

Kubernetesとエコシステム -2017.07-

Linux開発統括部

富士通株式会社


kamezawa.hiroyu@jp.fujitsu.com

- Kubernetesはわかったけど、どう成長しているのか、とか、そのまわりのOSSとか、どういうのがあるの？を駆け足でやりながら、3カ月に一度リリースされているKubernetesのここ最近の機能について駆け足で紹介します。
- じっくりやりませんけども、興味がわいたものは後から私を捕まえるか、ググってもらうかしてください。


コンテナの勢いとDocker

仮想化技術の勢い(世界)


Google Trend (WW)




仮想化技術の勢い(日本)



Google Trend(WW)



コンテナ技術の勢い(日本)



■ 2017年3月29-30日、ベルリン

■ Cloud Native Computing Foundation(CNCF)イベント

■ 開催地:ベルリンコンgresセンタ

■ 来場者:1500名超

- ・キーノートも立ち見・座り見で非常な熱気
- ・スポンサー43社: プラチナ: Red Hat, Huawei, CoreOS, Intel, Tigera

■ 概観

- ・CNCFの傘下プロジェクトが増加し、技術分野が網羅的に
 - ・オーケストレーション・性能監視・ログ・トレース・サービス管理・サービス接続・コンテナ管理
 - ・今後、ネットワーク・ストレージ関連のプロジェクト追加を予定
- ・(ヨーロッパだからか)スーツ組がほとんどおらず、開発者が中心
 - ・出展ブースも Huawei, Red Hat, VMWare, CA 等に加え、スタートアップが多い印象
- ・日本からは Yahoo, NTTから参加者(Yahoo, NTTとは7月のOpenstack Days Tokyoでコンテナセッション企画)
- ・12月の北米イベントは3000人規模で開催予定

■ Open Container Initiative

■ コンテナ標準フォーマットを定義する非営利団体

- Docker 単独支配にストップをかける業界からの一撃

■ コンテナ標準規格のバージョン1.0（昨日リリースされました！）

■ 3Qにコンテナ認証（イメージとRuntimeに規格準拠の印をつける）を提供予定

■ Kubernetes Certified Engineer

- Kubernetesの認定エンジニア制度。オンラインテストを受験する。βテスト中

■ Kubernetes Confirmation

- まだ始まったばかりだが、KuberentesのAPI互換保証/認定を作る仕組みの協議開始

Kubernetesと Cloud Native Computing Foundation



Orchestration



Prometheus

Monitoring



OPENTRACING

Tracing



fluentd

Logging



linkerd

Service Mesh



Remote
Procedure Call



CNI

Networking



CoreDNS

Service
Discovery



Container
Runtime



Container
Runtime

■ 参加企業は80社以上

■ Platinum Member(ボード)


- Cisco, CoreOS, Dell, Docker, Fujitsu, Google, Huawei, IBM, Intel, Joyent, Mesosphere, Red Hat, Samsung SDS, SuperNAP

■ ホストするプロジェクト数は10に増加

- 今後はストレージ関連プロジェクト、メトリクスAPIの共通化などが狙上に
- 規模的にはKubernetesが巨大プロジェクトで他は小さめ

CNCF のプロジェクト規模①

Project	Commits	Authors	Repositories
kubernetes	83982	2461	58
grpc	21849	366	12
prometheus	8479	547	35
Fluentd	7672	212	31
rkt	3566	142	2
linkerd	2746	64	8
opentracing	2532	102	35
containerd	2265	107	7
cncf	2002	67	19
CoreDNS	1005	44	8
CNI	637	64	2



