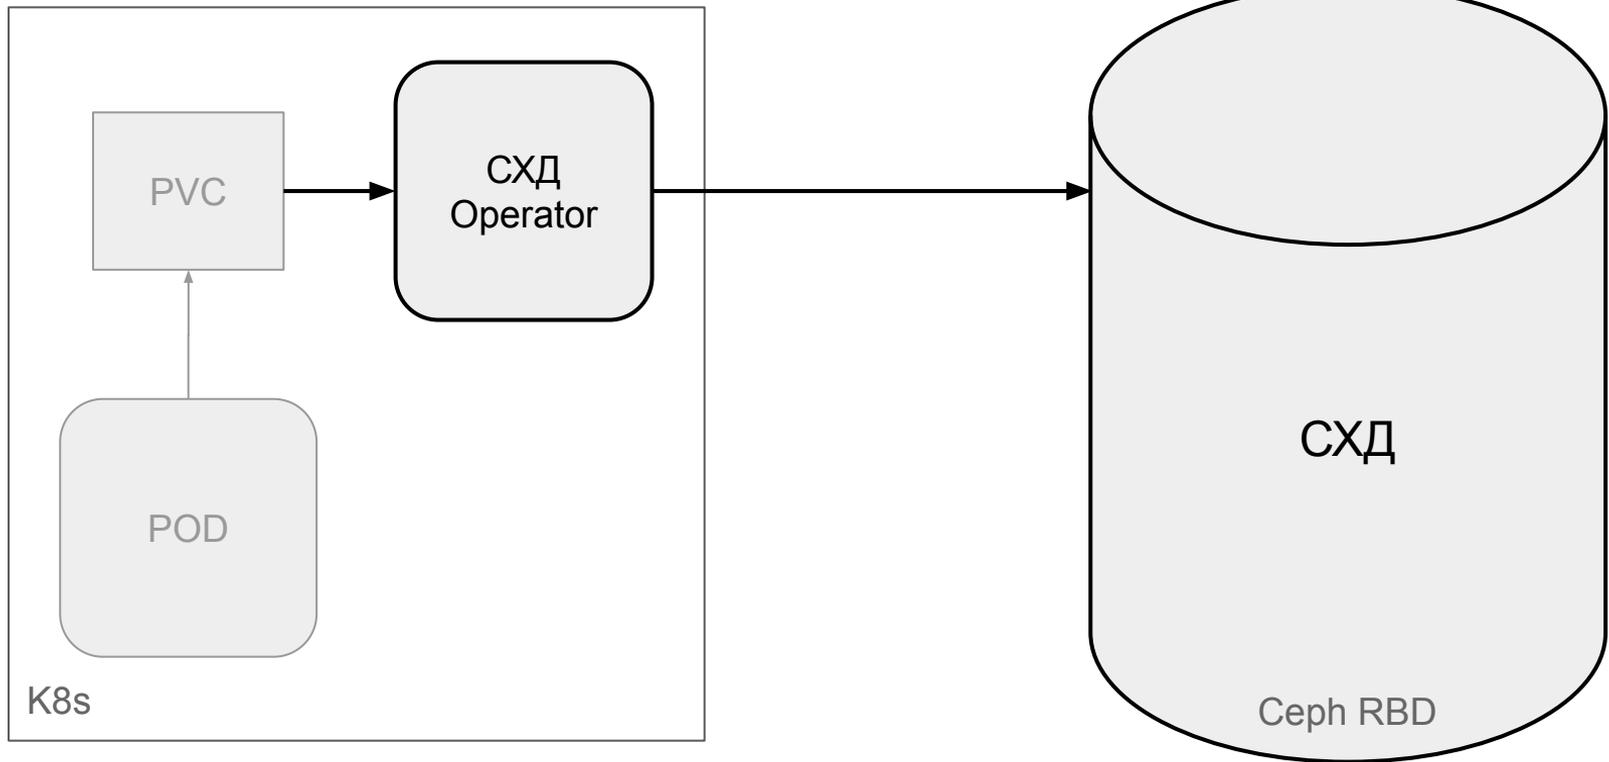
PGSQL

- 2 реплики (Master-Slave)
- Перезапуск POD = минимальный простой Slave
- WAL хватает, репликация не разваливалась

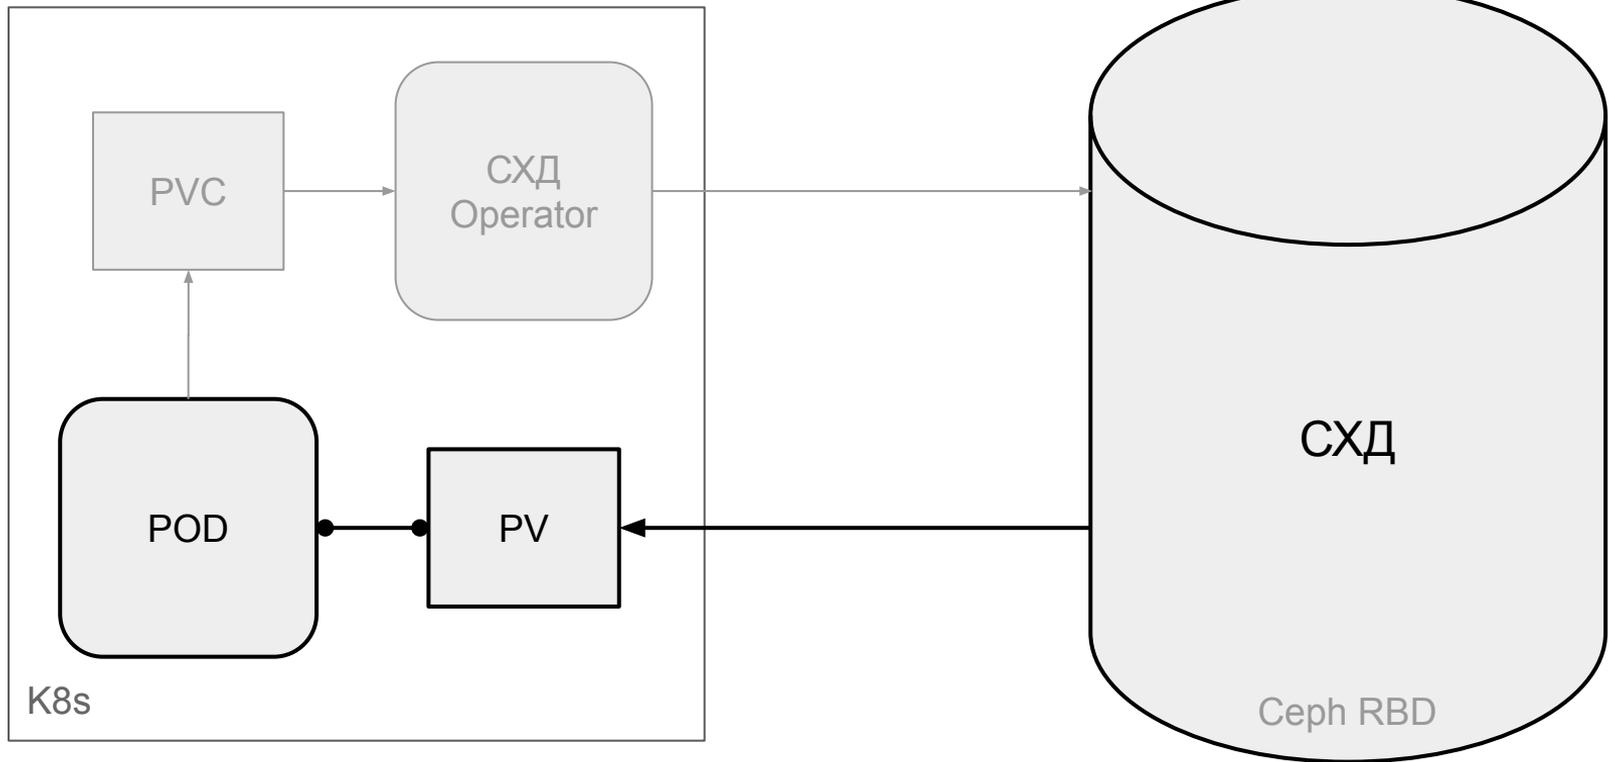
Сетевые Volume



Сетевые Volume



Сетевые Volume



Сетевые Volume. RBD Ceph

- Плюсы
 - Динамический provisioning
 - Простое расширение
 - Быстрое восстановление

Сетевые Volume. RBD Ceph

- Плюсы

- Динамический провижининг
- Простое расширение
- Быстрое восстановление

- Минусы

- Скорость зависит от:
 - скорости сети
 - дисков под CEPH
- Деградация СХД → увеличение времени ответа

