JPAAWG 5th General Meeting

レガシーなEメールシステムをKubernetes化しました！

IIJ
Internet Initiative Japan

2022/11/07

IIJ: 衣笠 茂浩

30th Anniversary
Ongoing Innovation

私は長年 Eメールシステムを開発・導入・運用しています。

物理サーバ・仮想・オブジェクトストレージ・NoSQLと世代が変わる中で、今回Kubernetesを全面採用しレガシー Eメールシステムを完全リプレースしました。

本日はKubernetes導入における「考え方」・「はまりどころ」を具体的にお伝えし、導入障壁が下がれば良いと考えています

お断り： 内容は会社としての見解では無く個人の見解です

- **話者: IIJ 衣笠 茂浩**
  - メール歴20年
    - 移行: 2桁超
    - のべ移行アカウント: 1100万超

- **仕事:**
  - メール・動画配信
  - アーキテクト
  - 管理職（部長）

2011年 ～ ASP・オンプレ時代

- 2021-年： 複数メールASP 導入
- 2020年： 数十万規模メールASP 導入
- 2019年： 数百万規模メールASP 導入
- 2018年：
  - 数十万規模メールASP導入
  - 新メールASP立ち上げ
- 2017年：数十万規模 導入
- 2015-16年：数百万規模 導入
- 2013-14年：
  - 数百万規模導入
  - 数十万規模導入
- 2011年：メールASP立ち上げ

2003年 ～ 2010年 オンプレ時代

- 2009年-2011年：数十万規模導入
- 2007年-2008年：数十万規模導入
- 2006年：数万規模導入
- 2005年：
  - 数十万規模導入
  - 数万規模導入
- 2004年：数十万規模導入
- 2003年：数十万規模導入

ASP化 が さらに加速

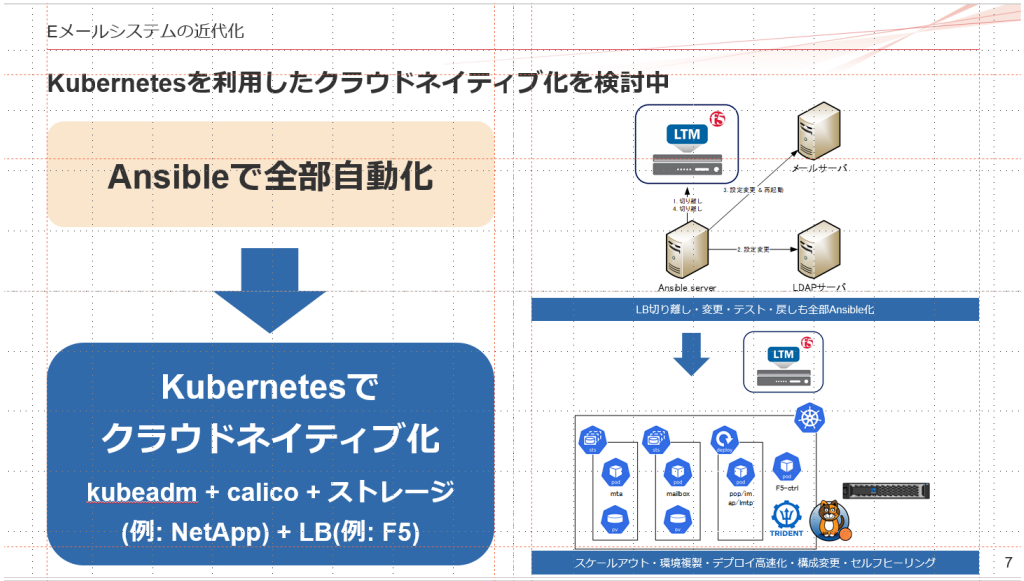

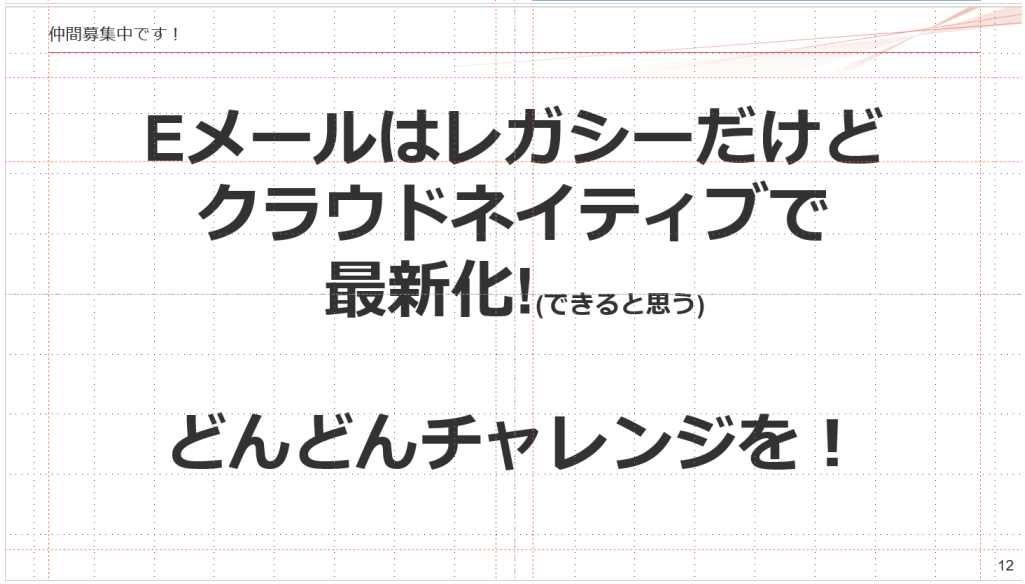

某サービスで Kubernetesを 全面採用 しました！

安定稼働中です！

Kubernetesとは

- デプロイやスケーリングを自動化
- コンテナ化されたアプリケーションを管理
- オープンソース

自分で調査可能（重要）

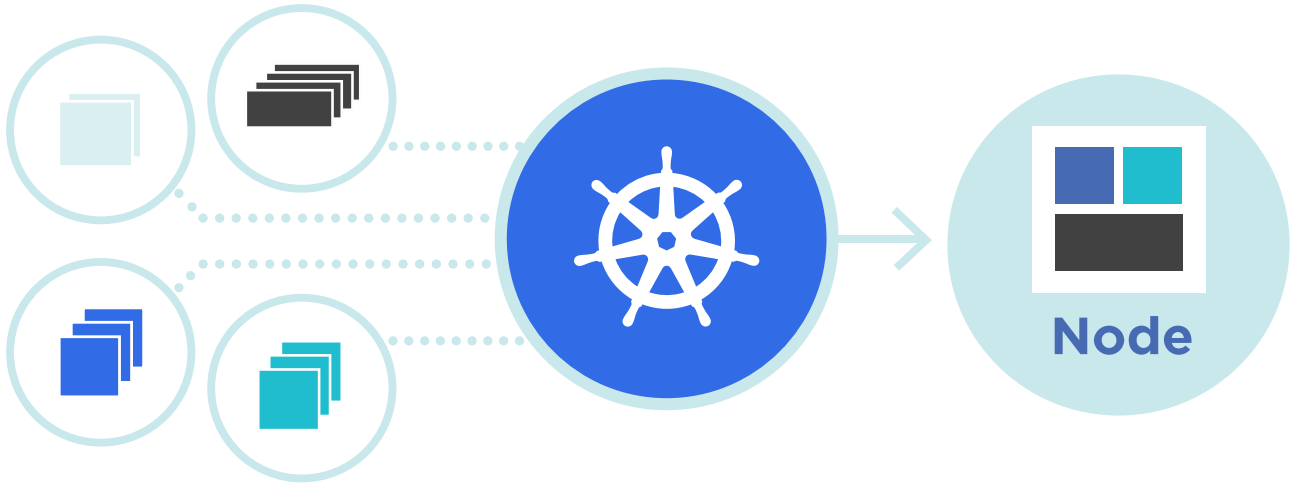

参考: https://kubernetes.io/ja/

いい感じなEメールシステム

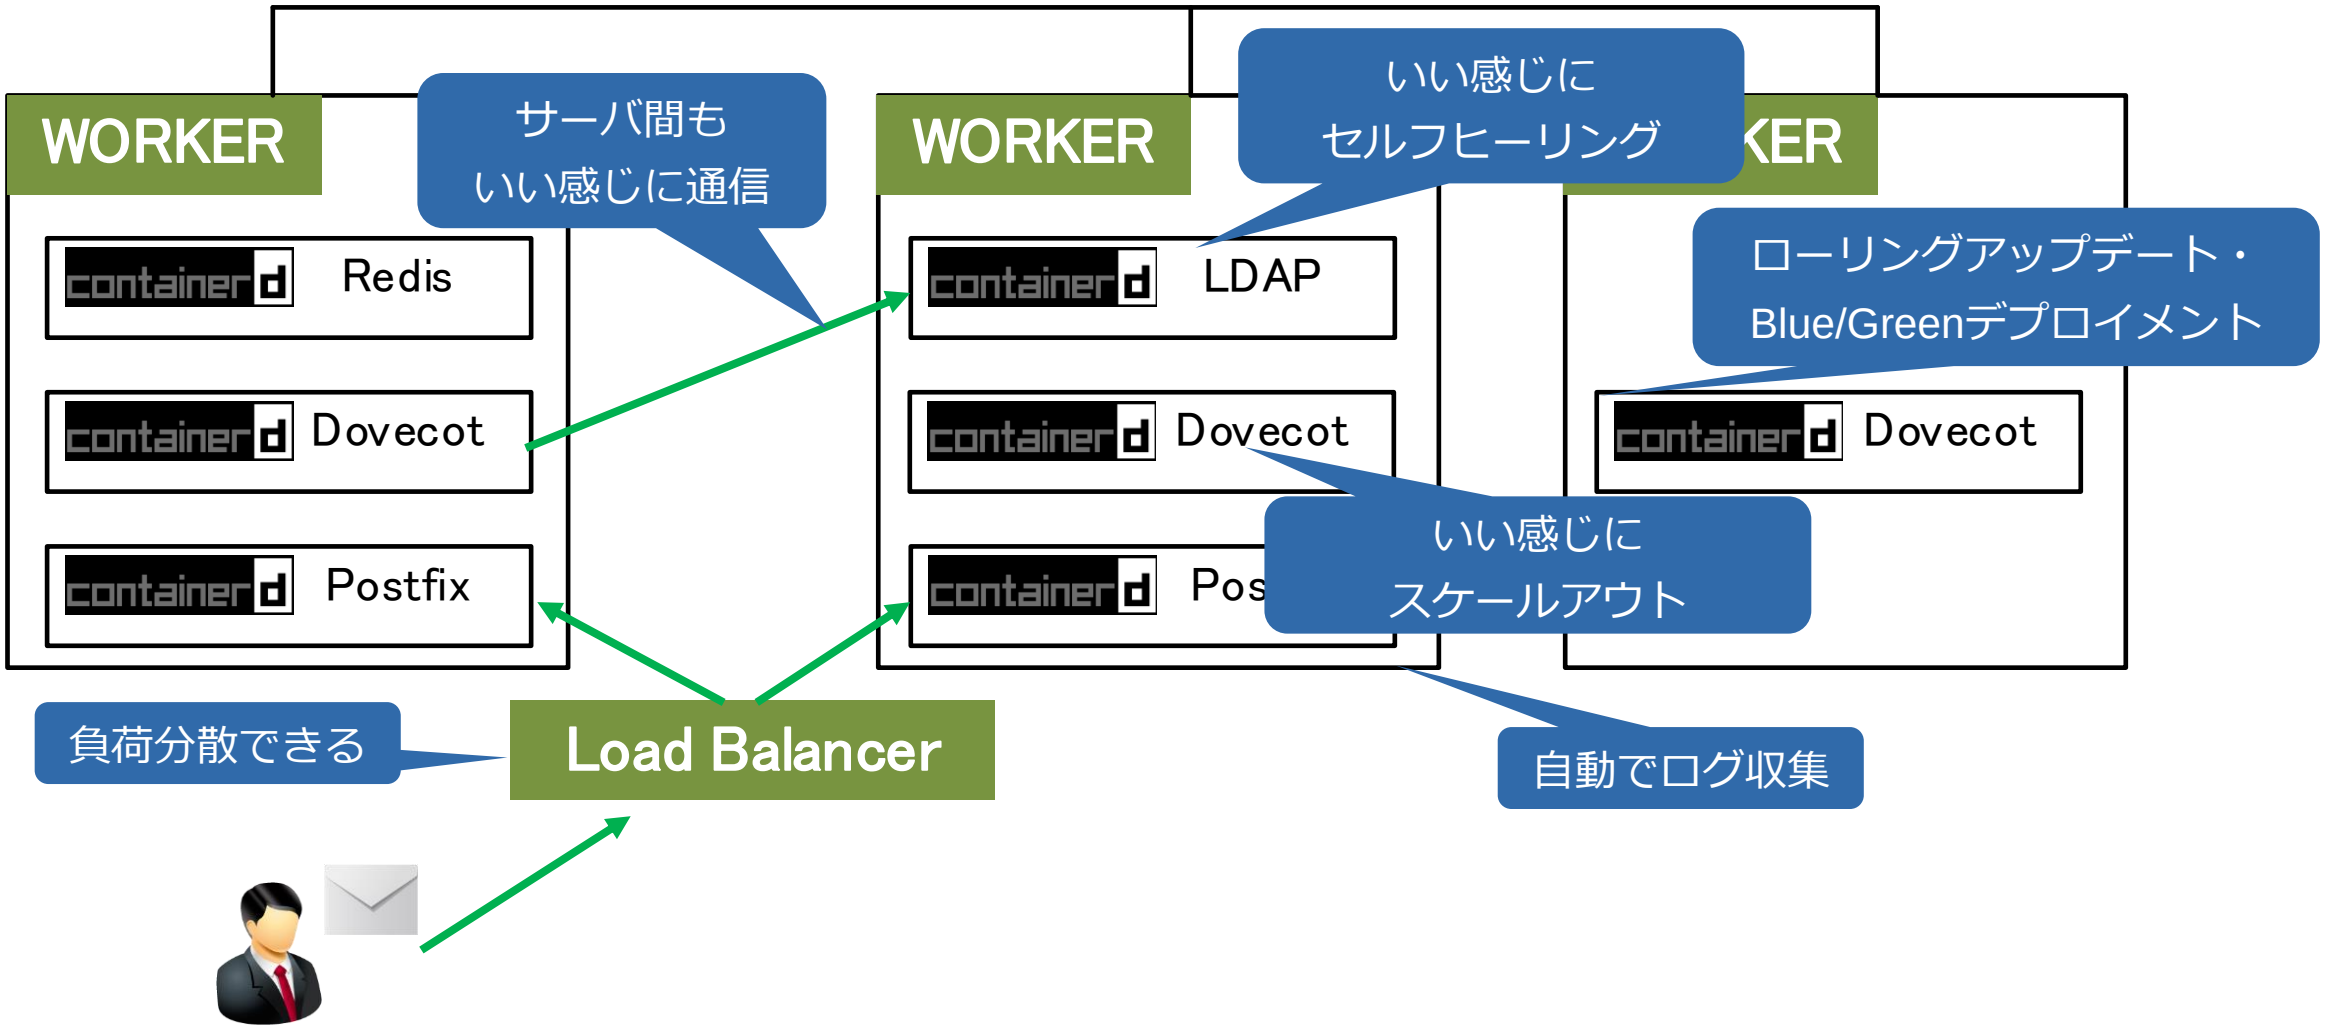

頑張るといっぱいでした

1. **クラスタ作りこみ**
    1. クラスタ作成
    2. 外部連携（LB・ストレージ)
2. **アプリ作りこみ**
    1. コンテナ作成
    2. デプロイ
    3. コントローラ自作
3. **モニタリング・ログ**
    1. モニタリング
    2. 監視
    3. ログ収集
4. **工夫**
    1. 性能面
    2. 可用性