■ ボード会議と TOC(Technical Oversight Committee)そのサブ会議で運営


■ ボード会議：投資判断や施策、メッセージングについての決定・合意

- マーケティングや認定試験等のサブ会議を持つ
- イベント運営、SNSを使ったマーケティング、記事の公開

■ TOC：プロジェクト間の課題の解決、新規プロジェクトの採用判断

- 新規のプロジェクト採用の仕組みと権限
- KubernetesのAPI標準化やメトリクスAPIの標準化
- CI環境の整備・整理

■ 運営には、Google, Docker, CoreOS, Red Hat, IBMなど積極的



Kubernetes
コミッターの所属分布

■ コンテナオーケストレーションのスタンダード

■ 以下の機能を持つ


- あらゆるワークロードへの対応
 - ステートレス、デーモン、バッチ、ステートフル、定期
- リソーススケジュール
- ライフサイクルマネジメント
- サービスとコンテナの紐付け
 - DNS
 - Load Balancing
- ネットワーク(plugin)
- ストレージ管理(plugin)
- 認証・認可・監査
- ログ管理...等

■ 以下のプロダクト・サービスでKubernetesをサポート

- Google Compute Engine
- Google Container Engine
- AWS EC2
- Azure (Azure Container Service)
- IBM Blue Mix
- Red Hat OpenShift
- SUSE Container as a Service Platform
- The Canonical Distribution of Kubernetes
- Tectonic by CoreOS
- RancherOS/Kubernetes
- VMWare Photon
- Mirantis

Etc.....

クラウドMWとクラウドインフラ(IaaS)を繋ぐオープンな共通クラウドOS, Kubernetes



■ Kubernetesはアプリケーションとクラウドの間の A P I を定義

- クラウドインフラはKubernetesのイベントに連動



■ ミドルウェアはKubernetes上で動作

- OpenStackをKubernetes上で
- CloudFoundryをKubernetes上で
- ビッグデータ、AI、DBをKubernetesで



<https://prometheus.io/>

■ Prometheus

■ モニタリングソフトウェア

- ハードやVM監視特化ではなく、任意のサービスを監視
- Prometheusに対応した統計情報APIからデータ収集

■ 時系列データベース、クエリ、可視化

■ アラート

■ アプリやノードの情報をメトリクス情報API(exporter)から収集


- KubernetesやetcdなどはPrometheusAPIを標準装備

■ Kubernetesのイベントと同期した情報収集(Beta)

■ CNCFでは OpenMetrics としてのAPI標準化を提案中



<https://grpc.io>



■ gRPC

- http/2 ベースのRPCフレームワーク、Protocol Buffersで値をやりとりする
- 同期/非同期モデルを両方をサポート
- 多くのプロジェクトで使われ始めている
- 機能が拡張されてきており、Load Balancing のフレームワークなども組み込まれてきている
 - 簡単な Client Side Load Balancing + 頭の良い外部ロードバランサー
 - <https://github.com/grpc/grpc/blob/master/doc/load-balancing.md>



<https://linkerd.io>

■ Linkerd


- サービスメッシュ
- マイクロサービスにおけるサービス管理
- サービス間のトラフィックをコントロール
 - ルーティング
 - トランスポート
 - セキュリティ
 - ロギング
 - 多重化
 - タイムアウト
 - ロードバランシング
 - リトライ
- サービスの論理名⇔バックエンドのマッピング



OPENTRACING

■ OPENTRACING

- トレース解析だとZipkinなどが有名だが、ツール毎にトレースの入れ方がバラバラだと困る
- 中立なトレーシングアノテーション"OpenTracing"
- Go, JavaScript, Java, Python, Ruby, Objective-C, C++, C# をサポート
- Zipkinを含め、トレーサーも多くサポート





■ CoreDNS

■ Service Discovery

- Kubernetesと連動できるDNSサービス

■ 高速かつ柔軟なDNSサーバ


- “middleware”プラグインで機能拡張

■ 標準ポート(53)、TLS(DNS by https)、gRPC




オーケストレーションへ

ホスト




- Containerd
- 元dockerエンジンのコア部
 - ノードローカルのコンテナ管理OSS
 - Cloud Native Computing Foundation寄贈