Особенности Stateful для PV

Локальные Volume в коммуналке

- PodAntiAffinity

Локальные Volume в коммуналке

- PodAntiAffinity
- PodPriority

Локальные Volume в коммуналке

- PodAntiAffinity
- PodPriority
- PodDisruptionBudget

Локальные Volume в коммуналке

- PodAntiAffinity
- PodPriority
- PodDisruptionBudget
- 2+ POD на 1 K8s Node — iowait

Локальные Volume в коммуналке

- PodAntiAffinity
- PodPriority
- PodDisruptionBudget
- 2+ POD на 1 K8s Node — iowait
- Не квотировать объём PV

Локальные Volume в коммуналке

- PodAntiAffinity
- PodPriority
- PodDisruptionBudget
- 2+ POD на 1 K8s Node — iowait
- Не квотировать объём PV
- Stateful, replicas 3+

Локальные Volume в коммуналке

- PodAntiAffinity
- PodPriority
- PodDisruptionBudget
- 2+ POD на 1 K8s Node — iowait
- Не квотировать объём PV
- Stateful, replicas 3+
- **Бэкап!**

Сетевые Volume в коммуналке

- PodAntiAffinity
 - *не обязательно

Сетевые Volume в коммуналке

- PodAntiAffinity
 - *не обязательно
- PodDisruptionBudget

Сетевые Volume в коммуналке

- PodAntiAffinity
 - *не обязательно
- PodDisruptionBudget
- Много операций с данными == iowait;

Сетевые Volume в коммуналке

- PodAntiAffinity
 - *не обязательно
- PodDisruptionBudget
- Много операций с данными == iowait;
- Обязательное квотирование и ограничения

Сетевые Volume в коммуналке

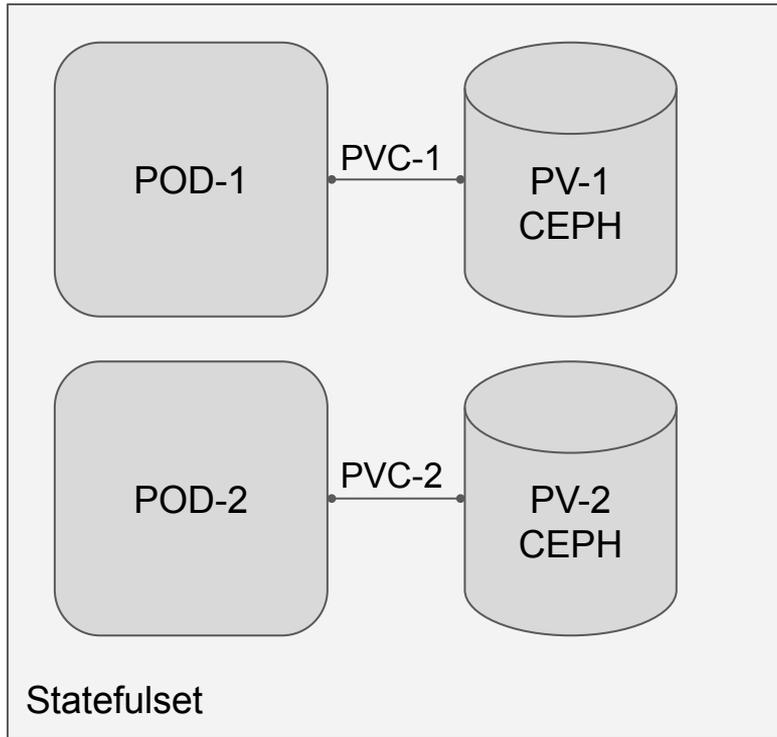
- PodAntiAffinity
 - *не обязательно
- PodDisruptionBudget
- Много операций с данными == iowait;
- Обязательное квотирование и ограничения
- Stateful, replicas 3+

Сетевые Volume в коммуналке

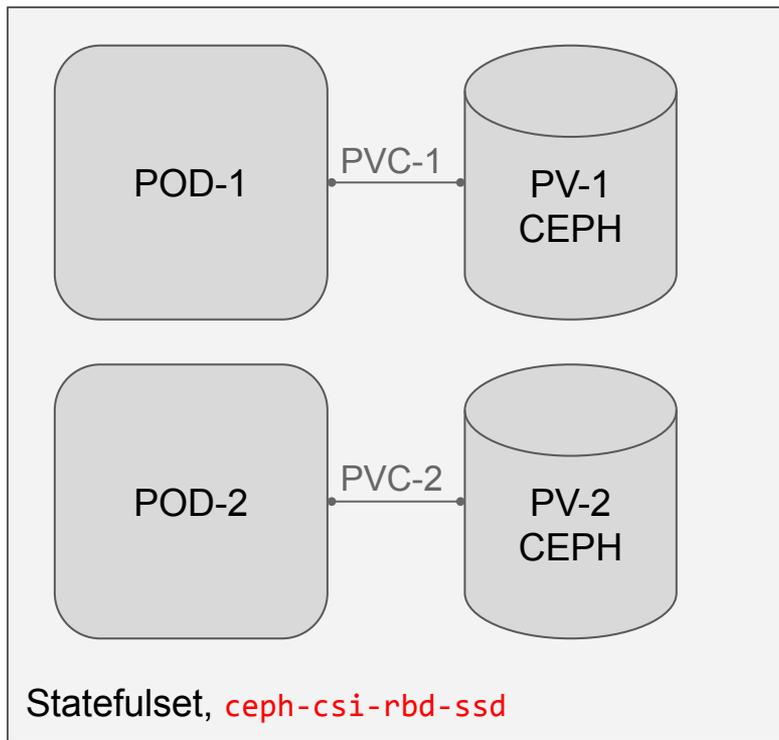
- PodAntiAffinity
 - *не обязательно
- PodDisruptionBudget
- Много операций с данными == iowait;
- Обязательное квотирование и ограничения
- Stateful, replicas 3+
- Бэкап!

Разные интересные штуки с практическими примерами

Миграция с одного на другой тип PV



Миграция с одного на другой тип PV



```
kind: StatefulSet
```

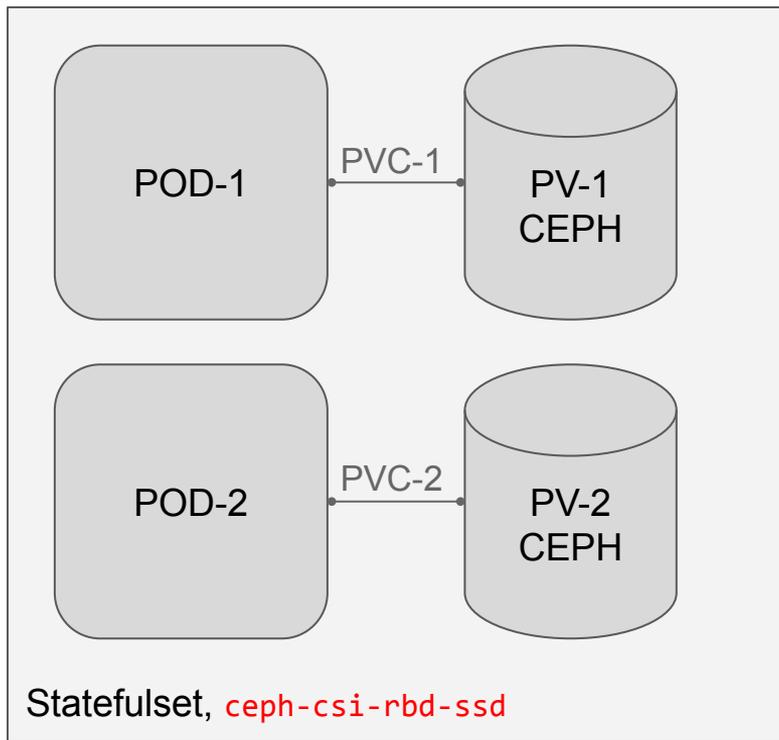
```
spec:
```

```
  volumeClaimTemplates(PVC):
```

```
    spec:
```

```
      storageClassName: ceph-csi-rbd-ssd
```