トピックとはまりどころを伝えます

お断り: 紹介内容はできるだけリアルな構成としていますが、アプリ周りは皆様にわかりやすいようにOSS系を中心に紹介します

Kubernetes クラスタ作りこみ
(オンプレです)

クラスタベース(今回利用した構成の場合)

	プロダクト名	説明
	RockyLinux	Linux OS
	Kubeadm	Kubernetesクラスター環境を作成・管理するツール
	Kubelet	Podやコンテナの起動
	Kubectl	クラスターにアクセスするためのコマンドラインツール
	etcd	クラスターの構成情報・状態を保存するKVS
	Calico	コンテナにネットワークとセキュリティポリシー機能を提供
	F5 Container Ingress Services	F5製連携ソフト。BIG-IP連携で利用。
	Astra Trident	NetApp製連携ソフト。NetApp連携(NFS/iSCSI)で利用。

基本OSS。コード調査可能

基本:

手順を見れば大体できます

- **Kubeadm + calicoでOK**

  https://kubernetes.io/docs/setup/production-environment/tools/kubeadm/install-kubeadm/

応用:

- **可用性考慮で構成変化有り**

  https://kubernetes.io/docs/setup/#production-environment

- **Container Network Interface(CNI)・Container Storage Interface (CSI) は状況に応じて選択を。**

3台で冗長化構成が基本

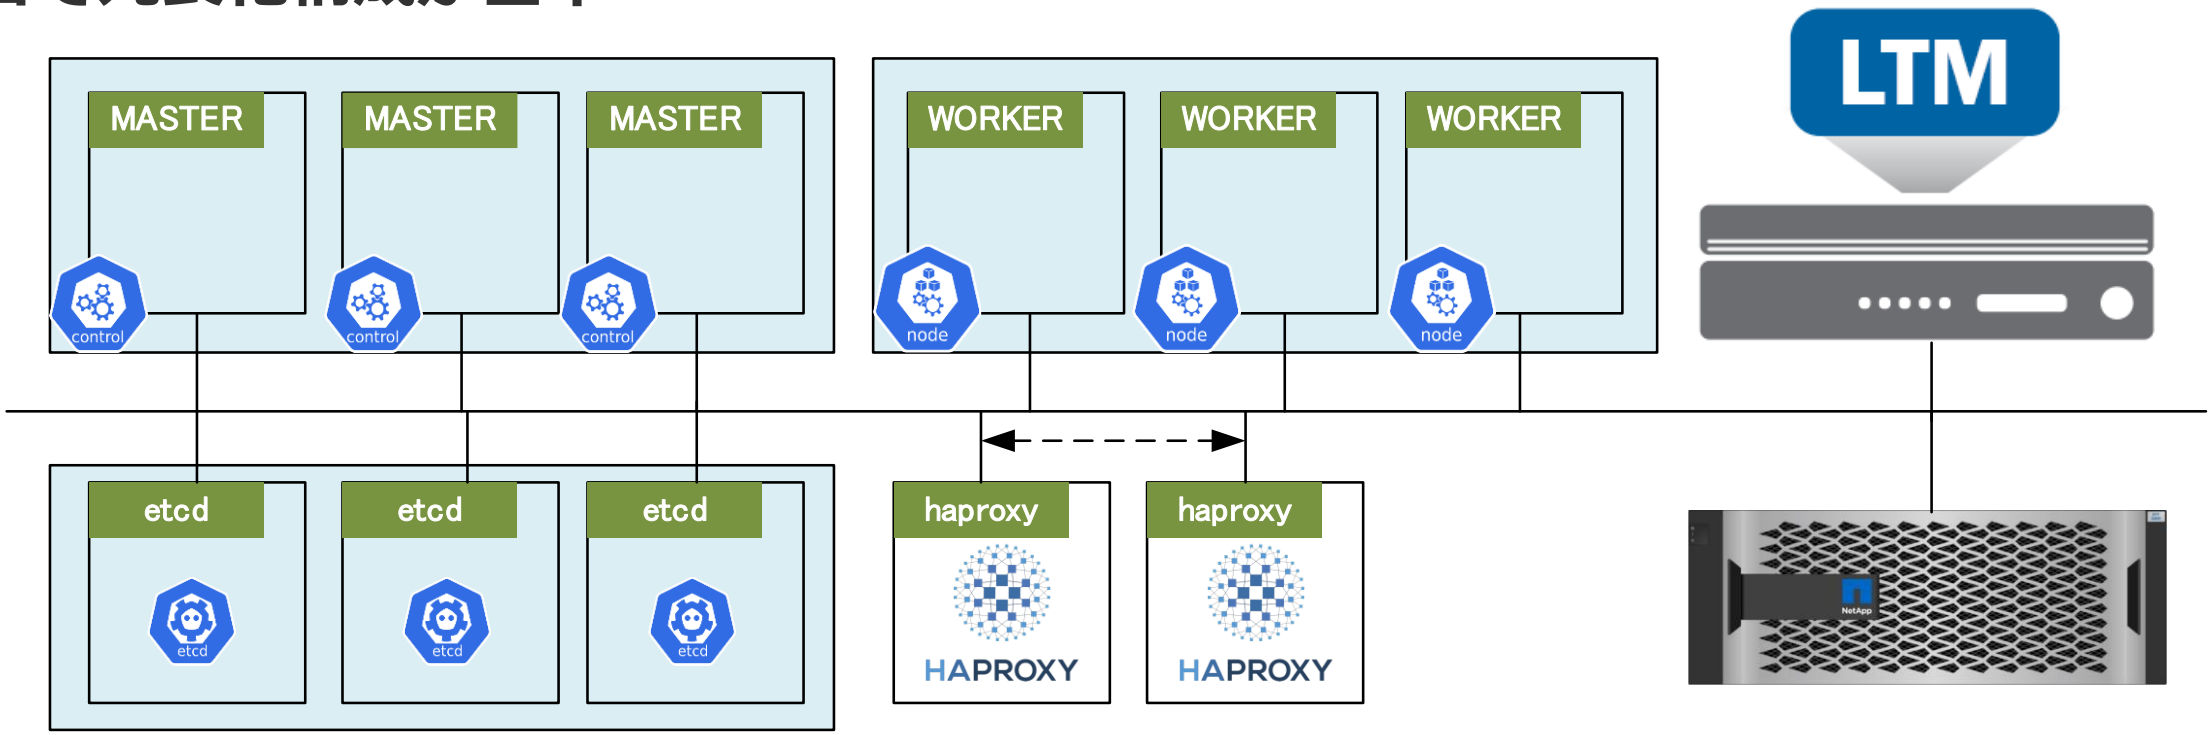

名称	説明
MASTER	コントロールプレーン。スケジューリング・イベント検出および応答等を行う。
WORKER	ワーカーノード。POD実行。
etcd	キーバリューストア。クラスタ情報保存に利用。多数決モデル利用。
haproxy	クラスタ外部からMASTER APIへのアクセス冗長化に利用

スケールアウトでLB配下に動的組み込み。IPv6にも対応。

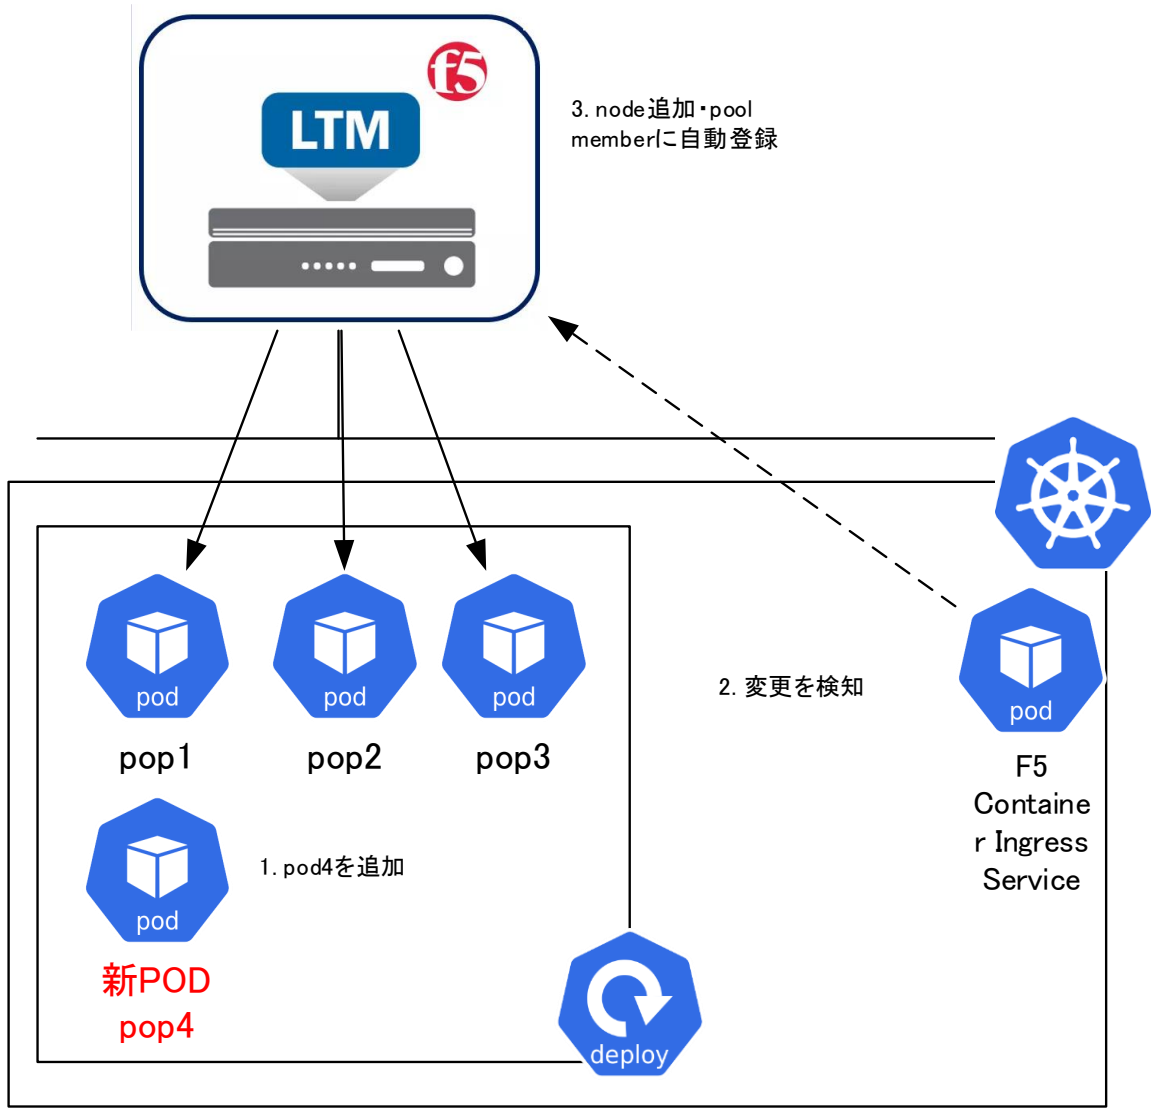

3台しかいない

Status	Name	Description	Application	Address	FQDN	Ephemeral	Partition / Path
	10.244.139.33			10.244.139.33		No	mail-test
	10.244.52.127			10.244.52.127		No	mail-test
	10.244.52.67			10.244.52.67		No	mail-test
	fd00:1:0:3459:57f7:b97b:403:244f			fd00:1:0:3459:57f7:b97b:403:244f		No	mail-test
	fd00:1:0:3459:57f7:b97b:403:247c			fd00:1:0:3459:57f7:b97b:403:247c		No	mail-test
	fd00:1:0:6258:3e51:ea64:3455:e2d6			fd00:1:0:6258:3e51:ea64:3455:e2d6		No	mail-test

Search / Create... / Enable / Disable / Force Offline / Delete...

```
# kubectl scale statefulset pop --replicas=4
```

4台構成に！
Dual Stackにも対応！

Status	Name	Description	Application	Address	FQDN	Ephemeral	Partition / Path
	10.244.139.33			10.244.139.33		No	mail-test
	10.244.139.60			10.244.139.60		No	mail-test
	10.244.52.127			10.244.52.127		No	mail-test
	10.244.52.67			10.244.52.67		No	mail-test
	fd00:1:0:3459:57f7:b97b:403:244f			fd00:1:0:3459:57f7:b97b:403:244f		No	mail-test
	fd00:1:0:3459:57f7:b97b:403:247c			fd00:1:0:3459:57f7:b97b:403:247c		No	mail-test
	fd00:1:0:6258:3e51:ea64:3455:e2c0			fd00:1:0:6258:3e51:ea64:3455:e2c0		No	mail-test
	fd00:1:0:6258:3e51:ea64:3455:e2d6			fd00:1:0:6258:3e51:ea64:3455:e2d6		No	mail-test

Search / Create... / Enable / Disable / Force Offline / Delete...

Scale outも簡単(自動でnode/poolに追加)

注意点・はまりどころ

1. **BIGIP本体でREST・BGP有効化・AS3導入が必要**

2. **（重要）構成変更（POD増減等)反映まで60秒程度かかる**
   - パーティションが複数存在する場合はさらに時間がかかる場合あり

3. **（重要） BIGIP restjavadが安定しないことがある**
   - BIGIP本体の最新化・Java HEAP最適化等必要
     https://cdn.f5.com/product/bugtracker/ID769581.html
     https://support.f5.com/csp/article/K12410040