Kubernetes Application の配布・実行には HelmというOSSが人気があり、
<http://kubernetes.io> で配布されている
※このkubernetesアプリ配布用のWebサイト自体もOSS公開されている



パッケージングには Helm Chart というツールを使う。
Helmは“LinuxにおけるRPM”(公式サイトより)



Kubernetesを利用するストレージ オーケストレーション Ceph on-top of Kubernetes

- これとは別にCSI (Container Storage Interface) を定義する動きアリ





■ Istio

■ サービスメッシュ


■ “サービスとネットワーク間のインフラストラクチャ

■ サービスに必要なコントロールを提供

- HTTP, gRPC, TCPトラフィックによる自動ロードバランス
- リッチなルーティングルールによるきめ細かいトラフィック制御
- トラフィックの暗号化、サービスからサービスへの認証、強力な同一性の表明
- 全体的なポリシー強制
- 綿密な測定とレポート

■ ローカルな L B はサービスメッシュに吸収される

■ 構造的にはEnvoy(LB)をサイドカーでくっつけて Istio Managerからコントロールする構成



■ (Docker)Notary/TUF

- 公開鍵暗号を使ったコンテンツの内容保証システム
- 安全な／サイン付きのイメージの公開
- 安全なイメージの検証
- The Update Framework (TUF)
 - <https://theupdateframework.github.io/>

Kubernetes 1.6/1.7ハイライト

■ Schedulingについて

■ 色々な機能

- RBAC
- kubeadm
- StatefulSet
- InitContainers
- PodDisruptionBudget
- NetworkPolicy
- Node Authorization

■ スケーラビリティ関連

- スケーラビリティ
- KubeFed
- オートスケール

■ MilliCPU

- KubernetesのCPUリソースはミリCPUという単位で管理され、例えば4CPUのホストなら4000MilliCPUのリソースを持つ。基本的にはコンテナの要求CPUと各ノードの容量を比較する

■ Affinity


- v1.6 で Node Affinity/Anti-Affinity, taints and tolerations, , pod affinity/anti-affinity追加
 - <http://blog.kubernetes.io/2017/03/advanced-scheduling-in-kubernetes.html>

■ 複数のスケジューラ

- <https://kubernetes.io/docs/tasks/administer-cluster/configure-multiple-schedulers/>
- Kubernetes1.6からスケジューラを複数搭載し、目的に応じて使い分けることが出来る
 - 何か特別についてくるわけじゃないのでスケジューラは自作する
 - Pod<->Nodeのバインド関係の拡張機能などもAlpha化
- 追加スケジューラはコンテナにしてクラスタに乗せ、アクセス権(RBAC)を設定する
- Podの spec で schedulerNameを指定する
- デフォルトスケジューラ> <https://kubernetes.io/docs/admin/kube-scheduler/>

■ Role Based Access Control

- v1.6からBeta （富士通も頑張って貢献）
- 役割と紐づけてあらゆるリソースへのアクセスを認可
 - <http://blog.kubernetes.io/2017/04/rbac-support-in-kubernetes.html>
 - <https://kubernetes.io/docs/admin/authorization/rbac/>
 - RBAC以前はkubernetesのスタート時にファイルを食わせて設定するような認可(ABAC)しかなかった。
- Role と Role Bindingを使って設定する。
 - Role <guest> は “pod”のget/listができる…とか。
- 標準のインストーラ：kubeadmを使うとデフォルトで設定される



■ インストールを含めたKubernetes Clusterのデプロイ管理機能

■ インストールで起こること

- コンテナランタイムを準備して(docker)
- TLSの為のカギの生成を行い
- クラスタリングの為のトークンその他を設定し
- Kubelet を OSサービスとして起動後
- api server や controller, proxy 等々をPodとして起動する
⇒ kubelet 以外は全てコンテナ化

