

Kubernetes とエコシステムの 継続的なバージョン更新

Tsubasa Nagasawa

株式会社コロプラ インフラ エンジニア



自己紹介



Tsubasa Nagasawa

(@toversus26)

株式会社コロプラ

技術基盤本部


インフラストラクチャ部

ゲームインフラグループ

Google Cloud


新卒で Sler に就職。2018 年に CyberAgent に入社し、認証基盤/ポイント サービスの SRE を担当。

2020 年 3 月からコロプラで Kubernetes エンジニアとしてソーシャル ゲームの運用やインフラ基盤の改善に従事しています。




本日の内容

- アーキテクチャの紹介と GKE のバージョン更新の戦略
- コロプラと Cloud Native / Kubernetes エコシステム
- GKE と Cloud Native / Kubernetes エコシステム
- Kubernetes への追従





コロブラのゲームの特徴

- 最新のテクノロジーと独創的なアイデア
 - 位置情報ゲームやライブ配信など新しい仕組み
- サービス停止を伴う定期メンテナンスを原則行わない
 - サービスを停止せずにアプリの更新や不具合修正
 - ゲームインフラの運用作業も対象
 - GKE クラスタのバージョン更新
 - GKE クラスタの新機能への移行
 - データストアの移行
 - 外部システムのメンテナンスを乗り切る仕組み
 - キューにタスクを積んで非同期処理など




バックエンドの構成要素

- **API Server**
 - ゲームロジックが実装された REST API サーバー
- **Realtime Game Server**
 - UDP/TCP でメッセージをやり取り
 - 対戦・協力・チャットルーム
 - Agones で Game Server を管理
 - リアルタイム通信の部分は内製フレームワーク (prizm)
- **Live Streaming**
 - 内製の UDP リレーサーバー





ゲームインフラの特徴

- ゲームタイトル毎に GCP アカウントを分離
 - Infrastructure as Code (IaC) で管理
- 環境がいくつか存在
 - 開発環境
 - 開発者やプランナーが日々利用
 - 検証環境
 - 本番相当の環境
 - 本番環境
 - RC (Release Candidate)
 - Canary



以前のアーキテクチャ



以前のアーキテクチャ


- GKE クラスターのバージョンはクラスター切り替えで更新
 - 安全に切り替え可能だが工数が掛かる (2 人月程度)
 - HAProxy の DNS 切り替えに時間が掛かる
 - データストアの移行が面倒
- マルチクラスター間の通信の複雑さ
 - API Server -> データストアのサービス検出が複雑
 - colopl/k8s-local-dns (*1) + colopl/expose-kubedns (*2) で独自実装 (*3)
 - 今は選択肢が増えている (*4)
 - Multi-cluster Services
 - Cloud DNS for GKE

*1: <https://github.com/colopl/k8s-local-dns>



*2: <https://github.com/colopl/expose-kubedns>

*3: <https://speakerdeck.com/toversus/reliable-and-performant-dns-resolution-with-high-available-nodelocal-dnscache>

*4: https://cloud.google.com/kubernetes-engine/docs/concepts/service-discovery#service_discovery_outside_a_single_cluster





現在のアーキテクチャ




現在のアーキテクチャ

- GKE クラスタのバージョンは in-place 更新
 - 工数を大幅に削減 (2 人日)
 - GKE クラスタを順番に更新
 - GKE 更新の Workflow を実行
 - 流量の少ないクラスタから更新して安全性を担保
 - 問題が起きたら HAProxy 配下から手動でクラスタを除外
- HAProxy (Global Load Balancer) を GKE 外に移動
- マルチクラスタ間の通信の複雑さを排除
 - データストアを GKE 外に移動
 - マネージド サービスを積極的に活用



GKE 更新のタイミング

- No channel を利用
 - Stable channel のデフォルト バージョンの更新サイクルに従う
 - デフォルト バージョンが一番安定
 - クラスタの更新順序を制御したい
 - 流量の少ないクラスタから順番に更新したい
 - ノードプールの自動更新を無効化したい
 - コントロール プレーンのマイナー バージョン更新のタイミングで上げる
 - パッチバージョンは更新しない
 - CVE 対応や影響の大きなバグ修正は例外
 - コントロール プレーンは自動でどんどん上がる
 - ノードプールとのパッチ バージョンの差異は目を瞑る