上記を踏まないチューニングが必須

ボリューム（NFS・iSCSI)を必要に応じて自動作成。DRにも対応。

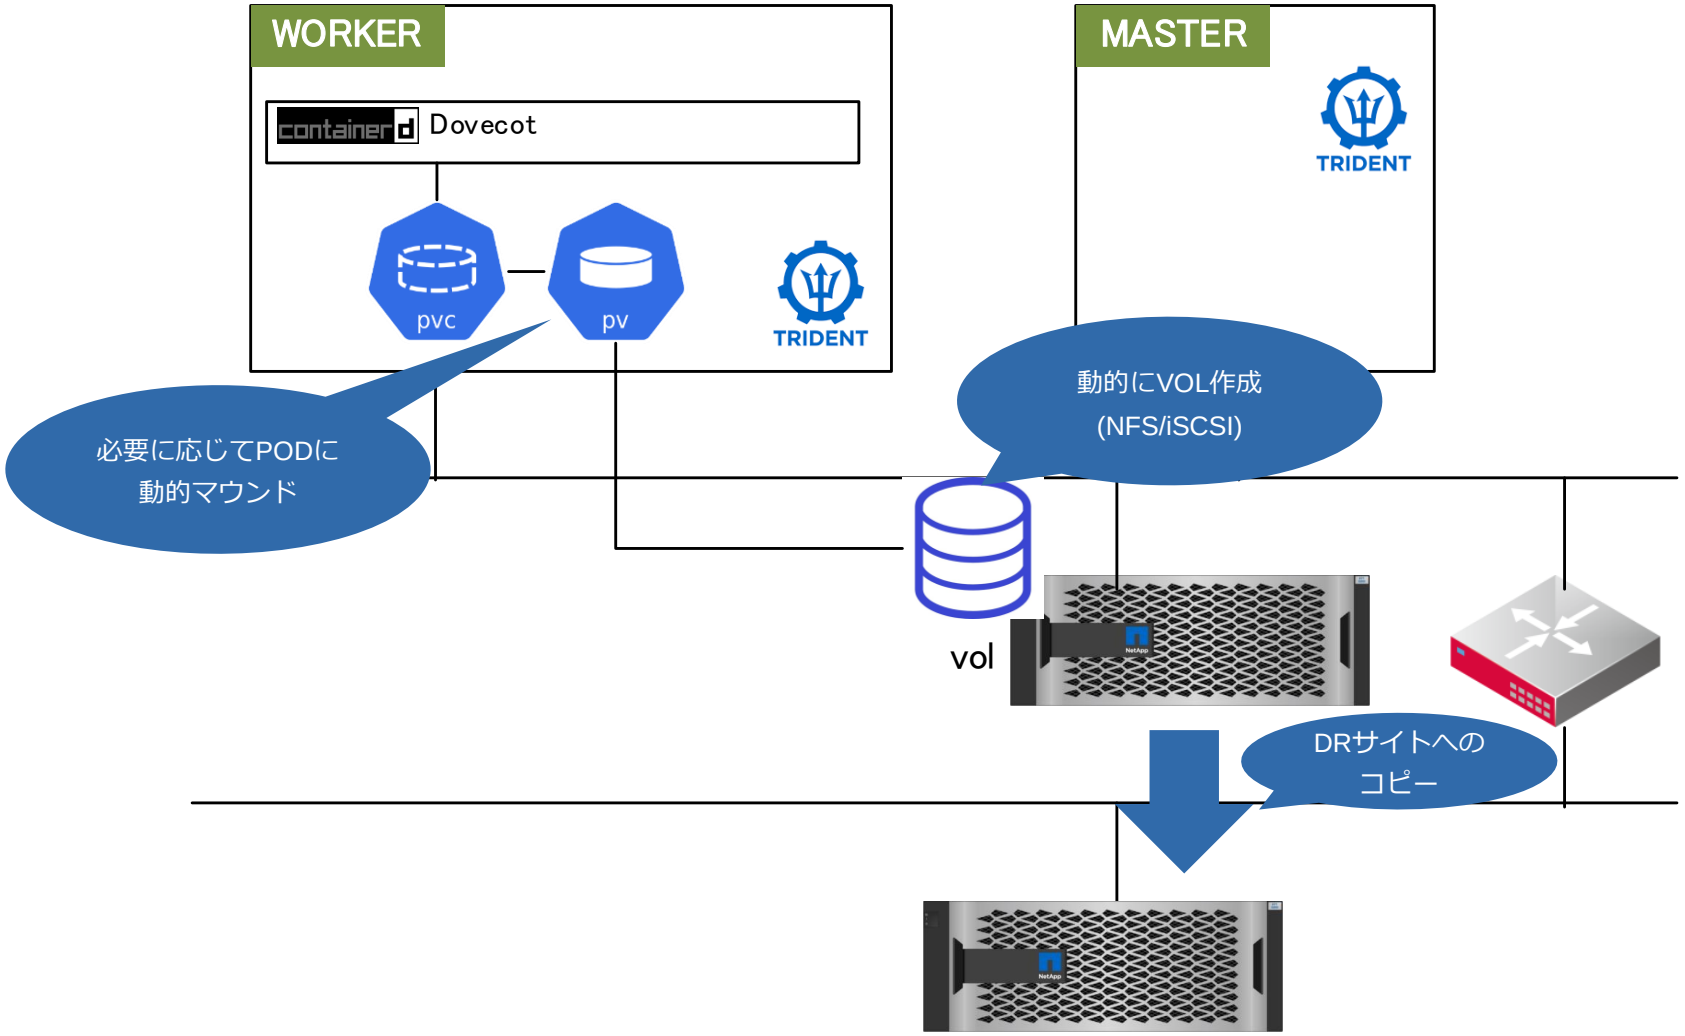

注意点・はまりどころはあまり無い（安定してる）。

1. メールキュー等ロック・性能が必要な部分はiSCSIを利用

- オンライン領域解放(discard option)は使わないこと！(プチフリします)
- https://docs.netapp.com/ja-jp/trident-2204/pdfs/fullsite-sidebar/Astra_Trident_22_04_%E3%81%AE%E3%83%89%E3%82%AD%E3%83%A5%E3%83%A1%E3%83%B3%E3%83%88.pdf

2. iSCSI利用時にiSCSIマウントできない(Linux Kernel 不具合)

- - scsi: iscsi: iscsi_tcp: Avoid holding spinlock while calling getpeername() (Chris Leech) [2011470]
- https://cbs.centos.org/koji/buildinfo?buildID=36146

回避策: Kernelを最新にあげて回避

Trident連携は安定していました

アプリの作り込み

お断り: アプリは皆様にわかりやすいようにOSS系を中心に紹介します

主な特徴

- **全部コンテナにする**
  - ミニマムアプリにする

(sample)Postfixでのコンテナプロセス例

```
[root@postfix-6db444b6b4-ccd29 /]# ps axwwuf
USER         PID %CPU %MEM    VSZ   RSS TTY      STAT START   TIME COMMAND
root        1098  0.1  0.0  22804  3484 pts/0    Ss   10:31   0:00 bash
root        1111  0.0  0.0  55440  3568 pts/0    R+   10:31   0:00  ¥_ ps axwwuf
root           1  0.0  0.0 105232  1996 ?        Ss   Oct24   0:03 /usr/libexec/postfix/master -i
postfix       77  0.0  0.0 121364  1836 ?        S    Oct24   0:00 qmgr -l -t unix -u
postfix       82  0.0  0.0 125524  1140 ?        S    Oct24   0:00 tlsmgr -l -t unix -u
postfix     1093  0.0  0.0 121244  8792 ?        S    10:22   0:00 pickup -l -t unix -u
[root@postfix-6db444b6b4-ccd29 /]#
```

- **(重要)通信は名前解決のみ**
  - IPアドレスは変わる

- **Kubernetesが提供しない機能は作りこむ**
  - クラスタリング(Dovecot Director)
  - MariaDB（Galera Cluster）

  他

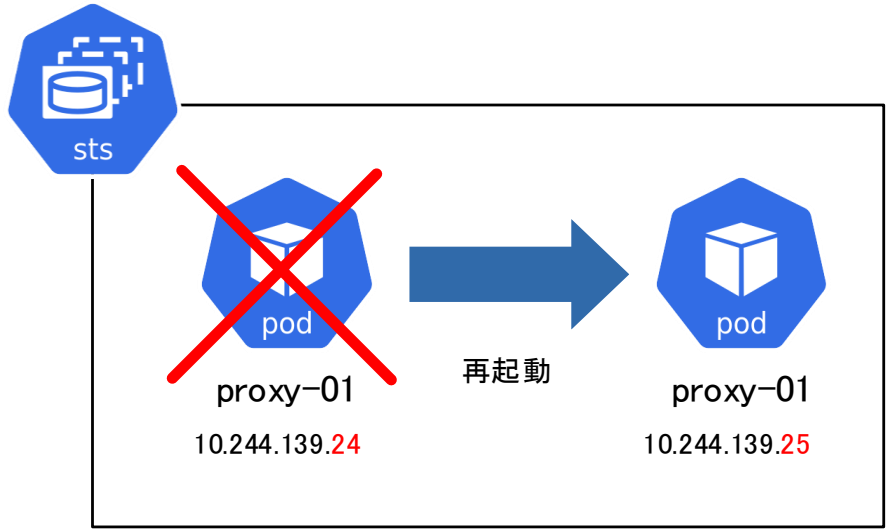

POD再起動でIPは変わる！

Dockerfile(sample: postfix)

```
FROM rockylinux/rockylinux:8.6

RUN dnf -y install postfix

RUN echo "maillog_file = /dev/stdout" >> /etc/postfix/main.cf

CMD ["/usr/sbin/postfix","start-fg"]
```

ポイント

- **ログ: 標準出力**
- **起動: フォアグラウンド**
- **開発・デバッグツール: ご自由に**

メールアプリコンテナ

作成コンテナ（これ以外も多数あり）

#	アプリケーション	ログ出力	フォアグラウンド起動
1	postfix	○	○
2	Dovecot	○	○
3	Halon MTA	○	○
4	Cloudmark Authority Server	○	○
5	TwoFive Safe25	○	○
6	Vade MTA	○	○
7	Zimbra	○	○
8	Haproxy	○	○
9	Fluentd	○	○
10	Fluent-bit	○	○
11	apache	○	○
12	Appsuite	○	○
13	Keycloak	○	○
14	Nginx	○	○
15	Guvicorn	○	○
16	Openldap	○	○
17	Mailman3	○	○
18	Openresty	○	○

一つ一つは大きくないが、全体で見ると作業量が多し

- **docker hub等のサンプルを改造**

- **下調べと十分な検証が必要**
  - 1. ログ出力
    - stdout/stderr or syslog
  - 2. モニタリング対応(後述)
    - exporter必要有無
  - 3. 同一コンテナで複数プロセス動作要否
    - rsyslog・外部exporter同居時はsupervisordが必要等

モニタリング連携まで揃えると作り込みに時間がかかる

sample: Dovecot Directorのコンテナ起動例

```
# ps axwwuf
USER         PID %CPU %MEM    VSZ   RSS TTY      STAT START   TIME COMMAND
root     3906217  0.0  0.0  23112  3880 pts/0    Ss   10:39   0:00 bash
root     3906804  0.0  0.0  55472  3672 pts/0    R+   10:43   0:00  ¥_ ps axwwuf
root           1  0.1  0.0 109548 17216 ?        Ss   Aug08 146:31 /usr/bin/python3.6 /usr/bin/supervisord -c /etc/supervisord.conf
root           9  0.0  0.0  16020   852 ?        S    Aug08   0:00 /bin/bash /boot-dovecot.sh
root          20  0.0  0.0  52944  1612 ?        S    Aug08  18:15  ¥_ /usr/sbin/dovecot -F
dovenull      23  0.0  0.0  32892  7924 ?        S    Aug08   3:18      ¥_ dovecot/pop3-login
dovenull      24  0.0  0.0  29472  3344 ?        S    Aug08   8:20      ¥_ dovecot/imap-login
dovecot       25  0.0  0.0  10384   764 ?        S    Aug08   1:18      ¥_ dovecot/anvil [8 connections]
root          26  0.0  0.0  11156  1340 ?        S    Aug08  10:43      ¥_ dovecot/log
dovenull      27  0.0  0.0  35136  8816 ?        S    Aug08   4:26      ¥_ dovecot/pop3-login
dovenull      28  0.0  0.0  33872  7944 ?        S    Aug08   3:44      ¥_ dovecot/pop3-login
dovenull      29  0.0  0.0  37912 10968 ?        S    Aug08   5:33      ¥_ dovecot/pop3-login
dovenull      30  0.0  0.0  30636  3624 ?        S    Aug08   8:48      ¥_ dovecot/imap-login
dovenull      31  0.0  0.0  30808  4232 ?        S    Aug08   9:23      ¥_ dovecot/imap-login
dovenull      32  0.0  0.0  31184  5724 ?        S    Aug08  10:20      ¥_ dovecot/imap-login
root          33  0.0  0.0  29556  3868 ?        S    Aug08  59:32      ¥_ dovecot/config
dovecot       34  0.0  0.0  15872  2872 ?        S    Aug08  35:44      ¥_ dovecot/stats [11 connections]
dovecot       36  0.0  0.0  18064  2248 ?        S    Aug08  35:50      ¥_ dovecot/director [121 users, 0+0 req/s, 0+0 kB/s]
dovecot      250  0.0  0.0  10508   848 ?        S    Aug08   2:39      ¥_ dovecot/ipc [9 connections]
root          10  0.1  0.0 530276 16288 ?        Sl   Aug08 251:20 /usr/bin/python3.6 /usr/sbin/healthcheck.py
root          11  0.0  0.0 199228  1536 ?        Sl   Aug08  46:34 /usr/sbin/rsyslogd -n
```

dovecot・ヘルスチェック・rsyslog起動のためにsupervisord利用

Dovecot フォアグラウンド起動(-F)
ログは/dev/stdoutに出力

ヘルスチェックPGはsyslogにログを出力するためrsyslogを準備

rsyslogは/dev/stdoutにログを出力

ステートレス・ステートフルでデプロイプランを検討

- **ステートレス: Deployment**
  - ステートレスアプリケーションの管理に利用
  - プロキシ・Webサーバ・アンチウイルス・アンチスパム等に利用

- **ステートフル: Statefulset**
  - ステートフルなアプリケーションの管理に利用
  - メールボックス・MTA・LDAP等ストレージを利用する物に利用