そこそこ動くけど、たまにハマルことがある……

■ 現在、kubeadmを使ったクラスタ全体のローリングアップデートなどが開発中

期待大

- v1.5からBeta ステートのあるPodを扱うための仕組み
- StatefulSets を使うと以下の特徴を持つPodを作ることが出来る
 - 各Replicaに通し番号を付与、ホスト名が <statefulset name>-<number>になる
 - 番号の小さい順に生成され、番号の大きな順に終了される
 - 前のPodがreadyになるまで後ろのPodは生成されない。
 - 後ろのPodがshutdownするまで前のPodは終了されない
 - V1.7でRolling Update追加。一つずつ順番にアップデートされる
 - 各Podに固有のDNS名がつけられる
 - volumeClaimを定義に内包、各Podにストレージをアタッチする
 - Pod終了の猶予期間(GracePeriod)に 0 を設定できない
- StatefulSetでPostgresを扱う例
 - <http://blog.kubernetes.io/2017/02/postgresql-clusters-kubernetes-statefulsets.html>
 - 番号と順番がついているので replicaをつくってもどちらがmasterでどちらがslaveかはっきりする

■ InitContainersはPod中の他のコンテナが動作する前に動作するコンテナ

- 順番に実行され、実行が終わるまでメインのコンテナは動作しない

■ 用途

- 待ち合わせ
- 動的なコードのpull
- テンプレートツール

めっちゃ便利

```
spec:
  containers:
  - name: myapp-container
    image: busybox
    command: ['sh', '-c', 'echo The app is running! && sleep 3600']
  initContainers:
  - name: init-myservice
    image: busybox
    command: ['sh', '-c', 'until nslookup myservice; do echo waiting for myservice; sleep 2; done;']
  - name: init-mydb
    image: busybox
    command: ['sh', '-c', 'until nslookup mydb; do echo waiting for mydb; sleep 2; done;']
```

v1.6からの記法

- 通常、Podは作成されると状態が維持されるが、強制停止される場合もある。
大まかにPodの強制停止は 2 種類のケースがある
 - 強制的なもの：ハード故障やVM停止でNodeが消えた場合、Out-Of-Resource 等
 - 自発的なもの：何等かの操作(deploymentの削除等)、Rolling Update 等
- PodDisruptionBudget
 - 同時にダウンしても良いレプリカの数指定を行う
 - kubectl drain でnodeを落とす際にも必要なpod数を計算して必要ならブロックさせる
 - Drainはノードをクラスタから切り離すコマンド（node上の全Podが安全に終了する）


- Namespace間のファイアウォール機能、ついに正式機能化(v1.7)
 - <https://kubernetes.io/docs/concepts/services-networking/network-policies/>
 - 利用するNetwork Pluginに依存する機能なので、例えばflannelでは使えない。
 - いまのところ、CalicoとRomana, Weave Netでサポート
- Kubernetesらしく、Labelをフル活用した機能
 - NamespaceにNetworkPolicy オブジェクトを関連付ける
 - NetworkPolicyはPodSelectorで指定したラベルを持つポッドに対して適用される
 - NetworkPolicyで①特定のラベルを持つネームスペースの②特定のラベルを持つポッドからのアクセスを許可する
 - 許可されていないアクセスは全て禁止される（PodSelectorにヒットするPodのみ）

アクセスの許可以外の機能はいまのところなし
- PodSelectorを空欄にして、全Podに適用する操作も可能

- v1.7から追加。
- Node上のKubeletからのアクセスを規定し、Node上のPodがアクセスしているオブジェクト以外のアクセスを禁止する
 - <https://kubernetes.io/docs/admin/authorization/node/>
 - <http://qiita.com/tkusumi/items/f6a4f9150aa77d8f9822>Kubeadmだとデフォルトでenabled.
- ある Pod X が Secret Y にアクセスし、Node-O で動作しているとして
 - Node-O上から Secret Y にアクセス可能
 - Pod Xが別のノードに動くと、Node-OからはSecretYにはアクセスできない