GKE 更新


- Temporal (*1)
 - Uber の Cadence からスピンオフ
 - 耐障害性のある状態を持った Workflow エンジン
 - Amazon Simple Workflow, Azure Durable Functions の元開発者
 - ユースケース
 - Netflix が社内の Workflow 基盤として提供 (*2)
 - Spinnaker を Temporal ベースで書き換え
 - Hashicorp が Terraform Cloud のインフラ プロビジョニングに使用 (*3)
 - Temporal の Workflow の中で Terraform を実行
 - Datadog がデータベースの運用作業をコード化して実行 (*4)

*1: <https://temporal.io/>

*2: <https://www.youtube.com/watch?v=LliBP7YMGyA>

*3: <https://www.youtube.com/watch?v=vOoPxs9NHgc>

*4: <https://docs.temporal.io/blog/how-datadog-ensures-database-reliability-with-temporal>



GKE 更新

- GKE 更新の Workflow を Temporal + Go SDK で実装

- コントロール プレーン


- バージョン更新
- 更新完了待ち

- ノードプール

- Max surge を割合から動的計算
- 自動修復機能の無効化
- Surge upgrade の実行
- Surge upgrade の完了待ち
- 自動修復の有効化

- 耐障害性があるので自身が動いている GKE クラスタも更新可能

Activity 5: NotifyGKEUpgradeStarted	INPUT	[{ "Name": "████-production-misc-0", "Location": "asia-northeast1", "ProjectID": "████-project-1" }]
Activity 11: GetCurrentMasterVersion	INPUT	[{ "Name": "████-production-misc-0", "Location": "asia-northeast1", "ProjectID": "████-project-1" }]
	RESULT	[{ "1.20.15-gke.3400" }]
Activity 17: GetValidMasterVersions	INPUT	[{ "Name": "████-production-misc-0", "Location": "asia-northeast1", "ProjectID": "████-project-1" }]
	RESULT	[{ "1.23.5-gke.2400", "1.23.5-gke.2400" }]
Activity 23: CanMasterUpgrade	INPUT	[{ "Name": "████-production-misc-0", "Location": "asia-northeast1", "ProjectID": "████-project-1" }]
	RESULT	[true]
Activity 29: PlanMasterUpgradeOrder	INPUT	[{ "Name": "████-production-misc-0", "Location": "asia-northeast1", "ProjectID": "████-project-1" }]
	RESULT	[{ "1.21.10-gke.2000" }]
Activity 35: NotifyMasterUpgradeStarted	INPUT	[{ "Name": "████-production-misc-0", "Location": "asia-northeast1", "ProjectID": "████-project-1" }]
Activity 41: UpgradeMaster	INPUT	[{ "Name": "████-production-misc-0", "Location": "asia-northeast1", "ProjectID": "████-project-1" }]
	RESULT	[{ "name": "operation-16533642-2022-05-24T04:12:00Z" }]
Activity 47: WatchMasterUpgrade	INPUT	[{ "Name": "████-production-misc-0", "Location": "asia-northeast1", "ProjectID": "████-project-1" }]
	RESULT	[{ "endTime": "2022-05-24T04:12:00Z" }]
Activity 53: NotifyMasterUpgradeCompleted	INPUT	[{ "Name": "████-production-misc-0", "Location": "asia-northeast1", "ProjectID": "████-project-1" }]




GKE 新機能への対応

- GKE Dataplane v2
 - Cilium によるコンテナ ネットワークの置き換え
 - eBPF ベースのルーティング、ネットワーク ポリシーとロギング
 - さようなら kube-proxy
 - 今後の Cilium ベースの機能拡張への期待
 - Hubble (*1) + Tetragon (*2) 連携
 - Sidecar-free eBPF Service Mesh (*3)
 - クラスタ作成時のみ有効化可能
 - 既存クラスタからの切り替えが必須

*1: <https://github.com/cilium/hubble>

*2: <https://github.com/cilium/tetragon>

*3: <https://www.youtube.com/watch?v=mpwTkm53YTY>




GKE 新機能への対応

- クラスタ切り替えの仕組みは必要
 - DNS ベース
 - Global Load Balancer
 - コロプラの場合は HAProxy MIGs
 - Multi-cluster Ingress (*1)
 - Multi-cluster Gateways (*2)
 - Traffic Director service routing APIs (*3)