必要に応じてスケールアウト

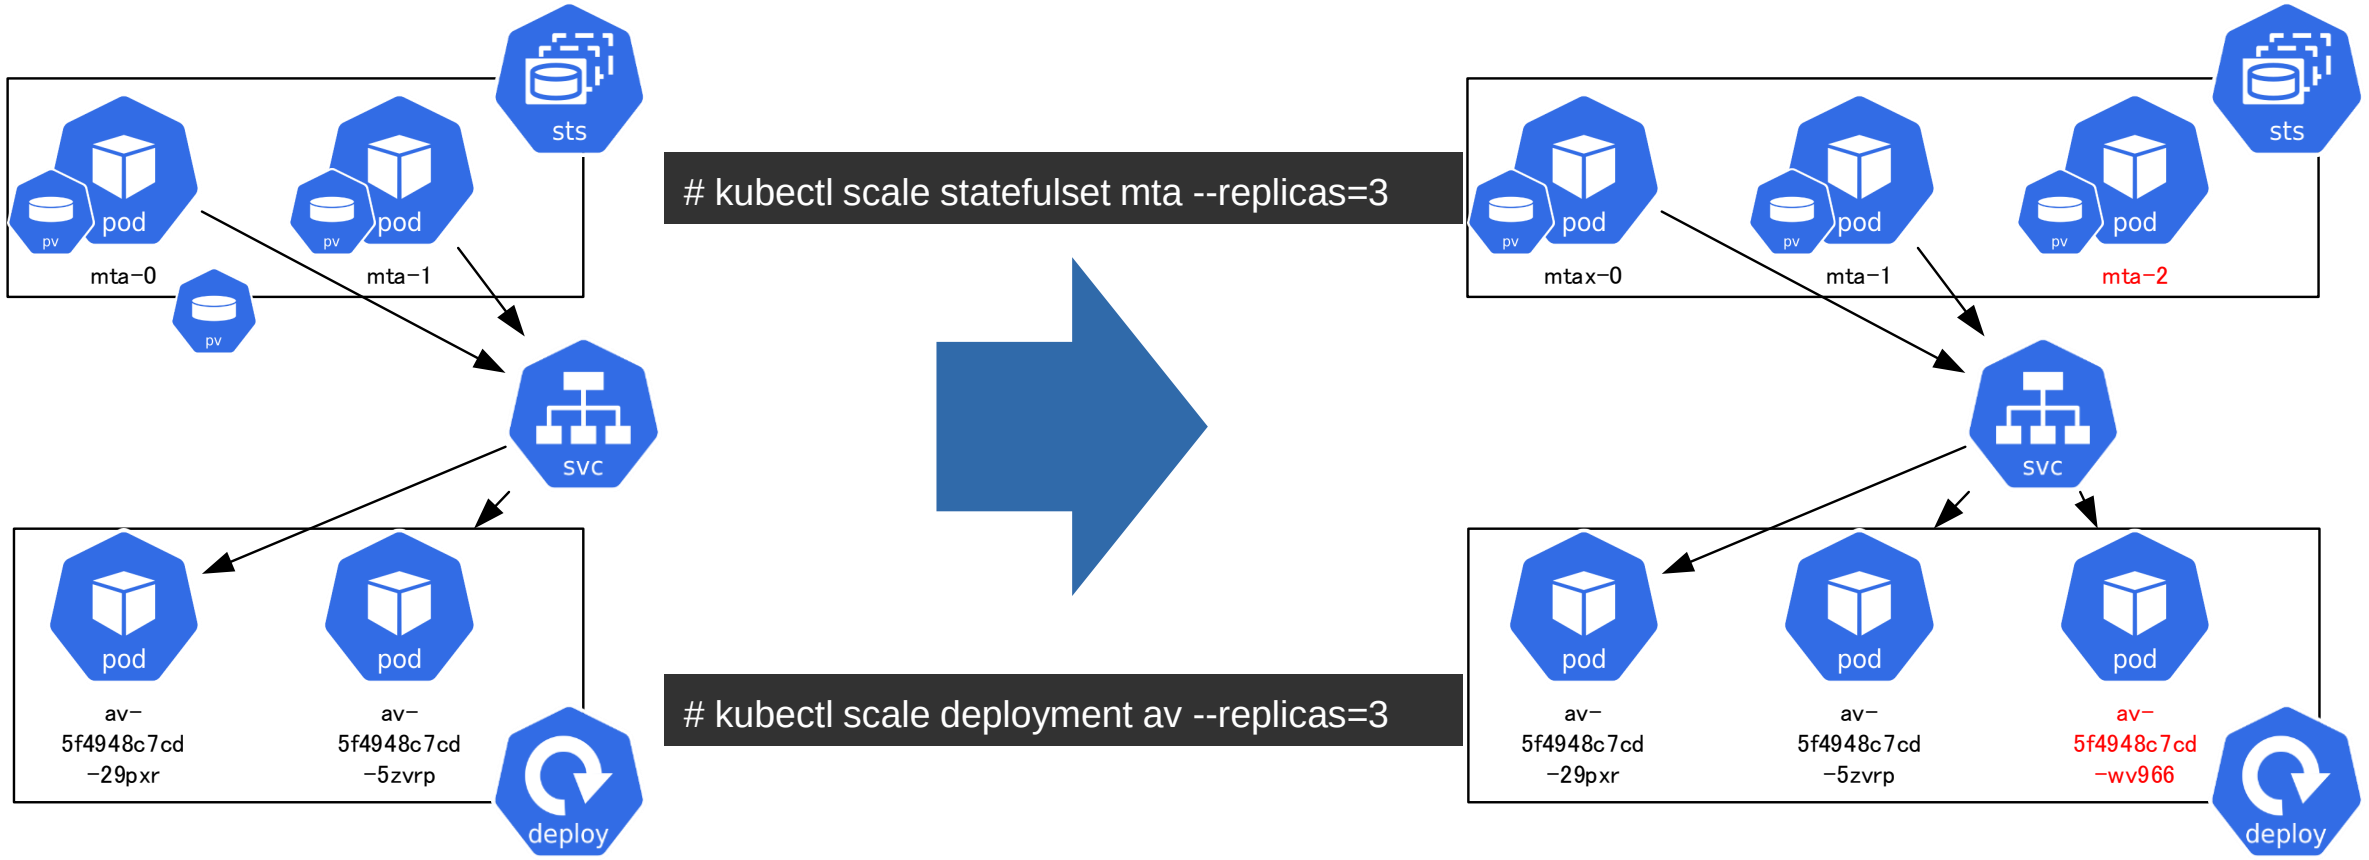

動的に増減できるのがKubernetesの醍醐味！

金曜日 の大量着信に備えて2倍にスケールアウト！

2倍きっちり打ち込まれる・・・

教訓: 大量着信には流量制御で勝負すべし

Kubernetes化に伴い以下の強化が必須に

- **起動・停止スクリプト**
  - VMの起動・停止とは前提が異なる
  - gracefulな停止が必要

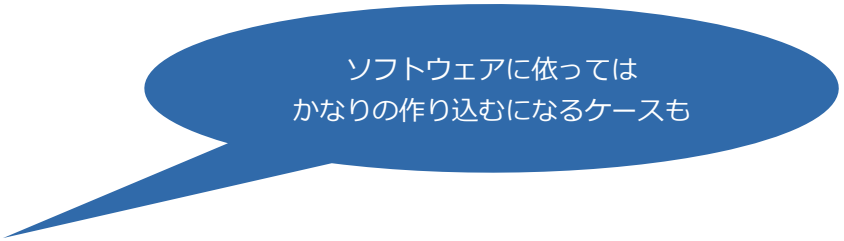

- **適切なヘルスチェックが肝**
  - POD生死判定: LivnessProbe
  - POD RUNNING判定: ReadinessProbe

セルフヒーリングに最も重要なポイント！

POD起動時のライフサイクル

POD終了時のライフサイクル

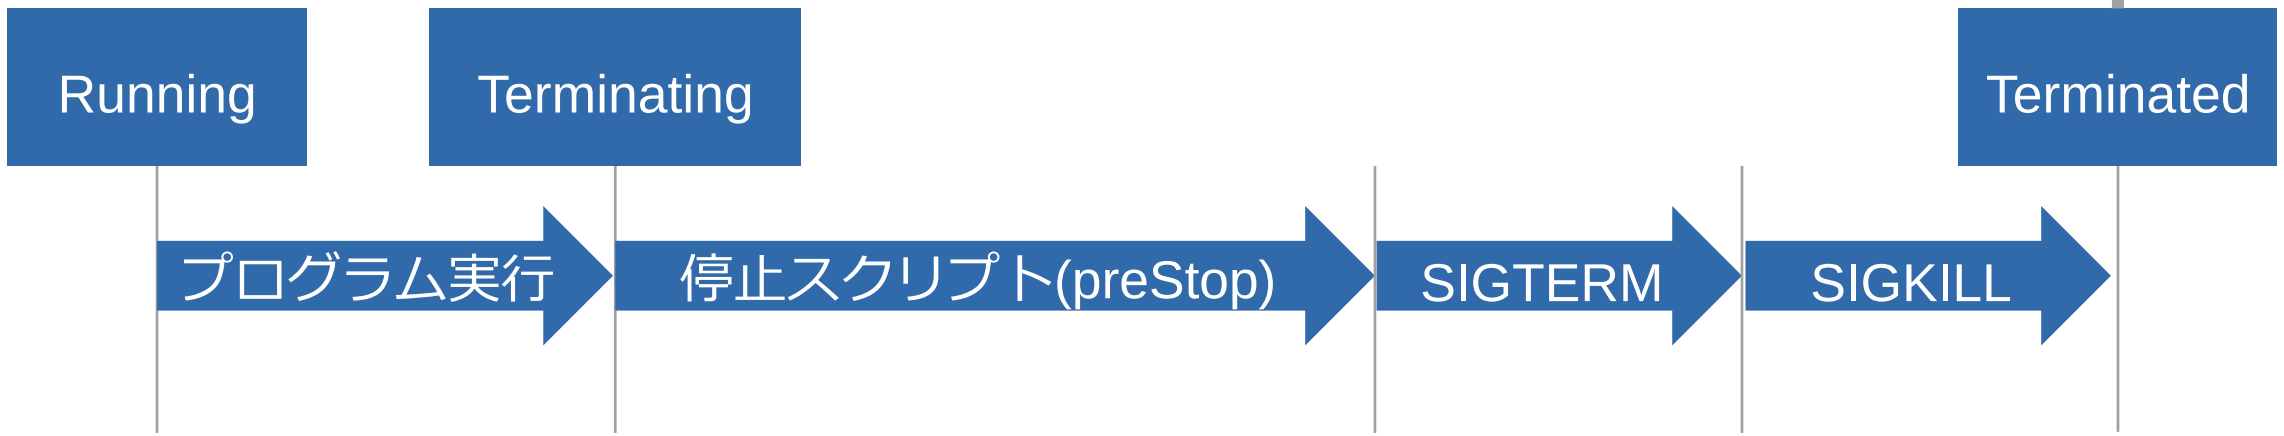

POD初期化含めた起動スクリプトが必須

- 例: メールキューディレクトリ作成

```
for D in  /var/spool/mailq /var/spool/mailq/queue /var/spool/mailq/tmp
do
    mkdir -p $D
    chown smtpd:smtpd $D
    chmod 750 $D
done
```