- Kubernetesにおける“スケーラビリティ”の基準
 - A P I の反応： 99%のリクエストが 1 秒以内
 - Podのスタートが 5 秒以内 (イメージを D L する時間を除く)
- 現在のスケーラビリティ： 5000 node / 150,000 pods
 - Kuberentes 1.0 では 100ノードまでしかスケールしなかった
 - Kubernetes 1.2 では 2000ノード
 - Kuberentes 1.6 で、5000ノードに
- まず悪かったのはREST/JSON と API Server内部データの変換効率(v1.2)
 - 昔からある話だが、ASCIIとGOの内部表現との変換が重かった
 - Protocol buffer フォーマットを使って打開
- Etcd2 から etcd3 になってパフォーマンスが向上(v1.6)
 - 500watch event/sec <https://github.com/kubernetes/kubernetes/issues/32361>
- いまのところ、「5000以上はFederationを使ってくれ」とのこと

API call latencies - 5000 node cluster



- 複数のkubernetesクラスタを繋げる。V1.5から提供されているコマンド
- Kubernetesの上に federation control plane という形でレイヤを作成
 - Hybrid cloudも可能
 - 今のところLBやDNSのサービス連携が無いと辛いのでクラウド連携
 - DNSについては“CoreDNS”を使うことが出来る
- 複数のkubernetesクラスタを同期させる
- 以下の機能に対応
 - Cluster, ConfigMap, DaemonSet, Events, Ingress Namespaces, ReplicaSets, Secrets, Services
 - 他のクラスタのサービスに接続できる
 - クラスタ間で同期する(ConfigMap/Secrets)
 - 全クラスタでデーモンを展開(DaemonSets)
 - 全クラスタでレプリカ作成(ReplicaSets)

```
kubefed init fellowship ¥  
  --host-cluster-context=rivendell ¥  
  --dns-provider="google-clouddns" ¥  
  --dns-zone-name="example.com."
```


■ <https://kubernetes.io/docs/tasks/run-application/horizontal-pod-autoscale/>

■ まだAlpha機能

- Horizontal Pod Autoscaler ... Podを動的に増やす
- Cloud AutoScaler ://GCE, AWS, Azure ... VMを動的に増やす

■ Pod AutoScalerの動作

- Pod には必要なCPU/メモリ量を宣言しておく
- `#kubectl autoscale deployment php-apache --cpu-percent=50 --min=1 --max=10`
 - 何秒か毎に現在ターゲットにしている Pod の使えているリソース量をチェック
 - デフォルトは 30 秒に一回
 - カスタムメトリクスも利用できる (<https://github.com/kubernetes/metrics>)



shaping tomorrow with you

■ 2017.Apr.17-18開催

- ブースは80以上。コンテナ管理、モニタリング、ネットワーク・ストレージ管理製品が中心
- Docker Store では500以上の信頼されたコンテナイメージを配布

■ キーノート

- 参加者は5500人、14Mのdocker host, 900Kのdocker アプリケーション, 3300名のdocker 貢献者
- (OSS版)Dockerの開発者
 - Docker(40%), Microsoft(7.7%), IBM(3.2%), Huawei(3.0%), Red Hat(3.0%)……
- Dockerを利用するエンタープライズ企業
 - AT&T, Sprint, Verizon, AMGEN, HUDSON ALPHA, MERCK, OPTUM, Juniper, RSA, TIBCO, splunk, GE, Anthem, Libery Mutual, MetLife等

■ 新規トピック

- Moby Project
- Hyper-V Isolation Technologyにより、Windows上でLinuxコンテナが動作可能に

■ Moby

- Moby is an open framework created by Docker to assemble specialized container systems without reinventing the wheel. It provides a “lego set” of dozens of standard components and a framework for assembling them into custom platforms.”