*1: <https://cloud.google.com/kubernetes-engine/docs/concepts/multi-cluster-ingress>

*2: <https://cloud.google.com/kubernetes-engine/docs/how-to/deploying-multi-cluster-gateways>

*3: <https://cloud.google.com/traffic-director/docs/service-routing-overview>




コロプラと Cloud Native / Kubernetes エコシステム




コロプラが利用しているエコシステム (*1)

- Agones
- Argo CD
- Berglas
- ChartMuseum
- Datadog (APM)
- Dex
- ExternalDNS
- Falco
- Fluentd
- GitLab
- Grafana
- Helm
- Helmfile
- kube-state-metrics
- Nginx
- Prometheus stack
- Spinnaker
- Temporal (Cadence)
- Terraform
- Victoria Metrics




エコシステムから提供されているコンテナ イメージを
GKE 上でどう使っていますか？



エコシステムのコンテナ イメージ

- コンテナ レジストリの使用状況
 - 全体的に DockerHub からの配布が根強い
 - Kubernetes SIG (Special Interest Group) 関連は GCR が多い
 - Quay や GitHub Container Registry から提供もちらほら
- なぜ気にするのか？
 - 外部コンテナ レジストリからのプル
 - プライベート クラスターだと Cloud NAT が必須
 - DockerHub のレート制限
 - kubelet は匿名ユーザーでイメージをプルする
 - 100 pulls per 6 hours per IP address



外部コンテナ レジストリのイメージ同期


- mirror.gcr.io (*1) の存在に依存
 - latest のタグしか使えない
 - 使用頻度の低いイメージはキャッシュから消える可能性がある
 - 開発環境で参照していた Debian イメージが消えたことがある
- Docker Registry Synchronizer (*2)
 - Python で書かれたスクリプトを定期実行して同期
 - どのイメージが更新されたか分からない
- dregsy - Docker Registry Sync (*3)
 - Golang で書かれた定期実行 or デーモンとして新規イメージタグを検知
 - イメージの同期処理は Docker デーモンや skopeo (*4) に投げる

*1: <https://cloud.google.com/container-registry/docs/pulling-cached-images>

*2: <https://github.com/AliyunContainerService/sync-repo>

*3: <https://github.com/xelalexv/dregsy>

*4: <https://github.com/containers/skopeo>



外部コンテナ レジストリのイメージ同期

- GitHub + Dependabot + Cloud Build で自動同期
 - 同期したい Docker イメージをモノレポで管理
 - Dependabot で Dockerfile のベースイメージのタグ更新を検知
 - 最新のバージョンを追従
 - Node.js のように LTS が最新でない場合
 - ignore (*1) を設定して頑張る
 - Dependabot が PR を作成
 - 特定のブランチ名で PR を作成
 - dependabot/docker/argoproj/argocd/argoproj/argocd-v2.3.4

*1:

<https://docs.github.com/en/code-security/dependabot/dependabot-version-updates/configuration-options-for-the-dependabot.yml-file#ignore>

```
> tree -a
```

```
.
├── .dependabot
│   └── config.yml
├── .cloudbuild.yaml
├── .editorconfig
├── .dockerignore
├── argoproj
│   └── argocd
│       └── Dockerfile
├── chartmuseum
│   └── chartmuseum
│       └── Dockerfile
└── (...)
```


```
> cat argoproj/argocd/Dockerfile
```

```
FROM argoproj/argocd:v2.3.4
```



外部コンテナ レジストリのイメージ同期

- GitHub + Dependabot + Cloud Build
 - PR 作成をトリガーとして Cloud Build を実行
 - スクリプトで同期対象のイメージ名を特定
 - ブランチ名から Dockerfile のパスを特定
 - Dockerfile の中をパースして対象のイメージ名とタグを特定
 - argoproj/argocd:v2.3.4
 - crane (*1) で GCR / Artifact Registry にイメージをコピー
 - マルチ アーキテクチャ対応したイメージを同期可能




```
> tree -a
```

```
.
├── .dependabot
│   └── config.yml
├── .cloudbuild.yaml
├── .editorconfig
├── .dockerignore
├── argoproj
│   └── argocd
│       └── Dockerfile
├── chartmuseum
│   └── chartmuseum
│       └── Dockerfile
└── (...)
```


```
> cat argoproj/argocd/Dockerfile
```

```
FROM argoproj/argocd:v2.3.3
```