- VMでは既に終わってる前提だった初期化を敢えて意識した実装が必要

独自起動スクリプトが必要なケース多し

停止スクリプト(preStop)は以下で実行される

- POD Terminating時
- LivnessProbe 失敗

停止スクリプト例

- **メールキュー強制吐き出し**
- **ユーザコネクション切断待ち & 切断**
- **クラスタリングからの自分自身の削除**

他

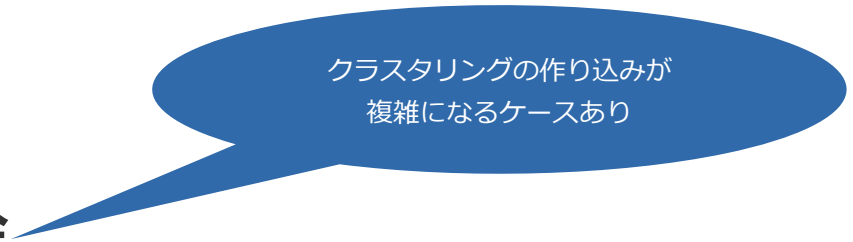

メンテナンス・セルフヒーリングには graceful停止が必須

アプリケーションクラスタリングは自作

sample: Dovecot Directorの場合

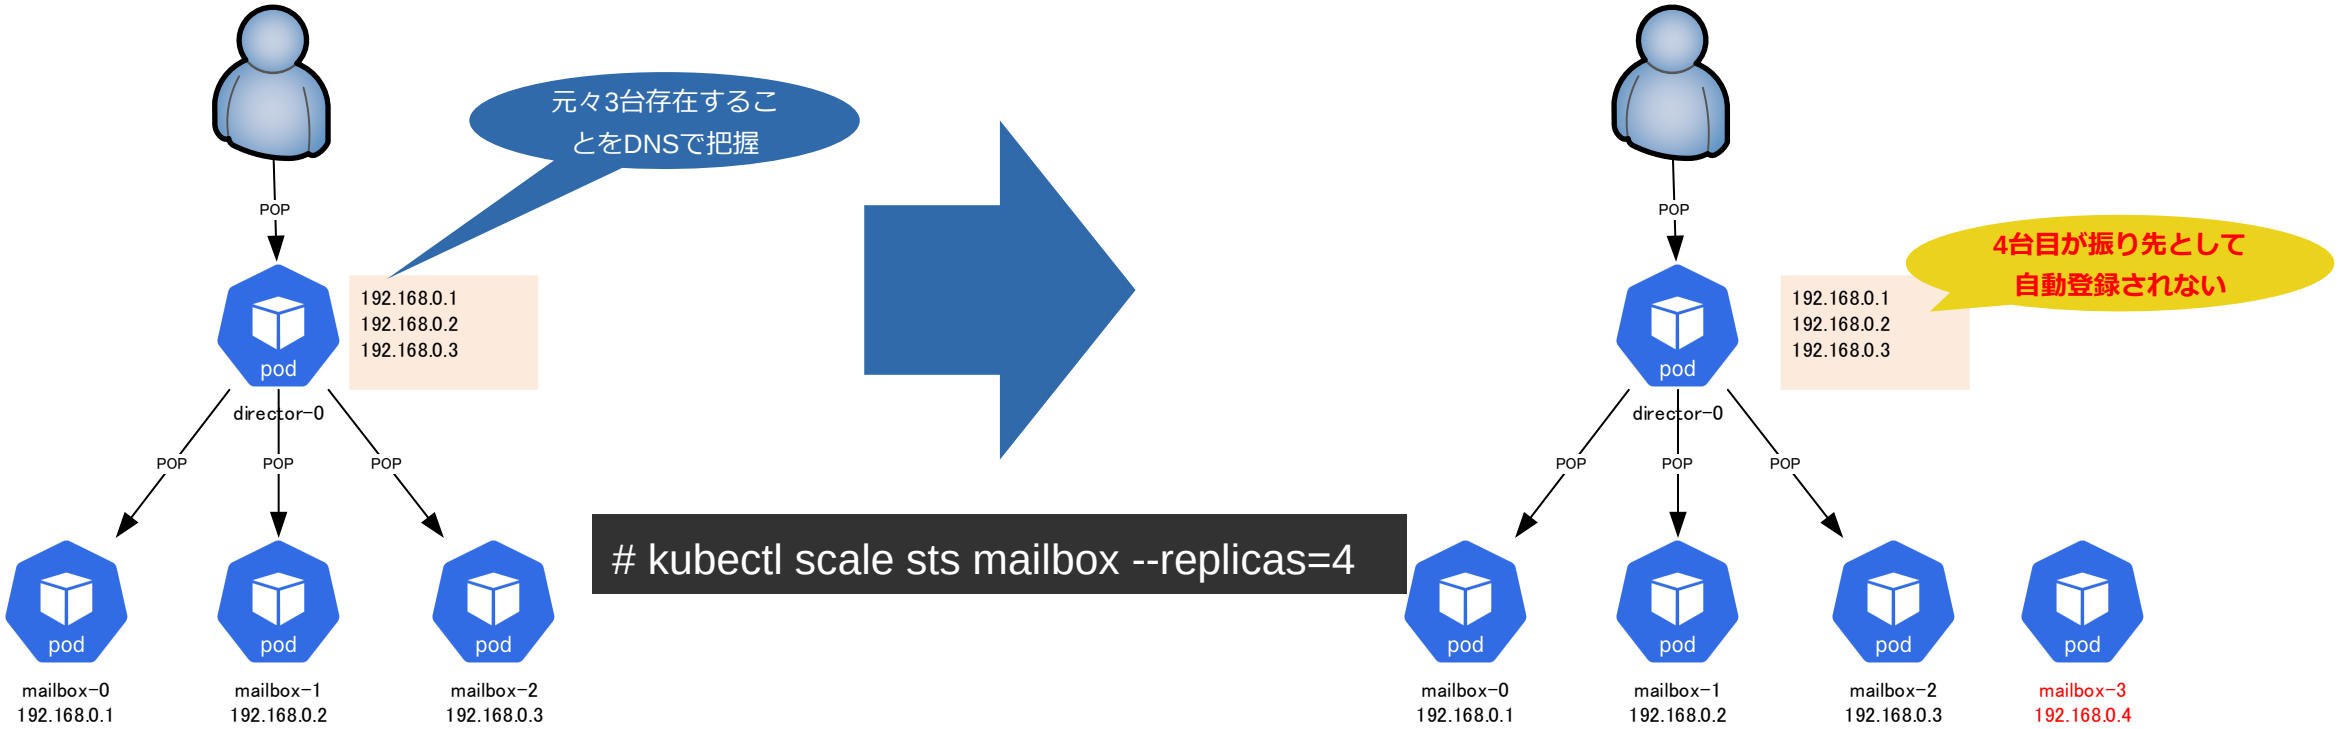

Directorは起動時のみ名前解決するため起動後のノード増減を把握できない

POD増減に応じて動作するコントローラが必要

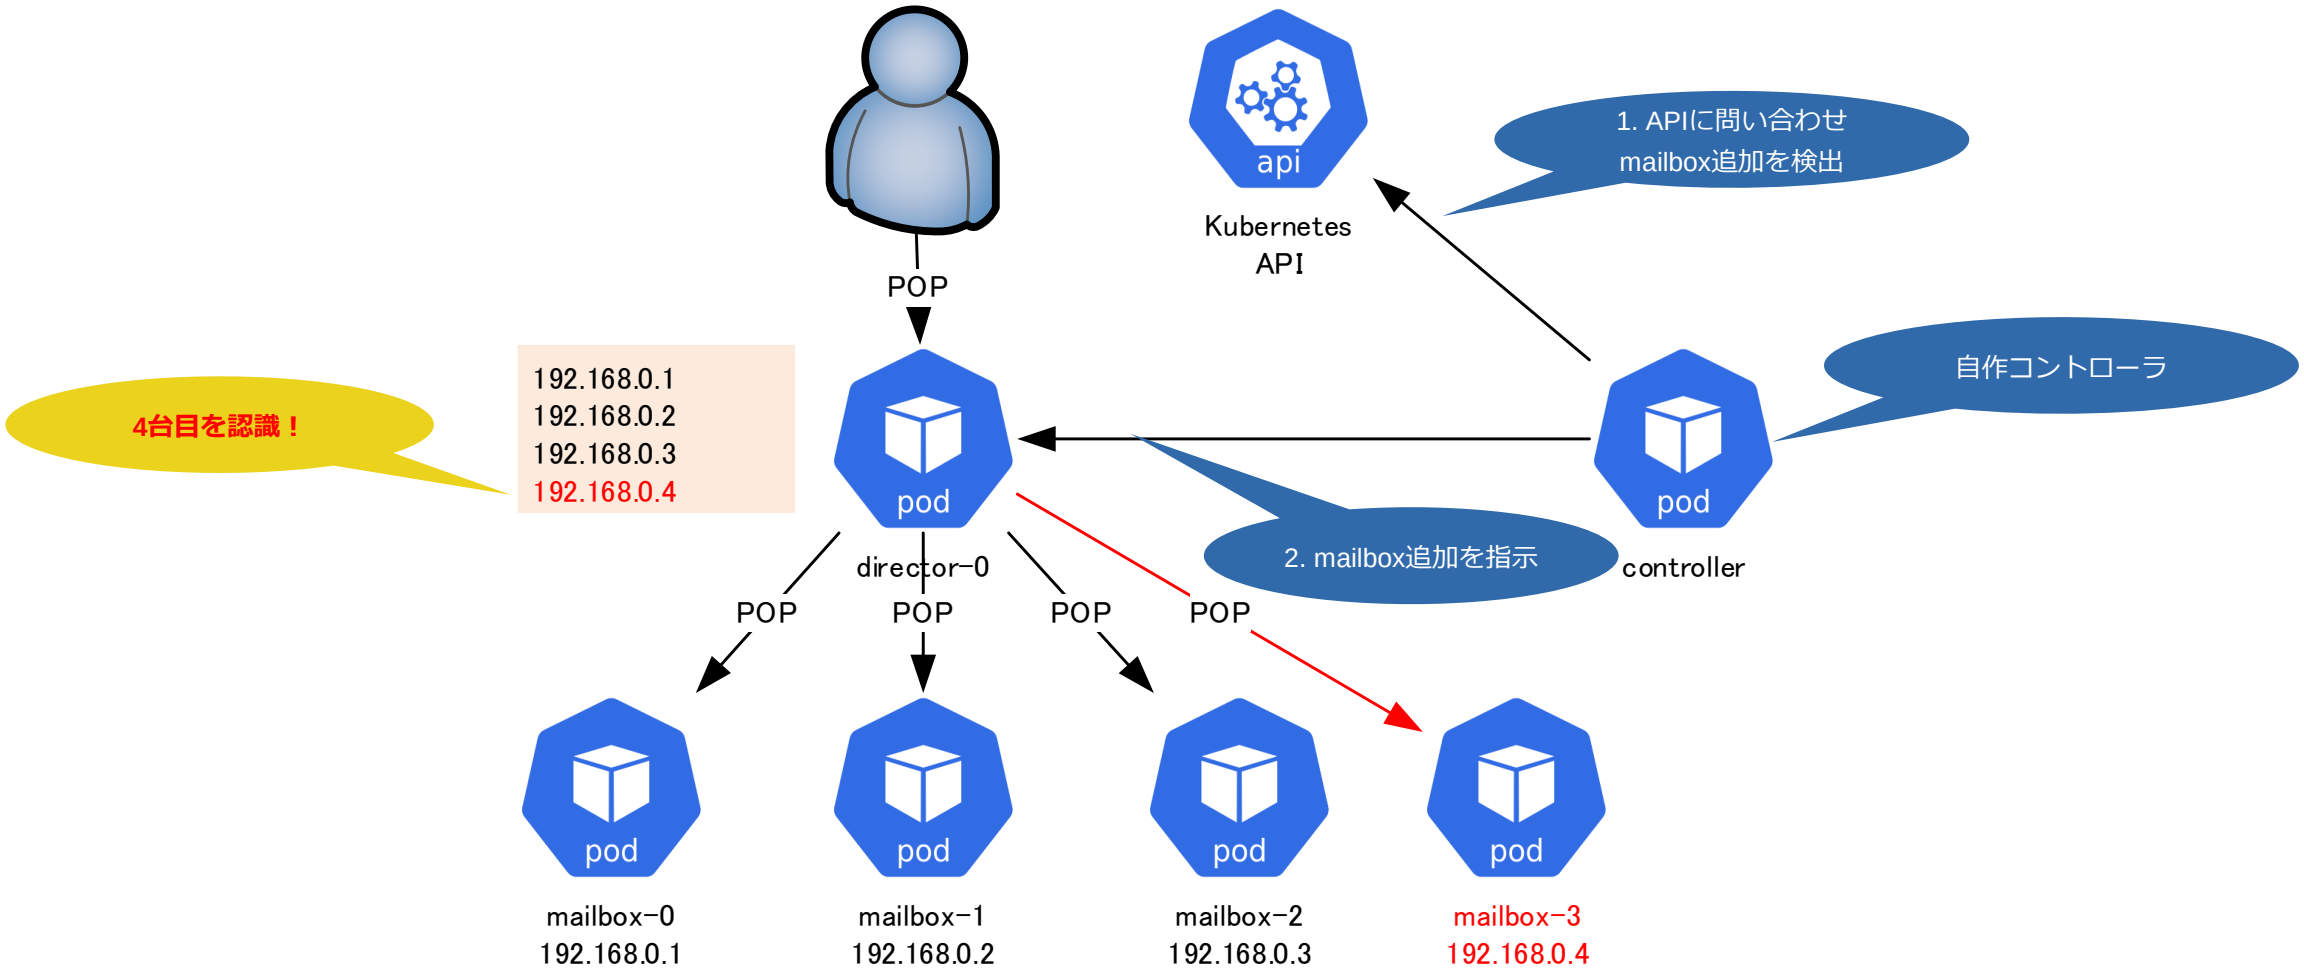

本日探してみたらこんな物が・・・（未検証です）
https://github.com/yartu/yartu-dovemon/

Kubernetesではノード外通信は基本ノード IPでNATされる

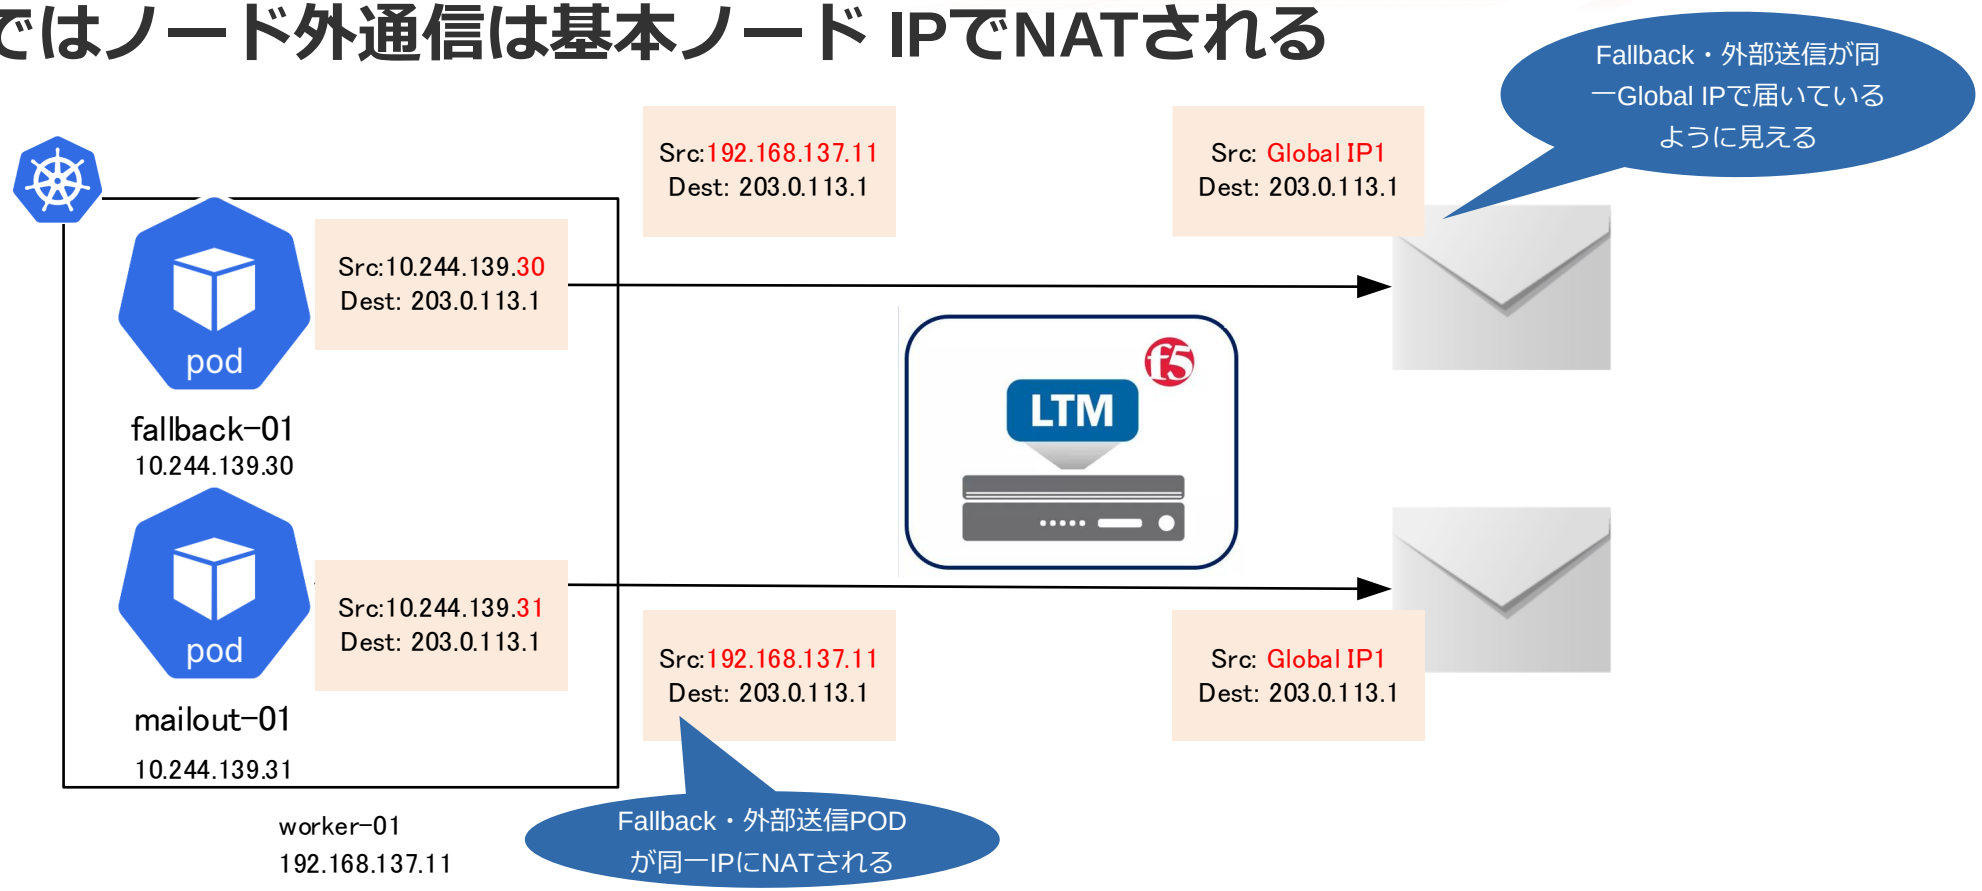

例: fallback・通常配送で同じsrc IP(192.168.137.11)にNATされるため、出口IP使い分けできないケース

Fallback・通常送信が同一グローバルIPとなり、IPの送信評価が低下するリスク

ノード出口でNATせず、ノード外(LB・FW)でNATすることで出口振り分け実施

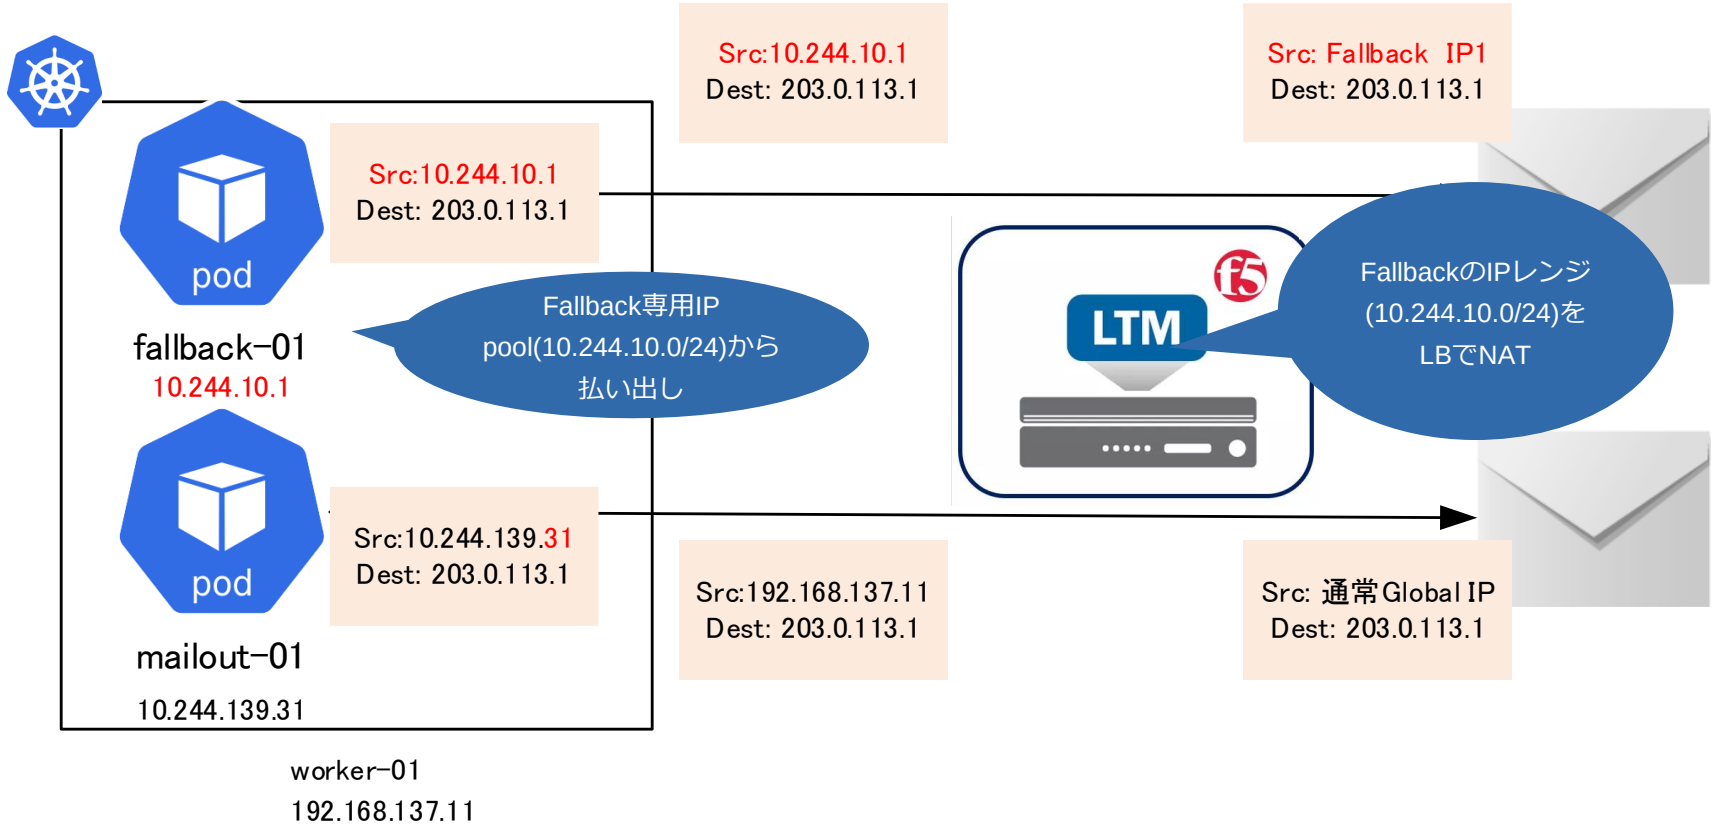


```
spec:
  template:
    metadata:
      annotations:
        "cni.projectcalico.org/ipv4pools":
"[¥“fallback-ipv4-ippool¥"]"
        "cni.projectcalico.org/ipv6pools":
"[¥" fallback-ipv6-ippool¥"]"
```

Fallback で
NATしないIPレンジを指定

IPv4・IPv6DualStack可能です

https://projectcalico.docs.tigera.io/networking/workloads-outside-cluster

モニタリング・ログ収集

主な特徴

- **PULL型監視**
  - 定期的にHTTP経由でmetricsを取得し評価
- **監視対象（POD）が動的に増減**
  - Service discover必須
- **ノードの監視・アプリの監視それぞれが必要**
  - ノード監視: 標準でほぼデータ取得可能
  - アプリ監視: HTTP経由でOpenMetricsに対応していればOK
    - メールアプリは基本非対応(Dovecot・Halonぐらいか?)