Миграция с одного на другой тип PV



```
kind: StatefulSet
```

```
spec:
```

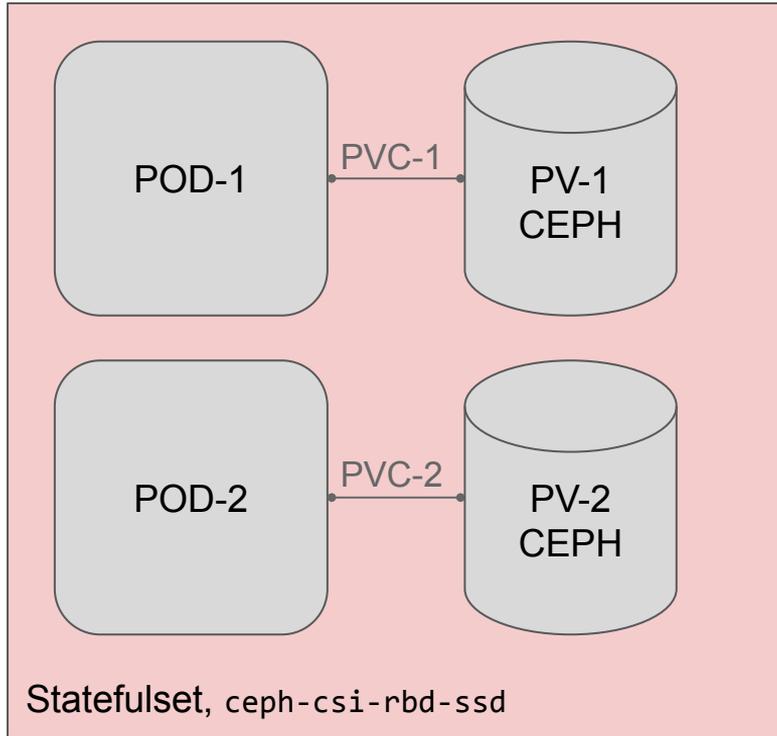
```
  volumeClaimTemplates(PVC):
```

```
    spec:
```

```
      storageClassName: ceph-csi-rbd-ssd
```

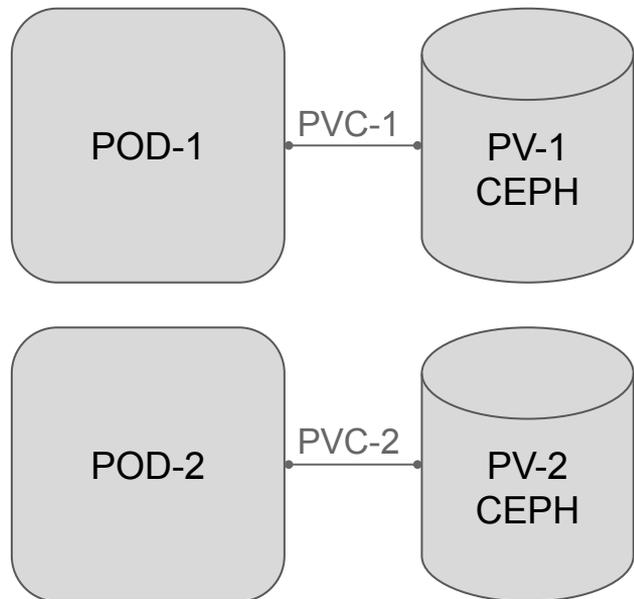
k8s не даёт изменить `volumeClaimTemplates`

Миграция с одного на другой тип PV



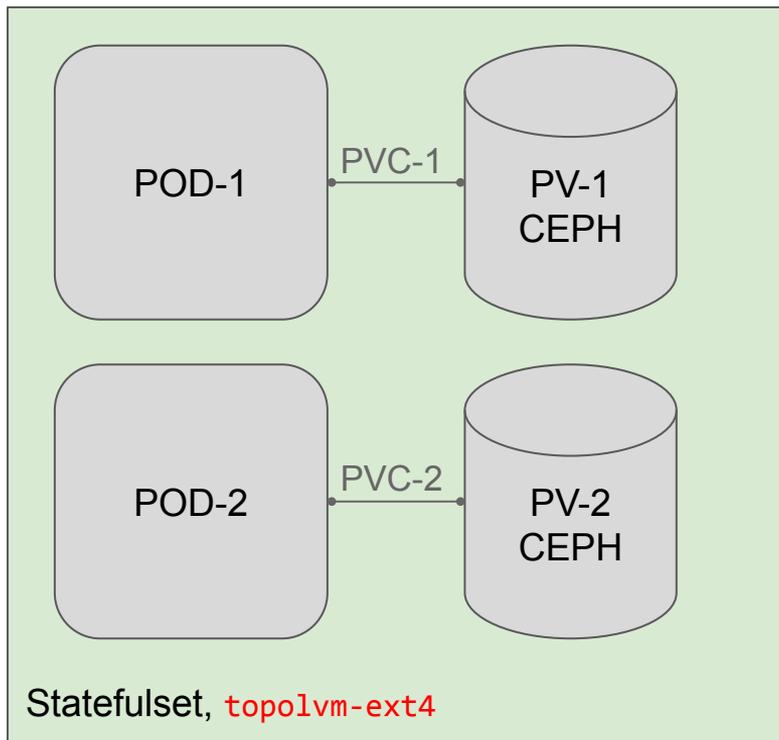
```
$ kubectl delete sts/name --cascade=orphan
```

Миграция с одного на другой тип PV



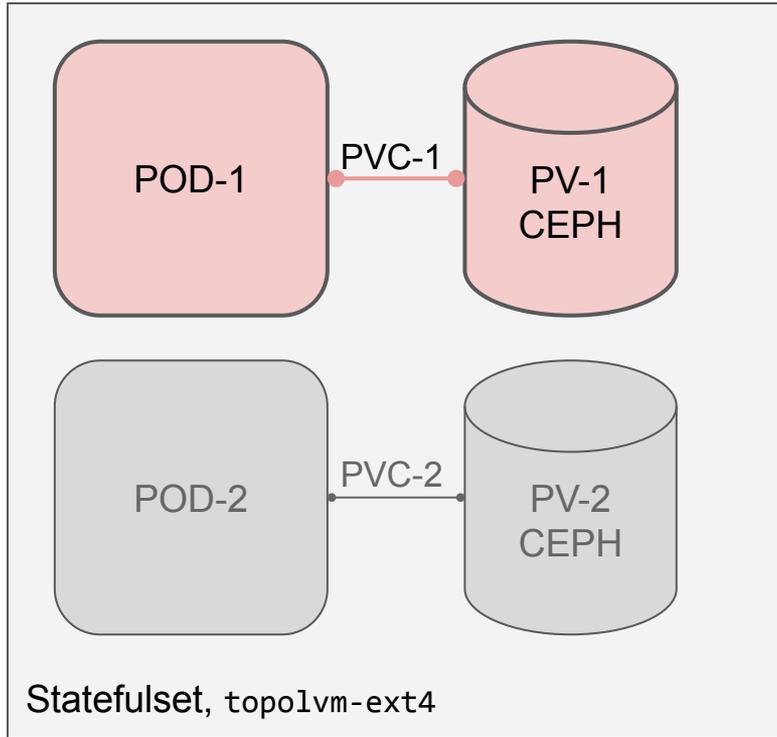
```
$ kubectl delete sts/name --cascade=orphan
```

Миграция с одного на другой тип PV



```
$ kubectl create -f sts_new_storage  
---  
kind: StatefulSet  
spec:  
  volumeClaimTemplates(PVC):  
    spec:  
      storageClassName: topolvm-ext4
```

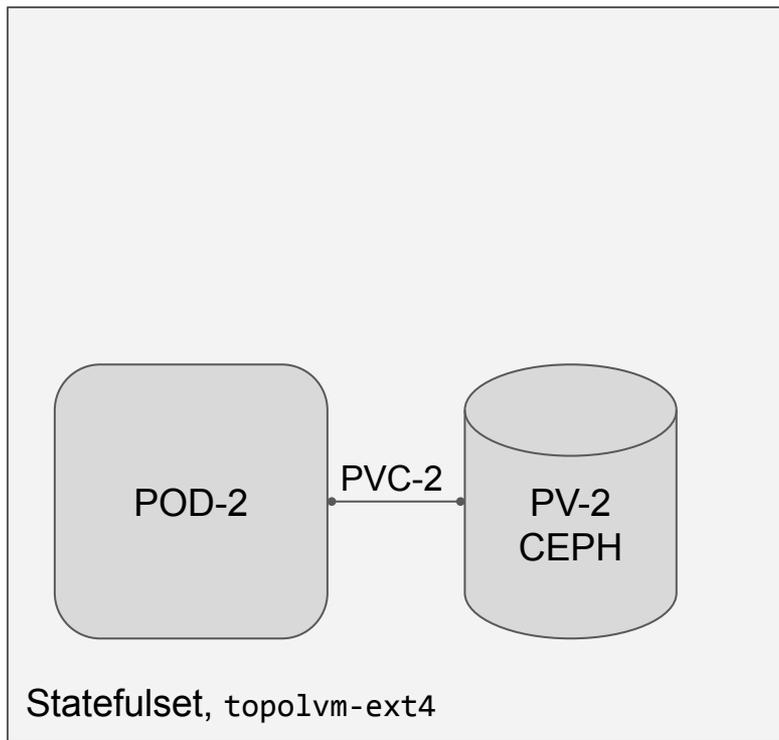
Миграция с одного на другой тип PV



```
$ kubectl delete POD-1
```