エコシステムへの追従

- コンテナ イメージの更新駆動
 - 週に1回チーム内でリリースノートの読み合わせ
 - 脆弱性対応が必要か
 - 新機能が使えそうか
 - バグ修正の恩恵を受けられそうか
 - Helm chart の更新と動作確認
 - 各ゲームタイトルに横展開
 - 脆弱性修正以外は更新のタイミングを担当に任せる
 - 運用中のタイトルは GKE 更新のタイミングでやることが多い



GKE と


Cloud Native / Kubernetes エコシステム



GKE のコントロールプレーンで動作

- v1.21.10-gke.2000 を想定
- クラスタで有効化している機能によって一部異なる


- Cluster Autoscaler
 - <https://github.com/kubernetes/autoscaler/tree/cluster-autoscaler-1.21.0>
- Common Webhooks
- etcd
 - <https://github.com/etcd-io/etcd/tree/v3.4.13>
- GLBC (ingress-gce)
 - <https://github.com/kubernetes/ingress-gce/tree/v1.13.4/cmd/glbcc>
- Konnectivity server
 - <https://github.com/kubernetes-sigs/apiserver-network-proxy/tree/v0.0.24/cmd/server>
- kube-addon-manager
 - <https://github.com/kubernetes/kubernetes/tree/v1.21.10/cluster/addons/addon-manager>
- kube-api-server
- kube-scheduler
- kube-controller-manager



GKE のノード上で動作 or バイナリ提供

- v1.21.10-gke.2000 を想定
- クラスタで有効化している機能によって一部異なる


- cAdvisor (kubelet 同梱)
 - <https://github.com/google/cadvisor/tree/v0.39.3>
- CNI network plugins
 - <https://github.com/containernetworking/plugins/tree/v1.0.1>
- containerd
 - <https://github.com/containerd/containerd/tree/v1.4.11>
- containerd-shim-runc-v2
 - <https://github.com/containerd/containerd/tree/v1.4.11/cmd/containerd-shim-runc-v2>
- containerized_mounter (*1)
 - <https://github.com/kubernetes/kubernetes/tree/v1.21.10/cluster/gce/gci/mounter>
- crictl (cri-tools)
 - <https://github.com/kubernetes-sigs/cri-tools/tree/v1.20.0>
- ctr
 - <https://github.com/containerd/containerd/tree/v1.4.11/cmd/ctr>



GKE のノード上で動作 or バイナリ提供

- v1.21.10-gke.2000 を想定
- クラスタで有効化している機能によって一部異なる


- gke-exec-auth-plugin
 - <https://github.com/kubernetes/cloud-provider-gcp/tree/providers/v0.21.0/cmd/gke-exec-auth-plugin>
- kubectl
- kubelet
- Node Problem Detector
 - <https://github.com/kubernetes/node-problem-detector/tree/v0.8.7>
- runc
 - <https://github.com/opencontainers/runc/tree/v1.0.0-rc95>



GKE の addons として動作

- v1.21.10-gke.2000 を想定
- クラスタで有効化している機能によって一部異なる


- event-exporter
 - <https://github.com/GoogleCloudPlatform/k8s-stackdriver/tree/event-exporter-v0.3.5>
- Fluent Bit
 - <https://github.com/fluent/fluent-bit/tree/v1.5.7>
- GCE Persistent Disk CSI Driver
 - <https://github.com/kubernetes-sigs/gcp-compute-persistent-disk-csi-driver/tree/v1.3.6>
- gke-metadata-server
- gke-metrics-agent (OpenTelemetry Collector)
- kube-proxy (static Pods)
 - <https://github.com/kubernetes/kubernetes/tree/v1.20.10/cmd/kube-proxy>
- kube-dns (Kubernetes DNS)
 - <https://github.com/kubernetes/dns/tree/1.21.0>
- kube-dns-autoscaler (Cluster Proportional Autoscaler)
 - <https://github.com/kubernetes-sigs/cluster-proportional-autoscaler/tree/1.8.1>