Prometheus互換。安定稼働中。

VICTORIA METRICS

- Highest Ingestion Rate
- Fastest Query Performance
- Smallest Disk Storage Size
- Lowest Memory Usage
- Long-term Storage for Metrics
- Highly Scalable
- Cloud Readiness
- Simple Set-up & Operation

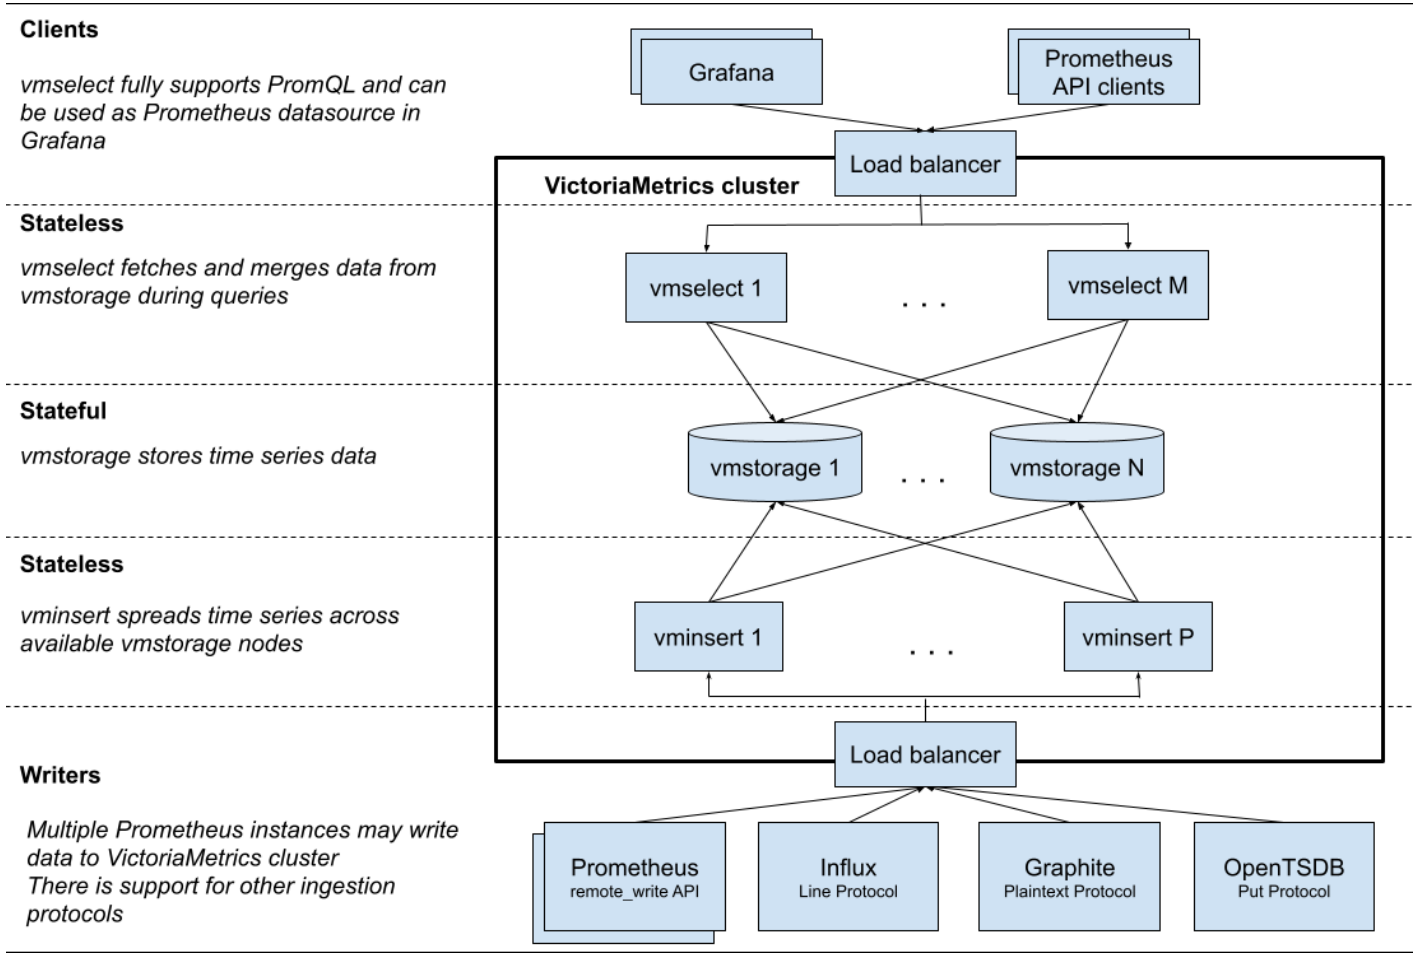

https://victoriametrics.com/
https://docs.victoriametrics.com/

VictoriaMetrics + GrafanaでPULL型監視

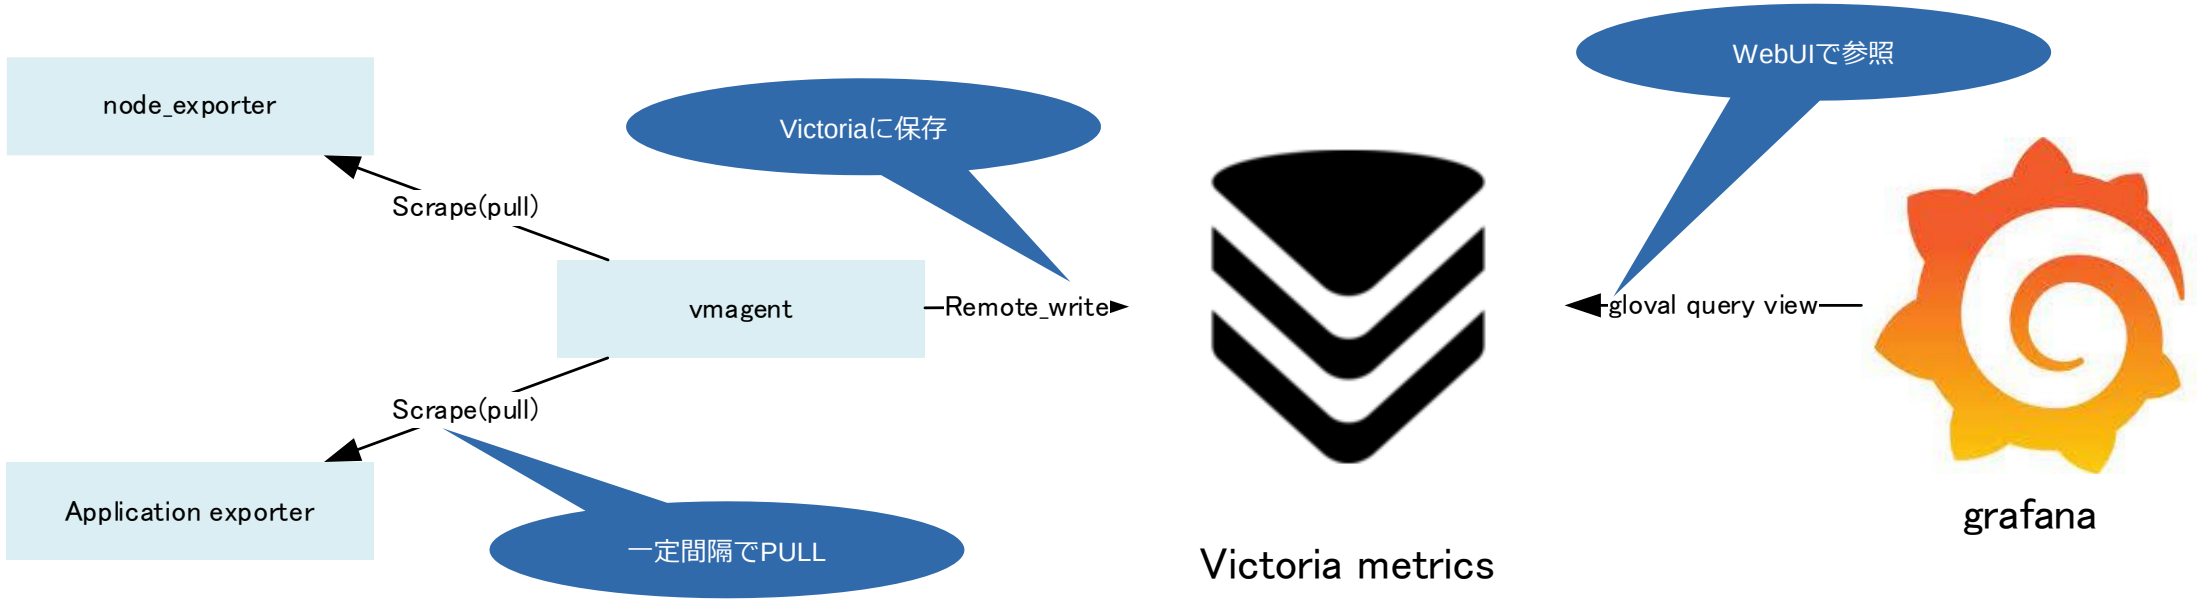

一定間隔でHTTPでmetricsデータ取得
VictoriaMetricsにデータ投入する

アプリ監視対応状況

検証結果

#	アプリケーション	監視ポイント	Grafanaダッシュボード
1	postfix	◯(外部ツール)	◯
2	Dovecot	◎(標準提供)	●(自作)
3	Halon MTA	◎(標準提供)	●(自作)
4	Cloudmark Authority Server	●(自作)	●(自作)
5	TwoFive Safe25	●(自作)	●(自作)
6	Zimbra	◎(標準提供) * 最新	●(自作)
7	Haproxy	◎(標準提供)	◯
8	Fluentd	◎(標準提供)	◯
9	Fluent-bit	◎(標準提供)	◯
10	apache	◯(外部ツール)	◯
11	Appsuite	◎(標準提供)	◯

望む監視のために自作するケースも多々あり
メールアプリのダッシュボードは基本自作

Grafana dashboardで可視化

監視はAlertmanager + barry(IIJ 内製 インシデント管理アプリ) + 他

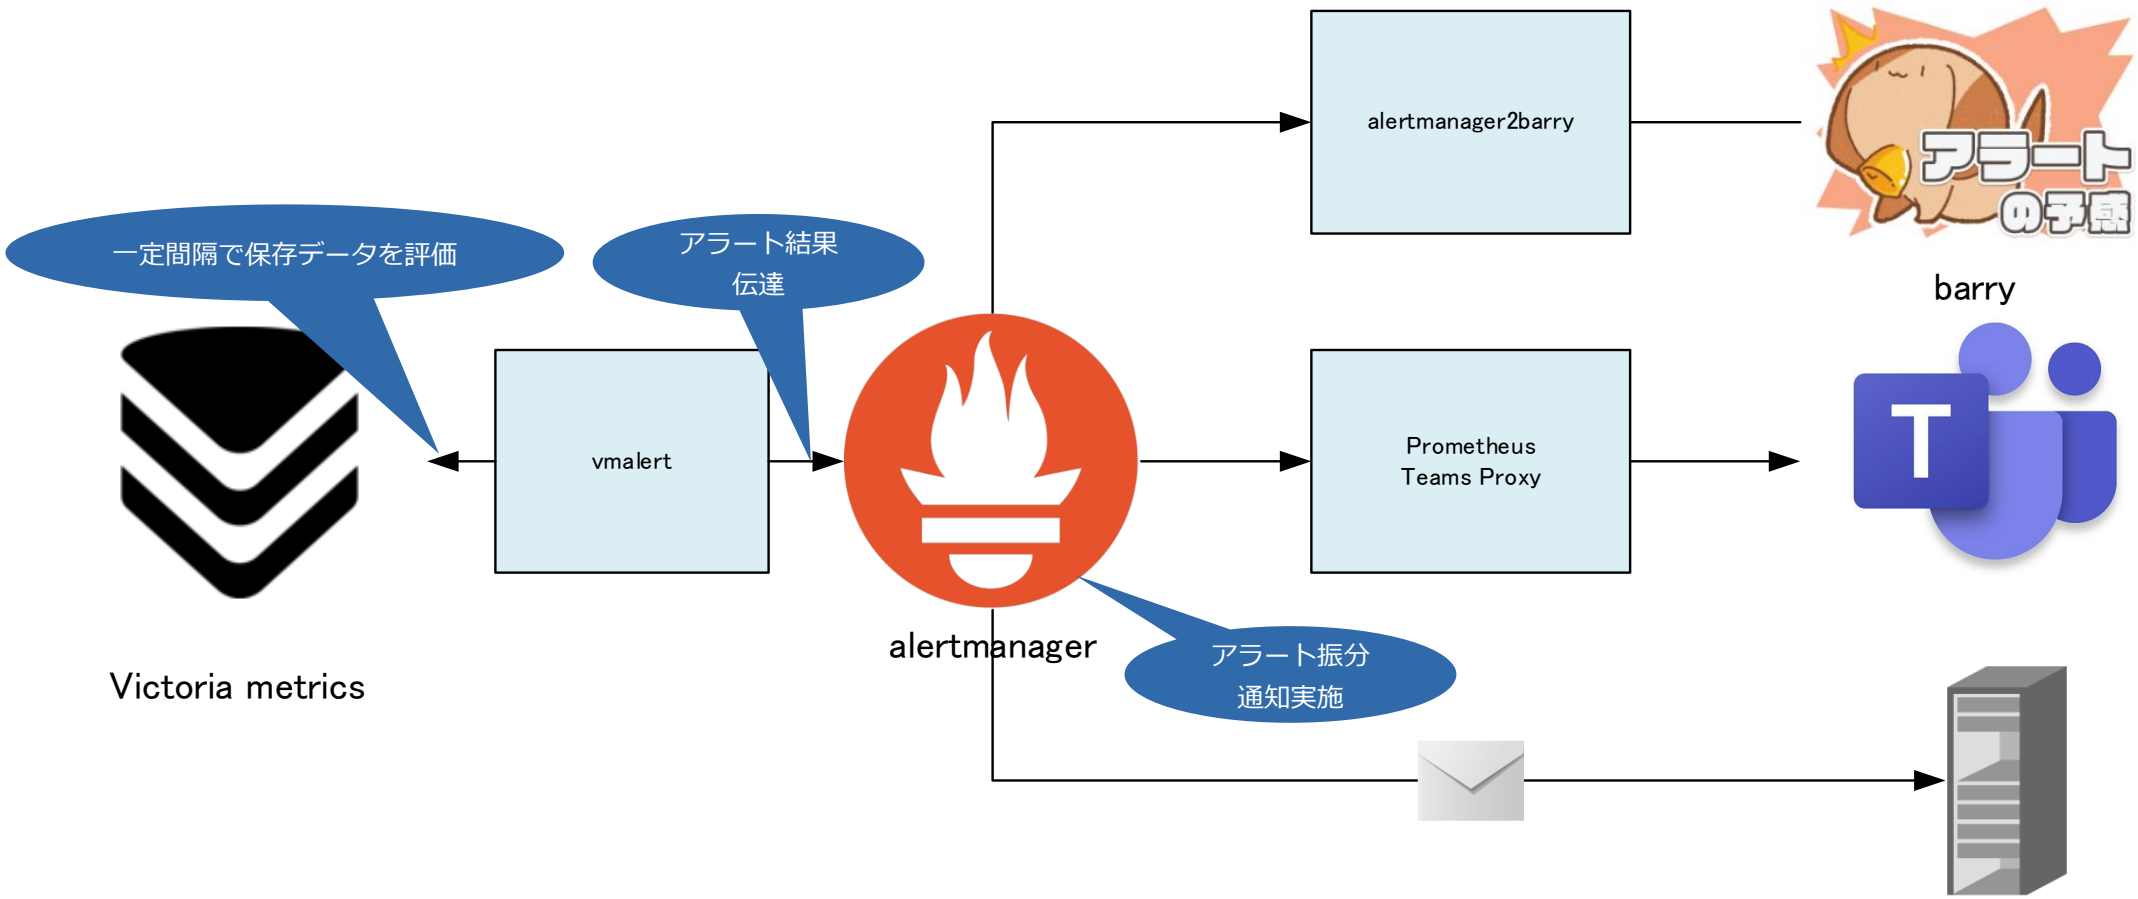

Barrryとは:
https://www.iij.ad.jp/dev/report/iir/051/03.html
https://eng-blog.iij.ad.jp/archives/4488