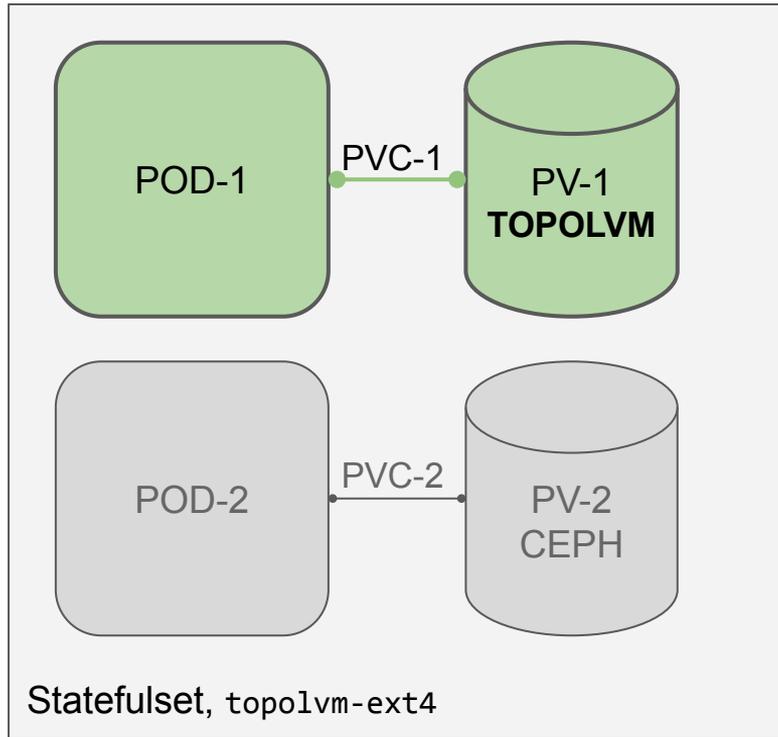
```
$ kubectl delete PVC-1
```

Миграция с одного на другой тип PV



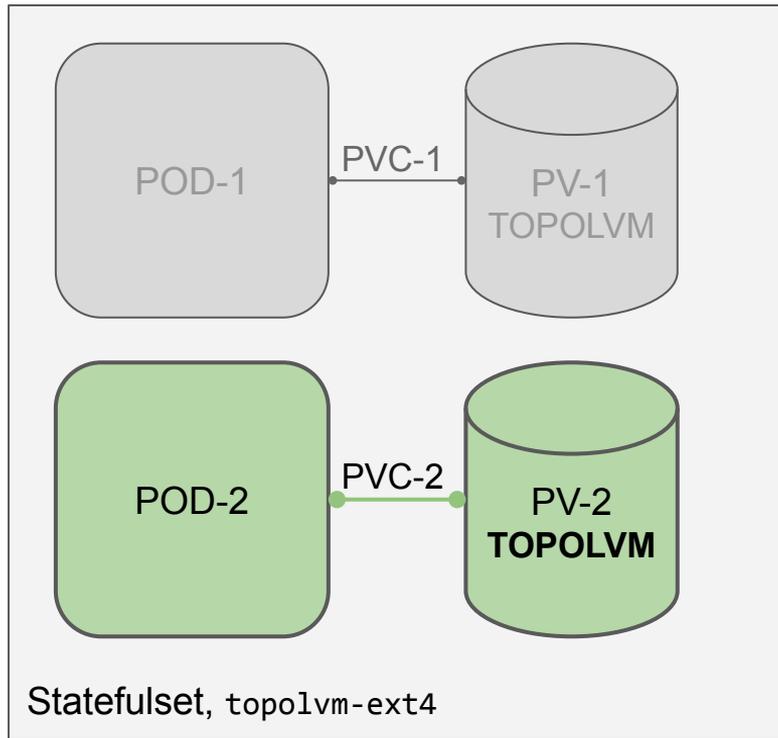
K8s пересоздаёт PV и POD

Миграция с одного на другой тип PV



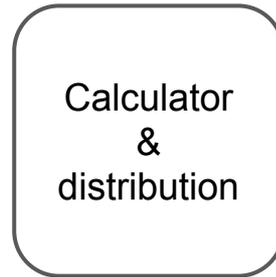
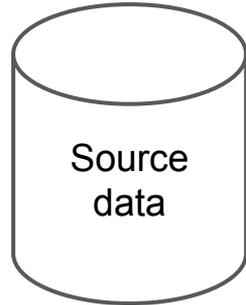
Повторяем с другими POD..

Миграция с одного на другой тип PV

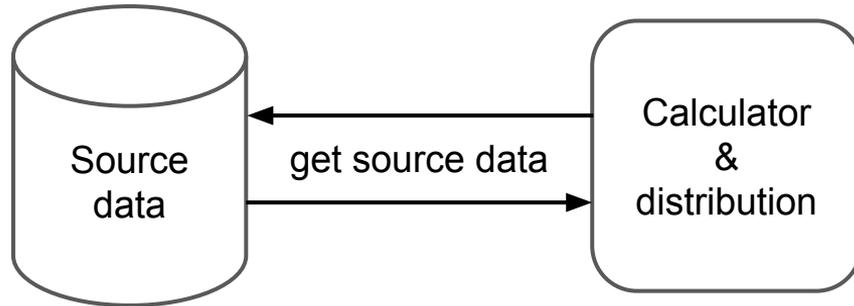


Profit!