GKE の addons として動作

- v1.21.10-gke.2000 を想定
- クラスタで有効化している機能によって一部異なる

- Kubernetes Metrics Server
 - <https://github.com/kubernetes-sigs/metrics-server/tree/v0.4.5>
- Kubernetes Metrics Server sidecar (Addon-resizer)
 - <https://github.com/kubernetes/autoscaler/tree/addon-resizer-1.8.13>
- Konnectivity agent
 - <https://github.com/kubernetes-sigs/apiserver-network-proxy/tree/v0.0.24/cmd/agent>
- I7-default-backend (404-server-with-metrics)
 - <https://github.com/kubernetes/ingress-gce/tree/v1.13.4/cmd/404-server-with-metrics>
- netd
 - <https://github.com/GoogleCloudPlatform/netd/tree/v0.2.13>
- Node Driver Register
 - <https://github.com/kubernetes-csi/node-driver-registrar/tree/v2.1.0>
- prometheus-to-sd
 - <https://github.com/GoogleCloudPlatform/k8s-stackdriver/tree/prom-to-sd-v0.10.0>



GKE との付き合い方


- コントロールプレーン更新の影響
 - リージョン クラスタ (*1) だと更新中にサービス影響はない
 - kube-addon-manager で管理しているコンポーネントの更新
 - kube-system の namespace にいる GKE 管理のシステムの Pod が対象
 - 新しくコンポーネントが追加されたり削除されたりもする
 - マイナー バージョン更新後に API が削除されることがある
 - GKE 1.22 で削除される API 一覧 (*2)
 - 削除されても既存のオブジェクトに影響はない (*3)
 - 削除された API で新規にオブジェクトが作れなくなる
 - 削除された API で既存のオブジェクトを更新できなくなる

*1: <https://cloud.google.com/kubernetes-engine/docs/concepts/regional-clusters>

*2: <https://cloud.google.com/kubernetes-engine/docs/deprecations/apis-1-22>

*3:

https://github.com/kubernetes/community/blob/master/contributors/devel/sig-architecture/api_changes.md




GKE との付き合い方

- ノードプール更新の影響
 - ノード上で動作している Pod が必ず再起動する
 - ノードのイメージに大きな変更がある場合は注意
 - GKE 1.20 で Ubuntu 18.04 から 20.04 に更新
 - NPD Service doesn't start properly on Ubuntu based GKE Nodes version 1.20.* and 1.21.* (*1)
 - Ubuntu のバージョンは GKE リリースノート (*2) で共有されなくなった
 - COS のバージョンと変更点は GKE リリースノートから確認可能

*1: <https://issuetracker.google.com/issues/202338644>

*2: <https://cloud.google.com/kubernetes-engine/docs/release-notes>




GKE との付き合い方

- GKE で利用しているエコシステムは GKE が管理
 - 問題が起きたらサポートに正確に報告する
 - 既知の問題か確認
 - Google IssueTracker (*1)
 - GCP のケース起票画面から見れる既知の問題 (*2)
 - GKE リリースノート (*3)
 - ドキュメントの既知の問題のセクション
 - Kubernetes や関連するエコシステムの Issue / PR
 - ログと再現手順を必ず添付
 - 既知の問題として追加してもらう

*1: <https://issuetracker.google.com/issues>

*2: https://cloud.google.com/support/docs/manage-cases#viewing_known_issues_with_services

*3: <https://cloud.google.com/kubernetes-engine/docs/release-notes>



Dataplane v2 の Pod IP リーク問題

- Pod が ContainerCreating 状態でスタック
- PodSandbox の作成に失敗
 - kubelet が Pod Sandbox の作成に失敗
 - Pod IP の割り当て可能範囲 (10.0.0.64/26) に空きがない

```
> kubectl describe pods -n kube-system metrics-server-v0.4.4-5698c9f6fc-sptpn
```

```
Name: metrics-server-v0.4.4-5698c9f6fc-sptpn
```


```
Namespace: kube-system
```

```
(...)
```

```
Events:
```

Type	Reason	Age	From	Message
----	-----	----	----	-----


Warning	FailedCreatePodSandBox	81s (x722 over 158m)	kubelet, dummy-node	(combined from similar events): Failed to create pod sandbox: rpc error: code = Unknown desc = failed to setup network for sandbox "6a2d08a2a02fc8e491f9237c598b0d505e56eb7731d757f4d0c1d62eeee3012c": failed to allocate for range 0: no IP addresses available in range set: 10.0.0.65-10.0.0.126
---------	------------------------	----------------------	---------------------	---