監視テンプレート有り

#	アプリケーション	監視テンプレート
1	Kubernetes	https://awesome-prometheus-alerts.grep.to/rules.html
2	ホスト	https://awesome-prometheus-alerts.grep.to/rules.html
3	MySQL	https://awesome-prometheus-alerts.grep.to/rules.html
4	Redis	https://awesome-prometheus-alerts.grep.to/rules.html

これで事足りる

Eメールアプリは監視テンプレート無し

#	アプリケーション	その他
1	postfix	ポート監視 自作SMTP・POP・IMAP・HTTPトランザクション等 キュー監視 リソース監視
2	Dovecot	
3	Halon MTA	
4	Cloudmark Authority Server	
5	TwoFive Safe25	
6	Zimbra	

メールアプリ監視は基本自作

Kubernetes側でのカバー範囲多し(PODダウン・リソース監視・ヘルスチェック失敗等)

コンテナログ収集はlokiで集約

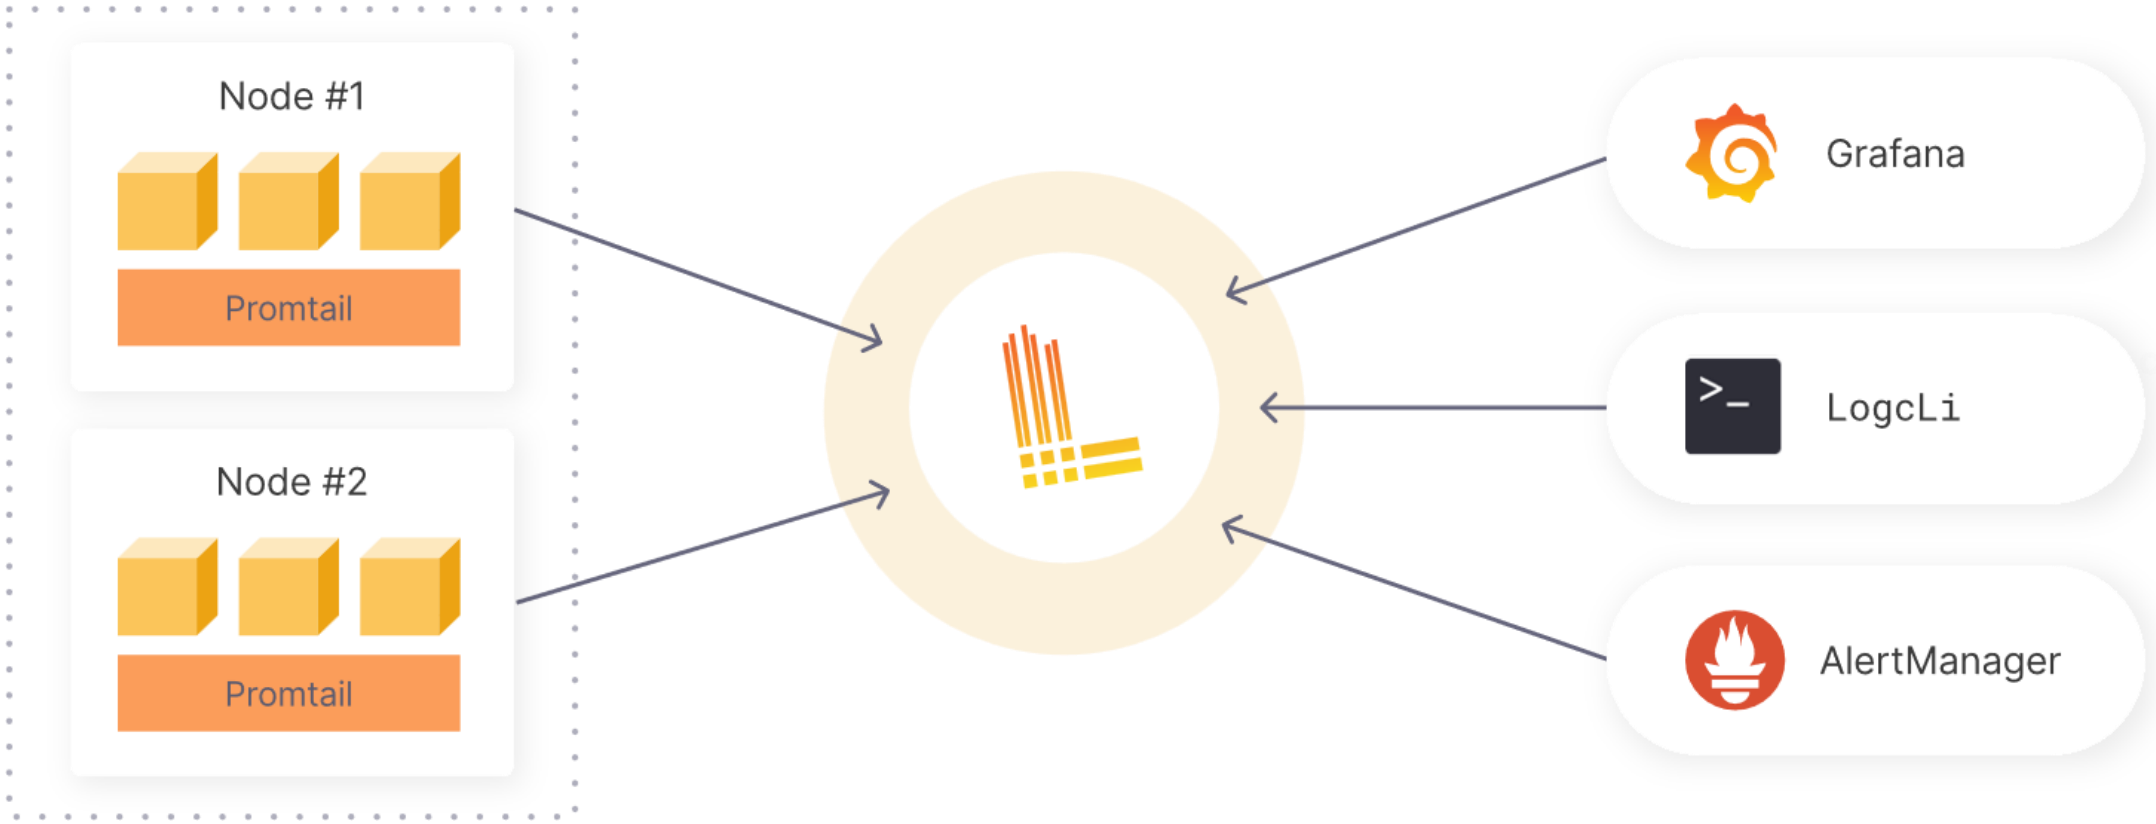

https://grafana.com/oss/loki/

Grafanaで串刺し検索

ログ検索がしっかりしていないとKubernetesは辛い(Loki・Splunk等必須)

LokiのログはS3互換ストレージに保管可能

- IIJオブジェクトストレージサービス
- minio
- AWS S3
- Scality S3

他

工夫したところ

- **デフォルト設定では名前解決「しすぎ」です！**

ndots: 1 は必須(と信じてる)

POD デフォルトの/etc/resolv.conf(ndots: 5)

```
search default.svc.cluster.local svc.cluster.local cluster.local test.example.com example.com

nameserver 10.96.0.10

options ndots:5
```

ndotsとは

```
$ man resolv.conf

….

ndots:n

       Sets a threshold for the number of dots which must appear in a name given to res_query(3) (see resolver(3)) before an initial absolute query will be made.  The default for n is 1, meaning that if there are any dots in a name, the name will be tried  first  as an absolute name before any search list elements are appended to it.  The value for this option is silently capped to 15.
```

ndots:

- **/etc/resolv.confで定義したドメイン補完 動作有無を「ドット」の数で判断**
- **OS標準 ndots: 1**
  - 「ドット」が1つ含まれていれば補完しない

ndots:5(Kubernetes default) でiij.ad.jpにメールを投げると・・・

1. omgi.iij.ad.jp.default.svc.cluster.local (A)
2. omgi.iij.ad.jp.default.svc.cluster.local (AAAA)
3. omgi.iij.ad.jp.svc.cluster.local (A)
4. omgi.iij.ad.jp.svc.cluster.local (AAAA)
5. omgi.iij.ad.jp.cluster.local (A)
6. omgi.iij.ad.jp.cluster.local (AAAA)
7. omgi.iij.ad.jp.test.example.com (A)
8. omgi.iij.ad.jp.test.example.com (AAAA)
9. omgi.iij.ad.jp.example.com (A)
10. omgi.iij.ad.jp.example.com (AAAA)
11. omgi.iij.ad.jp(A)
12. omgi.iij.ad.jp(AAAA)

*** omgi.iij.ad.jp: iij.ad.jpのMXレコード**

マジでやばいです

ndots:1 なら

1. omgi.iij.ad.jp(A)
2. omgi.iij.ad.jp(AAAA)