Sidecar и Volumes

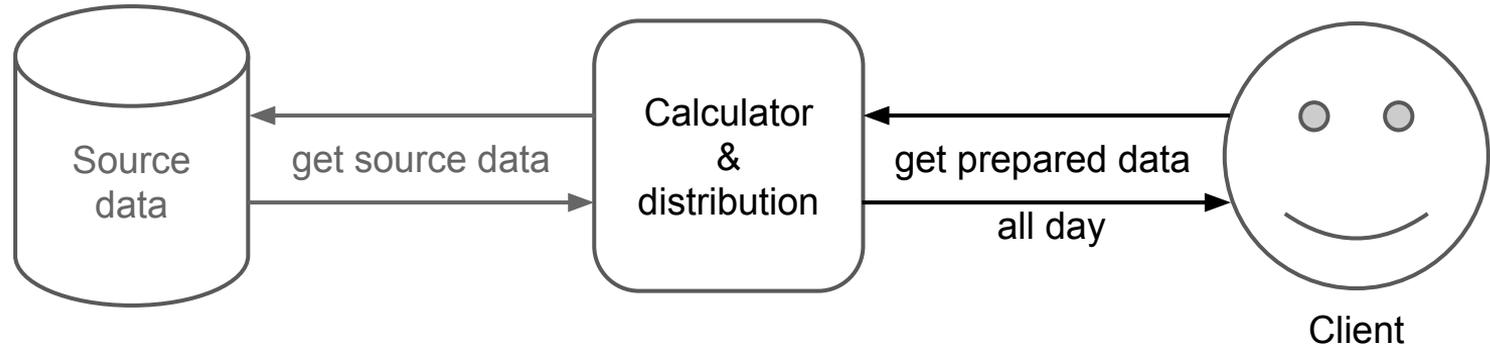


Sidecar и Volumes

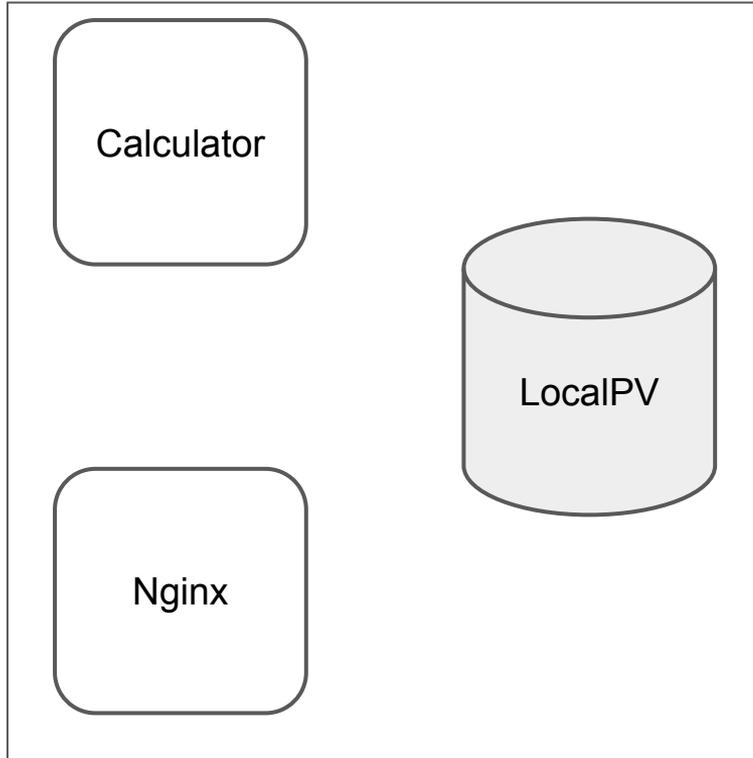


Client

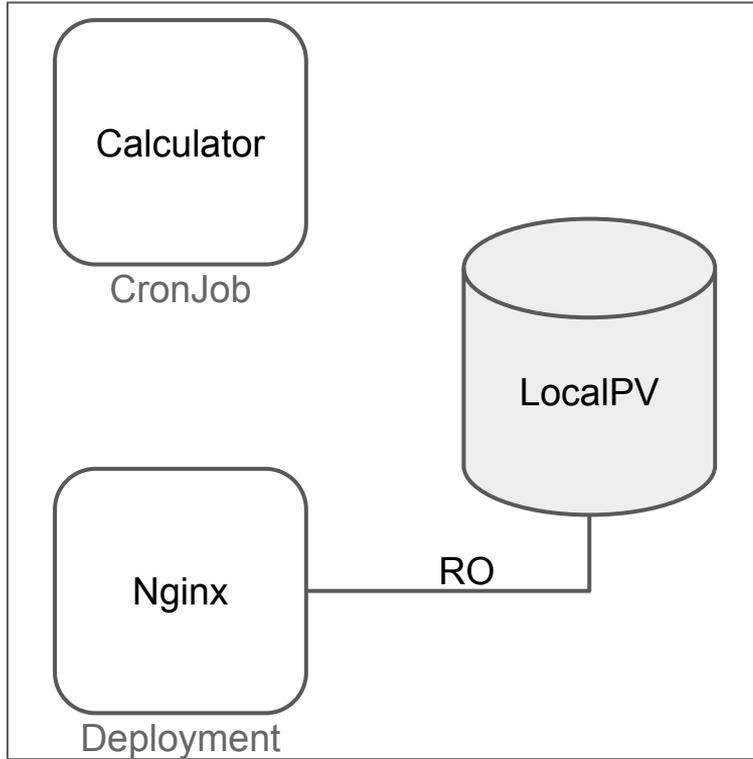
Sidecar и Volumes



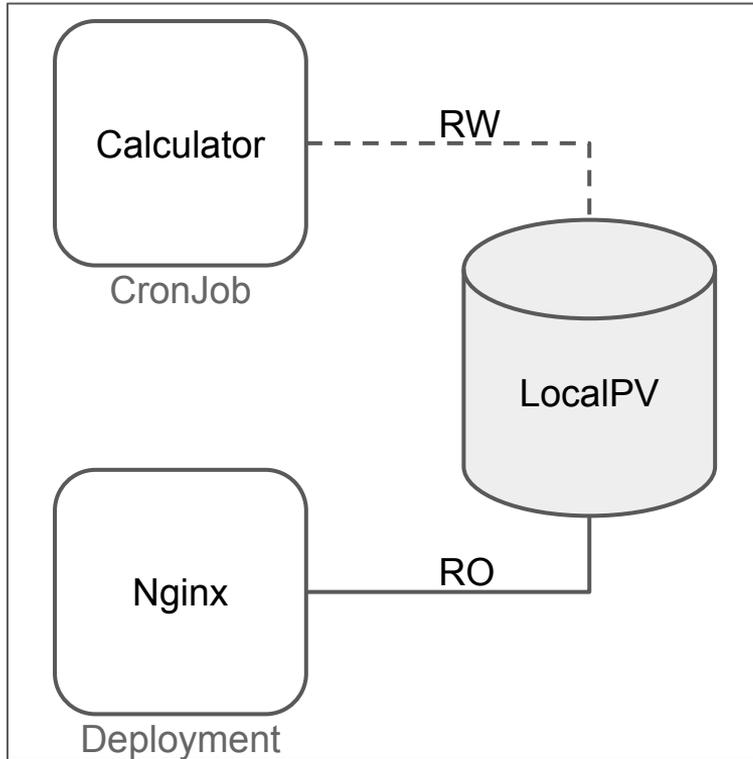
Sidecar и Volumes



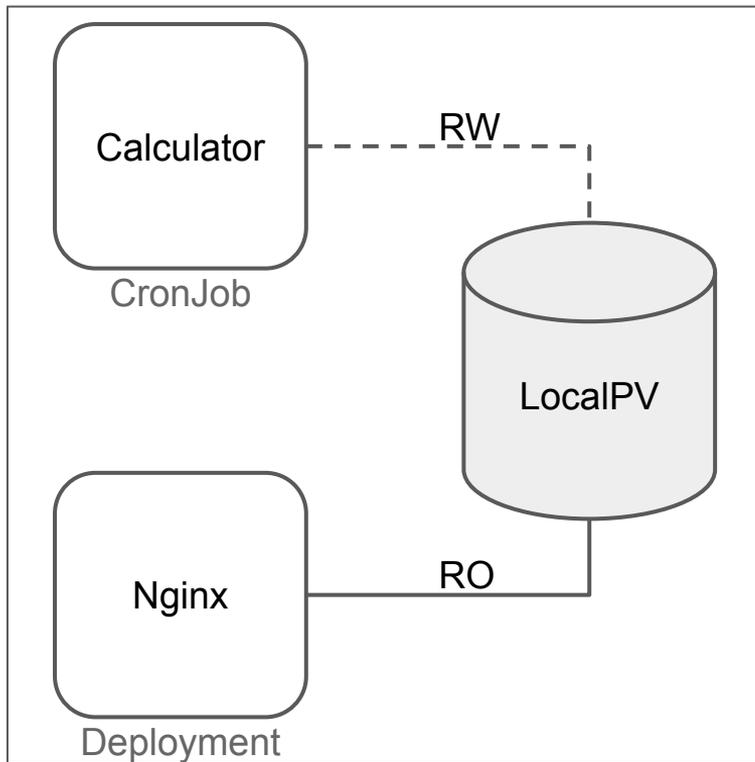
Sidecar и Volumes



Sidecar и Volumes

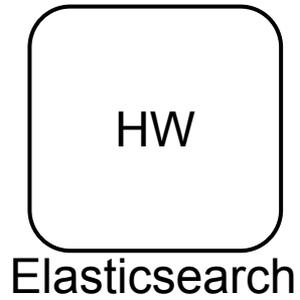


Sidecar и Volumes

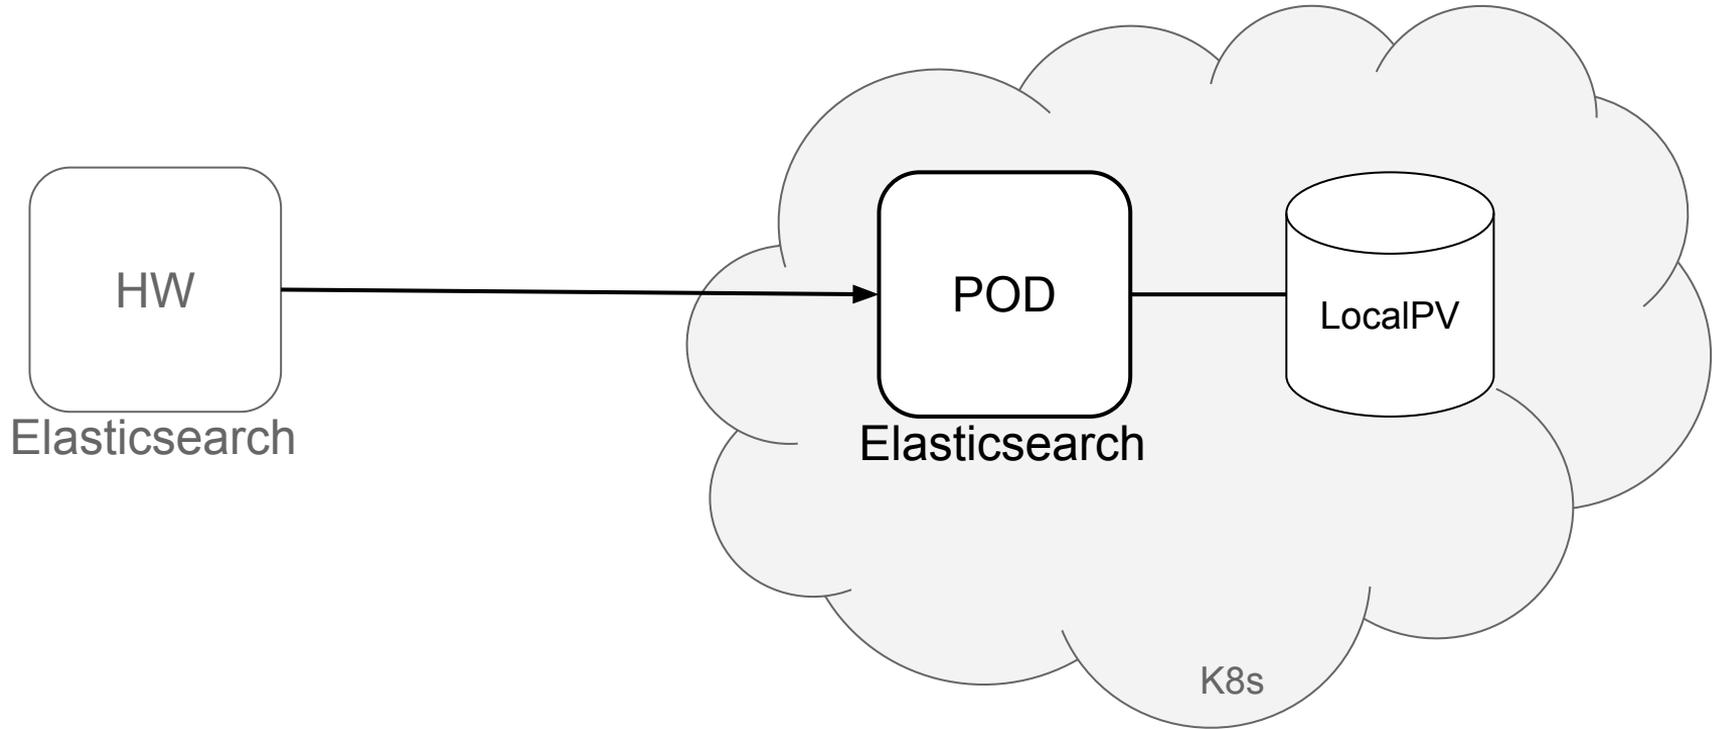


```
metadata:  
  name: calculator  
...  
affinity:  
  podAffinity:  
    requiredDuringSchedulingIgnoredDuringExecution:  
    - labelSelector:  
      matchExpressions:  
        - key: app.kubernetes.io/instance  
          operator: In  
          values:  
            - nginx  
    topologyKey: kubernetes.io/hostname
```