Dataplane v2 の Pod IP リーク問題

- kubelet のログを追う
 - logName="projects/<project id>/logs/kubelet"
 - resource.labels.node_name="dummy-node"


```
E0209 00:03:12.758449    2377 kuberuntime_sandbox.go:68] \"Failed to create sandbox for pod\" err=\"rpc error:
code = Unknown desc = failed to setup network for sandbox
\\\\\"372ea79037673d222c21d600302c83fbe139d4ba82adf61699aad8c102011ab4\\\\\": failed to find plugin
\\\\\"cilium-cni\\\\\" in path [/home/kubernetes/bin]\" pod=\"kube-system/metrics-server-v0.4.4-5698c9f6fc-sptpn\"
(...)
I0209 00:03:12.553946    2377 kuberuntime_manager.go:466] \"No sandbox for pod can be found. Need to start a
new one\" pod=\"kube-system/metrics-server-v0.4.4-5698c9f6fc-sptpn\"
(...)
E0209 00:03:33.803332    2377 kuberuntime_sandbox.go:68] \"Failed to create sandbox for pod\" err=\"rpc error:
code = Unknown desc = failed to setup network for sandbox
\\\\\"6a2d08a2a02fc8e491f9237c598b0d505e56eb7731d757f4d0c1d62eeee3012c\\\\\": failed to allocate for range 0: no IP
addresses available in range set: 10.0.0.65-10.0.0.126\"
pod=\"kube-system/metrics-server-v0.4.4-5698c9f6fc-sptpn\"
```



Dataplane v2 の Pod IP リーク問題

- container runtime (containerd) のログを追う
 - logName="projects/<project id>/logs/container-runtime"
 - resource.labels.node_name="dummy-node"

```
time=\"2022-02-09T00:03:12.752015398Z\" level=error msg=\"Failed to destroy network for sandbox  
\\\"372ea79037673d222c21d600302c83fbe139d4ba82adf61699aad8c102011ab4\\\"\" error=\"failed to find plugin  
\\\"cilium-cni\\\" in path [/home/kubernetes/bin]\"  
(...)  
time=\"2022-02-09T00:03:12.755882291Z\" level=error msg=\"RunPodSandbox for  
&PodSandboxMetadata{Name:metrics-server-v0.4.4-5698c9f6fc-sptpn,Uid:935de484-be1b-4e9a-8681-8331f469d8cd,N  
amespace:kube-system,Attempt:0,} failed, error\" error=\"failed to setup network for sandbox  
\\\"372ea79037673d222c21d600302c83fbe139d4ba82adf61699aad8c102011ab4\\\": failed to find plugin  
\\\"cilium-cni\\\" in path [/home/kubernetes/bin]\"
```



Dataplane v2 の Pod IP リーク問題

- Pod が余り載っていないノードで Pod IP が枯渇前に起動できることも確認
 - Endpoints 作成のレート制限に引っ掛かり起動が遅れる

```
> kubectl describe pods -n default nginx
```

```
Name:          nginx
```

```
Namespace:     default
```


```
(...)
```

```
Events:
```

Type	Reason	Age	From	Message
Warning	FailedCreatePodSandBox	5m25s	kubelet, dummy-node	Failed to create pod sandbox: rpc error: code = Unknown desc = failed to setup network for sandbox "5be5d50aa4b186fb0a5c232968cd43996dc3ed7e77cba669b4e1c09a66784903": failed to find plugin "cilium-cni" in path [/home/kubernetes/bin]
(...)				

Warning	FailedCreatePodSandBox	4m38s	kubelet, dummy-node	Failed to create pod sandbox: rpc error: code = Unknown desc = failed to setup network for sandbox "0f654d461f604a0780b96be6a80d03b05f265eb5a07c64e1330c3f048366d9ed": unable to create endpoint: [PUT /endpoint/{id}][429] putEndpointIdTooManyRequests
(...)				