*** omgi.iij.ad.jp: iij.ad.jpのMXレコード**

すっきり（普通・・・）

名前解決命なので、DNSキャッシュも必須
node-local-dnsという素晴らしいキャッシュソフト(daemonset)有り

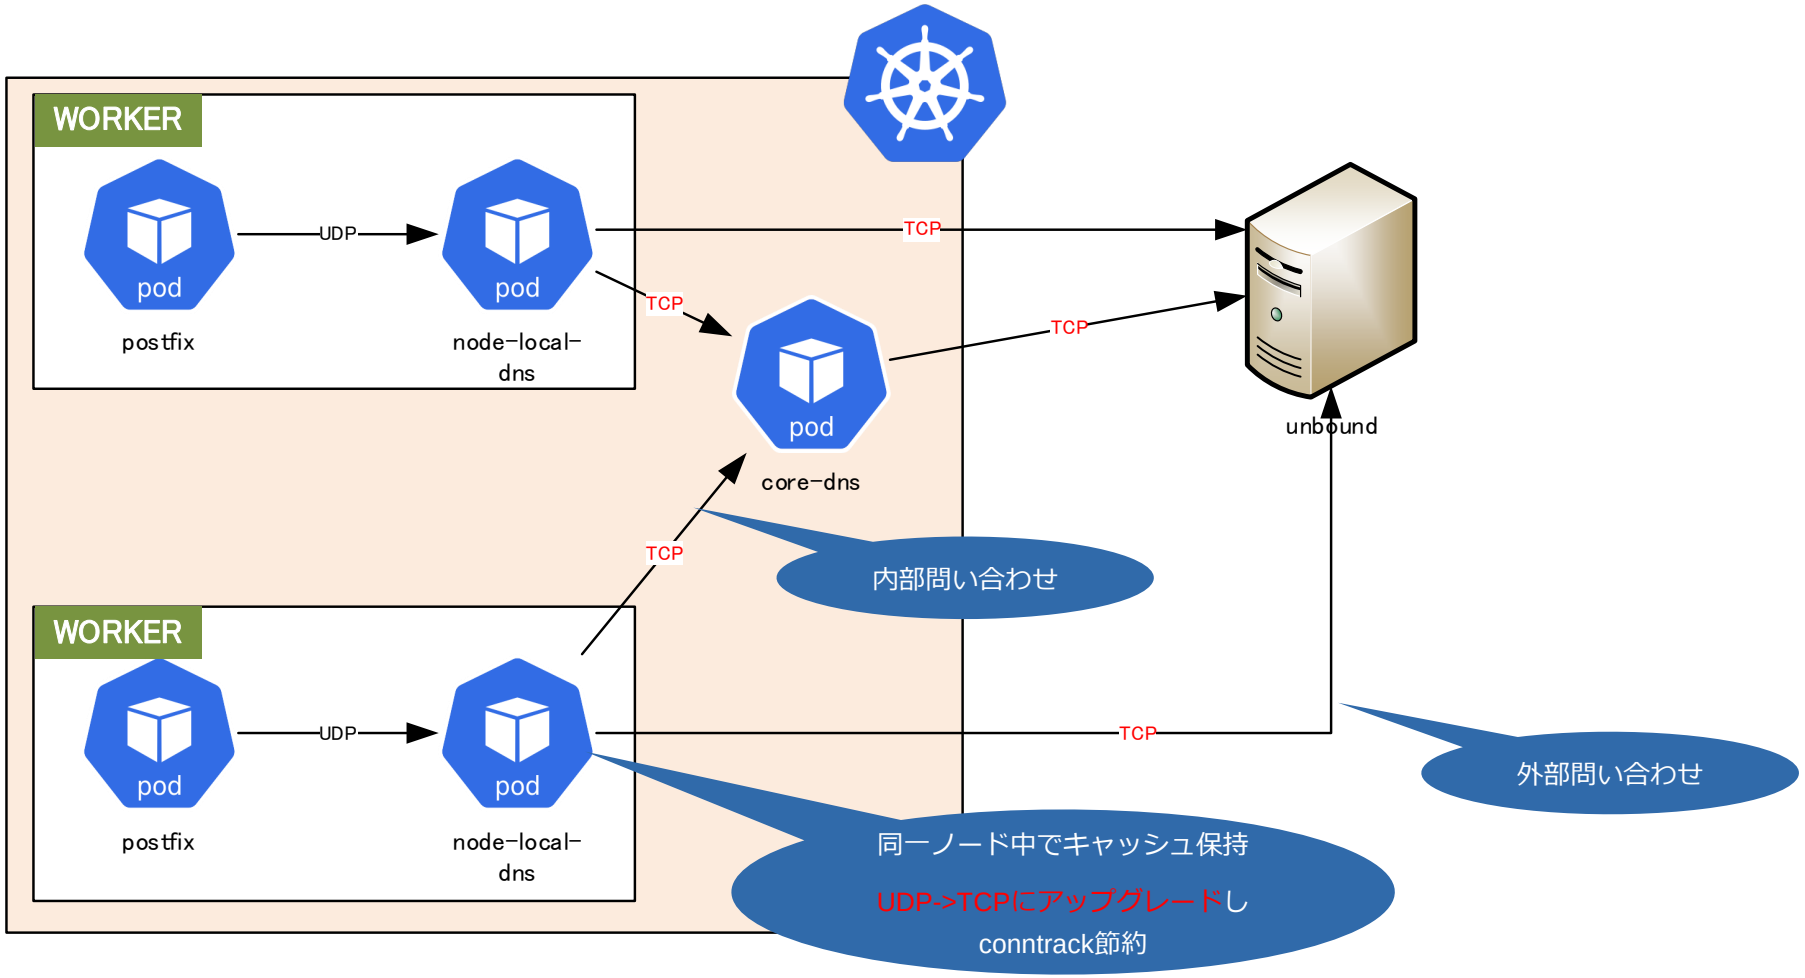

https://kubernetes.io/ja/docs/tasks/administer-cluster/nodelocaldns/

unbound側でTCP問い合わせ上限を増やさないと名前解決が飽和します

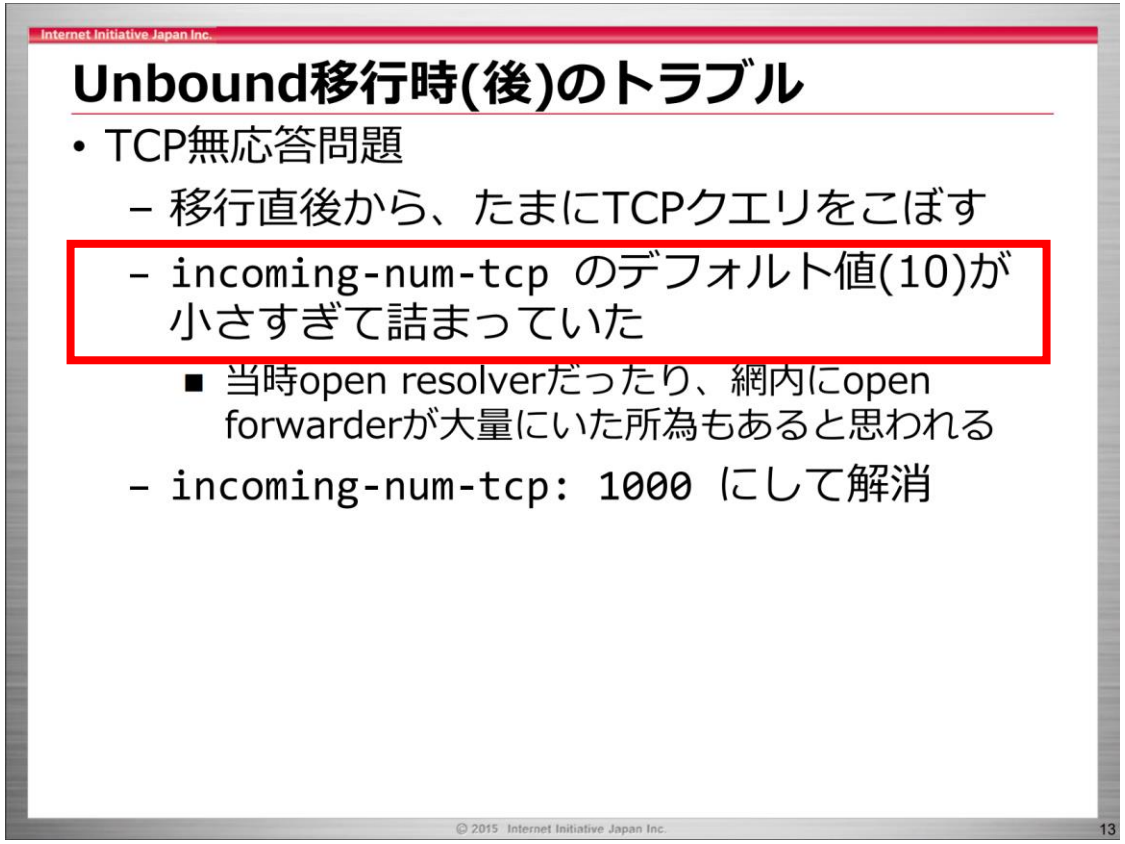

DNSのアップストリームがunboundの場合、
node-local-dnsはUDP->TCPに強制アップグレードするのではまります

https://dnsops.jp/event/20160624/unbound.pdf

- **各種最適化のためにKernelパラメータも随時調整**
- **PODレベル**
  - kernel.msgmax
  - kernel.msgmnb
  - net.core.somaxconn
  - net.ipv4.ip_local_port_range
  - net.ipv4.tcp_tw_reuse

  ….
- **ノードレベル**
  - fs.inotify.max_user_instances
  - fs.inotify.max_user_watches

  …

allowed-unsafe-sysctls で定義できるパラメータの追加が必要
https://kubernetes.io/docs/tasks/administer-cluster/sysctl-cluster/

Anti Affinityコントロール

- 同一種別のPODは別ノードで起動させる
- ラックレベルで分ける

等

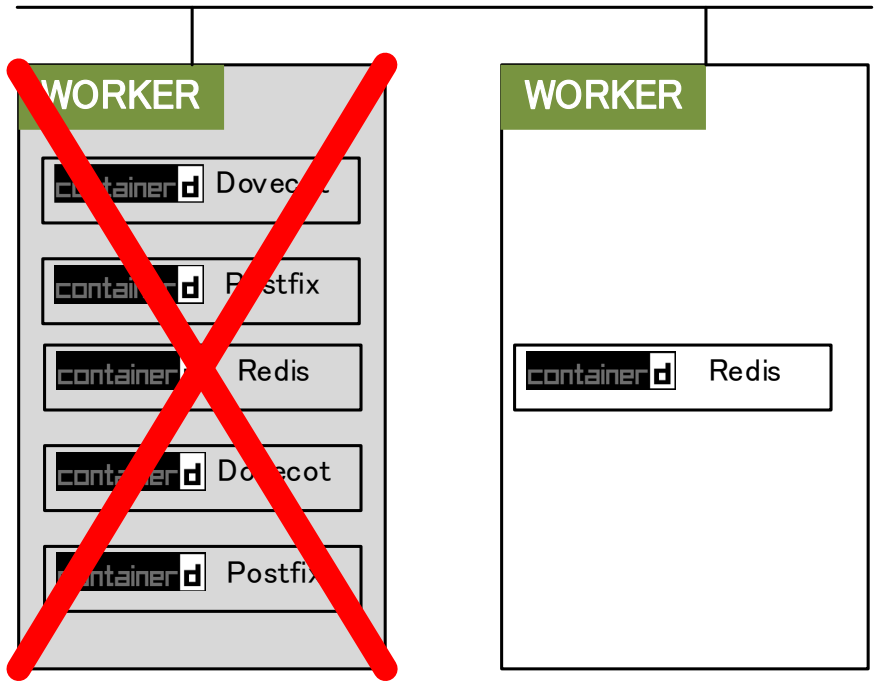

障害時影響大

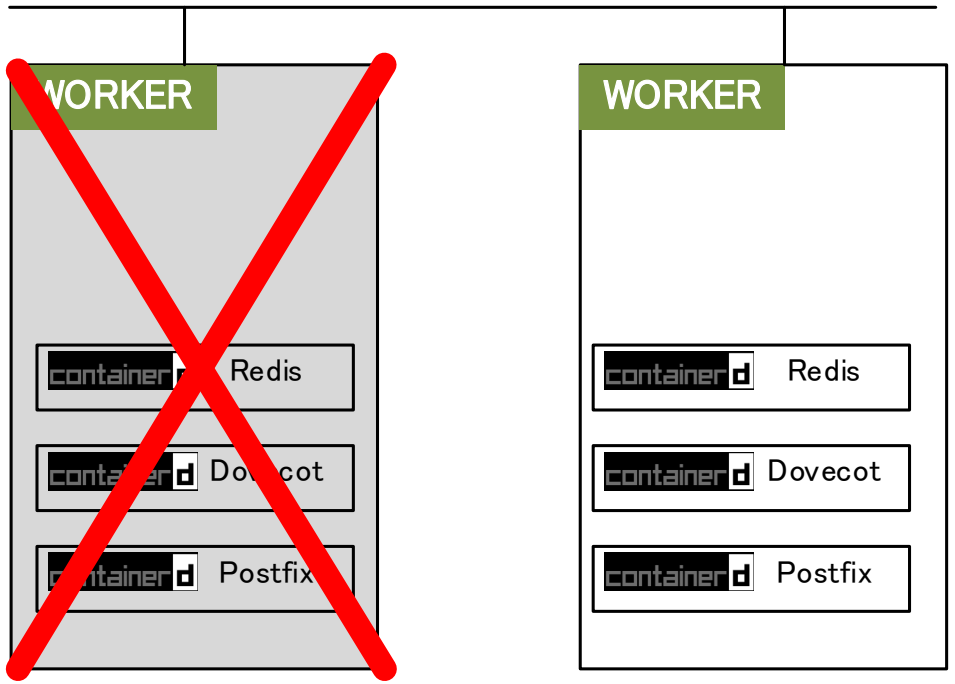

障害時影響低減

- **(重要)コンテナ化しても性能は(大して)変わらない**

- **ノードリソース使い切りは危険**
  - リソースの取り合い

- **CPU・I/O・NWを激しく使うコンテナは特に注意**
  - HEAVY PODがノードリソースを占有して全体がスローダウン
  - MTA・メールボックスは同居させない等

入念なスケジューリング設定が必要

最後に

作り上げるとこういうイメージになります(書ききれないので概要です)

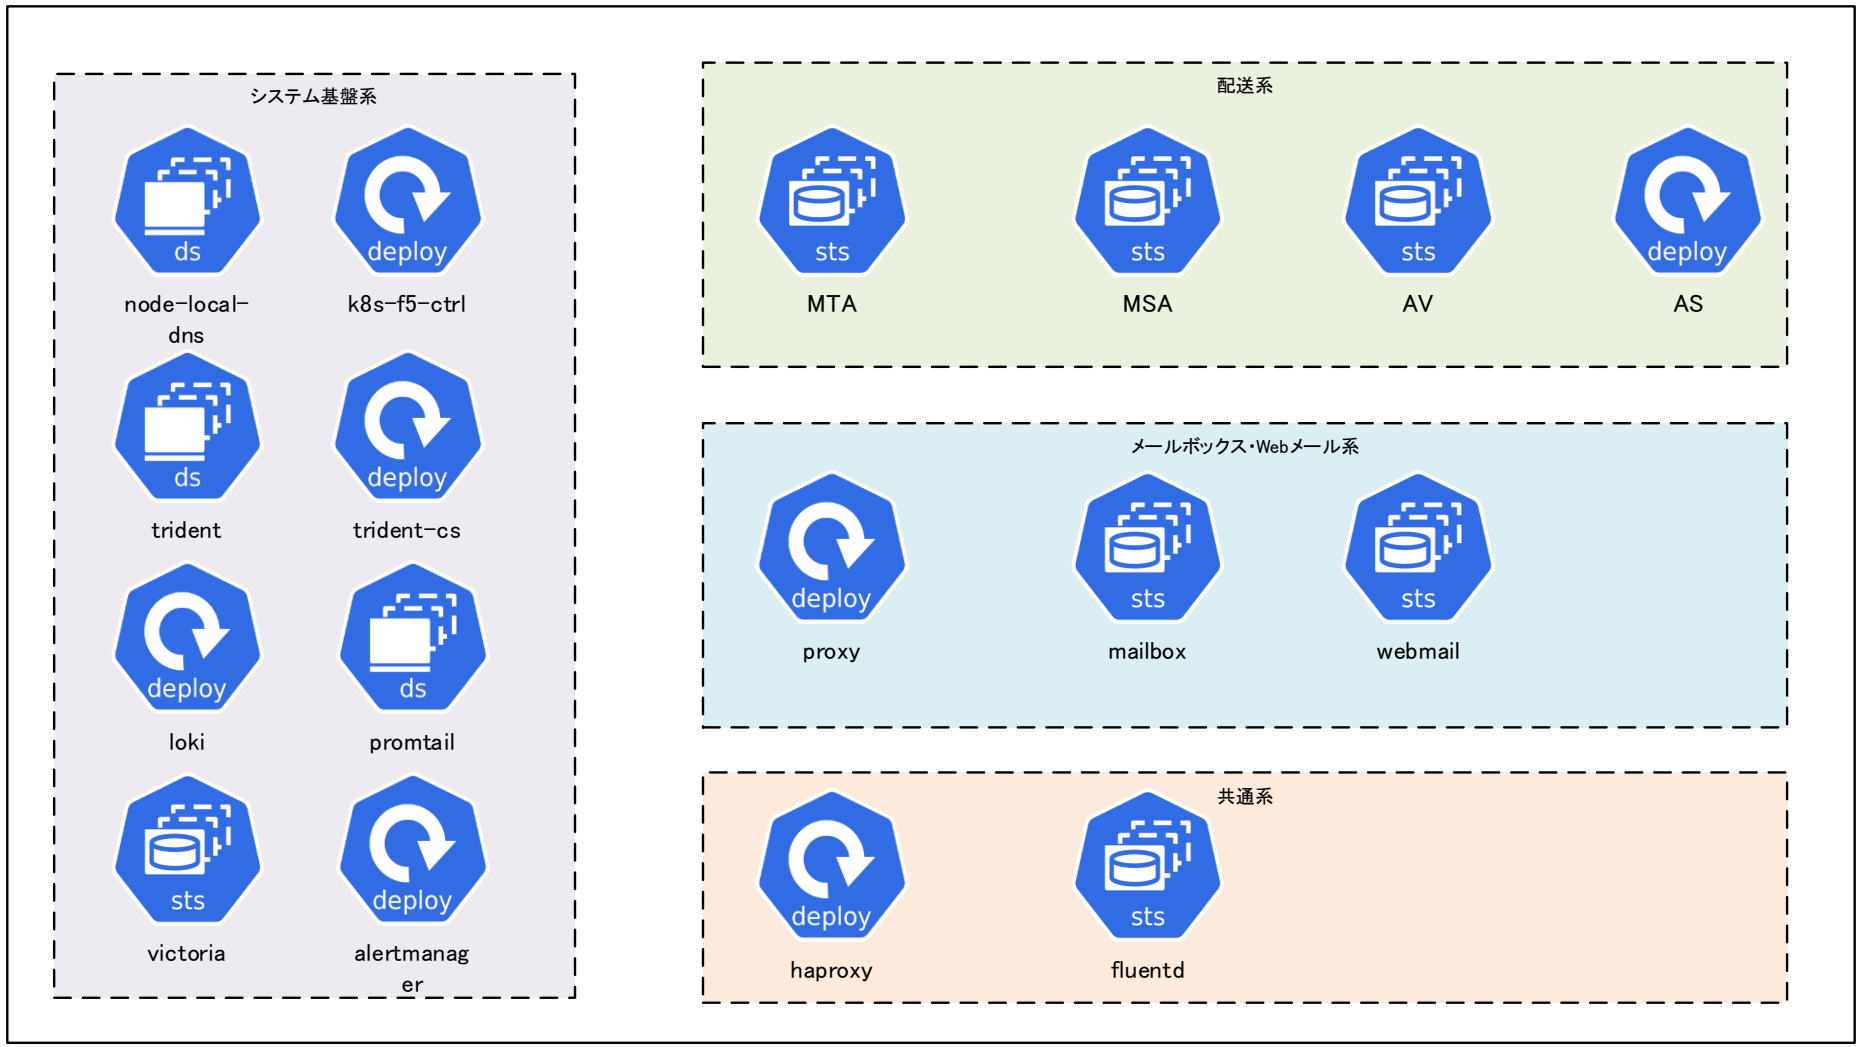

LDAP　KVS　オブジェクトストレージ　検索エンジン　DB　ストレージ　LB

1.影響無しメンテがいつでもできる

- ダウン無しに作り込めばOK

2.（重要）世代交代できた！

- 若手の活躍がすごかった！

3.開発速度が上がった！

- インフラとアプリの分離は偉大
- 汎用性が高い点も◎

1.EメールシステムをKubernetesでリプレース
しました

2.導入難度は高いが、構成・運用が今風になり世
代交代できました。

3.安定稼働。安心です。

IIJはメールエンジニアを絶賛募集中です

- メール好きな人（運用・開発）
- Kubernetesへの取り組み

IIJ 採用　検索

Ongoing Innovation

IIJ Internet Initiative Japan

ご清聴ありがとうございました。

30th Anniversary