Limits.memory, stateful & iowait

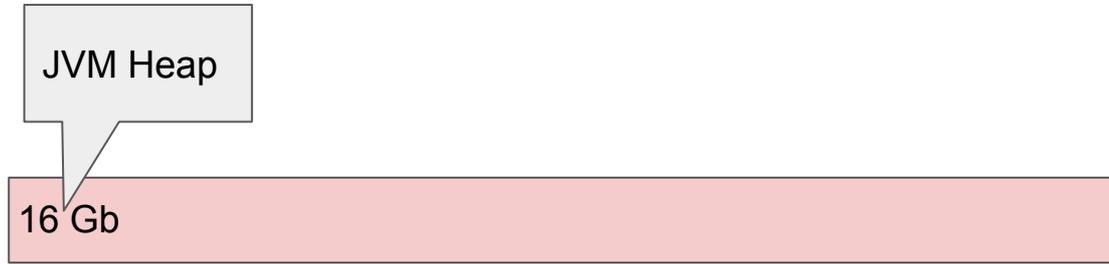


Limits.memory, stateful & iowait



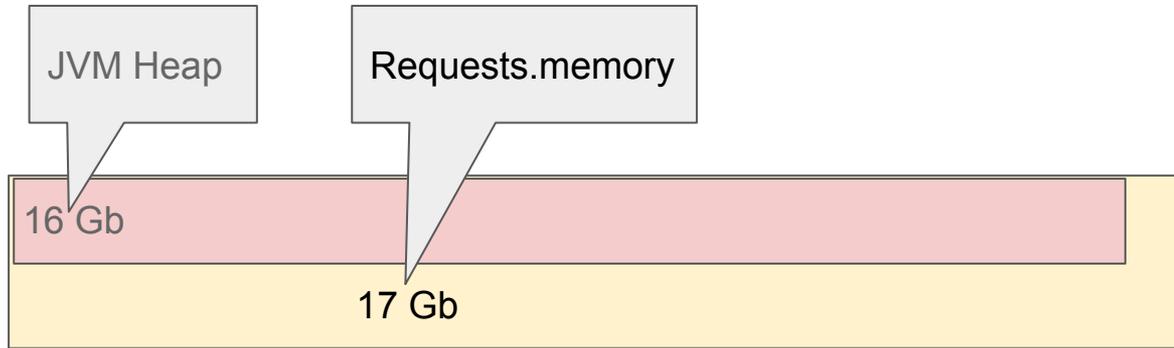
Limits.memory, stateful & iowait

Elasticsearch. JAVA



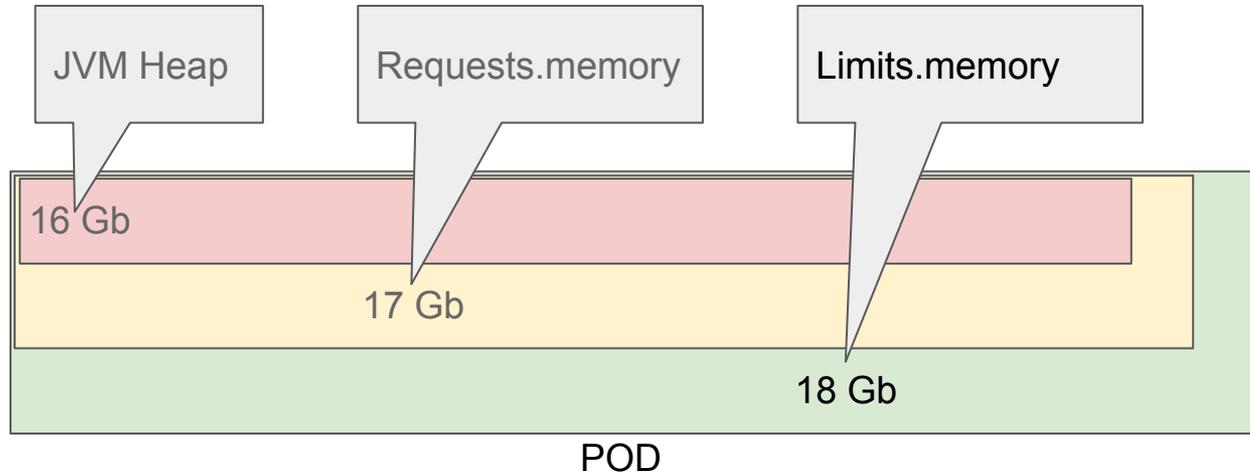
Limits.memory, stateful & iowait

Elasticsearch. JAVA



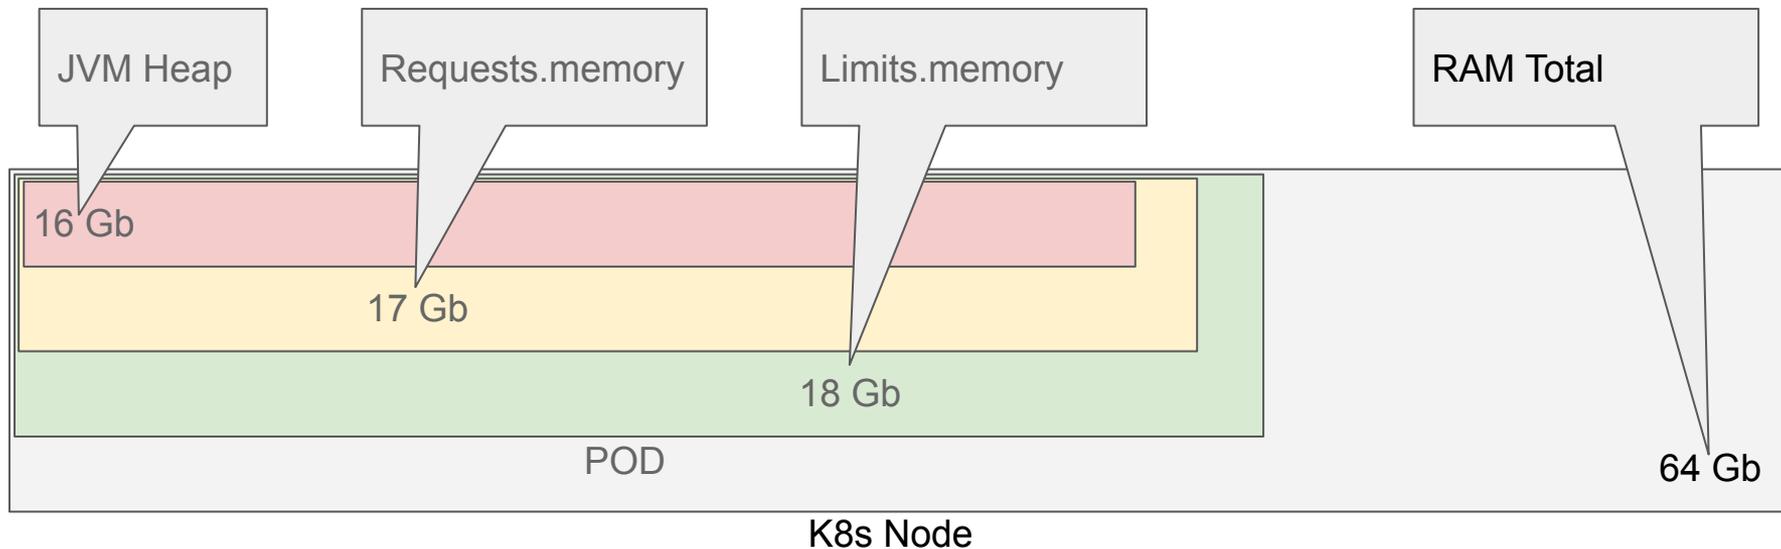
Limits.memory, stateful & iowait

Elasticsearch. JAVA



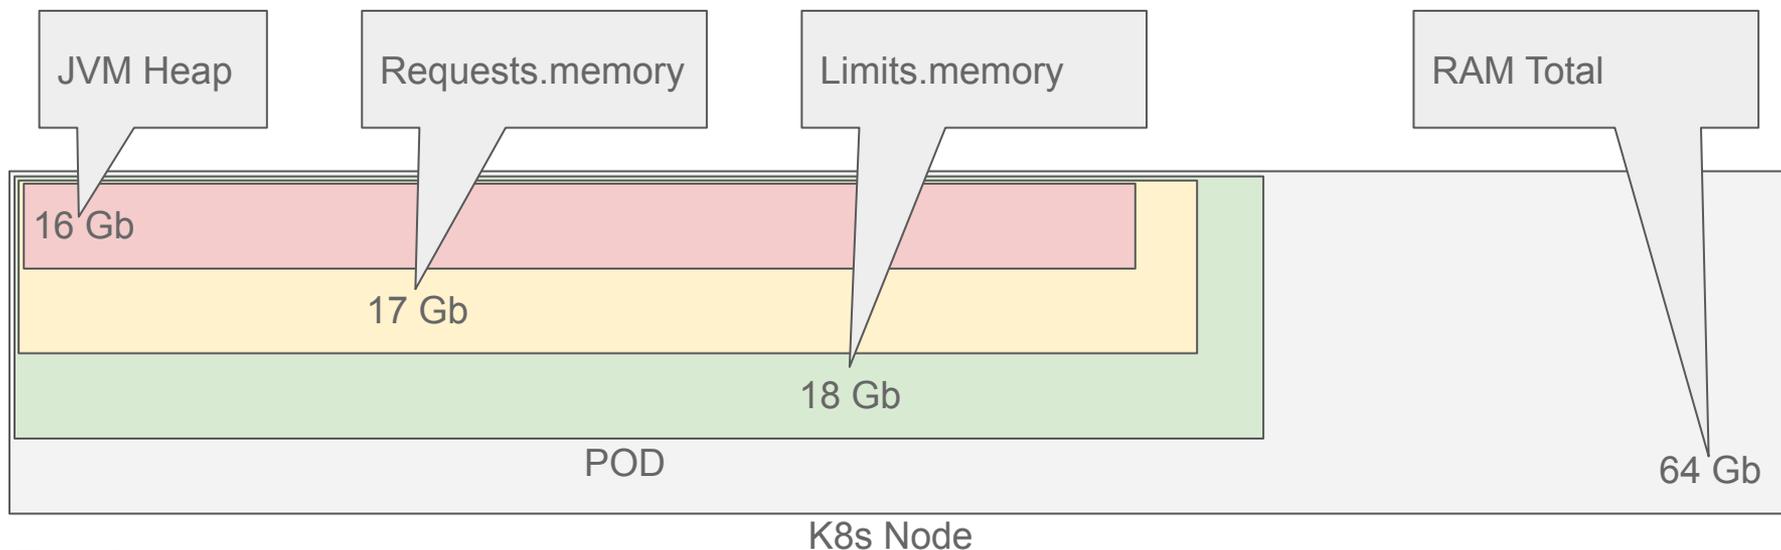
Limits.memory, stateful & iowait

Elasticsearch. JAVA



Limits.memory, stateful & iowait

Elasticsearch. JAVA

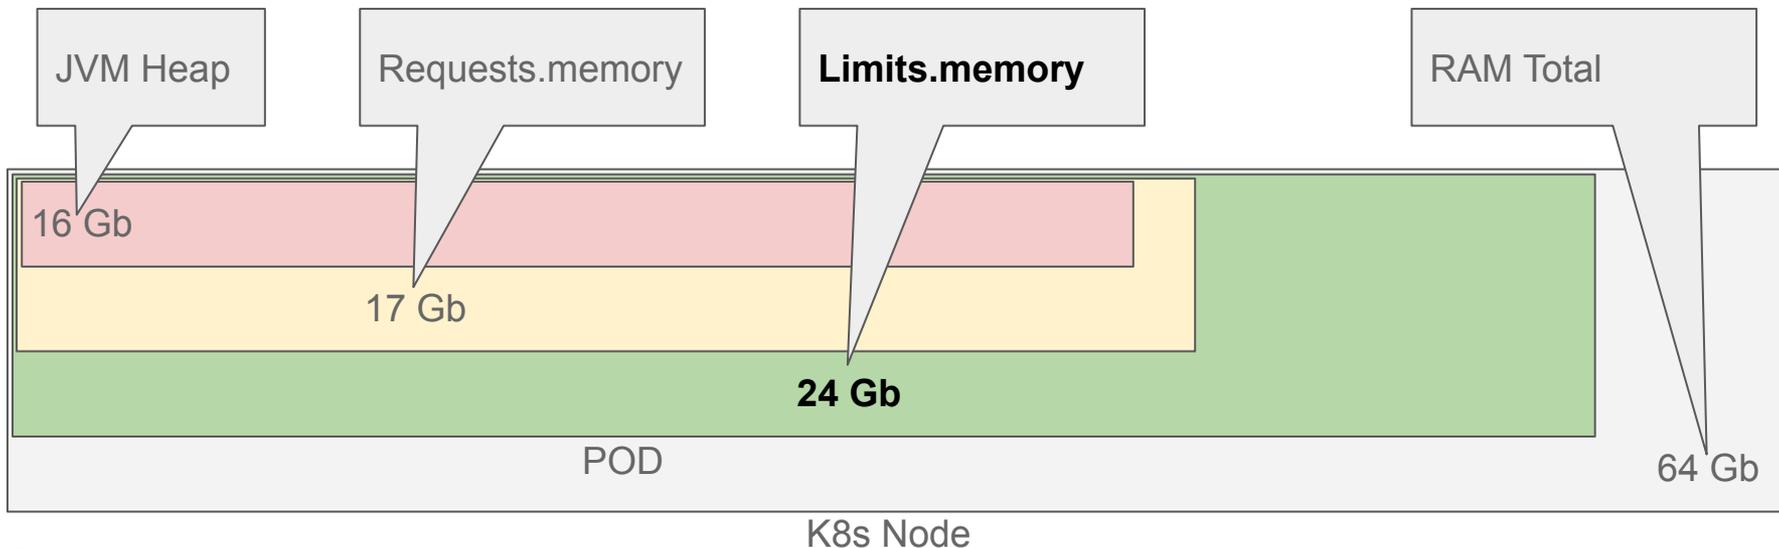


Проблема

- Активная работа с диском
- Сильный IOwait >15%

Limits.memory, stateful & iowait

Elasticsearch. JAVA



Решение

- Расширяем limits.memory для PageCache!
- IOwait проходит

Generic ephemeral volumes

- Сетевое или локальное хранилище
- Хранилище заданного размера
- Kubernetes сам выбирает куда зашедулить
- Типовые операции с томом(snapshot, resize)
- Можно наполнить начальными данными

Generic ephemeral volumes

Требования:

- Гарантия наличия места

Generic ephemeral volumes

Требования:

- Гарантия наличия места
- Стартовать в любой ситуации

Generic ephemeral volumes

Требования:

- Гарантия наличия места
- Стартовать в любой ситуации
- Быстрый диск - значит **локальный**