Normal	Started	31s	kubelet, dummy-node	Started container controller
--------	---------	-----	---------------------	------------------------------




Dataplane v2 の Pod IP リーク問題

- CNI と GKE の実装の理解 (*1)
 - CNI は複数の plugin を組み合わせ (chain) 可能
 - netd が CNI の設定ファイルをホスト上に配置
 - GKE の IPAM (IP Address Management) は host-local
 - Node IPAM controller がノードに割り当てた Pod CIDR (10.0.0.64/26) から払い出し
- Dataplane v2 を有効化した時の挙動の変化
 - netd が CNI の設定ファイルに Cilium CNI の chain を追加して配置
 - anetd (cilium-agent) が cilium-cni のバイナリをホスト上に配置
 - PostStart Hook で cni-install.sh (*2) を実行
 - netd が CNI の設定を追加してから時間差がそれなりにある


*1: <https://qiita.com/toVersus/items/4ff2525d562d8de4d530>

*2: <https://github.com/cilium/cilium/blob/v1.10.3/plugins/cilium-cni/cni-install.sh>



Dataplane v2 の Pod IP リーク問題

- 情報の整理とサポートケースの作成
 - Dataplane v2 を有効にしたクラスタでのみ発生
 - ノードの台数を 0 台からスケールさせた場合に発生しやすい
 - ノード作成直後に多くの Pod が起動する状態
 - ノードに Pod がそれほど載っていない場合は時間を置いて起動できる
 - 対象のノードの kubelet と container-runtime のログを添付
 - PodSandbox の作成に失敗した後に IPAM が払い出した IP を回収できてなさそう
 - Sandbox ネットワークの作成と削除に失敗
 - Sandbox を新たに作ろうとして延々と失敗して IP が枯渇




Dataplane v2 の Pod IP リーク問題

- containerd で Pod IP がリークする問題 (*1)
 - サポートから共有を受けた
 - Dataplane v2 (cilium-cni) に関係なく前から報告のあった問題
 - Pod ネットワークの初期化でタイムアウトする場合のみ解決済み
 - 他のエラー (e.g. cilium-cni のバイナリが存在しない) が発生した場合は未解決
- Dataplane v2 の既知の問題のセクションに追加して貰った (*2)
 - すぐに解決が難しそうだった
 - 他のユーザーへの共有
 - 解決したかを追跡したい


*1: <https://github.com/containerd/containerd/issues/5768>

*2: <https://cloud.google.com/kubernetes-engine/docs/how-to/dataplane-v2#containerd-pod-ip-leak>



Dataplane v2 の Pod IP リーク問題

- Dataplane v2 の既知の問題のセクションで解決済みに
 - 以下のバージョンで修正済み
 - 1.23.4-gke.1600 or later
 - 1.22.8-gke.200 or later
 - 1.21.11-gke.1100 or later
 - 1.20.15-gke.5200 or later
 - 1.21.11-gke.1100 に上げて問題が発生しなくなったことを確認
 - cilium-cni のバイナリが見つからないエラーが出なくなった




Dataplane v2 の Pod IP リーク問題


- GKE はどう問題を解決したか？
 - containerd の IP 枯渇問題は根深く解決できていない
 - Google の人が PR を投げてはいるが議論中 (*1)
 - GKE 側が個別にパッチを適用した？
 - containerd のバージョンは COS のイメージに依存
 - バイナリのバージョンを確認したところ変更は見られず
 - cilium-cni のバイナリを事前に配置した？
 - anetd にも独自パッチの形跡が見られない
 - netd で cilium-cni 用の chain の設定追加を遅らせた (*2)
 - cilium-cni のバイナリが存在することが確認できてから設定を追加

*1: <https://github.com/containerd/containerd/pull/5904>

*2: <https://github.com/GoogleCloudPlatform/netd/pull/121>



Kubernetes への追従




Kubernetes との付き合い方

- Kubernetes の大きな変更は事前に対応
 - 廃止予定の API の移行
 - マニフェストの更新
 - コントローラーなどが廃止予定の API を呼び出していないか確認 (*1)
 - マイナー バージョン更新の保護機能 (*2)
 - 完全に削除される API 呼び出しが過去 30 日間あると自動更新が止まる
 - デフォルトの挙動の変更
 - 新機能がベータに移行して有効化 (Kubernetes < 1.24)
 - バグ修正による挙動の変更

*1:

https://cloud.google.com/kubernetes-engine/docs/deprecations/apis-1-22#locating_api_clients_writing_to_deprecated_apis

*2: https://cloud.google.com/kubernetes-engine/docs/deprecations#how_kubernetes_deprecations_work_with




Kubernetes との付き合い方

- Kubernetes (upstream) の変更を追いかけておくと楽
 - 全部追っていたら時間が足りないので自分の嗅覚を信じる
 - kubernetes/kubernetes
 - kubernetes/enhancements
 - リグレッションや潜在的なバグ報告の把握
 - リリース直後より利用者が増えたタイミングで報告が増える
 - 大きめのリファクタリングが入った後は危険
 - KEP 3138: Increasing Reliability Bar (*1)
 - テストの品質や網羅率の悪さを改善
 - 安全に機能追加やリファクタリングができるように
 - 新機能よりも安定性が大事

*1:

<https://github.com/kubernetes/enhancements/pull/3139>



client-go / kubectl の認証方法の変更

- KEP 541: External credential providers (*1)
 - Kubernetes 1.22 で GA
 - client-go からクラウドプロバイダー固有の認証の仕組みを削除
 - クラウドプロバイダーが認証 plugin を提供
 - ExecCredential (*2) に指定して認証
 - Kubernetes 1.25 で gcp と azure の in-tree の認証機能が削除
 - GKE 1.25 までに kubectl 利用者は移行が必要 (*3)
 - gke-gcloud-auth-plugin (*4) を利用


*1:

<https://github.com/kubernetes/enhancements/tree/master/keps/sig-auth/541-external-credential-providers>

*2: <https://kubernetes.io/docs/reference/access-authn-authz/authentication/#configuration>

*3: <https://cloud.google.com/blog/products/containers-kubernetes/kubectl-auth-changes-in-gke>

*4: <https://github.com/kubernetes/cloud-provider-gcp/tree/master/cmd/gke-gcloud-auth-plugin>




Kubernetes Service Account の仕様変更

- KEP 1205 : Bound Service Access Token (*1)
 - Kubernetes 1.21 で Beta -> 1.22 で GA
 - 既存の Service Account Token の問題の解消
 - Service Account を作成すると Secret に JWT トークンが必ず保存される
 - JWT トークンにスコープが設定されていないので誰でも使える
 - JWT トークンに有効期限がない
- KEP 2799 : Reduction of Secret-based Service Account Tokens (*2)
 - Kubernetes 1.24 で Service Account Token の自動生成がデフォルトで無効化
 - TokenRequest API 経由で期限付きのトークンを手動生成する必要がある
 - `kubectl create token <sa name> --namespace <namespace>`
 - 将来的に Pod にマウントされていない自動生成されたトークンを削除


*1: <https://github.com/kubernetes/enhancements/tree/master/keps/sig-auth/1205-bound-service-account-tokens>

*2:

Google Cloud <https://github.com/kubernetes/enhancements/tree/master/keps/sig-auth/2799-reduction-of-secret-based-service-account-token>




Kubernetes Service Account の仕様変更



- 何が問題か？
 - CI/CD の過程で Argo CD や Spinnaker を利用
 - マルチクラスタ構成のため外部クラスタのリソースを管理
 - cluster-admin 権限を紐付けた Service Account Token を読み込ませて使用
 - Secret ベースの Service Account Token が自動的に発行されなくなる
 - Secret ベースの無期限のトークンも手動発行可能 (*1) だが...
 - トークンがローテーションされないのはセキュリティ的に問題
 - 非推奨なため、今後削除される可能性もある
 - Bound Service Account Token を使う場合
 - クラスタを跨いで自動的にトークンをローテーションできない
 - 自己署名証明書のように有効期限を長めに設定して使いたくない

*1:

<https://kubernetes.io/docs/tasks/configure-pod-container/configure-service-account/#manually-create-a-service-account-api-token>




Argo CD に対応を入れた話

- Argo CD のイメージの中に GKE 用の credential plugin を追加 (*1)
 - Argo CD v2.4.0 から利用可能
 - カスタム イメージが不要に
 - gcloud や gke-gcloud-auth-plugin を upstream のイメージに同梱し辛い
 - イメージのサイズが増える
 - バイナリのバージョン管理が面倒
 - argocd-k8s-auth の仕組みに相乗り
 - AWS 以外のクラウドプロバイダーもサポートしやすい仕組みが最近入った
 - credential plugin の再実装
 - ライブラリとして吸収することで上記の問題を軽減
 - GCP Service Account の権限でリソースを操作可能
 - Workload Identity と組み合わせればサービス アカウントキーの発行も不要
 - ClusterRole で必要な権限に絞ることも可能

*1:

<https://github.com/argoproj/argo-cd/pull/9190>



Thank you