Generic ephemeral volumes. Пример

- Cronjob/Job
 - Расчётный сервис, большой объём данных

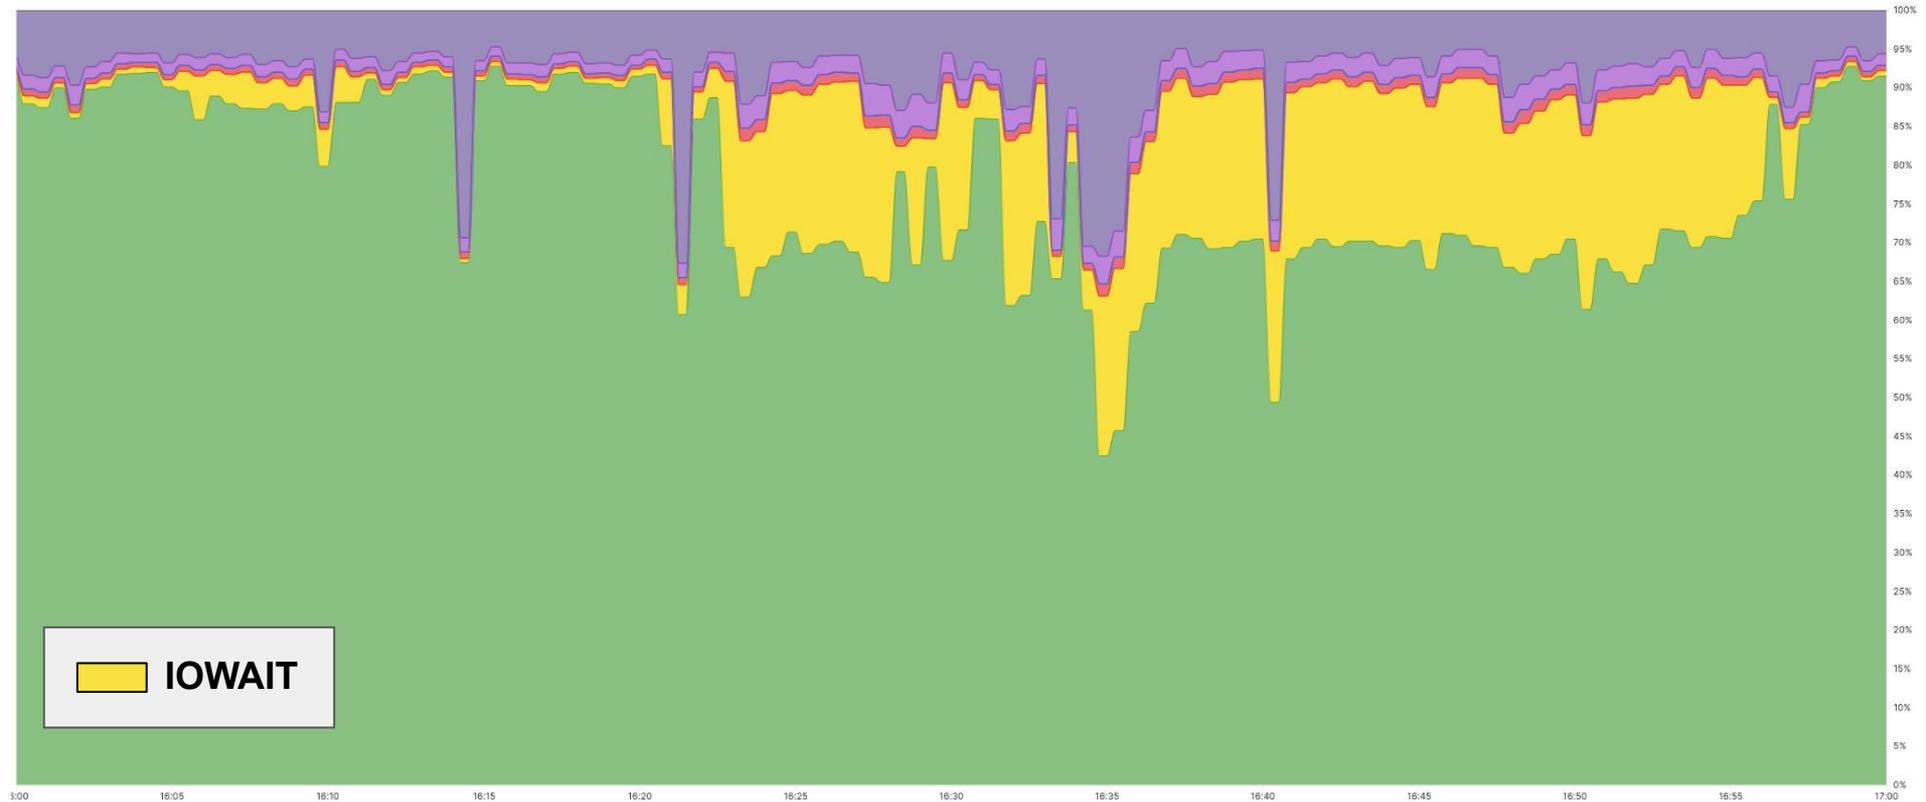
Generic ephemeral volumes. Пример

- Cronjob/Job
 - Расчётный сервис, большой объём данных
- Gitlab Runner
 - Кэш сборок

Generic ephemeral volumes. Пример

- Cronjob/Job
 - Расчётный сервис, большой объём данных
- Gitlab Runner
 - Кэш сборок
- Deployment
 - Скачать много данных на старте, но можно их терять

Ограничения IOPS



Ограничения IOPS. Как у нас?

- Подрывались 1 раз

Ограничения IOPS. Как у нас?

- Подрывались 1 раз
 - 2023 - SSD | 2024+ - NVMe

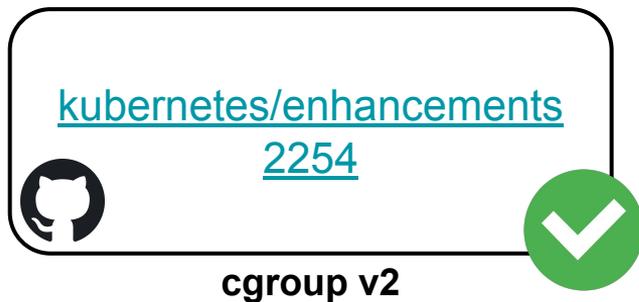
Metric	NVMe SSD	SATA SSD
IOPS	600,000+	100,000+
Latency (average)	80 microseconds	120 microseconds
Sequential Read Speed	3,500+ MB/s	550+ MB/s
Sequential Write Speed	3,000+ MB/s	520+ MB/s
Random Read Speed	400,000+ IOPS	40,000+ IOPS
Random Write Speed	400,000+ IOPS	80,000+ IOPS

Ограничения IOPS. Как у нас?

- Подрывались 1 раз
 - 2023 - SSD | 2024+ - NVMe
- Ничего не делаем,
костыль = 6+ месяцев

Metric	NVMe SSD	SATA SSD
IOPS	600,000+	100,000+
Latency (average)	80 microseconds	120 microseconds
Sequential Read Speed	3,500+ MB/s	550+ MB/s
Sequential Write Speed	3,000+ MB/s	520+ MB/s
Random Read Speed	400,000+ IOPS	40,000+ IOPS
Random Write Speed	400,000+ IOPS	80,000+ IOPS

Ограничения IOPS. А что сообщество?



Ограничения IOPS. А что сообщество?

[kubernetes/enhancements](#)
2254



cgroup v2

[kubernetes/enhancements](#)
3008



quality-of-service resources

[kubernetes/issue](#)
92287



iops limit

Плавный переход к результатам

Итоги: какие PV у нас используются

Список storageClass с которыми мы работаем:

- **topolvm-ext4** — локальное, стандартное, на SSD
- **topolvm-hdd-ext4** — локальное, медленное, большое, на HDD

Итоги: какие PV у нас используются

Список storageClass с которыми мы работаем:

- **topolvm-ext4** — локальное, стандартное, на SSD
- **topolvm-hdd-ext4** — локальное, медленное, большое, на HDD
- **ceph-csi-rbd** — сетевое, медленное, большое
- **ceph-csi-rbd-ssd** — сетевое, быстрое, маленькое

Итоги: какие PV у нас используются

Список storageClass с которыми мы работаем:

- **topolvm-ext4** — локальное, стандартное, на SSD
- **topolvm-hdd-ext4** — локальное, медленное, большое, на HDD
- **ceph-csi-rbd** — сетевое, медленное, большое
- **ceph-csi-rbd-ssd** — сетевое, быстрое, маленькое
- **nfs-<namespace>** — сетевое, с бэком на Netapp, ReadWriteMany

Итоги: правильный stateful

- Думать о кворуме

Итоги: правильный stateful

- Думать о кворуме
- Выпадение 1 POD — это норма
 - Настроить защиту!

Итоги: правильный stateful

- Думать о кворуме
- Выпадение 1 POD — это норма
 - Настроить защиту!
- Больше типов PV — не насилуем инфраструктуру

Итоги: правильный stateful

- Думать о кворуме
- Выпадение 1 POD — это норма
 - Настроить защиту!
- Больше типов PV — не насилуем инфраструктуру
- Можем советовать крутой оператор LocalPV
 - github.com/topolvm/topolvm 

Итоги: правильный stateful

- Думать о кворуме
- Выпадение 1 POD — это норма
 - Настроить защиту!
- Больше типов PV — не насилуем инфраструктуру
- Можем советовать крутой оператор LocalPV
 - github.com/topolvm/topolvm 
- Предоставляем разные типы PV и **больше не поднимаем VM для Stateful**

Итоги: правильный stateful

- Думать о кворуме
- Выпадение 1 POD — это норма
 - Настроить защиту!
- Больше типов PV — не насилуем инфраструктуру
- Можем советовать крутой оператор LocalPV
 - github.com/topolvm/topolvm 
- Предоставляем разные типы PV и больше не поднимаем VM для Stateful
- Бэкап!

Спасибо!

Вопросы?



Дехтярёв Женя

edekhtyarev 

e.dekhtyarev@2gis.ru

github.com/dekhtyarev/devoops-readme

